



**T.C.**  
**KONYA TEKNİK ÜNİVERSİTESİ**  
**LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**



**COVID-19 HASTALIĞININ DERİN**  
**ÖĞRENME YÖNTEMLERİ KULLANILARAK**  
**TESPİTİ**

**Hüseyin YAŞAR**

**DOKTORA TEZİ**

**Elektrik-Elektronik Mühendisliği Anabilim Dalı**

**Haziran-2022**  
**KONYA**  
**Her Hakkı Saklıdır**

## TEZ KABUL VE ONAYI

Hüseyin YAŞAR tarafından hazırlanan “COVID-19 Hastalığının Derin Öğrenme Yöntemleri Kullanılarak Tespiti” adlı tez çalışması 16/06/2022 tarihinde aşağıdaki jüri tarafından oy birliği / oy çokluğu ile Konya Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü Elektrik-Elektronik Mühendisliği Anabilim Dalı’nda DOKTORA TEZİ olarak kabul edilmiştir.

### Jüri Üyeleri

### İmza

#### Başkan

Prof. Dr. Salih GÜNEŞ

.....

#### Danışman

Doç. Dr. Murat CEYLAN

.....

#### Üye

Prof. Dr. Seral ÖZŞEN

.....

#### Üye

Dr. Öğr. Üyesi Muhammet Üsame ÖZİÇ

.....

#### Üye

Dr. Öğr. Üyesi Saim ERVURAL

.....

Yukarıdaki sonucu onaylarım.

Prof. Dr. Saadettin Erhan KESEN  
Enstitü Müdürü

## **TEZ BİLDİRİMİ**

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

## **DECLARATION PAGE**

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.

Hüseyin YAŞAR

Tarih: 16.06.2022

## ÖZET

### DOKTORA TEZİ

## COVID-19 HASTALIĞININ DERİN ÖĞRENME YÖNTEMLERİ KULLANILARAK TESPİTİ

Hüseyin YAŞAR

Konya Teknik Üniversitesi  
Lisansüstü Eğitim Enstitüsü  
Elektrik-Elektronik Mühendisliği Anabilim Dalı

Danışman: Doç. Dr. Murat CEYLAN

2022, 249 Sayfa

### Jüri

Prof. Dr. Salih GÜNEŞ

Doç. Dr. Murat CEYLAN

Prof. Dr. Seral ÖZŞEN

Dr. Öğr. Üyesi Muhammet Üsâme ÖZİÇ

Dr. Öğr. Üyesi Saim ERVURAL

2019 yılının son günlerinde Çin'in Hubei eyaletinin Wuhan kentinde ortaya çıkan SARS-CoV-2 virüsü, dünya çapında ciddi bir salgına neden olmuştur. Zoonotik kökenli olduğu değerlendirilen SARS-CoV-2 virüsü ilk olarak Çin'i etkisi altına almıştır. İlerleyen günlerde söz konusu virüsün diğer ülkelere de yayılmasıyla Dünya'nın bütün ülkeleri ciddi biçimde salgından etkilenmeye başlamıştır. SARS-CoV-2 virüsü hastalarda solunum sıkıntısına neden olmaktadır. Söz konusu virüsün insanlarda neden olduğu zatürre, Dünya Sağlık Örgütü (DSÖ) tarafından COVID-19 (Coronavirus Disease-2019) hastalığı olarak isimlendirilmiştir. COVID-19 hastalığının yaygın semptomları ateş, öksürük, nefes darlığı, kas ağrısı ve halsizlik olarak sıralanmaktadır. Hastalığın genel olarak akciğer üzerinde oldukça ağır ve olumsuz etkileri vardır.

Bilgisayarlı Tomografi (BT) ve X-ray görüntüleme, bir bakteri veya virüsün neden olduğu zatürrenin teşhisi ve klinik değerlendirmesi için önemli radyolojik bilgiler sağlamaktadır. COVID-19 hastalığının ortaya çıkmasından sonra söz konusu görüntüleme yöntemleri bu hastalığın radyolojik olarak görüntülenmesinde de yaygın olarak kullanılmaya başlamıştır. COVID-19 hastalığı akciğer üzerinde interstisyel tutulumla, iki taraflı ve düzensiz buzlu cam opasitelerine ve parankimal apselere neden olmaktadır. Bu radyolojik belirtiler BT ve X-ray görüntüleri üzerinden gözlemlenebilmektedir. Ayrıca, COVID-19 hastalığının radyolojik semptomları ile diğer viral veya bakteriyel zatürrelerin radyolojik semptomlarında bazı farklılıklar vardır.

COVID-19 hastalığının en yaygın teşhisi, Ters Transkripsiyon-Polimeraz Zincir Reaksiyonu (TT-PZR) testi ile yapılmaktadır. Bu test genellikle birkaç saat içinde sonuç vermektedir. Ancak, TT-PZR testinin COVID-19 hastalığına sebep olan SARS-CoV-2 virüsünün tespitindeki duyarlılığı oldukça düşüktür. Yani, gerçekte virüs taşıyanlar söz konusu test ile sıklıkla yanlış teşhis edilebilmektedir. Bu sebeple DSÖ, sadece TT-PZR testi pozitif olan vakaların değil, TT-PZR sonucu negatif olmasına rağmen radyolojik veya klinik semptomlarla bu virüsü taşıdığı tespit edilen vakaların da doğrudan bildirilmesini şart koşmaktadır. COVID-19 salgınının kontrol altına alınmasında en önemli faktörlerden biri virüsü taşıyan hastaların hızlı teşhis edilmesi ve izolasyonudur. TT-PZR testinin sonuç vermesinin saatler alması virüsü taşıyan kişilerin hızlı şekilde izole edilmesini zorlaştırmaktadır. Ayrıca, testin duyarlılığının düşük olması virüsü taşıyan kişilerin yanlış teşhis edilmesine bağlı olarak bulaş oranlarını yükseltmektedir. Bu durum COVID-19 salgını ile mücadele konusunda radyolojik görüntülemenin etkili şekilde kullanılmasını ve görüntülerin otomatik olarak değerlendirilmesini bir zorunluluk haline getirmektedir. Tez çalışmasında

söz konusu ihtiyaçlara cevap vermek için derin öğrenme temelli yapay zekâ uygulamaları gerçekleştirilmiştir.

Tez çalışması toplam yedi adet uygulama içermektedir. Birinci uygulamada BT görüntüleri üzerinden COVID-19 ve COVID-19 değil sınıflandırılması gerçekleştirilmiştir. Uygulamada klasik makine öğrenme yöntemleri olan Destek Vektör Makinesi ve k-En Yakın Komşu ile derin öğrenme yöntemi olan İki Boyutlu (2B) Evrişimli Sinir Ağları (ESA) mimarilerinin sınıflandırma performansları karşılaştırılmıştır. 2B ESA olarak uygulamada oluşturulmuş 23 katmanlı bir mimari ile transfer öğrenme AlexNet ve MobileNetV2'den yararlanılmıştır. Uygulamada doğrudan orijinal görüntülerin yanı sıra ön işlem olarak Gri Seviye Eş-oluşum Matrisi, Yerel İkili Desenler (YİD) ve Lokal Entropi (LE) kullanılarak elde edilen özellik görüntüleri için de sınıflandırma işlemi yapılmıştır. Ayrıca, tüm bu orijinal ve özellik görüntülerinin ikili, üçlü ve dörtlü olarak birleştirilmesi için deneyler tekrarlanmıştır. Uygulamada gerçekleştirilen deneyler iki kat çapraz doğrulama ve on kat çapraz doğrulama olmak üzere iki farklı eğitim ve test prosedürü ile gerçekleştirilmiştir. Tez çalışmasının bu uygulamasında ayrıca, veri artırımının uygulama sonuçlarına etkisi incelenmiştir. Bu kapsamda görüntülerin veri artırma teknikleri ile beş, on ve yirmi kat artırılması durumu için 23 katmanlı 2B ESA mimarisine iki kat çapraz doğrulama prosedürüne göre deneyler gerçekleştirilmiştir. Uygulama sonuçları özellik görüntülerinin orijinal görüntülerle birlikte kullanılmasının sonuçlara önemli katkılar sağladığını göstermektedir.

Tez çalışmasının ikinci uygulamasında BT görüntüleri üzerinden COVID-19 ve COVID-19 değil sınıflandırılması ile COVID-19 zatürresi ve diğer zatürre sınıflandırması olmak üzere iki başlıkta iki sınıflı sınıflandırma gerçekleştirilmiştir. Sınıflandırma için uygulama kapsamında oluşturulmuş 24 katmanlı bir 2B ESA mimarisinden yararlanılmıştır. Uygulamada orijinal BT görüntülerinin doğrudan kullanılması ve orijinal görüntüye ön işlem olarak YİD uygulanması durumu için deneyler gerçekleştirilmiştir. Ayrıca, ikincil işlem olarak Kompleks Değerli Dalgacık Dönüşümü (KDDD) uygulanmasıyla elde edilen görüntü alt bantlarının tek başlarına ve kombinasyonlar halinde kullanılması durumu için sınıflandırma işlemleri tekrarlanmıştır. Uygulamada son olarak orijinal BT görüntüleri kullanılarak elde edilen sonuçlar ile ön işlem olarak YİD uygulanarak elde edilen sonuçların birleştirilmesini sağlayan Veri Akış Hattı (VAH) yaklaşımlarının başarıları analiz edilmiştir. Uygulamanın deneyleri on kat çapraz doğrulama kullanılarak gerçekleştirilmiştir. Uygulama sonuçları VAH yaklaşımlarının sonuçların iyileştirilmesine önemli katkılar sağladığını göstermektedir. Ayrıca, KDDD kullanılarak görüntü boyutlarının başarılı şekilde azaltılabileceği ve VAH kullanılmasına bağlı olarak oluşan zaman maliyetinin ortadan kaldırılabilmesine işaret etmektedir.

Tez çalışmasının üçüncü uygulamasında BT görüntüleri üzerinden COVID-19 zatürresi, sağlıklı ve diğer zatürre olmak üzere üç sınıflı otomatik sınıflandırma gerçekleştirilmiştir. Uygulamada MobileNetV2, ResNet-101, GoogleNet, Xception, DenseNet-201, EfficientNetB0 ve InceptionV3 olmak üzere toplam yedi adet transfer öğrenme 2B ESA mimarisi kullanılmıştır. Uygulamada kullanılan COVID-19 görüntülerinden 810 tanesi Konya Selçuk Üniversitesi Tıp Fakültesi Hastanesi'nden (27.07.2020 tarih ve 220/326 sayılı etik kurul kararı) elde edilmiştir. Uygulamada doğrudan orijinal BT görüntüleri ve ön işlem olarak YİD uygulanarak elde edilen özellik görüntüleri için dört kat çapraz doğrulama esasına göre deneyler gerçekleştirilmiştir. Ayrıca, ikinci uygulamaya benzer şekilde VAH yaklaşımı kullanılarak sonuçlar birleştirilmiştir. Üçüncü uygulama sonuçları da VAH yaklaşımlarının sonuçların iyileştirilmesine önemli katkılar sağladığını göstermektedir. Ayrıca, VAH yaklaşımında YİD özellik görüntüleri kullanılmasının yanlış sınıflandırılan görüntülerin sayısının azaltılmasında daha etkili olduğuna işaret etmektedir.

Tez çalışmasının dördüncü uygulamasında ilk üç uygulamadan farklı olarak BT görüntüler üzerinden COVID-19 hastalık tespitini yerine COVID-19 zatürre seviyesinin sınıflandırılmasına odaklanılmıştır. Uygulamada kullanılan BT görüntüleri COVID-19 görüntüleri Selçuk Üniversitesi Tıp Fakültesi Hastanesi'nden (27.07.2020 tarih ve 220/327 sayılı etik kurul kararı) elde edilmiştir. Uygulamada sınıflandırma işlemleri MobileNetV2, ResNet-101, Xception, InceptionV3, GoogleNet, EfficientNetB0, DenseNet-201 ve DarkNet-53 olmak üzere toplam sekiz farklı transfer öğrenme 2B ESA mimarisi kullanılarak gerçekleştirilmiştir. En yüksek başarıyı gösteren transfer öğrenme 2B ESA mimarilerinin sonuçları VAH yaklaşımı kullanılarak birleştirilerek yeni sınıflandırma sonuçları hesaplanmıştır. Uygulamada eğitim ve test işlemleri beş kat çapraz doğrulama kullanılarak gerçekleştirilmiştir. Dördüncü uygulama sonuçları ESA mimarileri kullanılarak COVID-19 zatürre seviyesinin başarılı şekilde sınıflandırılabilmesine işaret etmektedir. Ayrıca, VAH yaklaşımlarının sonuçların iyileştirilmesine önemli katkılar sağladığını göstermektedir.

Tez çalışmasının beşinci uygulamasında X-ray görüntüleri üzerinden COVID-19 ve COVID-19 değil sınıflandırılması gerçekleştirilmiştir. Sınıflandırma için uygulama kapsamında oluşturulmuş 23 katmanlı ve 54 katmanlı iki farklı 2B ESA mimarisinden yararlanılmıştır. Beşinci uygulamada, ikinci uygulamaya benzer şekilde, orijinal X-ray görüntülerinin doğrudan kullanılması ve ön işlem olarak YİD uygulanarak kullanılması durumu için deneyler gerçekleştirilmiştir. Ayrıca, ikincil işlem olarak KDDD

uygulanmasıyla elde edilen görüntü alt bantlarının tek başlarına ve kombinasyonlar halinde kullanılmasıyla sınıflandırma işlemleri yapılmıştır. Uygulamada son olarak orijinal X-ray görüntüleri kullanılarak elde edilen sonuçlar ile ön işlem olarak YİD uygulanarak elde edilen sonuçların birleştirilmesini sağlayan VAH yaklaşımlarının başarıları analiz edilmiştir. Uygulamada deneyler iki kat çapraz doğrulama ve yirmi üç kat çapraz doğrulama prosedürü kullanılarak gerçekleştirilmiştir. Uygulama sonuçları VAH yaklaşımlarının sonuçların iyileştirilmesine önemli katkılar sağladığını göstermektedir. Ayrıca, KDDD kullanılarak görüntü boyutlarının başarılı şekilde azaltılabileceği ve VAH kullanımına bağlı olarak oluşan zaman maliyetinin ortadan kaldırılabilceği anlaşılmaktadır.

Tez çalışmasının altıncı uygulamasında X-ray görüntüleri üzerinden COVID-19 ve sağlıklı, COVID-19 zatürresi ve bakteriyel zatürre, COVID-19 zatürresi ve viral zatürre ile COVID-19 zatürresi ve diğer zatürre olmak üzere toplam dört başlıkta iki sınıflı sınıflandırma gerçekleştirilmiştir. Uygulamada orijinal X-ray görüntülerinin tek başına kullanılmasının yanı sıra ön işlem olarak YİD ve LE uygulanarak elde edilen görüntüler için de sınıflandırma sonuçları hesaplanmıştır. Orijinal görüntüler, YİD ve LE görüntülerinin çeşitli kombinasyonlarda birleştirilmesiyle elde edilen görüntüler için sınıflandırma işlemleri tekrarlanmıştır. Uygulamada sınıflandırıcı olarak transfer öğrenme 2B ESA ve Üç Boyutlu (3B) ESA mimarilerinden yararlanılmıştır. Uygulamada transfer öğrenme 2B ESA mimarisi olarak MobileNetV2, ResNet-101 ve GoogleNet mimarileri kullanılmıştır. 3B ESA için ise uygulama kapsamında 24 katmanlı bir mimari tasarlanmış ve kullanılmıştır. Uygulamanın eğitim ve test işlemleri beş kat çapraz doğrulama ile gerçekleştirilmiştir. Uygulama sonuçları 3B ESA mimarisinin transfer öğrenme 2B ESA mimarilerine göre daha yavaş ancak daha başarılı olduğunu göstermektedir. Ayrıca, özellik görüntülerinin orijinal görüntülerle birlikte kullanılmasının sonuçlara önemli katkılar sağladığına işaret etmektedir.

Tez çalışmasının yedinci uygulamasında X-ray görüntüleri üzerinden COVID-19 zatürresi, sağlıklı ve diğer zatürre ile COVID-19 zatürresi, sağlıklı, bakteriyel zatürre ve viral zatürre olmak üzere toplam iki başlıkta sırasıyla üç sınıflı ve dört sınıflı otomatik sınıflandırma gerçekleştirilmiştir. Uygulamada sınıflandırıcı olarak transfer öğrenme 2B ESA kullanılmıştır. Bu kapsamda MobileNetV2, ResNet-101, GoogleNet, Xception, DenseNet-201, EfficientNetB0 ve InceptionV3 olmak üzere toplam yedi adet transfer öğrenme 2B ESA mimarisinden yararlanılmıştır. Uygulamada doğrudan orijinal X-ray görüntüleri kullanılarak sınıflandırma sonuçları elde edilmiş olup ön işlem olarak YİD ve LE uygulanarak elde edilen özellik görüntüleri kullanılarak da sınıflandırma işlemleri gerçekleştirilmiştir. Ayrıca, VAH yaklaşımı kullanılarak daha önce elde edilen sonuçlar birleştirilmiş ve yeni sınıflandırma sonuçları elde edilmiştir. Uygulamada eğitim ve test işlemleri dört kat çapraz doğrulama kullanılarak yapılmıştır. Yedinci uygulama sonuçları VAH yaklaşımlarının sonuçların iyileştirilmesine önemli katkılar sağladığını göstermektedir.

**Anahtar Kelimeler:** Bilgisayarlı Tomografi, COVID-19, Gri Seviye Eş-oluşum Matrisi, İki Boyutlu Evrişimli Sinir Ağları, Lokal Entropi, Sınıflandırma, Üç Boyutlu Evrişimli Sinir Ağları, X-ray, Yerel İkili Desenler

## **ABSTRACT**

### **PhD THESIS**

## **DETECTION OF COVID-19 DISEASE USING DEEP LEARNING METHODS**

**Hüseyin YAŞAR**

**Konya Technical University  
Institute of Graduate Studies  
Department of Electrical and Electronics Engineering**

**Advisor: Assoc. Prof. Dr. Murat CEYLAN**

**2022, 249 Pages**

**Jury**

**Prof. Dr. Salih GÜNEŞ**

**Assoc. Prof. Dr. Murat CEYLAN**

**Prof. Dr. Seral ÖZŞEN**

**Asst. Prof. Dr. Muhammet Üsame ÖZİÇ**

**Asst. Prof. Dr. Saim ERVURAL**

The SARS-CoV-2 virus, which emerged in Wuhan, China's Hubei province, in the last days of 2019, has caused a serious epidemic worldwide. SARS-CoV-2 virus, which is considered of zoonotic origin, first affected China. In the following days, with the spread of the said virus to other countries, all countries began to be seriously affected by the epidemic. The SARS-CoV-2 virus causes respiratory distress in patients. Pneumonia caused by the virus in question in humans has been named COVID-19 (Coronavirus Disease-2019) by the World Health Organization (WHO). Common symptoms of COVID-19 are fever, cough, shortness of breath, muscle pain, and weakness. The disease has quite severe and adverse effects on the lung.

Computed Tomography (CT) and X-ray imaging provide important radiological information for diagnosing and clinically evaluating pneumonia caused by a bacteria or virus. After the emergence of COVID-19, these imaging methods began to be widely used in the radiological imaging of this disease. COVID-19 causes interstitial involvement in the lung, bilateral and irregular ground-glass opacities, and parenchymal abscesses. These radiological signs can be observed on CT and X-ray images. In addition, there are some differences in the radiological symptoms of COVID-19 and the radiological symptoms of other viral or bacterial pneumonias.

The most common diagnosis of COVID-19 is made by the Reverse Transcription-Polymerase Chain Reaction (RT-PCR) test. This test usually gives results within a few hours. However, the sensitivity of the RT-PCR test in detecting the SARS-CoV-2 virus that causes COVID-19 is very low. Therefore, those who carry the virus can often be misdiagnosed with the test. For this reason, WHO requires that patients with positive RT-PCR tests and cases carrying this virus with radiological or clinical symptoms despite negative RT-PCR results should be reported directly. One of the most important factors in controlling the COVID-19 epidemic is the rapid identification and isolation of patients with the virus. However, it takes hours for the RT-PCR test to give results, making it difficult to isolate people who carry the virus quickly. In addition, the test's low sensitivity increases the rate of transmission due to the misdiagnosis of nearly half of the people with the virus. This situation necessitates the effective use and automatic evaluation of radiological imaging in the fight against the COVID-19 epidemic. In the thesis study, deep learning-based artificial intelligence applications were carried out to respond to these needs.

A total of seven applications were carried out in the thesis study. In the first application, the classification of COVID-19 and Non-COVID-19 was carried out on CT images. In the application, classification performances of Support Vector Machine and k-Nearest Neighbor, which are classical

machine learning methods, and Two-Dimensional (2D) Convolutional Neural Networks (CNN) architectures, which are deep learning methods, are compared. As a 2D ESA, a 23-layer architecture created in the application and transfer learning AlexNet and MobileNetV2 were used. In the application, besides the original images directly, the classification process was performed for the feature images obtained by using Gray Level Co-occurrence Matrix, Local Binary Patterns (LBP), and Local Entropy (LE) as pre-processing. In addition, experiments were repeated to combine all these original and feature images in pairs, triplets, and quads. The experiments in the application were carried out with two different training and testing procedures, two-fold cross validation and ten-fold cross validation. In this application of the thesis, the effect of using data augmentation on the application results was also examined. In this context, experiments were carried out according to the two-fold cross validation procedure with a 23-layer 2D CNN architecture for five, ten, and twenty-fold augmentation of images with data augmentation techniques. The application results show that texture feature images and the original images contribute significantly to the results.

In the second application of the thesis study, a dual classification was carried out under two headings: COVID-19 and Non-COVID-19 classification, and COVID-19 pneumonia and other pneumonia classification, based on CT images. A 24-layer 2D ESA architecture created within the scope of the application was used for classification. Experiments have been carried out in the case of using the original CT images directly and applying LBP to the original images as a pre-processing in the application. In addition, classification processes are repeated for the case of using the image sub-bands obtained by applying Complex Value Wavelet Transform (CVWT) as a secondary process, alone or in combinations. Finally, the success of pipeline approaches, which combine the results obtained by using the original CT images and the results obtained by applying LBP as a pre-process, were analyzed in the application. In application, experiments were performed using ten-fold cross validation. Application results show that pipeline approaches make significant contributions to improving outcomes. It also points out that image sizes can be successfully reduced using CVWT, and the time cost associated with pipelines can be eliminated.

In the third application of the thesis, three-class automatic classification of COVID-19 pneumonia, healthy and other pneumonia was performed on CT images. Within the scope of the application, a total of seven transfer learning 2D CNN architectures were used, namely MobileNetV2, ResNet-101, GoogleNet, Xception, DenseNet-201, EfficientNetB0, and InceptionV3. 810 of the COVID-19 images used in the application were obtained from Konya Selcuk University Medical Faculty Hospital (ethics committee decision dated 27.07.2020 and numbered 220/326). In application, experiments were performed based on four-fold cross validation for the original CT images and feature images obtained by applying LBP as a pre-processing. Also, results were combined using the pipeline approach, similar to the second application. Similar to the second application, the results of the third application also show that pipeline approaches make significant contributions to improving the results. It also indicates that using LBP feature images in the pipeline approach is more effective in reducing the number of misclassified images.

In the fourth application of the thesis, unlike the first three applications, the focus was on classifying the COVID-19 pneumonia level instead of detecting COVID-19 disease from CT images. The automatic classification of COVID-19 pneumonia into three classes as mild, moderate, and severe; and two classes as non-severe and severe was carried out on CT images. The COVID-19 images used in the application were obtained from Konya Selcuk University Medical Faculty Hospital (ethics committee decision dated 27.07.2020 and numbered 220/327). In the application, classification processes were carried out using eight different transfer learning 2D CNN architectures, namely MobileNetV2, ResNet-101, Xception, InceptionV3, GoogleNet, EfficientNetB0, DenseNet-201 and DarkNet-53. The highest performing 2D CNN architectures were combined using the pipeline approach, and new classification results were calculated. The training and testing processes within the application were carried out using five-fold cross validation. The fourth application results indicate that the level of COVID-19 pneumonia can be successfully classified using CNN architectures. It also shows that pipeline approach makes significant contributions to improving outcomes.

In the fifth application of the thesis study, the classification of COVID-19 and Non-COVID-19 was carried out on X-ray images. Two different 2D ESA architectures with 23 and 54 layers were used for classification. In the fifth application, similar to the second application, experiments were carried out using the original X-ray images directly, and LBP as a pre-process. In addition, classification processes were carried out using the image sub-bands obtained by applying CVWT as a secondary process, alone or in combinations. Finally, the success of the pipeline approaches, which combined the results obtained using the original X-ray images and the results obtained by applying LBP as a pre-process, were analyzed in the application. In application, experiments were performed using two-fold cross validation and twenty-three-fold cross validation. Application results show that pipeline approaches make significant



contributions to improving outcomes. It also points out that image sizes can be successfully reduced by using CVWT and the time cost associated with using a pipeline can be eliminated.

In the sixth application of the thesis, binary classification was carried out on X-ray images under four headings: COVID-19 and healthy, COVID-19 pneumonia and bacterial pneumonia, COVID-19 pneumonia and viral pneumonia, and COVID-19 pneumonia and other pneumonia. In addition to using the original X-ray images alone in the application, the classification results were calculated using the images obtained by applying LBP and LE as a pre-process. The classification processes were repeated for the images obtained by combining the original images, LBP, and LE images in various combinations. 2D CNN and Three Dimensional (3D) CNN architectures were used as classifiers in the application. MobileNetV2, ResNet-101, and GoogleNet architectures were used as transfer learning 2D CNN architecture. For the 3D CNN, a 24-layer architecture was designed and used within the scope of the application. Five-fold cross validation was carried out in the training and testing processes in the application. The application results show that the 3D CNN architecture is slower but more successful than the 2D CNN architecture. It also points out that the texture feature images and the original images make significant contributions to the results.

In the seventh application of the thesis study, three-class automatic classification as COVID-19 pneumonia, healthy, and other pneumonia, and four-class COVID-19 pneumonia, healthy, bacterial pneumonia, and viral pneumonia were performed on X-ray images. In the application, transfer learning 2D CNN was used as a classifier. In this context, a total of seven transfer learning 2D CNN architectures, namely MobileNetV2, ResNet-101, GoogleNet, Xception, DenseNet-201, EfficientNetB0 and InceptionV3, were utilized. In the application, classification results were obtained by using the original X-ray images directly, and classification processes were carried out using the feature images obtained by applying LBP and LE as a pre-process. In addition, using the pipeline approach, previous results were combined, and new classification results were obtained. In application, training and testing was done using four-fold cross validation. The seventh application results show that pipeline approach make significant contributions to improving outcomes.

**Keywords:** Classification, Computed Tomography, COVID-19, Gray Level Co-occurrence Matrix, Local Binary Pattern, Local Entropy, Three-Dimensional Convolutional Neural Networks, Two-Dimensional Convolutional Neural Networks, X-ray

## ÖNSÖZ

Doktora tez çalışmalarımnda emeđi geen, ok deđerli yardım ve ynlemdirleri ile yolumu aydınlatan, danıřmanım Konya Teknik niversitesi Mhendislik ve Dođa Bilimleri Fakltesi Elektrik-Elektronik Mhendisliđi đretim yesi Do. Dr. Murat Ceylan'a katkılarından dolayı teřekkrlerimi sunarım.

Doktora tezimin bazı uygulamalarında kullanılan medikal verilerin sađlanmasında katkısı bulunan Seluk niversitesi Tıp Fakltesi Radyoloji Ana Bilim Dalı đretim yeleri Dr. đr. yesi Hakan Cebeci, Dr. đr. yesi Abidin Kılıner, Dr. Nusret Seher ve Prof. Dr. Mustafa Koplay ile Seluk niversitesi Tıp Fakltesi Gđs Hastalıkları Ana Bilim Dalı đretim yesi Prof. Dr. Fikret Kanat'a řukranlarımı sunarım.

Son olarak, hayatımın her adımında desteklerini hep hissettiđim kıymetli annem Hatice Yařar, babam Mustafa Yařar ve aileme; sevgisiyle beni cesaretlendiren, ilham veren eřim İmren Dařdemir Yařar'a ve en byk motivasyon kaynađım olan ođullarım Metehan Yařar ve Ođuzhan Yařar'a en iten minnet duygularım ile teřekkr ederim.

Hseyin YAřAR  
KONYA-2022

# İÇİNDEKİLER

<b>ÖZET</b> .....	<b>iv</b>
<b>ABSTRACT</b> .....	<b>vii</b>
<b>ÖNSÖZ</b> .....	<b>x</b>
<b>İÇİNDEKİLER</b> .....	<b>xi</b>
<b>SİMGELER VE KISALTMALAR</b> .....	<b>xv</b>
<b>1. GİRİŞ</b> .....	<b>1</b>
1.1. Tez Konusunun Tanıtılması .....	3
1.2. Tez Çalışmasının Önemi ve Amacı .....	6
<b>2. KAYNAK ARAŞTIRMASI</b> .....	<b>8</b>
2.1. BT Görüntüler Kullanılarak Gerçekleştirilen Uygulamalar .....	8
2.1.1. COVID-19 ve COVID-19 değil sınıflandırması .....	8
2.1.2. COVID-19 zatürresi ve diğer zatürre sınıflandırması .....	14
2.1.3. COVID-19 zatürresi, sağlıklı ve diğer zatürre sınıflandırması .....	16
2.1.4. COVID-19 zatürre seviye sınıflandırması .....	20
2.2. X-ray Görüntüler Kullanılarak Gerçekleştirilen Uygulamalar .....	22
2.2.1. COVID-19 ve COVID-19 değil sınıflandırması .....	22
2.2.2. COVID-19 zatürresi ve bakteriyel zatürre, COVID-19 zatürresi ve viral zatürre, COVID-19 zatürresi ve diğer zatürre sınıflandırması .....	26
2.2.3. COVID-19 zatürresi, sağlıklı ve diğer zatürre sınıflandırması .....	27
2.2.4. COVID-19 zatürresi, sağlıklı, bakteriyel zatürre ve viral zatürre sınıflandırması .....	31
<b>3. KOMPLEKS DEĞERLİ DALGACIK DÖNÜŞÜMÜ</b> .....	<b>32</b>
3.1. Bir Boyutlu Dalgacık Dönüşümü .....	32
3.2. İki Boyutlu Dalgacık Dönüşümü .....	34
3.3. Kompleks Değerli Dalgacık Dönüşümü .....	35
<b>4. DOKU ANALİZ (ÖZELLİK ÇIKARMA) YÖNTEMLERİ</b> .....	<b>37</b>
4.1. Yerel İkili Desenler .....	37
4.2. Lokal Entropi .....	39
4.3. Gri Seviye Eş-oluşum Matrisi .....	40
<b>5. MAKİNE ÖĞRENMESİ VE DERİN ÖĞRENME</b> .....	<b>43</b>
5.1. Destek Vektör Makinesi .....	43
5.2. k-En Yakın Komşu .....	45
5.3. Evrişimli Sinir Ağları .....	45
5.3.1. Evrişim .....	46

5.3.2. Normalizasyon .....	48
5.3.3. Aktivasyon fonksiyonları.....	48
5.3.4. Havuzlama .....	49
5.3.5. Düzleştirme .....	50
5.3.6. Tam bağlı katman .....	51
5.3.7. Unutturma .....	52
5.3.8. ESA hiperparametreleri .....	52
5.4. Tez Çalışmasında Kullanılan ESA Mimarileri .....	53
5.5. Tez Çalışmasında Özel Olarak Oluşturulan ESA Mimarileri.....	54
5.5.1. 23 katmanlı 2B ESA mimarisi .....	54
5.5.2. 24 katmanlı 2B ESA mimarisi .....	55
5.5.3. 54 katmanlı 2B ESA mimarisi .....	56
5.5.4. 24 katmanlı 3B ESA mimarisi .....	58
5.6. Tez Çalışmasında Transfer Edilerek Kullanılan ESA Mimarileri .....	59
5.6.1. 2B AlexNet ESA mimarisi .....	59
5.6.2. 2B MobileNetV2 ESA mimarisi .....	60
5.6.3. 2B ResNet-101 ESA mimarisi .....	61
5.6.4. 2B GoogleNet ESA mimarisi .....	62
5.6.5. 2B InceptionV3 ESA mimarisi .....	62
5.6.6. 2B Xception ESA mimarisi .....	63
5.6.7. 2B DenseNet-201 ESA mimarisi .....	63
5.6.8. 2B EfficientNetB0 ESA mimarisi.....	64
5.6.9. 2B DarkNet-53 ESA mimarisi.....	65
<b>6. EĞİTİM VE TEST PROSEDÜRLERİ İLE DEĞERLENDİRME KRİTERLERİ</b> .....	<b>66</b>
6.1. Eğitim ve Test Prosedürleri .....	66
6.2. Değerlendirme Kriterleri.....	67
6.2.1. İki sınıflı sınıflandırma .....	67
6.2.2. Çok sınıflı sınıflandırma .....	69
<b>7. BT GÖRÜNTÜLER ÜZERİNDEN COVID-19 VE COVID-19 DEĞİL</b> <b>SINIFLANDIRMASI.....</b>	<b>72</b>
7.1. Uygulamada Kullanılan Veriler .....	72
7.2. Veri Artırma.....	72
7.3. Özellik Çıkarma, ESA Modifikasyonları ve Hiperparametreler .....	73
7.4. Deneyler.....	75
7.5. Deney Sonuçları.....	77
7.6. BT Görüntüler Üzerinden COVID-19 ve COVID-19 Değil Sınıflandırma Sonuçlarının Değerlendirilmesi .....	86
<b>8. BT GÖRÜNTÜLER ÜZERİNDEN COVID-19 VE COVID-19 DEĞİL İLE</b> <b>COVID-19 ZATÜRRESİ VE DİĞER ZATÜRRE SINIFLANDIRMASI .....</b>	<b>91</b>
8.1. Uygulamada Kullanılan Veriler .....	91
8.2. Özellik Çıkarma, ESA Modifikasyonları ve Hiperparametreler .....	93
8.3. Uygulamada Kullanılan VAH Yaklaşımları.....	94
8.4. Deneyler.....	97
8.5. Deney Sonuçları.....	99

8.6. BT Görüntüler Üzerinden COVID-19 ve COVID-19 Değil ile COVID-19 Zatürresi ve Diğer Zatürre Sınıflandırma Sonuçlarının Değerlendirilmesi .....	110
--	-----

## **9. BT GÖRÜNTÜLER ÜZERİNDEN COVID-19 ZATÜRRESİ, SAĞLIKLI VE DİĞER ZATÜRRE SINIFLANDIRMASI..... 117**

9.1. Uygulamada Kullanılan Veriler .....	117
9.2. Özellik Çıkarma, ESA Modifikasyonları ve Hiperparametreler .....	119
9.3. Uygulamada Kullanılan VAH Yaklaşımları .....	120
9.4. Deneyler.....	121
9.5. Deney Sonuçları.....	122
9.6. BT Görüntüler Üzerinden COVID-19 Zatürresi, Sağlıklı ve Diğer Zatürre Sınıflandırma Sonuçlarının Değerlendirilmesi .....	127

## **10. BT GÖRÜNTÜLER ÜZERİNDEN COVID-19 ZATÜRRE SEVİYESİ SINIFLANDIRMASI..... 133**

10.1. Uygulamada Kullanılan Veriler .....	133
10.2. Özellik Çıkarma, ESA Modifikasyonları ve Hiperparametreler .....	136
10.3. Uygulamada Kullanılan VAH Yaklaşımları .....	137
10.4. Deneyler.....	138
10.5. Deney Sonuçları.....	139
10.6. BT Görüntüler Üzerinden COVID-19 Zatürre Seviye Sınıflandırma Sonuçlarının Değerlendirilmesi .....	142

## **11. X-RAY GÖRÜNTÜLER ÜZERİNDEN COVID-19 VE COVID-19 DEĞİL SINIFLANDIRMASI..... 146**

11.1. Uygulamada Kullanılan Veriler .....	146
11.2. Özellik Çıkarma, ESA Modifikasyonları ve Hiperparametreler .....	147
11.3. Uygulamada Kullanılan VAH Yaklaşımları .....	148
11.4. Deneyler.....	150
11.5. Deney Sonuçları.....	152
11.6. X-ray Görüntüler Üzerinden COVID-19 ve COVID-19 Değil Sınıflandırma Sonuçlarının Değerlendirilmesi .....	161

## **12. X-RAY GÖRÜNTÜLER ÜZERİNDEN COVID-19 VE SAĞLIKLI, COVID-19 ZATÜRRESİ VE BAKTERİYEL ZATÜRRE, COVID-19 ZATÜRRESİ VE VİRAL ZATÜRRE İLE COVID-19 ZATÜRRESİ VE DİĞER ZATÜRRE SINIFLANDIRMASI..... 166**

12.1. Uygulamada Kullanılan Veriler .....	166
12.2. Özellik Çıkarma, ESA Modifikasyonları ve Hiperparametreler .....	167
12.3. Deneyler.....	168
12.4. Deney Sonuçları.....	170
12.4.1. COVID-19 ve sağlıklı sınıflandırma sonuçları .....	170
12.4.2. COVID-19 zatürresi ve bakteriyel zatürre sınıflandırma sonuçları.....	172
12.4.3. COVID-19 zatürresi ve viral zatürre sınıflandırma sonuçları .....	173
12.4.4. COVID-19 zatürresi ve diğer zatürre sınıflandırma sonuçları.....	175

12.5. X-Ray Görüntüler Üzerinden COVID-19 ve Sağlıklı, COVID-19 Zatürresi ve Bakteriyel Zatürre, COVID-19 Zatürresi ve Viral Zatürre ile COVID-19 Zatürresi ve Diğer Zatürre Sınıflandırma Sonuçlarının Değerlendirilmesi ..... 176

**13. X-RAY GÖRÜNTÜLER ÜZERİNDEN COVID-19 ZATÜRRESİ, SAĞLIKLI VE DİĞER ZATÜRRE İLE COVID-19 ZATÜRRESİ, SAĞLIKLI, BAKTERİYEL ZATÜRRE VE VİRAL ZATÜRRE SINIFLANDIRMASI ..... 182**

13.1. Uygulamada Kullanılan Veriler ..... 182  
13.2. Özellik Çıkarma, ESA Modifikasyonları ve Hiperparametreler ..... 184  
13.3. Uygulamada Kullanılan VAH Yaklaşımları ..... 185  
13.4. Deneyler ..... 186  
13.5. Deney Sonuçları ..... 187  
    13.5.1. COVID-19 zatürresi, sağlıklı ve diğer zatürre sınıflandırma sonuçları .... 187  
    13.5.2. COVID-19 zatürresi, sağlıklı, bakteriyel zatürre ve viral zatürre sınıflandırma sonuçları ..... 191  
13.6. X-Ray Görüntüler Üzerinden COVID-19 Zatürresi, Sağlıklı ve Diğer Zatürre ile COVID-19 Zatürresi, Sağlıklı, Bakteriyel Zatürre ve Viral Zatürre Sınıflandırma Sonuçlarının Değerlendirilmesi ..... 199

**14. SONUÇ VE ÖNERİLER..... 206**

14.1. Sonuç ..... 206  
14.2. Öneriler ..... 207

**KAYNAKLAR ..... 209**

**EKLER .....Hata! Yer işareti tanımlanmamış.**

**ÖZGEÇMİŞ .....Hata! Yer işareti tanımlanmamış.**

## SİMGELER VE KISALTMALAR

### Simgeler

$a$	: Dalgacık Dönüşümü Ölçek Operatörü
$a_0$	: Ayrık Dalgacık Dönüşümü Genişletme Adımı
$b$	: Dalgacık Dönüşümü Kayma (Konum) Operatörü
$b_0$	: Ayrık Dalgacık Dönüşümü Çevirme Adımı
$boyut$	: Çok Boyutlu Uzayın Boyut Sayısı
$B_{çıkış}$	: Ağdan Alınması Beklenen Çıkış
$c$	: Polinom Çekirdek Fonksiyonu Kaydırma Parametresi
$C$	: Gri Seviye Eş-oluşum Matrisi
$d$	: Polinom Çekirdek Fonksiyonunun Polinom Derecesi
$dikey$	: Gri Seviye Eş-oluşum Matrisi Hesaplanan Görüntünün Dikey Boyutu
$e_k$	: Evrişim Dolgu Ekleme Miktarı
$f$	: Evrişim İşleminde Kullanılan Ana Matris
$f_i$	: Evrişim Filtre Matrisinin Büyüklüğü
$G_{çıkış}$	: Ağdan Alınan Gerçek Çıkış
$h$	: Evrişim İşleminde Kullanılan Evrişim Matrisi
$h_r(n)$	: Kompleks Değerli Dalgacık Dönüşümü Reel Filtre Kümesi
$h_i(n)$	: Kompleks Değerli Dalgacık Dönüşümü İmajiner Filtre Kümesi
$H$	: Hata
$i$	: Parametreleri Hesaplanan Sınıf
$I$	: Gri Seviye Eş-oluşum Matrisi Giriş Görüntüsü
$k$	: Çapraz Doğrulamada Kullanılan Katlama Sayısı
$K$	: Çekirdek Fonksiyonu
$kayma$	: Evrişim Filtre Kaydırma Parametresi
$kHz$	: Kiloherz
$m$	: Parametreleri Hesaplanan Toplam Eleman Sayısı
$m_i$	: Parametreleri Hesaplanan $i$ Sınıfının Eleman Sayısı
$n$	: Parametreleri Hesaplanan Toplam Sınıf Sayısı
$n_ç$	: Evrişim Özellik Matrisinin Büyüklüğü
$n_{giriş}$	: Evrişim Giriş Matrisinin Büyüklüğü
$nn$	: Ağ Eğitiminde Kullanılan Eleman Sayısı
$ÖM$	: Öklid Mesafesi
$p$	: Yerel İkili Desenler Merkez Piksel Komşu Sayısı
$p-1$	: Gri Seviye Eş-oluşum Matrisi Piksel Çiftinin Birinci Elemanı
$p-2$	: Gri Seviye Eş-oluşum Matrisi Piksel Çiftinin İkinci Elemanı
$p_i$	: Lokal Entropi $i$ . Piksel Değeri ile İlişkili Olasılık
$s$	: Gri Seviye Eş-oluşum Matrisinin Yatay ve Dikey Boyutu
$t$	: Zaman
$x$	: Gri Seviye Eş-oluşum Matrisi Görüntünün Yatay Uzamsal Konumu
$x_i$	: Yerel İkili Desenler $i$ . Komşunun Piksel Değeri
$x_m$	: Yerel İkili Desenler Merkez Pikselin Değeri
$y$	: Gri Seviye Eş-oluşum Matrisi Görüntünün Dikey Uzamsal Konumu
$yatay$	: Gri Seviye Eş-oluşum Matrisi Hesaplanan Görüntünün Yatay Boyutu
$\psi$	: Ana Dalgacık Fonksiyonu
$^\circ$	: Derece
$\sigma$	: Varyans

$\omega_i$	: Ağın Mevcut Ağırlığı
$\eta$	: Öğrenme Oranı
$\omega$	: Ağın Hesaplanan Yeni Ağırlığı

### Kısaltmalar

2B	: 2 (İki) Boyutlu
3B	: 3 (Üç) Boyutlu
AIKE	: Alıcı İşlem Karakteristiği Eğrisi
AIKE-AKA	: Alıcı İşlem Karakteristiği Eğrisi Altında Kalan Alan
BT	: Bilgisayarlı Tomografi
COVID-19	: Coronavirus Disease-2019
CPU	: Central Processing Unit
DD	: Dalgacık Dönüşümü
DN	: Doğru Negatif
DP	: Doğru Pozitif
DSÖ	: Dünya Sağlık Örgütü
DVM	: Destek Vektör Makinesi
ESA	: Evrişimli Sinir Ağları
FD	: Fourier Dönüşümü
GSEM	: Gri Seviye Eş-oluşum Matrisi
H	: Yüksek (High) Frekans Bileşeni
HH	: Yüksek-Yüksek Görüntü Alt Bandı
HL	: Yüksek-Alçak Görüntü Alt Bandı
KDDD	: Kompleks Değerli Dalgacık Dönüşümü
KZFD	: Kısa Zamanlı Fourier Dönüşümü
k-EYK	: k-En Yakın Komşu
L	: Alçak (Low) Frekans Bileşeni
LE	: Lokal Entropi
LH	: Alçak-Yüksek Görüntü Alt Bandı
LL	: Alçak-Alçak Görüntü Alt Bandı
TT-PZR	: Ters Transkripsiyon-Polimeraz Zincir Reaksiyonu
VAH	: Veri Akış Hattı
VAH-1	: Birinci Veri Akış Hattı
VAH-2	: İkinci Veri Akış Hattı
VAH-3	: Üçüncü Veri Akış Hattı
VAH-4	: Dördüncü Veri Akış Hattı
VAH-5	: Beşinci Veri Akış Hattı
YİD	: Yerel İkili Desenler
YN	: Yanlış Negatif
YOLO	: You Only Look Once
YP	: Yanlış Pozitif



## 1. GİRİŞ

2019 yılının aralık ayında ortaya çıkan SARS-CoV-2 virüsü, dünya çapında ciddi bir pandemiye neden olmuştur. Zoonotik kökenli olduğu değerlendirilen SARS-CoV-2 virüsü ilk olarak Çin'in Hubei eyaletinin Wuhan kentinde ortaya çıkmıştır (Zhu ve ark., 2020). Virüs insandan insana hızlı bir şekilde bulaşarak öncelikle Çin'i etkisi altına almıştır. İlerleyen günlerde söz konusu virüsün diğer ülkelere de yayılmasıyla Dünya'nın bütün ülkeleri ciddi biçimde salgından etkilenmeye başlamıştır. Dünya Sağlık Örgütü (DSÖ) 2020 yılının mart ayında söz konusu salgının seviyesini epidemiden pandemiye yükselterek küresel bir kriz ile karşı karşıya olduğunu ilan etmiştir (DSÖ, 2020(a)).

SARS-CoV-2 virüsü genel olarak hastalarda solunum sıkıntısına neden olmaktadır. Söz konusu virüsün insanlarda neden olduğu zatürre, DSÖ tarafından COVID-19 (Coronavirus Disease-2019) hastalığı olarak isimlendirilmiştir (DSÖ, 2020(b)). COVID-19 hastalığın yaygın semptomları ateş, öksürük, nefes darlığı, kas ağrısı ve halsizlik olarak sıralanmaktadır (Huang ve ark., 2020). Hastalığın genel olarak akciğer üzerinde oldukça ağır ve olumsuz etkileri vardır. COVID-19 salgını, ülkelerin sağlık sistemleri üzerinde büyük baskı oluşturmaktadır. Pandeminin başlangıcından 2022 yılı mayıs ayı sonuna kadar iki yıldan fazla bir süre geçmiştir. 2022 yılı mayıs ayı sonu itibariyle Dünya çapında toplam vaka sayısı 530 milyonu geçerken hastalığa bağlı ölüm sayısı ise 6,5 milyona yaklaşmıştır (DSÖ, 2022).

COVID-19 hastalığının tedavisi için ilaç geliştirme çalışmaları devam etmekle birlikte henüz hastalığa karşı tam kullanım onayı almış özel bir ilaç bulunmamaktadır. Salgının ortaya çıkmasının hemen akabinde araştırma ekipleri ve ilaç firmaları tarafından SARS-CoV-2 virüsüne karşı farklı teknolojiler kullanılarak aşı geliştirilmesine yönelik çalışmalar başlatılmıştır. Geliştirilen aşılarından bazıları, DSÖ'den acil kullanım onayı alarak 2021 yılı başından itibaren bazı ülkelerde uygulanmaya başlamıştır (DSÖ, 2021). Ancak; üretim, tedarik, depolama ve nakliye ile ilgili sorunlar aşılama süreçlerini yavaşlatmaktadır. Bir diğer önemli sorun ise ülkeler arasındaki ekonomik gelişmişlik farklılıkları sebebiyle 2021 sonu itibariyle bazı ülkelerde (özellikle Afrika ülkeleri) aşılamanın henüz hiç başlamamış olmasıdır. Aşıya ulaşan ülkelerde ise aşı karşıtlığı konusu toplum bağışıklığı oluşmasının önünde önemli bir engel niteliğindedir. Tüm bu zorluklar COVID-19 hastalığın kontrol altına alınmasının yıllar alabileceğini göstermektedir (Calina ve ark., 2020). Diğer bir önemli

sorun ise virüsün mutasyona uğramış versiyonlarıdır. Aşıların bu mutasyonlara karşı sağladığı koruma giderek azalmaktadır. Bu da COVID-19 hastalığının ülkeleri ve toplumları uzun süre daha etkileyeceğine işaret etmektedir.

Bilgisayarlı Tomografi (BT) ve X-ray görüntüleme, bir bakteri veya virüsün neden olduğu zatürrenin teşhisi ve klinik değerlendirmesi için önemli radyolojik bilgiler sağlamaktadır. COVID-19 hastalığının ortaya çıkmasından sonra söz konusu görüntüleme yöntemleri bu hastalığın radyolojik olarak görüntülenmesinde de yaygın olarak kullanılmaya başlamıştır. Birçok klinik çalışmada (Albarello ve ark., 2020; Hsieh ve ark., 2020; Zhang ve ark., 2020; Chen ve ark., 2020; Lee ve ark., 2020; Liu ve ark., 2020; Thevarajan ve ark., 2020; Lim ve ark., 2020; Kong ve Agarwal, 2020; Yoon ve ark., 2020; Wu ve ark., 2020(a); Zu ve ark., 2020; Song ve ark., 2020; Holshue ve ark., 2020; Cheng ve ark., 2020; Ng ve ark., 2020; Shi ve ark., 2020; Silverstein ve ark., 2020; Phan ve ark.; 2020; Cuong ve ark., 2020), COVID-19 hastalığının akciğer üzerinde interstisyel tutulumu, iki taraflı ve düzensiz buzlu cam opasitelerine ve parankimal apselere neden olduğu BT ve X-ray görüntüleri üzerinden ortaya konulmuştur. Benzer şekilde, COVID-19 hastalığının radyolojik semptomları ile diğer viral veya bakteriyel zatürrelerin radyolojik semptomlarının farklılıklarını ortaya koyan klinik çalışmalar (Wong ve ark., 2020; Pontone ve ark., 2021; Pianura ve ark., 2020; Zhao ve ark., 2020(a); Lin ve ark., 2021) gerçekleştirilmiştir.

Long ve Ehrenfeld (2020) ve McCall (2020) tarafından gerçekleştirilen çalışmalarda; COVID-19 pandemi krizinin etkilerini ve sağlık çalışanlarının iş yükünü azaltmak, hastalık teşhisini hızlandırmak ve teşhis başarısını artırmak için yapay zekâ sistemlerinin kullanılmasının kaçınılmaz bir gereklilik olduğu belirtilmiştir. Tez çalışmasında söz konusu ihtiyaçlara cevap vermek için derin öğrenme temelli yapay zekâ uygulamaları gerçekleştirilmiştir.

Tez çalışması on dört ana bölümden meydana gelmektedir. Birinci bölümde, tez konusunun genel tanıtımı gerçekleştirilmiştir. Ayrıca bu bölümde, tez çalışmasının hedefleri ve önemi üzerinde durulmuştur. İkinci bölümde, tezde gerçekleştirilen uygulama başlıklarında daha önce yapılmış akademik çalışmalara ilişkin bilgilere ve açıklamalara yer verilmiştir. Üçüncü bölümde bazı uygulamalarda görüntü boyutlarının azaltılması ve frekans düzlemine geçiş için kullanılan Kompleks Değerli Dalgacık Dönüşümü (KDDD) incelenmiştir. Dördüncü bölümde ise tezin bazı uygulamalarında yararlanılan Yerel İkili Desenler (YİD), Lokal Entropi (LE) ve Gri Seviye Eş-oluşum Matrisi (GSEM) olmak üzere görüntü özelliklerinin çıkarılmasını sağlayan doku analiz

(özellik çıkarma) yöntemleri irdelenmiştir. Tez çalışmasının beşinci bölümünde makine öğrenmesi yöntemleri olan Destek Vektör Makinesi (DVM) ve k-En Yakın Komşu (k-EYK) ile derin öğrenme yöntemleri olan İki Boyutlu (2B) ve Üç Boyutlu (3B) Evrişimli Sinir Ağları (ESA) üzerinde durulmuştur. Altıncı bölümde, deneylerde kullanılan eğitim ve test kümelerinin belirlenmesine ilişkin prosedürler açıklanmıştır. Ayrıca, uygulamalarda elde edilen sonuçların analizinde kullanılan değerlendirme kriterlerine yer verilmiştir. Tez çalışmasında toplam yedi adet uygulama gerçekleştirilmiş olup her uygulama ayrı bir başlıkta incelenmiştir. Bu kapsamda yedinci ve on üçüncü bölümler arasında uygulamalarda yararlanılan veriler, deneylerde kullanılan hiperparametreler, elde edilen sayısal sonuçlar ve gerçekleştirilen değerlendirmeler yer almaktadır. Son bölüm olan on dördüncü bölümde ise tez çalışmasının sonuçları ele alınmış ve gelecek çalışmalar için önerilerde bulunulmuştur.

### **1.1. Tez Konusunun Tanıtılması**

Tez çalışmasında toplam yedi adet uygulama gerçekleştirilmiştir. Birinci uygulamada BT görüntüleri üzerinden COVID-19 ve COVID-19 değil sınıflandırılması üzerinde durulmuştur. Uygulamada klasik makine öğrenme yöntemleri olan DVM ve k-EYK ile derin öğrenme yöntemi olan 2B ESA mimarilerinin sınıflandırma performansları karşılaştırılmıştır. 2B ESA mimarisi olarak uygulamada oluşturulmuş 23 katmanlı bir mimari ile transfer öğrenme AlexNet ve MobileNetV2 mimarilerinden yararlanılmıştır. Uygulamada doğrudan orijinal görüntülerin yanı sıra ön işlem olarak GSEM, YİD ve LE kullanılarak elde edilen özellik görüntüleri için de sınıflandırma işlemi yapılmıştır. Ayrıca, tüm bu orijinal ve özellik görüntülerinin ikili, üçlü ve dörtlü olarak birleştirilmesi için deneyler tekrarlanmıştır. Uygulamanın deneyleri iki kat çapraz doğrulama ve on kat çapraz doğrulama olmak üzere iki farklı eğitim ve test prosedürü ile gerçekleştirilmiştir. Tez çalışmasının bu uygulamasında ayrıca, veri artırımının uygulama sonuçlarına etkisi incelenmiştir. Bu kapsamda görüntülerin veri artırma teknikleri ile beş, on ve yirmi kat artırılması durumu için 23 katmanlı 2B ESA mimarisine iki kat çapraz doğrulama prosedürüne göre deneyler gerçekleştirilmiştir.

Tez çalışmasının ikinci uygulamasında BT görüntüleri üzerinden COVID-19 ve COVID-19 değil sınıflandırılması ile COVID-19 zatürresi ve diğer zatürre sınıflandırılması olmak üzere iki başlıkta iki sınıflı sınıflandırma gerçekleştirilmiştir. Sınıflandırma için uygulamada oluşturulmuş 24 katmanlı bir 2B ESA mimarisinden

yararlanılmıştır. Uygulamada orijinal BT görüntülerinin doğrudan kullanılması ve orijinal görüntüye ön işlem olarak YİD uygulanması durumu için deneyler gerçekleştirilmiştir. Ayrıca, ikincil işlem olarak KDDD uygulanmasıyla elde edilen görüntü alt bantlarının tek başlarına ve kombinasyonlar halinde kullanılması durumu için sınıflandırma işlemleri tekrarlanmıştır. Uygulamada son olarak orijinal BT görüntüleri kullanılarak elde edilen sonuçlar ile ön işlem olarak YİD uygulanarak elde edilen sonuçların birleştirilmesini sağlayan Veri Akış Hattı (VAH) yaklaşımlarının başarıları analiz edilmiştir. Uygulamada deneyler on kat çapraz doğrulama kullanılarak gerçekleştirilmiştir.

Tez çalışmasının üçüncü uygulamasında BT görüntüleri üzerinden COVID-19 zatürresi, sağlıklı ve diğer zatürre olmak üzere üç sınıflı otomatik sınıflandırma gerçekleştirilmiştir. Uygulamada MobileNetV2, ResNet-101, GoogleNet, Xception, DenseNet-201, EfficientNetB0 ve InceptionV3 olmak üzere toplam yedi adet transfer öğrenme 2B ESA mimarisi kullanılmıştır. Uygulamada doğrudan orijinal BT görüntüleri ve ön işlem olarak YİD uygulanarak elde edilen özellik görüntüleri için dört kat çapraz doğrulama esasına göre deneyler gerçekleştirilmiştir. Ayrıca, ikinci uygulamaya benzer şekilde VAH yaklaşımı kullanılarak sonuçlar birleştirilmiştir.

Tez çalışmasının dördüncü uygulamasında ilk üç uygulamadan farklı olarak BT görüntüler üzerinden COVID-19 hastalık tespitini yerine COVID-19 zatürre seviyesinin sınıflandırılmasına odaklanılmıştır. Uygulamada BT görüntüleri üzerinden COVID-19 zatürresinin hafif, orta ve şiddetli olmak üzere üç sınıflı; şiddetli değil ve şiddetli olmak üzere iki sınıflı otomatik sınıflandırılması gerçekleştirilmiştir. Uygulamada sınıflandırma işlemleri MobileNetV2, ResNet-101, Xception, InceptionV3, GoogleNet, EfficientNetB0, DenseNet-201 ve DarkNet-53 olmak üzere toplam sekiz farklı transfer öğrenme 2B ESA mimarisi kullanılarak gerçekleştirilmiştir. En yüksek başarıları sağlayan transfer öğrenme 2B ESA mimarilerinin sonuçları VAH yaklaşımı kullanılarak birleştirilmiş ve yeni sınıflandırma sonuçları hesaplanmıştır. Uygulamanın eğitim ve test işlemleri beş kat çapraz doğrulama kullanılarak gerçekleştirilmiştir.

Tez çalışmasının beşinci uygulamasında X-ray görüntüleri üzerinden COVID-19 ve COVID-19 değil sınıflandırılması gerçekleştirilmiştir. Sınıflandırma için uygulama kapsamında oluşturulmuş 23 katmanlı ve 54 katmanlı iki farklı 2B ESA mimarisinden yararlanılmıştır. Beşinci uygulamada, ikinci uygulamaya benzer şekilde, orijinal X-ray görüntülerinin doğrudan kullanılması ve ön işlem olarak YİD uygulanarak kullanılması durumu için deneyler gerçekleştirilmiştir. Ayrıca, ikincil işlem olarak KDDD

uygulanmasıyla elde edilen görüntü alt bantlarının tek başlarına ve kombinasyonlar halinde kullanılmasıyla sınıflandırma işlemleri gerçekleştirilmiştir. Uygulamada son olarak orijinal X-ray görüntüleri kullanılarak elde edilen sonuçlar ile ön işlem olarak YİD uygulanarak elde edilen sonuçların birleştirilmesini sağlayan VAH yaklaşımlarının başarıları karşılaştırılmıştır. Uygulamada deneyler iki kat çapraz doğrulama ve yirmi üç kat çapraz doğrulama kullanılarak gerçekleştirilmiştir.

Tez çalışmasının altıncı uygulamasında X-ray görüntüleri üzerinden COVID-19 ve COVID-19 değil, COVID-19 zatürresi ve bakteriyel zatürre, COVID-19 zatürresi ve viral zatürre ile COVID-19 zatürresi ve diğer zatürre olmak üzere toplam dört başlıkta iki sınıflı sınıflandırma gerçekleştirilmiştir. Uygulamada orijinal X-ray görüntülerinin tek başına kullanılmasının yanı sıra ön işlem olarak YİD ve LE uygulanarak elde edilen özellik görüntüleri için de sınıflandırma sonuçları hesaplanmıştır. Orijinal görüntüler, YİD ve LE özellik görüntülerinin çeşitli kombinasyonlarda birleştirilmesiyle elde edilen görüntüler için sınıflandırma işlemleri tekrarlanmıştır. Uygulamada sınıflandırıcı olarak transfer öğrenme 2B ESA ve 3B ESA mimarilerinden yararlanılmıştır. Uygulamada transfer öğrenme 2B ESA mimarisi olarak MobileNetV2, ResNet-101 ve GoogleNet mimarileri kullanılmıştır. 3B ESA için ise uygulama kapsamında 24 katmanlı bir mimari tasarlanmış ve kullanılmıştır. Uygulamada eğitim ve test işlemlerinde beş kat çapraz doğrulama prosedürüne göre gerçekleştirilmiştir.

Tez çalışmasının yedinci uygulamasında X-ray görüntüleri üzerinden COVID-19 zatürresi, sağlıklı ve diğer zatürre ile COVID-19 zatürresi, sağlıklı, bakteriyel zatürre ve viral zatürre olmak üzere toplam iki başlıkta sırasıyla üç sınıflı ve dört sınıflı otomatik sınıflandırma gerçekleştirilmiştir. Uygulamada sınıflandırıcı olarak transfer öğrenme 2B ESA kullanılmıştır. Bu kapsamda MobileNetV2, ResNet-101, GoogleNet, Xception, DenseNet-201, EfficientNetB0 ve InceptionV3 olmak üzere toplam yedi adet transfer öğrenme 2B ESA mimarisinden yararlanılmıştır. Uygulamada doğrudan orijinal X-ray görüntüleri kullanılarak sınıflandırma sonuçları elde edilmiş olup ön işlem olarak YİD ve LE uygulanarak elde edilen özellik görüntüleri kullanılarak da sınıflandırma işlemleri gerçekleştirilmiştir. Ayrıca, VAH yaklaşımı kullanılarak daha önce elde edilen sonuçlar birleştirilmiş ve yeni sınıflandırma sonuçları hesaplanmıştır. Uygulamanın eğitim ve test işlemleri dört kat çapraz doğrulama kullanılarak yapılmıştır.

## 1.2. Tez Çalışmasının Önemi ve Amacı

2019 yılının sonunda, ilk olarak Çin'in Hubei eyaletinin Wuhan kentinde ortaya çıkan SARS-CoV-2 virüsü dünya genelinde hızlı bir yayılım göstererek etkili bir salgına sebep olmuştur. Virüsün sebep olduğu COVID-19 hastalığın yaygın semptomları ateş, öksürük, nefes darlığı, kas ağrısı ve halsizlik olarak sıralanmaktadır (Huang ve ark., 2020). COVID-19 hastalığının en yaygın teşhisi, Ters Transkripsiyon-Polimeraz Zincir Reaksiyonu (TT-PZR) testi ile yapılmaktadır. Genellikle bu test birkaç saat içinde sonuç vermektedir (Kriegova ve ark., 2020).

Kovács ve arkadaşları tarafından 2021 yılından gerçekleştirilen klinik bir çalışmada, TT-PZR testinin COVID-19 hastalığına sebep olan SARS-CoV-2 virüsünün tespitindeki duyarlılığının 0,47 ile 0,65 arasında, özgüllüğünün ise 0,83 ile 1,00 arasında olduğu bildirilmiştir (Kovács ve ark., 2021). Söz konusu sonuçlar, TT-PZR testinin gerçekte virüs taşımayan kişilerin ayırımında göreceli daha başarılı olduğunu göstermektedir. Ancak, sonuçlar gerçekte virüs taşıyanların ortalama yarısının söz konusu test ile yanlış teşhis edildiği ve virüs taşımayan olarak sınıflandırıldığına işaret etmektedir.

Fang ve arkadaşları tarafından 2020 yılında gerçekleştirilen klinik çalışmada (Fang ve ark., 2020) TT-PZR testinin duyarlılığının düşük olmasının olası sebepleri nükleik asit saptama teknolojisinin henüz tam olgunlaşmamış olması, farklı test kiti üreticilerin algılama oranındaki değişkenlikler, hastanın düşük bir viral yüke sahip olması ve uygunsuz klinik örnekleme olarak sıralanmaktadır. Söz konusu çalışmada ayrıca, BT görüntüleri üzerinden teşhis ile TT-PZR testi kullanılarak teşhisin duyarlılığı karşılaştırıldığında BT görüntüleri üzerinden teşhisin daha yüksek duyarlılık sonuçları sağladığı gösterilmiştir. Tüm bu faktörler, DSÖ tarafından vakaların bildirilmesi prosedürlerinde de dikkate alınmıştır. DSÖ, sadece TT-PZR testi pozitif olan vakaların değil, TT-PZR sonucunun negatif olmasına rağmen radyolojik veya klinik semptomlarla bu virüsü taşıdığı tespit edilen vakaların da doğrudan bildirilmesini şart koşmaktadır (DSÖ, 2020(c)). Bu kapsamda TT-PZR testi pozitif olarak sonuçlanan vakalar için U07.1 kodu kullanılırken, TT-PZR testi negatif çıkmasına karşın radyolojik veya klinik semptomlarla bu virüsü taşıdığı tespit edilen vakalar için U07.2 kodu kullanılmaktadır (DSÖ, 2020(c)).

COVID-19 salgınının kontrol altına alınmasında en önemli faktörlerden biri virüsü taşıyan hastaların hızlı teşhis edilmesi ve izolasyonudur. TT-PZR testinin sonuç

vermesinin saatler alması virüsü taşıyan kişilerin hızlı şekilde izole edilmesini zorlaştırmaktadır. Ayrıca, testin duyarlılığının düşük olması virüsü taşıyan kişilerin yaklaşık yarı yarıya yanlış teşhis edilmesine bağlı olarak bulaş oranlarını yükseltmektedir. Bu durum COVID-19 salgını ile mücadele konusunda radyolojik görüntülemenin etkili şekilde kullanılmasını bir zorunluluk haline getirmektedir.

COVID-19 salgını ülkelerin sağlık sistemleri üzerinde önemli bir baskı oluşturmaktadır. Özellikle, sağlık personeli üzerindeki ciddi bir iş yükü bulunmaktadır. Radyolojik görüntüleme ihtiyacındaki bu artış görüntülerin değerlendirilmesi ve raporlanmasını gerçekleştiren radyologların iş yükünün de orantısız olarak artmasına neden olmuştur. Sağlık personeli sayısındaki yetersizlikler ve mevcut iş yükündeki artışlar radyolojik görüntülerin değerlendirmesini otomatik olarak gerçekleştiren yapay zekâ tabanlı sistemlere olan ihtiyacı önemli ölçüde artırmış durumdadır.

Long ve Ehrenfeld (2020) ile McCall (2020) tarafından gerçekleştirilen çalışmalarda; salgının etkilerini ve sağlık çalışanlarının iş yükünü azaltmak, hastalık teşhisini hızlandırmak ve teşhis başarısını iyileştirmek için yapay zekâ tabanlı otomatik sistemlerin kullanılmasının kaçınılmaz bir gereklilik olduğuna işaret edilmiştir. Tez çalışmasında söz konusu ihtiyaçlara cevap vermek amacıyla uygulamalar gerçekleştirilmiştir. Bu kapsamda gerçekleştirilen altı adet uygulamada COVID-19 hastalığının teşhisi ile diğer bakteriyel veya viral zatürrelerden ayırt edilmesi üzerinde durulmuştur. Bu uygulamaların üçünde BT görüntüler üzerinden otomatik olarak değerlendirme yapılırken diğer üç tanesinde X-ray görüntüleri kullanılmıştır. Bunun temel sebebi, iki önemli radyolojik görüntüleme yöntemi için de çözümler üretilmesinin amaçlanmasıdır. Tez çalışmasının bir diğer uygulama ise COVID-19 hastalığına bağlı olarak gelişen zatürrenin seviyesinin belirlenmesine yönelik olarak gerçekleştirilmiştir. Bu uygulama sayesinde sağlık çalışanlarının COVID-19 hastalarının zatürre seviyeleri hakkında hızlı şekilde fikir sahibi olması hedeflenmiştir.

Tez çalışmasında gerçekleştirilen tüm uygulamalarda dikkate değer başarılı sonuçlar sağlanmıştır. Ayrıca, bazı uygulamalarda sınıflandırma başarılarının daha da yükseltilmesini sağlayan VAH yaklaşımların test edilmesi literatüre önemli katkılar sunmaktadır. Tez çalışmasında gerçekleştirilen uygulamalar doku analiz (özellik çıkarma) yöntemleri, klasik makine öğrenmesi yöntemleri, derin öğrenme yöntemleri, boyut azaltma ve frekans düzlemine geçiş yöntemleri ile VAH yaklaşımlarını içermektedir. Tez çalışmasında kullanılan yöntemlerin çeşitliliği ve fazlalığına bağlı olarak kapsamlı sonuçlar elde edilmiş ve etkili tartışmalar gerçekleştirilmiştir.

## 2. KAYNAK ARAŞTIRMASI

Tez çalışmasında BT görüntüler ve X-ray görüntüler üzerinden COVID-19 hastalığının teşhisi ile diğer bakteriyel veya viral zatürrelerden ayırt edilmesi üzerine uygulamalar gerçekleştirilmiştir. Ayrıca, BT görüntüler üzerinden COVID-19 hastalığına bağlı olarak gelişen zatürrenin seviyesinin belirlenmesi üzerinde durulmuştur. Bu bölümde söz konusu uygulama başlıklarında daha önce gerçekleştirilen literatür çalışmalarının incelenmesi gerçekleştirilmiştir.

### 2.1. BT Görüntüler Kullanılarak Gerçekleştirilen Uygulamalar

Tez çalışmasının birinci uygulamasında BT görüntüler üzerinden COVID-19 ve COVID-19 değil sınıflandırması; ikinci uygulamasında COVID-19 ve COVID-19 değil sınıflandırması ile COVID-19 zatürresi ve diğer zatürre sınıflandırması; üçüncü uygulamasında COVID-19 zatürresi, sağlıklı ve diğer zatürre sınıflandırması; dördüncü uygulamasında COVID-19 zatürre seviye sınıflandırması gerçekleştirilmiştir. Söz konusu sınıflandırma başlıklarında daha önce gerçekleştirilen literatür çalışmaları dört alt başlık altında incelenmiştir.

#### 2.1.1. COVID-19 ve COVID-19 değil sınıflandırması

2020 yılında Ni ve arkadaşları tarafından (Ni ve ark., 2020) BT görüntüleri üzerinden otomatik COVID-19 ve COVID-19 değil sınıflandırması gerçekleştirilmiştir. Çalışmada 88 adet COVID-19 ve 8 adet COVID-19 değil olmak üzere toplam 96 adet BT görüntü çekim serisi kullanılmıştır. Sınıflandırma için MVP-Net ESA mimarisi kullanılan çalışma sonucunda duyarlılık parametresi 1,00; özgüllük parametresi 0,25; doğruluk parametresi 0,94 ve F-1 skoru parametresi 0,97 olarak elde edilmiştir. Çalışmada bir görünümün sınıflandırılması için gereken süre ise  $20,3 \pm 5,8$  saniye olarak hesaplanmıştır. Aynı yıl Wang ve arkadaşları tarafından gerçekleştirilen çalışmada (Wang ve ark., 2020(a)) COVID-19 ve COVID-19 değil sınıflandırması için zayıf denetimli derin öğrenme çerçevesinden yararlanılmıştır. Çalışmada, 499 adedi eğitim işlemlerinde ve 131 adedi test işlemlerinde olmak üzere toplam 630 adet BT görüntüsü kullanılmıştır. Çalışma sonucunda doğruluk parametresi 0,847 ile 0,901 arasında gerçekleşirken alıcı işlem karakteristiği eğrisi (AİKE) altında kalan alan (AİKE-AKA)



parametresi 0,959 olarak hesaplanmıştır. Ayrıca, pozitif tahmin parametresinin 0,733 ile 0,840 arasında, negatif tahmin parametresinin ise 0,839 ile 1,00 arasında olduğu bildirilmiştir. Çalışmada sınıflandırma için gereken süre 1,93 saniye olarak hesaplanmıştır.

2020 yılında Han ve arkadaşları tarafından gerçekleştirilen sınıflandırma çalışmasında (Han ve ark., 2020) 230 adet COVID-19 ve 230 adet COVID-19 değil olmak üzere toplam 460 adet BT görüntüsü kullanılmıştır. Çalışmada otomatik özellik çıkarma ve sınıflandırma için dikkat temelli 3B çoklu örnek derin öğrenme, DeCoVNet mimarisi ve 3B evrişim yöntemleri kullanılmıştır. Çalışmada deneyler %60 eğitim, %20 doğrulama ve %20 test ayrışımına göre gerçekleştirilmiştir. Deneyler sonucunda duyarlılık, doğruluk ve F-1 skoru parametreleri 0,968 ile 0,979 arasında, AİKE-AKA parametresi ise 0,982 ile 0,990 arasında elde edilmiştir. Ardakani ve arkadaşları tarafından aynı yıl gerçekleştirilen bir diğer otomatik sınıflandırma çalışmasında (Ardakani ve ark., 2020) ön işlem olarak görüntü kırpma yapılarak 60×60 ebatlarında ilgi alanları belirlenmiştir. Çalışmada eğitim başlangıç katsayıları transfer edilmiş (transfer öğrenme) AlexNet, VGG-16, VGG-19, SqueezeNet, GoogleNet, MobileNetV2, ResNet-18, ResNet-50, ResNet-101 ve Xception ESA mimarilerinden yararlanılmıştır. Çalışmanın deneyleri %80 eğitim ve %20 test prosedürüne göre yapılmıştır. 510 adet COVID-19 ve 510 adet COVID-19 değil olmak üzere toplam 1.020 adet BT görüntüsü kullanılarak gerçekleştirilen deneyler sonucunda duyarlılık parametresi 0,7843 ile 1,000; özgüllük parametresi 0,6863 ile 1,000; doğruluk parametresi 0,7892 ile 0,9951 ve AİKE-AKA parametresi ise 0,894 ile 0,994 arasında hesaplanmıştır.

2020 yılında Harmon ve arkadaşları tarafından gerçekleştirilen COVID-19 ve COVID-19 değil sınıflandırması çalışmasında (Harmon ve ark., 2020) DenseNet-121 ESA mimarisinden yararlanılmıştır. Çalışmada 1.029 adet COVID-19 ve 1.695 adet COVID-19 değil olmak üzere toplam 2.724 adet BT görüntüsü kullanılmıştır. Çalışmanın deneyleri BT görüntüleri eğitim (526 adet COVID-19 ve 533 adet COVID-19 değil olmak üzere toplam 1.059), doğrulama (177 adet COVID-19 ve 151 adet COVID-19 değil olmak üzere toplam 328) ve test (326 adet COVID-19 ve 1.011 adet COVID-19 değil olmak üzere toplam 1.337) olmak üzere üçe bölünerek gerçekleştirilmiştir. Deneyler sonucunda duyarlılık parametresi 0,751 ile 0,853; özgüllük parametresi 0,901 ile 0,951; doğruluk parametresi 0,889 ile 0,908; AİKE-AKA parametresi 0,938 ile 0,949 arasında hesaplanmıştır.

2020 yılında Horry ve arkadaşları tarafından gerçekleştirilen otomatik sınıflandırma çalışmasında (Horry ve ark., 2020) transfer öğrenme ile VGG-16, VGG-19, Xception, InceptionResNet, InceptionV3, NASNetLarge, ResNet-50V2 ve DenseNet-121 ESA mimarilerinden yararlanılmıştır. Çalışmanın deneyleri 349 adet COVID-19 ve 397 adet COVID-19 değil olmak üzere toplam 746 adet BT görüntüsü, %80 eğitim ve %20 test prensibine göre ikiye bölünerek gerçekleştirilmiştir. Çalışmada duyarlılık ve F-1 skoru parametreleri için 0,81 ile 0,83 arasında değişen sonuçlar elde edilmiştir. Ayrıca, pozitif tahmin parametresi 0,79 ile 0,84 arasında hesaplanmıştır. Aynı yıl Pathak ve arkadaşları tarafından gerçekleştirilen sınıflandırma çalışmasında (Pathak ve ark., 2020) 413 adet COVID-19 ve 439 adet COVID-19 değil olmak üzere toplam 852 adet BT görüntüsünden yararlanılmıştır. Çalışmada yeni bir ESA mimarisi tasarlanmış ve kullanılmıştır. Söz konusu ESA mimarisinin katsayıları ResNet-50 mimarisinden transfer edilmiştir. Çalışmada deneyler on kat çapraz doğrulama ile %50 eğitim, %10 doğrulama ve %40 test olmak üzere iki farklı prosedüre göre gerçekleştirilmiştir. Deneyler sonucunda duyarlılık parametresi 0,9146; özgüllük parametresi 0,9478 ve doğruluk parametresi 0,9302 olarak hesaplanmıştır.

2020 yılında Ouyang ve arkadaşları tarafından 3B ResNet-34 ESA mimarisi ile tekdüzen örnekleme, boyut dengeli örnekleme ve çift örnekleme yöntemleri kullanılarak gerçekleştirilen sınıflandırma çalışmasında (Ouyang ve ark., 2020) 3.389 adet COVID-19 ve 1.593 adet COVID-19 değil olmak üzere toplam 4.982 adet BT görüntüsünden yararlanılmıştır. Çalışmada deneyler beş kat çapraz doğrulama prosedürüne göre gerçekleştirilmiştir. Ayrıca deneyler, görüntüler eğitim (1.094 adet COVID-19 ve 1.092 adet COVID-19 değil olmak üzere toplam 2.186) ve test (2.295 adet COVID-19 ve 501 adet COVID-19 değil olmak üzere toplam 2.796) olmak üzere ikiye bölünerek tekrarlanmıştır. Deneyler sonucunda duyarlılık parametresi 0,869; özgüllük parametresi 0,901; doğruluk parametresi 0,875; F-1 skoru parametresi 0,82 ve AİKE-AKA parametresi 0,944 olarak elde edilmiştir. Aynı yıl Sakagianni ve arkadaşları tarafından otomatik makine öğrenmesi platformu olan Google AutoML Cloud Vision kullanılarak bir sınıflandırma çalışması (Sakagianni ve ark., 2020) gerçekleştirilmiştir. 349 adet COVID-19 ve 397 adet COVID-19 değil olmak üzere toplam 746 adet BT görüntüsünden yararlanılan çalışma sonucunda duyarlılık ve F-1 skoru parametreleri 0,8831 olarak hesaplanmıştır.

2020 yılında Hu ve arkadaşları tarafından (Hu ve ark., 2020) COVID-19 ve COVID-19 değil sınıflandırmasında zayıf denetimli derin öğrenme kullanılması

önerilmiştir. Çalışmada 150 adet COVID-19 ve 150 adet COVID-19 değil olmak üzere toplam 300 adet BT görüntüsünden yararlanılmış olup deneyler beş kat çapraz doğrulama prensibine göre gerçekleştirilmiştir. Deneyler sonucunda duyarlılık parametresi 0,833; özgüllük parametresi 0,956; doğruluk parametresi 0,906 ve AİKE-AKA parametresi 0,943 olarak hesaplanmıştır. Aynı yıl Ragab ve Attallah tarafından gerçekleştirilen çalışmada (Ragab ve Attallah, 2020) derin ve el yapımı özellik füzyonu kullanılmıştır. Çalışmada 1.252 adet COVID-19 ve 1.230 adet COVID-19 değil olmak üzere toplam 2.482 adet BT görüntüsünden yararlanılmıştır. Beş kat çapraz doğrulama prosedürüne göre gerçekleştirilen deneyler sonucunda duyarlılık, doğruluk ve F-1 skoru parametreleri 0,99 olarak gerçekleşirken AİKE-AKA parametresi 1,00 olarak hesaplanmıştır.

2021 yılında Jaiswal ve arkadaşları tarafından gerçekleştirilen otomatik sınıflandırma çalışmasında (Jaiswal ve ark., 2021) transfer öğrenme ile VGG-16, InceptionResNet, ResNet-152V2 ve DenseNet-201 ESA mimarileri kullanılmıştır. Çalışmada 1.262 adet COVID-19 ve 1.230 adet COVID-19 değil olmak üzere toplam 2.492 adet BT görüntüsünden yararlanılmıştır. Çalışmanın deneyleri %68 eğitim, %17 doğrulama ve %15 test ayrışımına göre gerçekleştirilmiştir. Deneyler sonucunda, duyarlılık parametresi 0,9206 ile 0,9735; özgüllük parametresi 0,8972 ile 0,9621; doğruluk parametresi 0,909 ile 0,9625 ve F-1 skoru parametresi 0,9109 ile 0,9629 arasında gerçekleşirken AİKE-AKA parametresi ise 0,97 olarak hesaplanmıştır.

2021 yılında Sen ve arkadaşları tarafından gerçekleştirilen çalışmada (Sen ve ark., 2021) otomatik COVID-19 ve COVID-19 değil sınıflandırması için ESA ve iki aşamalı özellik seçimi kullanılması önerilmiştir. Çalışmanın deneyleri 2.482 BT görüntüsü (1.252 COVID-19 ve 1.230 COVID-19 değil) ve 812 BT görüntüsü (349 COVID-19 ve 463 COVID-19 değil) içeren iki farkı veri seti kullanılarak gerçekleştirilmiştir. Beş kat çapraz doğrulama prensibine göre gerçekleştirilen deneyler sonucunda duyarlılık parametresi 0,8406 ile 0,9778; doğruluk parametresi 0,90 ile 0,9839; F-1 skoru parametresi 0,8855 ile 0,98; AİKE-AKA parametresi 0,9414 ile 0,9952 arasında gerçekleşmiştir. Aynı yıl Konar ve arkadaşları tarafından gerçekleştirilen otomatik sınıflandırma çalışmasında (Konar ve ark., 2021) yarı denetimli sığ öğrenme ağından yararlanılmıştır. Çalışmada 1.252 adet COVID-19 ve 1.230 adet COVID-19 değil olmak üzere toplam 2.482 adet BT görüntüsü kullanılmıştır. Deneyler görüntülerin eğitim-doğrulama (868 adet COVID-19 ve 896 adet COVID-19 değil olmak üzere toplam 1.764) ve test (384 adet COVID-19 ve 334

adet COVID-19 değil olmak üzere toplam 718) olmak üzere ikiye bölünmesi ile gerçekleştirilmiştir. Çalışma sonucunda duyarlılık parametresi 0,935; doğruluk parametresi 0,944 ve F-1 skoru parametresi 0,948 olarak gerçekleştirilen AİKE-AKA parametresi 0,983 olarak hesaplanmıştır.

2021 yılında Kaur ve arkadaşları tarafından gerçekleştirilen çalışmada (Kaur ve ark., 2021) derin özellikler ve parametre içermeyen küresel optimizasyon için meta-sezgisel bir algoritma ile optimize edilmiş bulanık k-EYK sınıflandırıcıdan yararlanılmıştır. Çalışmada 1.253 adet COVID-19 ve 1.229 adet COVID-19 değil olmak üzere toplam 2.482 adet BT görüntüsü kullanılmıştır. Eğitim ve doğrulama olmak üzere ikiye ayırma ve beş kat çapraz doğrulama prosedürleri kullanılarak gerçekleştirilen deneyler sonucunda duyarlılık parametresi 0,9960 olarak hesaplanırken doğruluk parametresi 0,9918 ile 0,9938; F-1 skoru parametresi 0,992 ile 0,994 ve AİKE-AKA parametresi 0,9916 ile 0,9958 arasında gerçekleşmiştir. Aynı yıl Goel ve arkadaşları tarafından gerçekleştirilen çalışmada (Goel ve ark., 2021) Kaur ve arkadaşları (2021) tarafından kullanılan açık erişimli veri setine ilave olarak çekişmeli üretici ağlar ile üretilmiş 518 BT görüntüsünden yararlanılmıştır. Görüntülerin 2.100 adedi eğitim işlemlerinde 900 adedi ise testlerde kullanılmıştır. Sınıflandırıcı olarak InceptionV3 ESA mimarisi kullanılan çalışma sonucunda duyarlılık parametresi 0,9978; özgüllük parametresi 0,9778; doğruluk parametresi 0,9922 ve F-1 skoru parametresi 0,9879 olarak hesaplanmıştır.

2021 yılında Zhu ve arkadaşları tarafından gerçekleştirilen çalışmada (Zhu ve ark., 2021(a)) otomatik COVID-19 ve COVID-19 değil sınıflandırması için ResNet-50 ESA mimarisinden yararlanılmış olup ESA mimarisinin başlangıç ağırlıkları transfer öğrenme yoluyla transfer edilmiştir. Çalışmada 2.542 adet COVID-19 ve 1.235 adet COVID-19 değil olmak üzere toplam 3.777 adet BT görüntüsü kullanılmıştır. Çalışmanın deneyleri görüntüler eğitim (1.267 adet COVID-19 ve 600 adet COVID-19 değil olmak üzere toplam 1.867), doğrulama (1.000 adet COVID-19 ve 400 adet COVID-19 değil olmak üzere toplam 1.400) ve test (275 adet COVID-19 ve 235 adet COVID-19 değil olmak üzere toplam 510) olmak üzere üçe bölünerek gerçekleştirilmiştir. Deneyler sonucunda duyarlılık, doğruluk, F-1 skoru ve AİKE-AKA parametreleri 0,93; özgüllük parametresi 0,92 olarak gerçekleşmiştir. Aynı yıl Saad ve arkadaşları tarafından gerçekleştirilen çalışmada (Saad ve ark., 2021) derin özellik birleştirme tekniğinden yararlanılmış olup özelliklerin çıkarılması için ResNet ve GoogleNet ESA mimarileri kullanılmıştır. Çalışmada 2.628 adet COVID-19 ve 1.620

adet COVID-19 değil olmak üzere toplam 4.248 adet BT görüntüsünden yararlanılmıştır. Deneyler %70 eğitim ve %30 test prosedürüne göre gerçekleştirilmiş olup duyarlılık parametresi 0,985; doğruluk parametresi 0,989 ve F-1 skoru parametresi 0,9892 olarak hesaplanmıştır.

2021 yılında Liang ve arkadaşları tarafından gerçekleştirilen çalışmada (Liang ve ark., 2021) 3B ESA, transfer öğrenme ve grafik evrişim ağı kullanılması önerilmiştir. Çalışmada 399 adet COVID-19 ve 400 adet COVID-19 değil olmak üzere toplam 799 adet BT görüntüsü kullanılmış olup deneyler beş kat çapraz doğrulama prosedürüne göre gerçekleştirilmiştir. Çalışma sonucunda duyarlılık parametresi 0,999; özgüllük parametresi 0,97 ve doğruluk parametresi 0,985 olarak hesaplanırken AİKE-AKA parametresi 0,999 olarak gerçekleşmiştir. Aynı yıl Alshazly ve arkadaşları tarafından gerçekleştirilen sınıflandırma çalışmasında (Alshazly ve ark., 2021) 2.482 (1.252 COVID-19 ve 1.230 COVID-19 değil) adet ve 746 adet (349 COVID-19 ve 397 COVID-19 değil) BT görüntüsü içeren iki farklı veri seti kullanılmıştır. Çalışmada sınıflandırıcı olarak SqueezeNet, ShuffleNet, ResNet-18, ResNet-50, ResNet-101, ResNeXt-50, ResNeXt-101, InceptionV3, Xception, DenseNet-121, DenseNet-169 ve DenseNet-201 ESA mimarilerinden yararlanılmıştır. Beş kat çapraz doğrulama kullanılarak yapılan deneyler sonucunda duyarlılık parametresi 0,937 ile 0,998; özgüllük parametresi 0,922 ile 0,996; doğruluk parametresi 0,929 ile 0,994 ve F-1 skoru parametresi 0,925 ile 0,994 arasında hesaplanmıştır.

2021 yılında Chaudhary ve Pachori tarafından gerçekleştirilen otomatik COVID-19 ve COVID-19 değil sınıflandırma çalışmasında (Chaudhary ve Pachori, 2021) Fourier-Bessel serisi genişletme tabanlı ayrıştırma ve ESA kullanılmıştır. Çalışmada 1.253 adet COVID-19 ve 1.229 adet COVID-19 değil olmak üzere toplam 2.482 adet BT görüntüsünden yararlanılmıştır. Deneylerde %85 eğitim, %5 doğrulama ve %10 test ayrışımı ve beş kat çapraz doğrulama kullanılmıştır. Deneyler sonucunda duyarlılık parametresi 0,97 ile 0,976; özgüllük parametresi 0,965 ile 0,9836 ve F-1 skoru parametresi 0,97 ile 0,98 arasında gerçekleşirken doğruluk parametresi 0,976 olarak hesaplanmıştır. Aynı yıl Lacerda ve arkadaşları tarafından yapılan çalışmada (Lacerda ve ark., 2021) VGG, Inception, ResNet ve DenseNet ESA mimarileri ile hiperparametre optimizasyonu kullanılması önerilmiştir. Çalışmada toplam 2.175 BT görüntüsünden (856 COVID-19 ve 1.319 COVID-19 değil) yararlanılmış olup deneyler %79 eğitim, %7 doğrulama ve %14 test ayrışımına göre gerçekleştirilmiştir. Deneyler sonucunda duyarlılık parametresi 0,97 ve doğruluk parametresi 0,88 olarak hesaplanmıştır.

2021 yılında Singh ve arkadaşları tarafından gerçekleştirilen çalışmada (Singh ve ark., 2021) transfer öğrenme temelli grup DVM modeli kullanılmıştır. Çalışmada toplam 702 BT görüntüsünden (344 COVID-19 ve 358 COVID-19 değil) yararlanılmıştır. Deneyler, görüntülerin eğitim (204 COVID-19 ve 228 COVID-19 değil olmak üzere toplam 432), doğrulama (29 COVID-19 ve 33 COVID-19 değil olmak üzere toplam 62) ve test (111 COVID-19 ve 97 COVID-19 değil olmak üzere toplam 208) olmak üzere üç gruba ayrılmasıyla gerçekleştirilmiştir. Çalışma sonucunda doğruluk parametresi 0,957; F-1 skoru parametresi 0,953 ve AİKE-AKA parametresi 0,958 olarak hesaplanmıştır. Bir görüntünün sınıflandırılması için gereken süre ise 385 mili saniye olarak gerçekleşmiştir.

### **2.1.2. COVID-19 zatürresi ve diğer zatürre sınıflandırması**

2020 yılında Wu ve arkadaşları tarafından gerçekleştirilen otomatik COVID-19 zatürresi ve diğer zatürre sınıflandırma çalışmasında (Wu ve ark., 2020(b)) sınıflandırıcı olarak ResNet-50 ESA mimarisinden yararlanılmıştır. Çalışmada 368 adet COVID-19 zatürresi ve 127 adet diğer zatürre olmak üzere toplam 495 adet BT görüntüsü kullanılmıştır. Çalışmanın deneyleri veri setinin 395 adet eğitim, 50 adet doğrulama ve 50 adet test olmak üzere üç parçaya ayrılması ile gerçekleştirilmiştir. Deneyler sonucunda duyarlılık parametresi 0,622 ile 0,811 arasında, doğruluk parametresi 0,620 ile 0,760 arasında, AİKE-AKA parametresi 0,634 ile 0,819 arasında ve özgüllük parametresi 0,615 olarak gerçekleşmiştir. Aynı yıl Yan ve arkadaşları tarafından gerçekleştirilen çalışmada (Yan ve ark., 2020) çok ölçekli ESA mimarisi kullanılması önerilmiştir. Çalışmada 416 adet COVID-19 zatürresi ve 412 adet diğer zatürre olmak üzere toplam 828 adet BT görüntüsünden yararlanılmış olup deneyler %80 eğitim, %10 doğrulama ve %10 test ayrışımına göre gerçekleştirilmiştir. Çalışma sonucunda duyarlılık parametresi 0,891; özgüllük parametresi 0,857 ve doğruluk parametresi 0,875 olarak gerçekleşirken AİKE-AKA parametresi 0,934 olarak hesaplanmıştır.

2021 yılında Zhang ve arkadaşları tarafından gerçekleştirilen COVID-19 zatürresi ve diğer zatürre sınıflandırma çalışmasında (Zhang ve ark., 2021) toplam 466 adet BT görüntüsünden (203 COVID-19 zatürresi ve 263 diğer zatürre) yararlanılmıştır. Derin öğrenme ve çok katmanlı algılayıcı kullanılarak gerçekleştirilen çalışmada 268 adet BT görüntüsünü içeren eğitim ve doğrulama grubu kullanılarak eğitim işlemleri gerçekleştirilmiştir. 103 adet BT görüntüsü ve 95 adet BT görüntüsü içeren iki adet test

grubu ile gerçekleştirilen test işlemleri sonucunda duyarlılık parametresi 0,879 olarak hesaplanmıştır. Özgüllük parametresi 0,887 ile 0,9 arasında ve AİKE-AKA parametresi 0,922 ile 0,959 arasında gerçekleşmiştir. Çalışmada sınıflandırma için gereken süre ise 38 saniye olarak hesaplanmıştır. Aynı yıl Song ve arkadaşları tarafından gerçekleştirilen sınıflandırma çalışmasında (Song ve ark., 2021) sınıflandırıcı olarak ayrıntılı ilişki çıkarımı sinir ağı kullanılmıştır. Çalışmada 777 adet COVID-19 zatürresi ve 505 adet diğer zatürre olmak üzere toplam 1.282 adet BT görüntüsünden yararlanılmış olup deneyler %60 eğitim, %10 doğrulama ve %30 test ayrışımına göre gerçekleştirilmiştir. Deneyler sonucunda duyarlılık parametresi 0,96; özgüllük parametresi 0,77; doğruluk parametresi 0,86 ve F-1 skoru parametresi 0,87 olarak gerçekleşirken AİKE-AKA parametresi 0,95 olarak hesaplanmıştır.

2021 yılında Kang ve arkadaşları tarafından gerçekleştirilen COVID-19 zatürresi ve diğer zatürre sınıflandırma çalışmasında (Kang ve ark., 2021) derin özellikler, k-ortalama kümeleme ve DVM kullanılan bir sınıflandırma yapısı önerilmiştir. Çalışmada 90 adedi eğitimlerde (33 COVID-19 zatürresi ve 57 diğer zatürre) ve 80 adedi testlerde (40 COVID-19 zatürresi ve 40 diğer zatürre) olmak üzere toplam 170 adet BT görüntüsü kullanılmıştır. Çalışma sonucunda duyarlılık parametresi 0,85 ile 0,925 ve özgüllük parametresi 0,75 ile 0,975 arasında gerçekleşirken doğruluk parametresi ise 0,8125 ile 0,912 arasında hesaplanmıştır. Aynı yıl Giordano ve arkadaşları tarafından 34 COVID-19 zatürresi ve 36 diğer zatürre olmak üzere toplam 70 BT görüntüsü kullanılarak derin öğrenme temelli bir sınıflandırma çalışması (Giordano ve ark., 2021) yapılmıştır. Çalışma sonucunda duyarlılık parametresi 0,63 ile 0,87 arasında ve özgüllük parametresi 0,51 ile 0,74 arasında gerçekleşmiştir. Ayrıca, doğruluk parametresi 0,7 ve AİKE-AKA parametresi 0,84 olarak hesaplanmıştır. Aynı yıl Saba ve arkadaşları tarafından gerçekleştirilen geleneksel makine öğrenmesi ve transfer öğrenmenin kullanıldığı sınıflandırma çalışmasında (Saba ve ark., 2021) toplam 3.778 BT görüntüsünden (2.788 COVID-19 zatürresi ve 990 diğer zatürre) yararlanılmıştır. On kat çapraz doğrulama prosedürüne göre gerçekleştirilen deneyler sonucunda 0,5097 ile 0,9899 arasında değişen duyarlılık, 0,9099 ile 0,9964 arasında değişen özgüllük ve 0,622 ile 0,9899 arasında değişen F-1 skoru başarıları sağlanmıştır. AİKE-AKA parametresi ise 0,993 olarak hesaplanmıştır.

### 2.1.3. COVID-19 zatürresi, sağlıklı ve diğer zatürre sınıflandırması

2020 yılında Xu ve arkadaşları tarafından gerçekleştirilen otomatik COVID-19 zatürresi, sağlıklı ve diğer zatürre sınıflandırma çalışmasında (Xu ve ark., 2020) sınıflandırıcı olarak ResNet-50 ESA mimarisinden ve Bayes fonksiyonundan yararlanılmıştır. Çalışmada 219 COVID-19 zatürresi, 224 diğer zatürre ve 175 sağlıklı olmak üzere toplam 618 BT görüntüsü kullanılmıştır. Deneyle, görüntülerin eğitim (toplam 528 BT görüntüsü) ve test (toplam 90 BT görüntüsü) olmak üzere ikiye bölünmesiyle gerçekleştirilmiştir. Çalışma sonucunda COVID-19 zatürresi sınıfı için geri çağırma parametresi 0,867; kesinlik parametresi 0,813 ve F-1 skoru parametresi 0,839 olarak hesaplanmıştır. Diğer zatürre sınıfı için geri çağırma parametresi 0,833; kesinlik parametresi 0,862 ve F-1 skoru parametresi 0,847 olarak gerçekleşmiştir. Sağlıklı sınıfı için geri çağırma, kesinlik ve F-1 skoru parametreleri ise sırasıyla 0,900; 0,931 ve 0,915 olarak hesaplanmıştır. Çalışma sonucunda genel doğruluk 0,867 olarak gerçekleşmiştir.

2020 yılında Hasan ve arkadaşları tarafından gerçekleştirilen çalışmada (Hasan ve ark., 2020) BT görüntülerinden üç sınıflı otomatik sınıflandırma için Q-deforme entropi, derin özellikler, uzun kısa süreli bellek sinir ağı, doğrusal DVM, k-EYK ve lojistik regresyon yöntemlerinin başarıları karşılaştırılmıştır. 118 COVID-19 zatürresi, 96 diğer zatürre ve 107 sağlıklı olmak üzere toplam 321 BT görüntüsü kullanılan çalışmanın deneyleri %70 eğitim ve %30 test ayrışımına göre gerçekleştirilmiştir. Çalışma sonucunda COVID-19 sınıfı için 0,932 ile 1,000 arasında değişen, diğer zatürre sınıfı için 0,958 ile 0,989 arasında değişen ve sağlıklı sınıfı için 0,972 ile 1,000 arasında değişen doğruluk başarıları sağlanmıştır. Ayrıca, genel doğruluk parametresi 0,953 ile 0,9968 arasında gerçekleşmiştir. Aynı yıl Wang ve arkadaşları tarafından gerçekleştirilen otomatik COVID-19 zatürresi, sağlıklı ve diğer zatürre sınıflandırma çalışmasında (Wang ve ark., 2020(b)) 3B UNet ESA mimarisi kullanılmıştır. Çalışmada 1.315 COVID-19 zatürresi, 2.406 diğer zatürre ve 936 sağlıklı olmak üzere toplam 4.657 BT görüntüsünden yararlanılmıştır. Deneyle veri setinin eğitim (toplam 3.997 BT görüntüsü), doğrulama (toplam 60 BT görüntüsü) ve test (toplam 600 BT görüntüsü) olmak üzere üç parçaya ayrılmasıyla gerçekleştirilmiştir. Çalışma sonucunda genel doğruluk 0,778 ile 0,897 arasında hesaplanmıştır.

2020 yılında Li ve arkadaşları tarafından gerçekleştirilen otomatik sınıflandırma çalışmasında (Li ve ark., 2020(a)) 3B ESA mimarisinin sınıflandırma performansı test



edilmiştir. Çalışmada 1.292 COVID-19 zatürresi, 1.735 diğer zatürre ve 1.325 sağlıklı olmak üzere toplam 4.352 BT görüntüsü kullanılmış olup deneyler görüntülerin eğitim, doğrulama ve test olmak üzere üçe bölünmesiyle gerçekleştirilmiştir. Çalışma sonucunda COVID-19 sınıfı için duyarlılık parametresi 0,898; özgüllük parametresi 0,958 ve AİKE-AKA parametresi 0,96 olarak gerçekleşmiştir. Diğer zatürre sınıfı için duyarlılık, özgüllük, AİKE-AKA parametreleri sırasıyla 0,869; 0,923 ve 0,95 olarak hesaplanırken sağlıklı sınıfı için sırasıyla 0,939; 0,964 ve 0,98 olarak gerçekleşmiştir. Aynı yıl Han ve arkadaşları tarafından üç sınıflı otomatik sınıflandırma için dikkate dayalı derin 3B çoklu örnek öğrenme kullanılması önerilmiştir (Han ve ark., 2020). Çalışmada 230 COVID-19 zatürresi, 100 diğer zatürre ve 130 sağlıklı olmak üzere toplam 460 BT görüntüsü kullanılmış olup deneyler %60 eğitim, %20 doğrulama ve %20 test ayrışımına göre gerçekleştirilmiştir. Deneyler sonucunda genel doğruluk parametresi 0,897 ile 0,943 arasında hesaplanırken genel AİKE-AKA parametresi 0,971 ile 0,988 arasında gerçekleşmiştir. Genel F-1 skoru parametresi 0,861 ile 0,923 arasında, genel kesinlik parametresi 0,882 ile 0,959 arasında ve genel geri çağırma parametresi 0,841 ile 0,905 arasında hesaplanmıştır.

2020 yılında Ko ve arkadaşları tarafından gerçekleştirilen otomatik COVID-19 zatürresi, sağlıklı ve diğer zatürre sınıflandırma çalışmasında (Ko ve ark., 2020) VGG-16, ResNet-50, InceptionV3 ve Xception ESA mimarilerinin sınıflandırma performansları incelenmiştir. Çalışmanın deneyleri %80 eğitim ve %20 test ayrışımına göre gerçekleştirilmiştir. 1.194 COVID-19 zatürresi, 1.357 diğer zatürre ve 1.442 sağlıklı olmak üzere toplam 3.993 BT görüntüsü kullanılarak gerçekleştirilen deneyler sonucunda 0,626 ile 0,995 arasında değişen genel doğruluk başarısı sağlanmıştır. Aynı yıl Sharma tarafından ResNet ve Grad-Cam kullanılarak gerçekleştirilen üç sınıflı otomatik sınıflandırma çalışmasında (Sharma, 2020) 800 COVID-19 zatürresi, 600 diğer zatürre ve 800 sağlıklı olmak üzere toplam 2.200 BT görüntüsünden yararlanılmıştır. Çalışma sonucunda genel doğruluk parametresi 0,91 olarak hesaplanırken genel duyarlılık ve özgüllük parametreleri sırasıyla 0,921 ve 0,9029 olarak gerçekleşmiştir.

2020 yılında Hu ve arkadaşları otomatik COVID-19 zatürresi, sağlıklı ve diğer zatürre sınıflandırması için zayıf denetimli derin öğrenme kullanılmasını önermiştir (Hu ve ark., 2020). Eşit sayıda COVID-19 zatürresi, diğer zatürre ve sağlıklı BT görüntüsü içeren toplam 450 adet BT görüntüsü kullanılarak gerçekleştirilen çalışmanın deneylerinde beş kat çapraz doğrulama prosedüründen yararlanılmıştır. Çalışma

sonucunda doğruluk parametresi; COVID-19 sınıfı için 0,81 ile 0,892 arasında, diğer zatürre sınıfı için 0,748 ile 0,847 arasında ve sağlıklı sınıfı için 0,786 ile 0,883 arasında gerçekleşmiştir. Aynı yıl Amyar ve arkadaşları tarafından gerçekleştirilen BT görüntülerinden üç sınıflı otomatik sınıflandırma çalışmasında (Amyar ve ark., 2020) ise kod çözücü, kodlayıcı ve çok katmanlı algılayıcı yöntemlerinin içinde bulunduğu derin öğrenme yaklaşımlarından yararlanılmıştır. Çalışmada 449 COVID-19 zatürresi, 495 diğer zatürre ve 425 sağlıklı olmak üzere toplam 1.369 BT görüntüsü kullanılmıştır. Görüntülerin eğitim (toplam 1.069 BT görüntüsü), doğrulama (toplam 150 BT görüntüsü) ve test (toplam 150 BT görüntüsü) olmak üzere üçe ayrılmasıyla gerçekleştirilen deneyler sonucunda genel doğruluk parametresi 0,9467; genel duyarlılık parametresi 0,96 ve genel özgüllük parametresi 0,92 olarak gerçekleşmiştir. 2020 yılında Jin ve arkadaşları tarafından gerçekleştirilen otomatik sınıflandırma çalışmasında (Jin ve ark., 2020) ResNet-152 ESA mimarisinden yararlanılmıştır. Çalışmada 1.257 COVID-19 zatürresi, 1.528 diğer zatürre ve 1.079 sağlıklı olmak üzere toplam 3.784 BT görüntüsü kullanılmış olup deneyler görüntülerin eğitim ve test olmak üzere iki eşit parçaya bölünmesiyle gerçekleştirilmiştir. Çalışma sonucunda genel doğruluk parametresi 0,8391 ile 0,8483 arasında hesaplanırken genel AİKE-AKA parametresi 0,927 ile 0,933 arasında gerçekleşmiştir.

2021 yılında Yousefzadeh ve arkadaşları tarafından gerçekleştirilen otomatik COVID-19 zatürresi, sağlıklı ve diğer zatürre sınıflandırma çalışmasında (Yousefzadeh ve ark., 2021) EfficientNetB3 ESA mimarisi kullanılarak özellik çıkarma işlemi gerçekleştirilmiştir. Çalışmada eğitim, doğrulama ve test olmak üzere üç gruba ayrılmış toplam 3.953 BT görüntüsü kullanılmıştır. Deneyler sonucunda genel duyarlılık parametresi 0,956 ile 0,988 arasında, genel özgüllük parametresi 0,954 ile 0,982 arasında, genel F-1 skoru parametresi 0,954 ile 0,986 arasında ve genel AİKE-AKA parametresi 0,993 ile 0,999 arasında gerçekleşmiştir. Aynı yıl Mishra ve arkadaşları tarafından üç sınıflı otomatik sınıflandırma için VGG-16 ve ResNet-50 ESA mimarilerinden yararlanılması önerilmiştir (Mishra ve ark., 2021). Çalışmada 400 COVID-19 zatürresi, 250 diğer zatürre ve 400 sağlıklı olmak üzere toplam 1.050 BT görüntüsü kullanılmıştır. Görüntülerin; eğitim (toplam 672 BT görüntüsü), doğrulama (toplam 168 BT görüntüsü) ve test (toplam 210 BT görüntüsü) olmak üzere üçe bölünmesiyle gerçekleştirilen deneyler sonucunda genel doğruluk parametresi 0,8674 ile 0,8852 arasında hesaplanmıştır.

2021 yılında Shi ve arkadaşları tarafından otomatik COVID-19 zatürresi, sağlıklı ve diğer zatürre sınıflandırması için deforme edilebilir dikkat modüllü öğretmen ağı ve dikkat aktarımlı öğrenci ağı kullanılması önerilmiştir (Shi ve ark., 2021). Çalışmada 349 COVID-19 zatürresi, 384 diğer zatürre ve 304 sağlıklı olmak üzere toplam 1.037 BT görüntüsünden oluşan bir veri setinden yararlanılmıştır. Deneyler %70 eğitim, %10 doğrulama ve %20 test ayrışımına göre gerçekleştirilmiştir. Deneyler sonucunda duyarlılık, kesinlik ve F-1 skoru parametreleri COVID-19 sınıfı için sırasıyla 0,8649; 0,9014 ve 0,8828; diğer zatürre sınıfı için sırasıyla 0,7758; 0,8491 ve 0,8108; sağlıklı sınıfı için sırasıyla 0,9737; 0,8916 ve 0,9308 olarak hesaplanmıştır. Genel doğruluk parametresi ise 0,8798 olarak gerçekleşmiştir. Aynı yıl Peng ve arkadaşları tarafından ESA kullanılarak gerçekleştirilen sınıflandırma çalışmasında (Peng ve ark., 2021) toplam 1.225 BT görüntüsünden yararlanılmıştır. Çalışmada 983 BT görüntüsü eğitim işlemlerinde kullanılırken kalan 242 BT görüntüsünden test işlemlerinde yararlanılmıştır. Deneyler sonucunda genel duyarlılık parametresi 0,723; genel özgüllük parametresi 0,852; genel kesinlik parametresi 0,699; genel F-1 skoru parametresi 0,696 ve genel AİKE-AKA parametresi 0,879 olarak elde edilmiştir.

2021 yılında Song ve arkadaşları tarafından otomatik COVID-19 zatürresi, sağlıklı ve diğer zatürre sınıflandırması için ayrıntılar ilişki çıkarma sinir ağı kullanılması önerilmiştir (Song ve ark., 2021). Çalışmada 777 COVID-19 zatürresi, 505 diğer zatürre ve 708 sağlıklı olmak üzere toplam 1.990 BT görüntüsünden oluşan bir veri setinden yararlanılmıştır. Çalışmanın deneyleri %60 eğitim, %10 doğrulama ve %30 test ayrışımına göre yapılmıştır. Çalışma sonucunda genel doğruluk, genel duyarlılık, genel özgüllük, genel F-1 skoru ve genel kesinlik parametreleri 0,93 olarak hesaplanmıştır. Aynı yıl Xiao ve arkadaşları tarafından gerçekleştirilen BT görüntülerinden üç sınıflı sınıflandırma çalışmasında (Xiao ve ark., 2021) paralel dikkat modülü ve DenseNet ESA mimarisinden yararlanılmıştır. Çalışmada toplam 1.235 BT görüntüsünden oluşan bir veri seti kullanılmış olup deneyler görüntülerin 954 BT görüntüsü eğitim ve 281 BT görüntüsü test olmak üzere ikiye bölünmesiyle gerçekleştirilmiştir. Deneyler sonucunda genel doğruluk parametresi 0,9429; genel duyarlılık parametresi 0,9894; genel özgüllük parametresi 0,9516 ve genel kesinlik parametresi 0,9118 olarak gerçekleşmiştir.

#### 2.1.4. COVID-19 zatürre seviye sınıflandırması

2020 yılında Li ve arkadaşları tarafından şiddetli ve kritik seviyede COVID-19 zatürresine sahip hastalara ait BT görüntüleri üzerinden 3B derin öğrenme yöntemleri kullanılarak otomatik zatürre seviye sınıflandırması gerçekleştirilmiştir (Li ve ark., 2020(b)). Çalışmada 82 adet şiddetli seviyede zatürreli ve 135 kritik seviyede zatürreli olmak üzere toplam 217 hastanın BT görüntüleri kullanılmıştır. Çalışmanın deneyleri görüntülerin eğitim (toplam 174 BT görüntüsü) ve test (toplam 43 BT görüntüsü) olmak üzere ikiye ayrılmasıyla gerçekleştirilmiştir. Çalışma sonucunda eğitim seti için AİKE-AKA parametresi 0,812 ile 0,909 arasında gerçekleşirken, test seti için AİKE-AKA parametresi 0,787 ile 0,861 arasında hesaplanmıştır. Aynı yıl Carvalho ve arkadaşları tarafından 130 COVID-19 hastasından elde edilmiş toplam 141 BT çekim seti kullanılarak bir zatürre seviye sınıflandırma çalışması (Carvalho ve ark., 2020) gerçekleştirilmiştir. Çalışmada BT çekim setleri tasnif edilerek 1.475 adet ilgi alanı belirlenmiştir. Daha sonra iki radyolog tarafından söz konusu ilgi alanları üzerinden iyi havalandırılmış bölgeler (472 adet), buzlu cam opaklığı bölgeleri (413 adet), çılgın kaplama-lineer opaklık bölgeleri (340 adet) ve konsolidasyon bölgeleri (250 adet) belirlenmiştir. Akciğer tutulumu oranı; buzlu cam opasitesi, çılgın kaplama-lineer opasite büyüklüğü ve konsolidasyonun bölgelerinin toplamının akciğer hacmine bölünmesiyle elde edilmiştir. Bu sayede hafif, orta ve şiddetli akciğer tutulumu olmak üzere üç sınıf oluşturulmuştur. Yapay sinir ağları kullanılarak gerçekleştirilen sınıflandırma işlemlerinin sonucunda duyarlılık parametresi 0,80; özgüllük parametresi 0,86; AİKE-AKA parametresi 0,90; doğruluk parametresi 0,82 ve F-1 skoru parametresi 0,85 olarak hesaplanmıştır.

2020 yılında Xiao ve arkadaşların tarafından yürütülen otomatik COVID-19 zatürre seviye sınıflandırma çalışmasında (Xiao ve ark., 2020) iki farklı hastaneden alınan toplam 408 hastaya ait BT görüntüleri kullanılmıştır. Görüntüler, eğitim için 303 BT görüntüsü ve test için 105 BT görüntüsü olmak üzere iki gruba ayrılmıştır. Şiddetli değil ve şiddetli zatürre olmak üzere iki sınıflı gerçekleştirilen otomatik sınıflandırma işlemlerinde ResNet-34, AlexNet, VGGNet ve DenseNet ESA mimarileri kullanılmıştır. Deneyler sonucunda en başarılı ESA mimarisinin ResNet-34 olduğu görülmüş olup doğruluk parametresi 0,819 ve AİKE-AKA parametresi 0,892 olarak hesaplanmıştır.

2020 yılında Li ve arkadaşları tarafından gerçekleştirilen otomatik COVID-19 zatürre seviye sınıflandırma çalışmasında (Li ve ark., 2020(c)) şiddetli zatürreye sahip

32 COVID-19 hastasının 95 BT görüntüsü ve şiddetli olmayan zatürreye sahip 164 COVID-19 hastasının 436 BT görüntüsü olmak üzere toplam 531 BT görüntüsü kullanılmıştır. Çalışmada bölütleme süreçleri için UNet ve ResNet-34 tabanlı bir derin öğrenme yaklaşımından yararlanılmıştır. Deneyler sonucunda duyarlılık, özgüllük ve AİKE-AKA parametreleri sırasıyla 0,9241; 0,9049 ve 0,97 olarak gerçekleşmiştir. Aynı yıl Yu ve arkadaşları tarafından gerçekleştirilen otomatik COVID-19 zatürre seviye sınıflandırma çalışmasında (Yu ve ark., 2020) şiddetli ve şiddetli değil olmak üzere iki sınıf etiketi kullanılmıştır. Çalışmada toplam 202 COVID-19 hastasından alınan 246 şiddetli ve 483 şiddetli değil BT görüntü diliminden yararlanılmıştır. Çalışmada görüntü özelliklerini çıkarmak için InceptionV3, ResNet-50, ResNet-101 ve DenseNet-201 olmak üzere dört farklı ESA mimarisi ve sınıflandırma için doğrusal diskriminant, doğrusal DVM, kübik DVM, k-EYK ve Adaboost olmak üzere beş farklı sınıflandırıcı yöntemi kullanılmıştır. Deneyler bekletme doğrulaması, on kat çapraz doğrulama ve birini dışarıda bırakma doğrulaması olmak üzere üç farklı prosedüre göre ayrı ayrı gerçekleştirilmiştir. Deneylerde en yüksek doğruluk parametresi DenseNet-201 ve kübik DVM yöntemleri kullanılarak on kat çapraz doğrulama ile elde edilmiş olup 0,9520 olarak hesaplanmıştır. Aynı yıl Meng ve arkadaşları tarafından şiddetli ve kritik olmak üzere iki sınıflı COVID-19 zatürre seviye sınıflandırması (Meng ve ark., 2020) gerçekleştirilmiştir. Çalışmada derin öğrenme yöntemi kullanılmış ve geliştirilen ESA mimarisi De-COVID19-Net olarak isimlendirilmiştir. Deneylerde 256 şiddetli ve 110 kritik seviyeli olmak üzere toplam 366 BT görüntüsünden yararlanılmıştır. Deneyler sonucunda doğruluk parametresi 0,875 ve AİKE-AKA parametresi 0,943 olarak hesaplanmıştır.

2021 yılında Huang ve arkadaşları tarafından 207 normal, 194 hafif seviye zatürre ve 15 şiddetli seviye zatürre COVID-19 hastasının BT görüntülerini kullanılarak bir hastalık seviye sınıflandırma çalışması (Huang ve ark., 2021) gerçekleştirmiştir. Çalışmada sınıflandırıcı olarak derin öğrenme kullanılmış ve ortaya atılan ESA mimarisine hızlı değerlendirme ağı ismi verilmiştir. Deneylerde, eğitim için 300 BT görüntüsünden ve test için 116 BT görüntüsünden yararlanılmıştır. Deneyler sonucunda sınıflandırma doğruluğu parametresi 0,9483 olarak hesaplanmıştır.

2021 yılında Ho ve arkadaşları tarafından düşük riskli ve yüksek riskli olmak üzere iki sınıflı otomatik COVID-19 zatürre seviye sınıflandırması gerçekleştirilmiştir (Ho ve ark., 2021). Çalışmanın deneylerinde 297 BT görüntüsü kullanılmış olup eğitim ve test işlemleri beş kat çapraz doğrulama prosedürüne göre yapılmıştır. Sınıflandırıcı

olarak 3B ESA mimarisi kullanılan çalışma sonucunda en yüksek doğruluk parametresi 0,933 olarak gerçekleşirken en yüksek AİKE-AKA parametresi 0,900 olarak hesaplanmıştır. Aynı yıl Zhu ve arkadaşları tarafından şiddetli ve şiddetli değil olmak üzere iki sınıflı otomatik sınıflandırma için seyrek lojistik regresyon, dengeli ve seyrek lojistik regresyon, ortak lojistik regresyon ve lineer regresyon, optimizasyon ve yakınsama analizi kullanılması önerilmiştir (Zhu ve ark., 2021(b)). Çalışmada 322 şiddetli ve 86 şiddetli değil olmak üzere toplam 408 BT görüntüsü kullanılmıştır. Beş kat çapraz doğrulama prosedürüne göre gerçekleştirilen deneyler sonucunda doğruluk parametresi 0,8569 ve AİKE-AKA parametresi 0,8591 olarak gerçekleşmiştir.

## **2.2. X-ray Görüntüler Kullanılarak Gerçekleştirilen Uygulamalar**

Tez çalışmasının beşinci uygulamasında X-ray görüntüler üzerinden COVID-19 ve COVID-19 değil sınıflandırması; altıncı uygulamasında COVID-19 ve COVID-19 değil sınıflandırması, COVID-19 zatürresi ve bakteriyel zatürre sınıflandırması, COVID-19 zatürresi ve viral zatürre sınıflandırması ile COVID-19 zatürresi ve diğer zatürre sınıflandırması; yedinci uygulamasında COVID-19 zatürresi, sağlıklı ve diğer zatürre sınıflandırması ile COVID-19 zatürresi, sağlıklı, bakteriyel zatürre ve viral zatürre sınıflandırması gerçekleştirilmiştir. Söz konusu sınıflandırma başlıklarında daha önce gerçekleştirilen literatür çalışmaları dört alt başlık altında incelenmiştir.

### **2.2.1. COVID-19 ve COVID-19 değil sınıflandırması**

2020 yılında Tuncer ve arkadaşları tarafından X-ray görüntülerinden COVID-19 ve COVID-19 değil sınıflandırması (Tuncer ve ark., 2020) için artık örnek YİD, yinelemeli kabartma, karar ağacı, doğrusal ayırıcı, DVM, k-EYK ve alt uzay ayırıcı yöntemleri kullanılması önerilmiştir. Çalışmada toplam 321 X-ray görüntüsünden yararlanılmış olup bu görüntülerden 87 tanesi COVID-19 ve 234 tanesi COVID-19 değil olarak etiketlidir. Çalışmada on kat çapraz doğrulama, %80 eğitim ve %20 test, %50 eğitim ve %50 test olmak üzere üç farklı prosedür ile eğitim ve test işlemleri gerçekleştirilmiştir. Çalışma sonucunda 0,8149 ile 1,0000 arasında değişen duyarlılık, 0,9380 ile 1,0000 arasında değişen özgüllük ve 0,9049 ile 0,9955 arasında değişen doğruluk sonuçları elde edilmiştir. Aynı yıl Panwar ve arkadaşları tarafından gerçekleştirilen çalışmada (Panwar ve ark., 2020) sınıflandırma için nCOVNet ESA

mimarisi kullanılmıştır. Eşit sayıda COVID-19 ve COVID-19 değil X-ray görüntüsünden oluşan ve toplam 284 görüntü içeren bir veri seti kullanılarak gerçekleştirilen deneyler %70 eğitim ve %30 test ayrışımına göre yapılmıştır. Çalışma sonucunda duyarlılık parametresi 0,9762; özgüllük parametresi 0,7857 ve doğruluk parametresi 0,881 olarak hesaplanmıştır.

2020 yılında Öztürk ve arkadaşları tarafından DarkNet ESA mimarisi kullanılarak gerçekleştirilen otomatik sınıflandırma çalışmasında (Öztürk ve ark., 2020) 125 COVID-19 ve 500 COVID-19 değil olmak üzere toplam 625 adet X-ray görüntüsünden yararlanılmıştır. Beş kat çapraz doğrulama prosedürüne göre gerçekleştirilen deneyler sonucunda 0,9513 duyarlılık ve 0,953 özgüllük başarıları sağlanmıştır. Ayrıca, doğruluk parametresi 0,9808 ve F-1 skoru parametresi 0,9651 olarak hesaplanmıştır. Aynı yıl Mohammed ve arkadaşları tarafından gerçekleştirilen otomatik COVID-19 ve COVID-19 değil sınıflandırma çalışmasında (Mohammed ve ark., 2020) 50 X-ray görüntüsü içeren bir veri seti kullanılmıştır. Çalışmada naive bayes, sinir ağı, DVM, radyal temel fonksiyonu, k-EYK, stokastik gradyan inişi, rastgele ormanlar, karar ağacı, AdaBoost, CN2 kural indükleyici algoritması kullanılarak çok kriterli karar verme süreci işletilmiştir. Deneyler sonucunda 0,706 ile 0,974 arasında değişen duyarlılık, 0,557 ile 1,000 arasında değişen özgüllük, 0,620 ile 0,987 arasında değişen doğruluk, 0,555 ile 0,987 arasında değişen F-1 skoru ve 0,800 ile 0,988 arasında değişen AİKE-AKA başarıları sağlanmıştır. Çalışmada sınıflandırma için gereken süre kullanılan yöntemle göre değişiklik göstermek kaydıyla 0,14 ile 7,57 saniye arasında hesaplanmıştır.

2020 yılında Toraman ve arkadaşları tarafından X-ray görüntülerinden COVID-19 ve COVID-19 değil sınıflandırması (Toraman ve ark., 2020) için CapsNet ESA mimarisi kullanılması önerilmiştir. Çalışmada 231 COVID-19 ve 1.050 COVID-19 değil olmak üzere toplam 1.281 X-ray görüntüsünden yararlanılmış olup deneyler on kat çapraz doğrulama prosedürüne göre gerçekleştirilmiştir. Deneyler sonucunda 0,28 ile 0,9742 arasında değişen ortalama duyarlılık, 0,8095 ile 0,98 arasında değişen ortalama özgüllük, 0,4914 ile 0,9724 arasında değişen ortalama doğruluk ve 0,55 ile 0,9724 arasında değişen ortalama F-1 skoru başarıları sağlanmıştır. Çalışmada otomatik sınıflandırma için gereken sürenin 16 ile 500 saniye arasında olduğu hesaplanmıştır. Aynı yıl Khan ve arkadaşları otomatik sınıflandırma için CoroNet ismini verdikleri Xception ESA mimarisini temel alan bir çözüm önermiştir (Khan ve ark., 2020). Dört kat çapraz doğrulama esasına göre gerçekleştirilen deneylerde 284 COVID-19 ve 310

COVID-19 değil olmak üzere toplam 594 X-ray görüntüsü kullanılmıştır. Deneyler sonucunda duyarlılık parametresi 0,993; özgüllük parametresi 0,986; doğruluk parametresi 0,990 ve F-1 skoru parametresi 0,985 olarak hesaplanmıştır.

2020 yılında Waheed ve arkadaşları tarafından gerçekleştirilen çalışmada (Waheed ve ark., 2020) VGG-16 ESA mimarisi ve sentetik veri artırma kullanılmıştır. Çalışmada toplam 1.124 X-ray görüntüsü içeren bir veri setinden yararlanılmış olup deneylerin gerçekleştirilmesinde görüntüler eğitim (toplam 932 X-ray görüntüsü) ve test (toplam 192 X-ray görüntüsü) olmak üzere ikiye ayrılmıştır. Deneyler sonucunda 0,69 ile 0,90 arasında değişen duyarlılık başarıları sağlanmıştır. Ayrıca, 0,95 ile 0,97 arasında değişen özgüllük ve 0,85 ile 0,95 arasında değişen doğruluk sonucu elde edilmiştir. Aynı yıl Duran-Lopez ve arkadaşları tarafından ESA kullanılarak bir otomatik sınıflandırma çalışması (Duran-Lopez ve ark., 2020) gerçekleştirilmiştir. Çalışmada 2.589 COVID-19 ve 4.337 COVID-19 değil olmak üzere toplam 6.926 X-ray görüntüsü kullanılmış olup deneylerde beş kat çapraz doğrulama prosedüründen yararlanılmıştır. Deneyler sonucunda duyarlılık parametresi 0,9253; özgüllük parametresi 0,9633; doğruluk parametresi 0,9443; F-1 skoru parametresi 0,9314 ve AİKE-AKA parametresi 0,988 olarak gerçekleşmiştir.

2020 yılında Vaid ve arkadaşları X-ray görüntülerinden otomatik COVID-19 ve COVID-19 değil sınıflandırması için VGG-19 ESA mimarisi ve eğitilebilir tam bağlantılı katmanlar kullanılmasını önermiştir (Vaid ve ark., 2020). Çalışmada toplam 545 X-ray görüntüsü içeren bir veri setinden yararlanılmıştır. Deneylerde söz konusu veri seti; eğitim (toplam 348 X-ray görüntüsü), doğrulama (toplam 88 X-ray görüntüsü) ve test (toplam 109 X-ray görüntüsü) olmak üzere üçe ayrılmıştır. Deneyler sonucunda duyarlılık parametresi 0,9863 olarak gerçekleşirken özgüllük parametresi 0,9166; doğruluk parametresi 0,9633 ve F-1 skoru parametresi 0,9729 olarak hesaplanmıştır. Aynı yıl Benbrahim ve arkadaşları otomatik sınıflandırma için transfer öğrenmeli InceptionV3 ve ResNet-50 ESA mimarisi kullanılmasını önermiştir (Benbrahim ve ark., 2020). Çalışmanın deneyleri COVID-19 ve COVID-19 değil sınıflarından eşit sayıda olmak üzere toplam 320 X-ray görüntüsü içeren bir veri seti kullanılarak gerçekleştirilmiştir. Deneyler %70 eğitim ve %30 test ayrışımına göre yapılmış olup deneyler sonucunda 0,9803 ile 0,9811 arasında değişen duyarlılık, 0,9803 ile 0,9901 arasında değişen doğruluk ve 0,9803 ile 0,9901 arasında değişen F-1 skoru başarıları elde edilmiştir.



2020 yılında Loey ve arkadaşları otomatik sınıflandırma için transfer öğrenmeli AlexNet, GoogleNet ve ResNet-18 ESA mimarilerinin başarılarını karşılaştırmıştır (Loey ve ark., 2020). Çalışmada eğitim işlemlerinde 130 adet ve test işlemlerinde 18 adet olmak üzere toplam 148 X-ray görüntüsünden yararlanılmıştır. Deneyler sonucunda duyarlılık, özgüllük ve doğruluk parametrelerinin 1,00 olarak hesaplandığı bildirilmiştir. Aynı yıl Minaee ve arkadaşları tarafından benzer bir çalışma (Minaee ve ark., 2020) transfer öğrenme yapılmış ResNet-18, ResNet-50, SqueezeNet ve DenseNet-121 ESA mimarileri kullanılarak gerçekleştirilmiştir. Çalışmada 184 COVID-19 ve 5.000 COVID-19 değil olmak üzere toplam 5.184 X-ray görüntüsünden yararlanılmış olup deneylerde görüntülerin 2.084 tanesi eğitim işlemlerinde kalan 3.100 tanesi ise test işlemlerinde kullanılmıştır. Deneyler sonucunda duyarlılık parametresi 0,98 olarak hesaplanırken 0,751 ile 0,929 arasında değişen özgüllük başarısı sağlanmıştır.

2020 yılında Elaziz ve arkadaşları otomatik COVID-19 ve COVID-19 değil sınıflandırması için kesirli çok kanallı üs momentleri, Manta-Ray arama optimizasyonu ve k-EYK sınıflandırıcı kullanılmasını önermiştir (Elaziz ve ark., 2020). Çalışmada 1.819 X-ray görüntüsü ve 1.560 X-ray görüntüsü içeren iki farklı veri seti kullanılmıştır. %80 eğitim ve %20 test ayrışımına göre gerçekleştirilen deneyler sonucunda 0,9875 ile 0,9891 arasında değişen duyarlılık ve 0,9609 ile 0,9809 arasında değişen doğruluk başarısı sağlanmıştır. Aynı yıl Martínez ve arkadaşları tarafından sinir mimarisi arama ağı kullanılarak bir otomatik sınıflandırma çalışması (Martínez ve ark., 2020) gerçekleştirilmiştir. Eşit sayıda COVID-19 ve COVID-19 değil X-ray görüntüsü içeren toplam 240 görüntülük bir veri seti kullanılarak gerçekleştirilen deneylerde %70 eğitim ve %30 test ayrışımından yararlanılmıştır. Deneyler sonucunda duyarlılık, doğruluk ve F-1 skoru parametreleri 0,97 olarak hesaplanmıştır.

2020 yılında Mahmud ve arkadaşları tarafından gerçekleştirilen çalışmada (Mahmud ve ark., 2020) transfer öğrenmeli yığılanmış çok çözünürlüklü CovXNet ESA mimari kullanılmıştır. Eşit sayıda COVID-19 ve COVID-19 değil etiketli görüntü içeren toplam 610 görüntülük bir veri seti kullanılarak gerçekleştirilen deneyler beş kat çapraz doğrulama prosedürüne göre yürütülmüştür. Deneyler sonucunda duyarlılık parametresi 0,978 ve özgüllük parametresi 0,947 olarak hesaplanmıştır. Ayrıca, doğruluk parametresi 0,974; F-1 skoru parametresi 0,971 ve AİKE-AKA parametresi 0,969 olarak gerçekleşmiştir. Aynı yıl Apostolopoulos ve Mpesiana tarafından otomatik sınıflandırma için VGG-19, MobileNetV2, Inception, Xception, Inception ve ResNetV2 ESA mimarilerinin kullanılması önerilmiştir (Apostolopoulos ve Mpesiana, 2020).

Çalışmada 224 COVID-19 ve 504 COVID-19 değil olmak üzere toplam 728 X-ray görüntüsü kullanılmıştır. On kat çapraz doğrulama prosedürüne göre gerçekleştirilen deneyler sonucunda duyarlılık parametresi 0,9866; özgüllük parametresi 0,9646 ve doğruluk parametresi 0,9678 olarak hesaplanmıştır.

### **2.2.2. COVID-19 zatürresi ve bakteriyel zatürre, COVID-19 zatürresi ve viral zatürre, COVID-19 zatürresi ve diğer zatürre sınıflandırması**

2020 yılında Mahmud ve arkadaşları tarafından otomatik COVID-19 zatürresi ve viral zatürre ile COVID-19 zatürresi ve bakteriyel zatürre ayırımına yönelik iki sınıflı sınıflandırma çalışması (Mahmud ve ark., 2020) gerçekleştirilmiştir. Çalışmada COVID-19 zatürresi ve viral zatürre ayırımı için toplam 610 adet X-ray görüntüsü (305 COVID-19 zatürresi ve 305 viral zatürre) kullanılmıştır. COVID-19 zatürresi ve bakteriyel zatürre ayırımı için toplam 610 adet X-ray görüntüsünden (305 COVID-19 zatürresi ve 305 bakteriyel zatürre) yararlanılmıştır. Sınıflandırıcı olarak transfer öğrenmeli yığılanmış çok çözünürlüklü CovXNet ESA mimarisi kullanılan çalışmada, beş kat çapraz doğrulama prosedürüne göre eğitim ve test işlemleri gerçekleştirilmiştir. Çalışma sonucunda COVID-19 zatürresi ve viral zatürre sınıflandırması için duyarlılık parametresi 0,874; özgüllük parametresi 0,855; doğruluk parametresi 0,873; F-1 skoru parametresi 0,878 ve AİKE-AKA parametresi 0,921 olarak hesaplanmıştır. COVID-19 zatürresi ve bakteriyel zatürre sınıflandırması için ise duyarlılık, özgüllük, doğruluk, F-1 skoru ve AİKE-AKA parametreleri sırasıyla 0,944; 0,933; 0,947; 0,939 ve 0,951 olarak gerçekleşmiştir.

2020 yılında Horry ve arkadaşları tarafından COVID-19 zatürresi ve diğer zatürre sınıflandırması için VGG-16, VGG-19, Xception, Inception ResNet, InceptionV3, NASNetLarge, ResNet-50V2, DenseNet-121 ESA mimarilerinin kullanılması önerilmiştir. Söz konusu ESA mimarilerinin ağırlıkları transfer öğrenme ile transfer edilmiştir. Çalışmada 139 COVID-19 zatürresi ve 190 diğer zatürre olmak üzere toplam 329 X-ray görüntüsünden yararlanılmıştır. Deneyler %80 eğitim ve %20 test ayrışımına göre gerçekleştirilmiştir. Deneyler sonucunda 0,86 ile 0,89 arasında değişen duyarlılık ve F-1 skoru başarıları sağlanmıştır.

### 2.2.3. COVID-19 zatürresi, sağlıklı ve diğer zatürre sınıflandırması

2020 yılında Islam ve arkadaşları tarafından otomatik COVID-19 zatürresi, sağlıklı ve diğer zatürre sınıflandırmasına yönelik bir çalışma (Islam ve ark., 2020) gerçekleştirilmiştir. Çalışmada sınıflandırıcı olarak ESA ve uzun kısa süreli bellek yöntemleri kullanılmıştır. Deneyler her üç sınıftan eşit sayıda görüntü içermek üzere toplam 4.575 X-ray görüntüsü ile gerçekleştirilmiş olup söz konusu görüntülerden 3.360 tanesi eğitim ve 915 tanesi test işlemlerinde kullanılmıştır. Çalışma sonucunda genel doğruluk parametresi 0,994 olarak gerçekleşmiştir. COVID-19 zatürresi sınıfı için duyarlılık parametresi 0,990 ile 0,993 arasında, özgüllük parametresi 0,982 ile 0,992 arasında, doğruluk parametresi 0,985 ile 0,992 arasında, F-1 skoru parametresi 0,977 ile 0,989 arasında ve AİKE-AKA parametresi 0,953 ile 0,999 arasında hesaplanmıştır. Aynı yıl Yıldırım ve Çınar tarafından AlexNet, ResNet-50, GoogleNet, VGG-16 ESA mimarileri ve çalışma kapsamında geliştirilmiş hibrit bir ESA mimarisi kullanılarak X-ray görüntüleri üzerinden üç sınıflı otomatik sınıflandırma gerçekleştirilmiştir (Yıldırım ve Çınar, 2020). Çalışmada 136 COVID-19 zatürresi, 162 diğer zatürre ve 245 sağlıklı olmak üzere 543 X-ray görüntüsünden yararlanılmıştır. Deneyler %80 eğitim ve %20 test ayrışımına göre gerçekleştirilmiş olup 0,8889 ile 0,9630 arasında değişen genel doğruluk başarıları sağlanmıştır. COVID-19 zatürresi sınıfı için duyarlılık parametresi 0,8438 ile 0,9630 arasında, özgüllük parametresi 0,9737 ile 1,000 arasında, doğruluk parametresi 0,9505 ile 0,9811 arasında ve F-1 skoru parametresi 0,9153 ile 0,9643 arasında hesaplanmıştır.

2020 yılından Rahimzadeh ve Attar otomatik COVID-19 zatürresi, sağlıklı ve diğer zatürre sınıflandırması için Xception ve ResNet-50V2 mimarilerinin birleştirilmesiyle elde edilen hibrit bir ESA mimarisi kullanılmasını önermiştir (Rahimzadeh ve Attar, 2020). Çalışmada 180 COVID-19 zatürresi, 6.054 diğer zatürre ve 8.851 sağlıklı olmak üzere toplam 15.085 X-ray görüntüsü kullanılmış olup deneyler eğitim (toplam 3.783 X-ray görüntüsü) ve test (toplam 11.302 X-ray görüntüsü) olmak üzere ikiye bölme ve beş kat çapraz doğrulama prosedürüne göre ayrı ayrı yapılmıştır. Deneyler sonucunda genel doğruluk parametresi 0,8979 ile 0,9140 arasında gerçekleşmiştir. COVID-19 zatürresi sınıfı için duyarlılık parametresi 0,7335 ile 0,8053 arasında, özgüllük parametresi 0,9933 ile 0,9956 arasında ve doğruluk parametresi 0,9926 ile 0,9950 arasında hesaplanmıştır. Aynı yılı Nour ve arkadaşları tarafından gerçekleştirilen sınıflandırma çalışmasında (Nour ve ark., 2020) derin özellikler, bayes

optimizasyonu, DVM, karar ağacı ve k-EYK yöntemleri kullanılmıştır. Çalışmada toplam 2.905 X-ray görüntüsünden yararlanılmış olup söz konusu görüntülerin 2.033 tanesi eğitim işlemlerinde kalan 872 tanesi ise test işlemlerinde kullanılmıştır. Deneyler sonucunda genel duyarlılık parametresi 0,8753 ile 0,9461 arasında, genel özgüllük parametresi 0,9554 ile 0,9975 arasında, genel doğruluk parametresi 0,9209 ile 0,9897 arasında ve genel F-1 skoru parametresi 0,8769 ile 0,9672 arasında gerçekleşmiştir.

2020 yılında Das ve arkadaşları tarafından gerçekleştirilen X-ray görüntülerinden üç sınıflı otomatik sınıflandırma çalışmasında (Das ve ark., 2020) başlangıç ağırlıkları transfer edilmiş Xception ESA mimarisi kullanılması önerilmiştir. Çalışmada 125 COVID-19 zatürresi, 500 diğer zatürre, 500 sağlıklı olmak üzere toplam 1.125 X-ray görüntüsünden yararlanılmış olup deneyler %70 eğitim, %10 doğrulama ve %20 test ayrışımına göre gerçekleştirilmiştir. Deneyler sonucunda genel duyarlılık parametresi 0,970921; genel özgüllük parametresi 0,972973; genel doğruluk parametresi 0,974068 ve genel F-1 skoru parametresi 0,969697 olarak hesaplanmıştır. Aynı yıl Öztürk ve arkadaşları DarkNet ESA mimarisi kullanılan üç sınıflı bir otomatik sınıflandırma çalışması (Öztürk ve ark., 2020) gerçekleştirmiştir. Deneyler 125 COVID-19 zatürresi, 500 diğer zatürre ve 500 sağlıklı olmak üzere toplam 1.125 X-ray görüntüsü ile beş kat çapraz doğrulama prosedürüne göre yapılmıştır. Çalışma sonucunda genel duyarlılık parametresi 0,8535; genel özgüllük parametresi 0,9218; genel doğruluk parametresi 0,8702 olarak gerçekleşirken genel F-1 skoru parametresi 0,8737 olarak hesaplanmıştır.

2020 yılında Toraman ve arkadaşları tarafından gerçekleştirilen otomatik üç sınıflı sınıflandırma çalışmasında (Toraman ve ark., 2020) CapsNet ESA mimarisinin başarısı test edilmiştir. Çalışmada 231 COVID-19 zatürresi, 1.050 diğer zatürre ve 1.050 sağlıklı olmak üzere toplam 2.331 X-ray görüntüsü kullanılmıştır. On kat çapraz doğrulama prosedürüne göre gerçekleştirilen deneyler sonucunda her çapraz katta elde edilen duyarlılık parametresi değerlerinin ortalaması 0,8422; özgüllük parametre değerlerinin ortalaması 0,9179; doğruluk parametre değerlerinin ortalaması 0,8919 ve F-1 skoru parametre değerlerinin ortalaması 0,8421 olarak hesaplanmıştır. Deneyler sonucunda genel doğruluk parametresi ise 0,8422 olarak gerçekleşmiştir. Aynı yıl Khan ve arkadaşları üç sınıflı otomatik sınıflandırma için temeli Xception ESA mimarisine dayanan ve CoroNet olarak isimlendirilen bir ESA mimarisi kullanılmasını önermiştir (Khan ve ark., 2020). Dört kat çapraz doğrulama prosedürüne göre gerçekleştirilen deneylerde 284 COVID-19 zatürresi, 657 diğer zatürre ve 310 sağlıklı olmak üzere

toplam 1.251 X-ray görüntüsü kullanılmıştır. Deneysel sonuçta duyarlılık parametresi 0,969; özgüllük parametresi 0,975; doğruluk parametresi 0,95 ve F-1 skoru parametresi 0,956 olarak gerçekleşmiştir.

2020 yılında Toğaçar ve arkadaşları tarafından SqueezeNet ve MobileNetV2 ESA mimarileri, sosyal mimik optimizasyonu ve DVM kullanılarak bir sınıflandırma çalışması (Toğaçar ve ark., 2020) gerçekleştirilmiştir. Çalışmanın deneylerinde 295 COVID-19, 98 diğer zatürre ve 65 sağlıklı olmak üzere toplam 458 X-ray görüntüsü kullanılmıştır. Deneyler, %70 eğitim ve %30 test ile beş kat çapraz doğrulama olmak üzere iki farklı prosedüre göre yapılmıştır. Deneyler sonucunda genel doğruluk parametresi 0,9781 ile 0,9927 arasında hesaplanmıştır. COVID-19 zatürresi sınıfına ait duyarlılık parametresi 0,9932 ile 1,000 arasında, özgüllük parametresi 0,9937 ile 1,000 arasında, doğruluk parametresi 0,9926 ile 1,000 arasında ve F-1 skoru parametresi 0,9944 ile 1,000 arasında gerçekleşmiştir. Aynı yıl Uçar ve Korkmaz tarafından derin Bayes-SqueezeNet ESA mimarisi kullanılarak gerçekleştirilen sınıflandırma çalışmasında (Uçar ve Korkmaz, 2020) 76 COVID-19 zatürresi, 4.290 diğer zatürre ve 1.583 sağlıklı olmak üzere 5.949 X-ray görüntüsünü içeren bir veri seti kullanılmıştır. Deneylerde veri seti, eğitim (toplam 5.310 X-ray görüntüsü) ve test (toplam 639 X-ray görüntüsü) olmak üzere ikiye ayrılmıştır. Deneyler sonucunda genel duyarlılık parametresi 0,6921 ile 0,9826 arasında, genel özgüllük parametresi 0,7993 ile 0,9913 arasında, genel doğruluk parametresi 0,7637 ile 0,9826 arasında ve genel F-1 skoru parametresi 0,6689 ile 0,9825 arasında gerçekleşmiştir.

2020 yılında Civit-Masot ve arkadaşları tarafından otomatik COVID-19 zatürresi, sağlıklı ve diğer zatürre sınıflandırması için VGG-16 mimarisi kullanılması önerilmiştir (Civit-Masot ve ark., 2020). Çalışmada her sınıftan eşit sayıda X-ray görüntüsü içeren toplam 396 görüntülük bir veri setinden yararlanılmıştır. Veri setinde yer alan 316 X-ray görüntüsü ile eğitilen ESA mimarisi kalan 80 X-ray görüntüsü kullanılarak test edilmiştir. Deneyler sonucunda makro ölçekte hesaplanan genel duyarlılık, doğruluk ve F-1 skoru parametreleri 0,85 ile 0,86 arasında, genel özgüllük parametresi 0,92 ile 0,93 arasında gerçekleşirken genel AİKE-AKA parametresi 0,949 olarak hesaplanmıştır. Aynı yıl Singh ve arkadaşları tarafından ESA kullanılarak gerçekleştirilen üç sınıflı otomatik sınıflandırma çalışmasında (Singh ve ark., 2020) toplam 1.419 X-ray görüntüsü (132 COVID-19 zatürresi, 619 diğer zatürre ve 668 sağlıklı) içeren bir veri setinden yararlanılmıştır. Veri seti içindeki görüntüler, eğitim (toplam 1.135 X-ray görüntüsü) ve test (toplam 284 X-ray görüntüsü) olmak üzere ikiye

ayrılmıştır. Çalışma sonucunda genel duyarlılık parametresi 0,956; genel doğruluk parametresi 0,958 ve genel F-1 skoru parametresi 0,9588 olarak gerçekleşmiştir. COVID-19 zatürresi sınıfına ait duyarlılık parametresi 0,96; doğruluk parametresi 0,9894 ve F-1 skoru parametresi 0,94 olarak hesaplanmıştır.

2020 yılında Shorfuzzaman ve Masud tarafından üç sınıflı sınıflandırma için ağırlıkları transfer edilmiş VGG-16, ResNet-50V2, MobileNet, Xception ve DenseNet-121 ESA mimarileri ve bu mimarilerin toplu olarak kullanılması önerilmiştir (Shorfuzzaman ve Masud, 2020). 226 COVID-19 zatürresi, 226 diğer zatürre ve 226 sağlıklı olmak üzere toplam 678 X-ray görüntüsü kullanılan çalışmada deneyler beş kat çapraz doğrulama prosedürüne göre gerçekleştirilmiştir. Deneyler sonucunda genel duyarlılık parametresi 0,9565 ile 1,000 arasında, genel özgüllük parametresi 0,9767 ile 0,9889 arasında, genel doğruluk parametresi 0,9411 ile 0,9926 arasında, genel F-1 skoru parametresi 0,9573 ile 0,9889 arasında ve genel AİKE-AKA parametresi 0,9547 ile 0,9944 arasında gerçekleşmiştir. Aynı yıl Pandit ve Banday tarafından gerçekleştirilen sınıflandırma çalışmasında (Pandit ve Banday, 2020) ağırlıkları transfer edilmiş VGG-16 ESA mimarisinin performansı test edilmiştir. Çalışmada toplam 1.428 X-ray görüntüsünden (224 COVID-19 zatürresi, 700 diğer zatürre ve 504 sağlıklı) oluşan bir veri seti kullanılmış olup deneyler %70 eğitim ve %30 test ayrışımına göre gerçekleştirilmiştir. Çalışma sonucunda genel duyarlılık parametresi 0,867 ve genel özgüllük parametresi 0,951 olarak hesaplanırken genel doğruluk parametresi 0,9253 olarak gerçekleşmiştir. Aynı yıl benzer bir çalışma Loey ve arkadaşları tarafından ağırlıkları transfer edilmiş AlexNet, GoogleNet ve ResNet-18 ESA mimarileri kullanılarak gerçekleştirilmiştir (Loey ve ark., 2020). Çalışmada 200 X-ray görüntüsü (60 COVID-19 zatürresi, 70 diğer zatürre ve 70 sağlıklı) eğitim işlemlerinde kullanılırken 27 X-ray görüntüsünden (9 COVID-19 zatürresi, 9 diğer zatürre ve 9 sağlıklı) test işlemlerinde yararlanılmıştır. Çalışma sonucunda genel duyarlılık parametresi 0,8148 ile 0,8519 arasında, genel doğruluk parametresi 0,8148 ile 0,8519 arasında ve genel F-1 skoru parametresi 0,8146 ile 0,8519 arasında gerçekleşmiştir. COVID-19 zatürre sınıfı için doğruluk parametresi ise 0,818 ile 1,000 arasında hesaplanmıştır.

#### **2.2.4. COVID-19 zatürresi, sağlıklı, bakteriyel zatürre ve viral zatürre sınıflandırması**

2020 yılında Khan ve arkadaşları tarafından gerçekleştirilen otomatik COVID-19 zatürresi, sağlıklı, bakteriyel zatürre ve viral zatürre sınıflandırma çalışmasında (Khan ve ark., 2020) temeli Xception ESA mimarisine dayanan ve CoroNet olarak isimlendirilen bir ESA mimarisi kullanılmıştır. Çalışmada 284 COVID-19 zatürresi, 330 bakteriyel zatürre, 327 viral zatürre ve 310 sağlıklı olmak üzere toplam 1.251 X-ray görüntüsünden yararlanılmıştır. Dört kat çapraz doğrulama prosedürüne göre gerçekleştirilen deneyler sonucunda genel duyarlılık parametresi 0,8992; genel özgüllük parametresi 0,964; genel doğruluk parametresi 0,896 olarak gerçekleştirirken genel F-1 skoru parametresi 0,898 olarak hesaplanmıştır. Aynı yıl Loey ve arkadaşları tarafından X-ray görüntülerinden dört sınıflı otomatik sınıflandırma için ağırlıkları transfer edilmiş AlexNet, GoogleNet ve ResNet-18 ESA mimarisi kullanılması önerilmiştir (Loey ve ark., 2020). Çalışmada 306 X-ray görüntüsünden (69 COVID-19 zatürresi, 79 bakteriyel zatürre, 79 viral zatürre ve 79 sağlıklı) oluşan bir veri setinden yararlanılmıştır. Veri seti içinde yer alan 270 X-ray görüntüsü eğitim işlemlerinde kullanılırken kalan 36 X-ray görüntüsü ile testler gerçekleştirilmiştir. Deneyler sonucunda genel duyarlılık parametresi 0,6667 ile 0,8056 arasında, genel doğruluk parametresi 0,6667 ile 0,8056 arasında ve genel F-1 skoru parametresi 0,6566 ile 0,8232 arasında gerçekleşmiştir. Aynı yıl Mahmud ve arkadaşları tarafından gerçekleştirilen sınıflandırma çalışmasında (Mahmud ve ark., 2020) ise yığılanmış çok çözünürlüklü CovXNet ESA mimarisi kullanılmıştır. Çalışmada COVID-19 zatürresi, bakteriyel zatürre, viral zatürre ve sağlıklı sınıflarından eşit sayıda olmak üzere toplam 1.220 X-ray görüntüsünden oluşan bir veri setinden yararlanılmıştır. Beş kat çapraz doğrulama prosedürüne göre gerçekleştirilen deneyler sonucunda genel duyarlılık parametresi 0,899; genel özgüllük parametresi 0,891; genel doğruluk parametresi 0,902 ve genel F-1 skoru parametresi 0,904 olarak hesaplanmıştır. Çalışma sonucunda AİKE-AKA parametresi ise 0,911 olarak gerçekleşmiştir.

### 3. KOMPLEKS DEĞERLİ DALGACIK DÖNÜŞÜMÜ

Tez çalışmasında BT görüntüler üzerinden COVID-19 ve COVID-19 değil sınıflandırması ile COVID-19 zatürresi ve diğer zatürre sınıflandırmasında görüntü boyutlarının azaltılması amacıyla Kompleks Değerli Dalgacık Dönüşümü (KDDD) kullanılmıştır. Benzer şekilde X-ray görüntüler üzerinden COVID-19 ve COVID-19 değil sınıflandırma uygulamasında aynı amaçla KDDD'den yararlanılmıştır.

#### 3.1. Bir Boyutlu Dalgacık Dönüşümü

Fourier Dönüşümü (FD), zaman düzlemindeki bir sinyalin frekans düzlemindeki bileşenlerinin elde edilmesinde kullanılan en temel frekans analizi yöntemidir. Zaman içinde frekans bilgisi değişmeyen sinyallerin analizinde FD başarılıdır. Ancak, zaman içinde frekans bilgisi değişen sinyaller için FD'nin tersine işletilmesi esnasında hangi frekans bileşenin hangi zaman diliminde veya dilimlerinde etkin olduğu bilinemediği için sinyalin yeniden oluşturulması mümkün olmamaktadır. Gerçek hayatta karşımıza çıkan bir boyutlu sinyallerin hemen hemen tamamı zaman içinde frekans bilgisi değişen sinyallerdir. Bu soruna çözüm bulmak amacıyla 1946 yılında Gabor tarafından sinyallerin daha küçük parçalara ayrılarak FD uygulanması fikri ortaya atılmıştır (Gabor, 1946). Kısa Zamanlı Fourier Dönüşümü (KZFD) olarak isimlendirilen bu yaklaşımda uzunluğu ihtiyaca göre belirlenen sabit pencereler kullanılarak sinyalin frekans analizi gerçekleştirilmektedir. Söz konusu pencereler zaman içinde frekans bilgisi değişen ana sinyali daha küçük parçalara ayırarak zaman içinde frekans bilgisi değişmeyen veya çok az değişen sinyal bölümleri elde edilmesini sağlamaktadır.

KZFD'nin sinyallerin frekans bileşenlerinin elde edilmesinde avantajları olmakla birlikte bazı dezavantajları da vardır. Bu kapsamda en önemli dezavantaj KZFD'de belirlenen pencerenin sabit uzunlukta olmasıdır (Misiti ve ark., 2004). KZFD uygulanırken pencere uzunluğunun kısa seçilmesi düşük frekans bileşenlerinin, uzun seçilmesi ise yüksek frekans bileşenlerinin tespit edilmesini zorlaştırmaktadır. KZFD'nin bu dezavantajını ortadan kaldırmak için değişken uzunluklu pencere kullanılması önerilmiş ve Dalgacık Dönüşümü (DD) ortaya atılmıştır. DD'de kullanılan fonksiyonlar ana dalgacık olarak isimlendirilen  $\psi(t)$  fonksiyonunun kaydırma ve ölçeklendirmeye tabi tutulması ile oluşturulur. Eşitlik (3.1)'de  $a$  ölçekleme (reel ve



sıfırdan büyük bir sayı),  $b$  ise kayma (reel sayı) parametresi olmak üzere ana dalgacık fonksiyonunun matematiksel karşılığı yer almaktadır.

$$\psi(a,b)(t) = \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right) \quad (3.1)$$

Eşitlik (3.2)'de ise örnek bir  $x(t)$  fonksiyonun sürekli dalgacık katsayılarının matematiksel olarak elde edilmesi görülmektedir.

$$SDD(a,b) = \int_{-\infty}^{+\infty} x(t) \psi_{(a,b)}^*(t) dt \quad (3.2)$$

Sürekli dalgacık katsayıları ölçekleme ve kayma parametrelerinin her olası durumu için elde edilebilir. Ancak, söz konusu bu işlem oldukça maliyetlidir. Bir diğer önemli husus ise söz konusu dalgacık katsayılarının önemli bir kısmının hesaplanmasa bile sinyalin işlenmesinde kullanılmıyor olmasıdır. Bu sebeple sürekli DD'nin sadece belirli ölçek ve kayma parametreleri için hesaplanması daha kullanışlı olarak görülmüş ve ayrık DD tanımlanmıştır. Ayrık DD'de işlemlerde kolaylık sağlanması için iki ve ikinin katlarını içeren ölçek ve kayma parametreleri kullanılır (Daubechies, 1990). Eşitlik (3.3)'de  $a_0$  genişletme adımı (büyüktür 1) ve  $b_0$  ise çevirme adımı (eşit değildir 0) olmak üzere ölçek ve kayma parametrelerinin ayrık versiyonları görülmektedir. Eşitlik (3.4) ayrık DD fonksiyonunu matematiksel olarak ifade etmektedir. Örnek bir  $x(t)$  fonksiyonunun ayrık DD katsayılarının elde edilmesi ise Eşitlik (3.5) kullanılarak gerçekleştirilir.

$$a = a_0^j \text{ ve } b = k.a_0^j.b_0 \quad j, k \in Z \quad (3.3)$$

$$\psi_{j,k}(t) = a_0^{-j/2} \psi(a_0^{-j}t - kb_0) \quad (3.4)$$

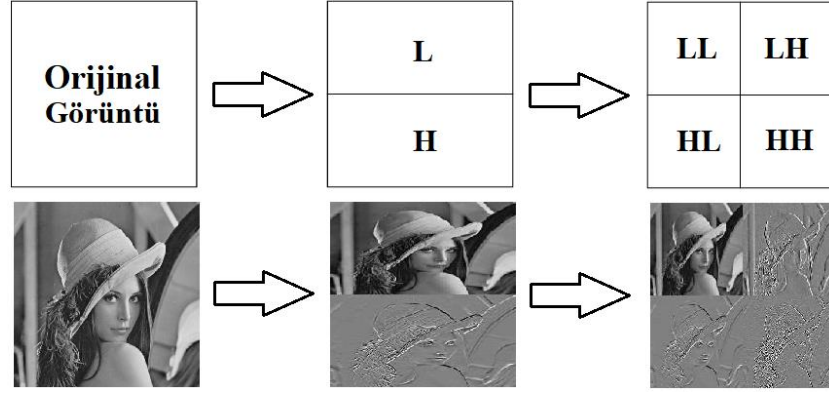
$$x(t) = \sum_j \sum_k D_f(j,k) \psi_{j,k}(t) \quad (3.5)$$

Ayrık DD ikinin katlarını kullanarak hesaplama yaptığı için uygulandığı sinyalin iki farklı gruptaki frekans bileşenlerini içeren alt sinyallerinin elde edilmesini sağlamaktadır. Bu bileşenler Alçak (L) ve Yüksek (H) frekans bileşenleri olarak isimlendirilebilir. Ayrık DD kullanılarak elde edilen alt sinyallere tekrar ayrık DD uygulanarak istenilen bir frekans aralığı bilgisinin kolayca elde edilmesi mümkündür. Örneğin, 0 ile 100 kHz aralığında frekanslar içeren bir ana sinyalin 0 ile 25 kHz aralığındaki alt sinyal bileşenleri elde edilmek isteniyorsa öncelikle ana sinyale ayrık DD uygulanarak L ve H bileşenleri bulunur. Bu aşamada L bileşeni 0 ile 50 kHz

aralığındaki frekansları içeren alt sinyaller, H bileşeni ise 50 ile 100 kHz aralığındaki frekansları içeren alt sinyallerdir. Daha sonra L bileşenine tekrar ayrık DD uygulanır ve 0 ile 25 kHz aralığındaki frekansları içeren alt sinyaller elde edilmiş olur. Bu işlemin gerçekleştirilmesinde dalgacık filtre kümesi kullanılması en yaygın yaklaşımdır (Mallat 1989). Dalgacık filtre kümesi uygulanarak elde edilen alt bileşenlerin sentezlenmesiyle ana sinyalin yeniden elde edilmesi mümkündür.

### 3.2. İki Boyutlu Dalgacık Dönüşümü

Bir boyutlu ayrık DD'nin iki boyut için genişletilmesi görüntülerin işlenmesine yönelik ihtiyaçlardan kaynaklı olarak ortaya çıkmıştır. İki boyutlu sinyallerin yani görüntülerin elde edilmesinin ve dijital ortamda saklanmasının yaygınlaşmasıyla görüntü işleme önemli bir çalışma başlığı haline gelmiştir. Bu aşamada ilk ortaya çıkan yaklaşımlar bir boyutlu sinyallerin analizinde kullanılan yöntemlerin görüntülerin analizi için genişletilmesi yönündedir. Ayrık DD görüntülerin satır ve sütunlarına ardışık olarak uygulanarak analiz gerçekleştirilebilir. Bu aşamada bir boyutlu sinyallerden farklı olarak L ve H olmak üzere iki alt bileşen yerine LL (Alçak-Alçak Görüntü Alt Bandı), LH (Alçak-Yüksek Görüntü Alt Bandı), HL (Yüksek-Alçak Görüntü Alt Bandı) ve HH (Yüksek-Yüksek Görüntü Alt Bandı) olmak üzere toplam dört alt bileşen elde edilmektedir. Bunun temel sebebi görüntülerde satırlar ve sütunlar boyunca işlem yapıldığı için satırların analizi ile elde edilen L ve H bileşenlerinin sütunların analizi ile elde edilen L ve H bileşenleri ile çaprazlanıyor olmasıdır. Yani, LL görüntünün satır ve sütunların alçak bileşenlerini, LH görüntü satırlarının alçak ve sütunlarının yüksek bileşenlerini, HL görüntü satırlarının yüksek ve sütunlarının alçak bileşenlerini, HH ise görüntünün satır ve sütunlarının yüksek bileşenlerini yansıtmaktadır. Söz konusu işlemler önce satırlara ardından sütunlara uygulanabileceği gibi önce sütunlara daha sonra satırlara da uygulanabilir. Söz konusu alt bileşenlerin boyutları orijinal görüntü boyutlarının yarısı kadardır. Şekil 3.1'de Lena görüntüsünün satır ve sütunlarına ayrık DD uygulanmasıyla alt bant bileşenlerinin elde edilmesi yani ayrık DD'nin iki boyuta genişletilmesi işlemi yer almaktadır. LL alt bant bileşenine ayrık DD'nin tekrar uygulanmasıyla daha düşük alt bantlarının elde edilmesi mümkündür. İki boyutlu ayrık DD'nin değişime duyarlılık, zayıf yönlülük ve faz bilgisi eksikliği gibi bazı dezavantajları vardır (Guo, 1995; Strang ve Nguyen, 1996; Lawton, 1993; Lina, 1997; Ceylan, 2009).



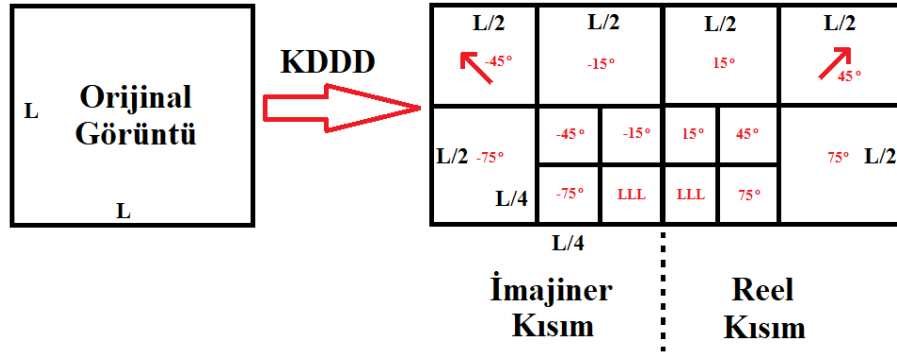
Şekil 3.1. Ayrık DD'nin iki boyuta genişletilmesi

### 3.3. Kompleks Değerli Dalgacık Dönüşümü

Dalgacık dönüşümünde kullanılan dalgacık fonksiyonlarının kompleks çözümleri olduğu çeşitli çalışmalarla ortaya çıkarılmıştır (Lawton, 1993; Lina, 1997). Kompleks formda tanımlanabilen dalgacık fonksiyonları sayesinde DD'nin kompleks olarak işletilebileceğinin gösterilmesinden sonra iki boyutlu ayrık DD'de kullanılmak üzere filtre kümesi tanımlanmasına yönelik çalışmalar gerçekleştirilmiştir (Zhang ve ark., 1999). Bu kapsamda standart ayrık DD'de  $h_r(n)$  olarak tanımlanan filtreler KDDD'de  $h_r(n) + jh_i(n)$  olarak tanımlanmıştır. Burada  $h_r(n)$  KDDD reel filtre kümesini,  $h_i(n)$  KDDD imajiner filtre kümesini temsil etmektedir. Söz konusu eşlenik filtre çiftleri iki boyuta Eşitlik (3.6) kullanılarak genişletilebilir.

$$(h_{rx} + jh_{ix})(h_{ry} + jh_{iy}) = (h_{rx}h_{ry} - h_{ix}h_{iy}) + j(h_{rx}h_{iy} + h_{ix}h_{ry}) \quad (3.6)$$

Standart ayrık DD bir görüntüye sadece reel düzlemde uygulanırken KDDD görüntüye kompleks düzlemde uygulanır. Bu sayede reel ve imajiner olmak üzere iki ağaç yapısını içeren bir ayrışma sağlanır (Kingsbury, 2001). Şekil 3.2'de, bir görüntüye KDDD uygulanması ile elde edilen reel ve imajiner alt bant bileşenleri görülmektedir. Standart ayrık DD'ye benzer şekilde alt bileşenlerin boyutları orijinal görüntü boyutlarının yarısı kadardır. Ancak, LH, HL ve HH alt bantlarının reel ve imajiner olmak üzere iki farklı birleşeni vardır. Yani, KDDD sayesinde görüntü üzerinde filtreleme yapılan yön sayısı üçten altıya çıkarılmıştır. Şekil 3.2'de görüldüğü gibi KDDD'de  $+15^\circ$ ,  $-15^\circ$ ,  $+45^\circ$ ,  $-45^\circ$ ,  $+75^\circ$  ve  $-75^\circ$  olmak üzere altı farklı yön için alt bant matrisi elde edilir.



Şekil 3.2. KDDD ayrışımı (Yaşar ve Ceylan, 2022(a))

#### 4. DOKU ANALİZ (ÖZELLİK ÇIKARMA) YÖNTEMLERİ

Tez çalışmasında görüntü tipi ve sayısının zenginleştirilmesi için doku analiz (özellik çıkarma) yöntemleri kullanılmıştır. Bu kapsamda; Yerel İkili Desenler (YİD), Lokal Entropi (LE) ve Gri Seviye Eş-oluşum Matrisi (GSEM) olmak üzere toplam üç yöntemden yararlanılmıştır.


##### 4.1. Yerel İkili Desenler

Yerel İkili Desenler (YİD) ilk olarak 1996 yılında Ojala ve arkadaşları tarafından tanımlanmıştır (Ojala ve ark., 1996). Bu yöntem genellikle görüntüler üzerindeki yerel mekansal yapıların ortaya çıkarılması için kullanılmaktadır. YİD, bir merkez pikselin komşu piksel değerleriyle sıralı bir şekilde karşılaştırılması işlemidir. Dolayısıyla parametrik olmayan bir yöntemdir. Bu karşılaştırmanın ilk örneği 3×3 kare bir operatör yani yarıçap değerinin 1 olması durumu için gerçekleştirilmiştir. Daha sonra yöntemin popülerlik kazanmasıyla farklı büyüklükteki yarıçap ve operatörler için de işlemler gerçekleştirilmiştir. Eşitlik (4.1)'de YİD işlemin matematiksel olarak gösterimi yer almaktadır. Eşitlik (4.1)'de  $p$  merkez piksele komşu olan piksellerin sayısı,  $x_i$   $i$ . komşu pikselin değeri ve  $x_m$  merkez pikselin değeridir.

$$YİD = \sum_{i=0}^{p-1} s(x_i - x_m) 2^i$$

$$s(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (4.1)$$


Eşitlik (4.1)'den de anlaşılacağı üzere, merkez piksel komşuları ile teker teker karşılaştırılarak eşik ölçümü yapılmaktadır. Eşik ölçümü işleminde, komşu pikselin değeri merkez pikselden büyük veya ona eşitse komşu piksele 1, daha küçükse 0 değeri atanır. Eşik ölçümü sonucunda toplam 256 kombinasyonu olan 8 bitlik bir YİD kodu ortaya çıkarılır. Bu kod daha sonra matematiksel olarak merkez pikselin yeni değerini belirleyecek bir sayısal değere dönüştürülür. Söz konusu sayısal değer hesaplanmasında, komşu piksellerin sırasına göre hesaplanan ikinin üstel katları ağırlık değerleri olarak kullanılır. Örnek bir 3×3 kare operatör için YİD yönteminin uygulanması Şekil 4.1'de gösterilmektedir.



$$YID = (0*1) + (1*2) + (1*4) + (1*8) + (0*16) + (0*32) + (1*64) + (0*128) = 78$$

Şekil 4.1. Örnek bir 3×3 kare operatör için YİD yönteminin uygulanması (Yaşar ve Ceylan, 2022(a))

Görüntülere YİD uygulanması durumunda görüntü boyutları küçülmektedir. Örneğin, 224×224 boyutlarındaki bir görüntüye yarıçapı 2 olan bir YİD işlemi uygulandığında, 220×220 boyutlarında bir özellik görüntüsü elde edilir. Bunun sebebi seçilen yarıçap büyüklüğüne bağlı olarak YİD işleminin orijinal görüntünün başlangıç ve bitiş satır ve sütunlarındaki piksellere uygulanamamasıdır. Uygulamalarda YİD işleminden sonra orijinal görüntülerle bir denklik yakalanması isteniyorsa YİD özellik görüntülerinin yeniden boyutlandırılması gerekmektedir. Tez çalışmasında, YİD yönteminin kullanıldığı uygulamalarda YİD işleminden sonra elde edilen görüntülerin boyutları MATLAB *imresize* fonksiyonu kullanılarak tekrar orijinal görüntü boyutlarına ayarlanmıştır. Şekil 4.2’de tez çalışmasında kullanılan birer adet COVID-19 zatürresi, sağlıklı ve diğer zatürre BT görüntüsüne yarıçap değeri sırasıyla 1, 2 ve 3 olmak üzere YİD işleminin uygulanması ve yeniden boyutlandırma yapılması ile elde edilen özellik görüntü örnekleri görülmektedir.



Şekil 4.2. a) COVID-19 zatürresi, b) sağlıklı ve c) diğer zatürre BT görüntülerine YİD uygulanarak elde edilen özellik görüntüleri (soldan sağa yarıçaplar sırasıyla 1, 2 ve 3'dür) (Yaşar ve Ceylan, 2022(a))

## 4.2. Lokal Entropi


Entropi, bir görüntüdeki belirsizliğin veya rastgeleliğin ölçüsü olarak açıklanabilir (Yang ve ark., 2020). Bir görüntünün global entropisi, Eşitlik (4.2) kullanılarak matematiksel olarak hesaplanabilir.

$$H = -\sum_{i=0}^{255} p_i \log_2 p_i \quad (4.2)$$

Eşitlik (4.2)'de  $p_i$  görüntünün normalleştirilmiş histogramından elde edilir ve  $i$  piksel değeri ile ilişkili olasılık olarak adlandırılır. Global histogramlar yerine lokal histogramlar kullanılmasıyla Lokal Entropi (LE) hesaplanabilir. LE, doku analizinde kullanılan etkili bir özellik çıkarma yöntemidir.

Görüntü işleme uygulamalarında görüntülerin LE özellik matrisleri uzun matematiksel hesaplamalar yerine LE filtreleri kullanılarak elde edilir. Tez çalışmasında

LE yönteminin kullanıldığı uygulamalarda LE özellik görüntülerinin elde edilmesinde MATLAB *entropyfilt* fonksiyonu kullanılmıştır. Fonksiyonun işletilmesi sonucunda elde edilen görüntünün piksel değerleri MATLAB *rescale* fonksiyonu kullanılarak 0 ile 255 arasına normalize edilmiş ve orijinal görüntülerle eşit hale getirilmiştir. Şekil 4.3’de tez çalışmasında kullanılan birer adet COVID-19 zatürresi, bakteriyel zatürre, viral zatürre ve sağlıklı X-ray görüntüsüne LE işleminin uygulanması ile elde edilen özellik görüntü örnekleri yer almaktadır.



Şekil 4.3. a) COVID-19 zatürresi, b) bakteriyel zatürre c) viral zatürre ve d) sağlıklı X-ray görüntülerine LE uygulanarak elde edilen özellik görüntüleri (Yaşar ve Ceylan, 2022(b))

### 4.3. Gri Seviye Eş-oluşum Matrisi

Gri Seviye Eş-oluşum Matrisi (GSEM) bir görüntüde belirli bir değere ve kaymaya sahip piksel çiftlerinin ne sıklıkla meydana geldiğini ortaya çıkarmak için kullanılır (Xing ve Jia, 2020). Bir görüntünün GSEM matrisi eşleniği Eşitlik (4.3) kullanılarak matematiksel olarak hesaplanabilir.

$$C_{\Delta x, \Delta y}(p-1, p-2) = \sum_{x=1}^{yatay} \sum_{y=1}^{dikey} \begin{cases} 1, & I(x, y) = p-1 \text{ ve } I(x+\Delta x, y+\Delta y) = p-2 \\ 0, & \text{diğer} \end{cases} \quad (4.3)$$

Eşitlik (4.3)’de *yatay* ve *dikey* GSEM matrisi hesaplanan görüntünün yatay ve dikey boyutlarıdır. Eşitlik (4.3)’de  $p-1$  ve  $p-2$  piksel çiftlerini,  $x$  ve  $y$  ise görüntünün uzamsal konumunu belirtir. Sonuç olarak olası bütün piksel çiftleri için  $C$  olarak ifade edilen GSEM matrisi hesaplanmış olur. GSEM matrisi  $C$ ’nin yatay ve dikeydeki boyutu




$s$ 'dir. Eşitlik (4.3)'de açık bir parametre olarak yer almayan  $s$ ,  $I$  görüntüsündeki bir pikselin alabileceği değerlerin sayısıdır. Örneğin, 8 bitlik gri seviye bir görüntüde bir piksel 0 ile 255 arasında toplam 256 değer alabilir. Bu durumda, söz konusu görüntüsünün bit derinliği değiştirilmediği takdirde GSEM matrisinin boyutları  $256 \times 256$  olacaktır.

Eşitlik (4.4)'de yer alan 3 bit derinliğine ve  $3 \times 6$  boyutlarına sahip  $I$  görüntüsünün yatay yöndeki GSEM matrisi olan  $C$ , Eşitlik (4.5)'de verilmiştir. Eşitlik (4.5)'de yer alan  $C$  matrisinin boyutları  $I$  görüntüsü 3 bitlik bir derinliğe sahip olduğu için  $8 \times 8$ 'dir.

$$I = \begin{vmatrix} 1 & 2 & 7 & 6 & 4 & 4 \\ 2 & 3 & 4 & 7 & 1 & 2 \\ 0 & 1 & 3 & 5 & 4 & 7 \end{vmatrix} \quad (4.4)$$

$$C = \begin{vmatrix} 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 2 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 & 0 & 1 \\ 0 & 0 & 0 & 0 & 1 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 & 0 & 2 \\ 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 & 1 & 0 \end{vmatrix} \quad (4.5)$$

GSEM matrisi yatayda hesaplanabileceği gibi  $45^\circ$ ,  $90^\circ$  ve  $135^\circ$  açıları için de hesaplanabilir. 8 bitlik gri seviye görüntülerde bit derinliği değiştirilmeden GSEM matrisi hesaplanması genel olarak maliyetlidir. Bu sebeple görüntünün bit derinliği azaltılarak GSEM matrisinin boyutları azaltılabilir. Bu durumda, görüntü genel hatlarını korumaktadır. Ancak, bit derinliğinin azaltılmasına bağlı olarak birbirine yakın değerdeki pikseller tek bir piksel değerine dönüştürüldüğü için görüntülerin ayrıntılarında azalmalar olmaktadır. Şekil 4.4'de 8 bitlik derinliğe sahip COVID-19 ve COVID-19 değil BT görüntü örnekleri ve bu görüntülerin GSEM matrisi hesaplanması sırasında gri seviye sayısı olarak 8 seçilmesi yani 3 bitlik görüntüye dönüştürülmesi sonucunda elde edilen dönüş görüntüleri yer almaktadır. Dönüş görüntüsü MATLAB *rescale* fonksiyonu kullanılarak 0 ile 255 arasına normalize edilmiştir.



**Şekil 4.4.** GSEM matrisi hesaplanırken a) COVID-19, b) COVID-19 değil görüntüsünün bit derinliğinin azaltılması sonucu elde edilen dönüş görüntüleri (Yaşar ve Ceylan, 2021(a))

Tez çalışmasının birinci uygulamasında GSEM yöntemi kullanılmıştır. GSEM matrisi ve dönüş görüntülerinin elde edilmesinde MATLAB *graycomatrix* fonksiyonundan yararlanılmıştır. Uygulamada doğrudan GSEM özellik matrislerinin kendisi değil özellik matrislerinin hesaplanmasında dikkate alınan ölçeklenmiş dönüş görüntüleri kullanılmıştır. GSEM dönüş görüntülerinin piksel değerleri MATLAB *rescale* fonksiyonu kullanılarak 0 ile 255 arasına normalize edilmiştir.

## 5. MAKİNE ÖĞRENMESİ VE DERİN ÖĞRENME

Makine öğrenmesi, insanların öğrenme şekillerine benzer öğrenme süreçleri geliştirerek problemlerin otomatik çözümüne odaklanmaktadır. Yani, makine öğrenmesi temelde insanları taklit etmektedir. Bu aşamada insanların öğrenme süreçleri nasıl ki birden fazla aşamadan oluşuyorsa makine öğrenmesi de veri ve algoritmaları kullanarak aşamalı olarak yeteneklerini geliştirmekte yani problemlere daha doğru çözümler üretmektedir. Makine öğrenimi istatistik, veri madenciliği, görüntü tanıma, olasılık, biyoloji gibi birçok bilim dalı ile doğrudan ilgilidir. Makine öğrenmesinin ortaya çıkışı Alan Turing tarafından gerçekleştirilen Turing testi ile gerçekleşmiştir (Turing, 1950). Makine öğrenmesi süreç içinde büyük bir gelişim göstererek temel bilim dallarında birçok uygulamaya konu olmuştur. Yapay sinir ağları, Destek Vektör Makinesi (DVM), karar ağacı, rastgele orman, lojistik regresyon, k-En Yakın Komşu (k-EYK), naive bayes sınıflandırıcı kullanımı en yaygın makine öğrenmesi yöntemleri arasındadır.

Derin öğrenme, makine öğrenmesinin son yıllarda önemli ölçüde gelişim gösteren önemli bir alt alanıdır. Derin öğrenme, makine öğrenmesinde genellikle insan faktörü ile gerçekleştiren özellik seçim süreçlerini otomatikleştirmesiyle dikkat çekmektedir. Bunun için makine öğrenmesine göre daha büyük veri kümelerine ihtiyaç duymaktadır. Bu açıdan bir karşılaştırma yapıldığında, makine öğrenmesinin öğrenme süreçlerinde derin öğrenmeye göre daha fazla insan müdahalesine ihtiyaç duyduğu söylenebilir. Derin öğrenmenin son yıllardaki hızlı yükselişindeki en büyük motivasyon bilgisayar kapasitelerinin hızlı bir şekilde gelişmiş olmasıdır. Çünkü, derin öğrenmede daha fazla verinin kullanılması daha fazla işlemci performansı ve kapasitesi gerekliliği anlamına gelmektedir. Evrişimli Sinir Ağları (ESA), tekrarlayan sinir ağları, uzun kısa süreli bellek ağları, derin inanç ağları, derin oto kodlayıcı en yaygınlaşmış derin öğrenme yöntemleri olarak sıralanabilir.

Tez çalışması kapsamında makine öğrenmesi olarak DVM ve k-EYK, derin öğrenme olarak ise 2B ESA ve 3B ESA kullanılmıştır.

### 5.1. Destek Vektör Makinesi

Destek Vektör Makinesi (DVM) kavramı AT&T Bell laboratuvarlarında Vladimir Vapnik tarafından 1990'lı yıllarda bir dizi araştırma sonucu oluşturulmuştur (Cortes ve Vapnik, 1995). DVM, sınıflandırma ve regresyon analizi için etkili şekilde

kullanılabilir. DVM'nin temeli ilişkili öğrenme algoritmaları ve denetimli öğrenme modellerine dayanmaktadır.

DVM kullanılarak sınıflandırma yapılırken öncelikle giriş verisi çok boyutlu bir öznelik matrisine çevrilir. Daha sonra sınıflar arasındaki mesafeyi maksimize edecek şekilde bir optimum karar sınırı oluşturur. Optimum karar sınırının şekli kullanılan fonksiyonun türüne göre doğrusal veya doğrusal olmayandır (homojen polinomik, homojen olmayan polinomik veya radyal). Eşitlik (5.1)'de nokta çekirdek fonksiyonu, Eşitlik (5.2)'de polinom çekirdek fonksiyonu ve Eşitlik (5.3)'de radyal temelli çekirdek fonksiyonunun matematiksel tanımlaması yer almaktadır. Bu eşitliklerde yer alan  $K$  çekirdek fonksiyonunu temsil etmektedir. Çekirdek fonksiyonları DVM'de optimum karar sınırının belirlenmesinde kullanılan fonksiyonlardır.

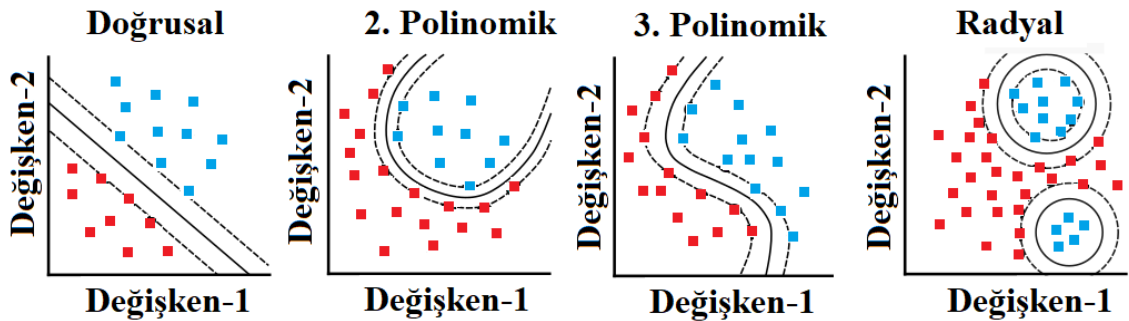
$$K(x, \bar{x}) = x \bar{x} \quad (5.1)$$

$$K(x, \bar{x}) = (x \bar{x} + c)^d \quad (5.2)$$

$$K(x, x') = \exp\left(-\frac{\left(\|x - x'\|\right)^2}{2\sigma^2}\right) \quad (5.3)$$

Eşitlik (5.1) ve Eşitlik (5.2)'de gerçekleştirilen çarpma işlemi noktasaldır. Eşitlik (5.2)'de  $c$  kaydırma parametresini ve  $d$  polinomun derecesini göstermektedir. Eşitlik (5.3)'de varyansı temsil eden  $\sigma$  ise gerçek bir pozitif tamsayıdır.

DVM kullanılarak iki veya çok sınıflı sınıflandırma gerçekleştirilebilir. Şekil 5.1'de bir veri kümesinin doğrusal, polinomik ve radyal çekirdek fonksiyonları kullanılarak sınıflandırılması görülmektedir.



Şekil 5.1. DVM'de kullanılan doğrusal, polinomik ve radyal çekirdek fonksiyon örnekleri

## 5.2. k-En Yakın Komşu

k-En Yakın Komşu (k-EYK) sınıflandırma ve regresyon uygulamalarında yaygın kullanıma sahip bir makine öğrenmesi yöntemidir. k-EYK'nin temelleri 1951 yılında Fix ve Hodges tarafından atılmış olup 1992 yılında Altman tarafından genişletilmiştir (Fix ve Hodges, 1951; Altman, 1992). Parametrik olmaması kullanımını kolaylaştırmaktadır. k-EYK temelde benzerlik tabanlı denetimli öğrenmeyi kullanmaktadır. Bu yöntem bir veri kümesinde sınıflandırması gerçekleştirilecek örneğe en yakın k adet komşuyu belirlemek ve örneği buna göre en uygun sınıfa yerleştirmek esasına dayanmaktadır.

k-EYK'nin eğitim işlemlerinde, eğitim setinde yer alan her bir örnek çok boyutlu uzayda bir noktayı temsil edecek şekilde yerleştirilir. Test işlemlerinde ise sınıflandırması yapılacak örnek için çok boyutlu uzayda en yakın olduğu k adet komşusu belirlenir. Daha sonra örneğin söz konusu komşularına göre uzaklıkları hesaplanarak ait olduğu sınıf belirlenir. Söz konusu uzaklığın hesaplanmasında Öklid mesafesinden yararlanılır (Thanh Noi ve Kappas, 2018). Koordinatları  $A(x_1, x_2, x_3, \dots, x_n)$  ve  $B(y_1, y_2, y_3, \dots, y_n)$  olan iki nokta arasındaki Öklid Mesafesi ( $\ddot{O}M$ ), *boyut* çok boyutlu uzayın boyut sayısı olmak üzere Eşitlik (5.4) ile hesaplanır.

$$\ddot{O}M = \sqrt{\sum_{i=1}^{boyut} (x_i - y_i)^2} \quad (5.4)$$

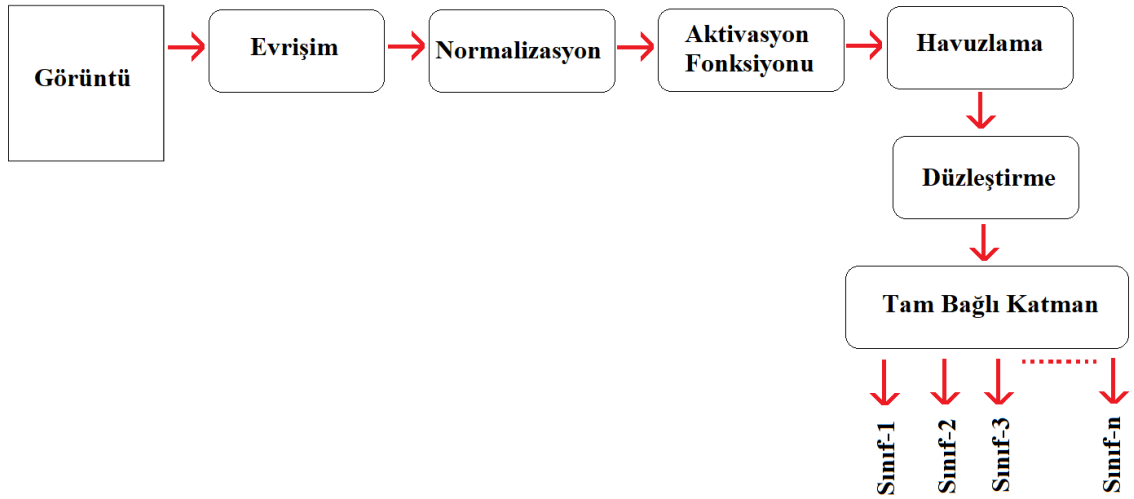
k-EYK yönteminde; komşu sayısının çok küçük seçilmesi durumunda hesaplama maliyetinin azalacağı ancak veri gürültüsü sebebiyle sınıflandırma doğruluğunun kısmi olarak bozulacağı, komşu sayısının çok büyük seçilmesi durumunda ise sınıflandırma doğruluğunun kısmi olarak artacağı ancak hesaplama maliyetinin de yükseleceği dikkate alınması gereken önemli bir olgudur. Bu sebeple pratik uygulamalarda komşu sayısının optimizasyonu genellikle deneme yanılma yoluyla gerçekleştirilir.

## 5.3. Evrişimli Sınır Ağları

Evrişimli Sınır Ağları (ESA) iki boyutlu ve üç boyutlu görüntülerde algılama, sınıflandırma ve bölütleme gibi bilgisayarlı görü uygulamalarında başarılı sonuçlar elde edilmesini sağlayan etkili bir derin öğrenme yöntemidir. ESA'nın ortaya atılması

1980'li yılların ikinci yarısında olmuştur (Atlas ve ark., 1987). Ancak, ESA'nın işletilmesi için yüksek bilgisayar donanımlarına ihtiyaç duyulması gelişimini yavaşlatmıştır. 2010'lu yıllarda donanım kapasiteleri ESA'yı kabul edilebilir sürelerde çalıştırmaya yetecek seviyelere ulaşmıştır. Bu yıllardan itibaren ESA kullanımı hızlı bir şekilde yaygınlaşmıştır. ESA'nın bir boyutlu uygulamaları da olmakla birlikte bilgisayarlı görü uygulamalarında genellikle iki boyutlu (2B) ESA mimarileri kullanılmaktadır. Ancak, son yıllarda bilgisayar donanım kapasitelerinin daha da güçlenmesiyle üç boyutlu (3B) ESA mimarileri de geliştirilmeye başlanmıştır.

2B ESA mimarileri 2B evrişim, aktivasyon fonksiyonu, 2B havuzlama ve tam bağlı katman gibi temel elemanlardan oluşur. Bir 2B ESA mimarisine bu elemanların yanı sıra isteğe bağlı olarak normalizasyon ve unutturma gibi katmanlar da eklenebilir. Evrişim ve havuzlama işlemlerin 2B yerine 3B işletilmesi ile 3B ESA mimarilerinin tasarlanması mümkündür. Diğer katmanlar 2B ESA ve 3B ESA mimarileri için benzer şekilde çalışmaktadır. Şekil 5.2'de bir ESA mimarisinin genel çalışma yapısı yer almaktadır.



Şekil 5.2. Bir ESA mimarisinin genel çalışma yapısı

### 5.3.1. Evrişim

ESA mimarilerinde evrişim katmanları giriş matrisini belirli ebatlardaki (örneğin  $3 \times 3$ ,  $5 \times 5$  veya  $7 \times 7$ ) filtreler ile evrişim işlemine sokmaktadır. İki matrisin evrişim işlemi Eşitlik (5.5) ile tanımlanabilir. Eşitlik (5.5)'de  $f$  ana matrisi  $h$  ise evrişim filtresini temsil etmektedir.

$$f(x, y) * h(x, y) = \sum_{n_1=-\infty}^{\infty} \sum_{n_2=-\infty}^{\infty} f(n_1, n_2) \times h(x-n_1, y-n_2) \quad (5.5)$$

Evrişim işlemi sonucu oluşan özellik matrisinin büyüklüğü ( $n_\phi$ ); giriş matris büyüklüğü ( $n_{giriş}$ ), filtre matris boyutu ( $f_i$ ), dolgu ekleme miktarı ( $e_k$ ) ve filtre kaydırma parametrelerine ( $kayma$ ) bağlıdır. Özellik matrisinin büyüklüğü Eşitlik (5.6) kullanılarak hesaplanabilir.

$$n_\phi = \frac{n_{giriş} + 2e_k - f_i}{kayma} + 1 \quad (5.6)$$

Örneğin, 4×4 büyüklüğündeki bir giriş matrisi ile 3×3 büyüklüğünde bir filtre, kaydırma parametresi 1 olacak şekilde dolgu ekleme yapılmaksızın evrişim işlemine sokulursa 2×2 büyüklüğünde bir özellik matris çıkışı elde edilir. Şekil 5.3’de örnek bir 2B evrişim işleminin yürütülmesi hesaplamaları ile birlikte anlatılmaktadır. Şekil 5.3’de görüldüğü üzere evrişim işlemi sonucunda özellik çıkış matrisinin büyüklüğünde giriş matrisine göre azalma olmaktadır. Söz konusu boyut azalması olmasının istenmediği durumlarda giriş matrisinin çevresine 0 değerli dolgu elemanları eklenir.

4	1	4	7
1	7	5	2
5	3	3	4
1	4	7	2

Giriş Matrisi

1	0	-1
1	0	-1
1	0	-1

Evrişim Matrisi

$$(4 \times 1) + (1 \times 1) + (5 \times 1) + (1 \times 0) + (7 \times 0) + (3 \times 0) + (4 \times -1) + (5 \times -1) + (3 \times -1) = -2$$

$$(1 \times 1) + (7 \times 1) + (3 \times 1) + (4 \times 0) + (5 \times 0) + (3 \times 0) + (7 \times -1) + (2 \times -1) + (4 \times -1) = -2$$

$$(1 \times 1) + (5 \times 1) + (1 \times 1) + (7 \times 0) + (3 \times 0) + (4 \times 0) + (5 \times -1) + (3 \times -1) + (7 \times -1) = 8$$

$$(7 \times 1) + (3 \times 1) + (4 \times 1) + (5 \times 0) + (3 \times 0) + (7 \times 0) + (2 \times -1) + (4 \times -1) + (2 \times -1) = 6$$

-2	-2
8	6

Çıkış Matrisi

Şekil 5.3. Örnek bir 2B evrişim işlemi

Eşitlik (5.7)'de  $f$  ana matrisi  $h$  ise evrişim filtresini temsil etmek üzere evrişim işlemi 3B olarak tanımlanmıştır.

$$f(x, y, z) * h(x, y, z) = \sum_{n_1=-\infty}^{\infty} \sum_{n_2=-\infty}^{\infty} \sum_{n_3=-\infty}^{\infty} f(n_1, n_2, n_3) \times h(x-n_1, y-n_2, z-n_3) \quad (5.7)$$

3B evrişim işlemi 2B evrişim işlemine benzer şekilde gerçekleştirilir. Bu aşamada temel fark giriş matrisi, evrişim matrisi ve çıkış matrisinin 3B olarak tanımlı olmasıdır.

### 5.3.2. Normalizasyon

ESA mimarilerinde evrişim işlemi sonucunda oluşan evrişim katmanları isteğe bağlı olarak normalize edilebilir. Normalizasyon işlemi, evrişim katmanının işlemlerde kullanılan bölümüne göre toplu normalizasyon, katman normalizasyonu ve grup normalizasyon şeklinde gerçekleştirilebilir. Toplu normalizasyonda, evrişim matrisi katman farkı gözetilmeksizin normalize edilmektedir. Katman normalizasyonunda evrişim katmanları kendi içlerinde normalize edilmektedir. Grup normalizasyon ise evrişim katmanlarındaki grupların kendi içlerinde normalizasyonudur. Şekil 5.4'de toplu normalizasyon, katman normalizasyonu ve grup normalizasyon işleminde kullanılan evrişim katman bölümleri yer almaktadır.



Şekil 5.4. Normalizasyon örnekleri (Wu ve He, 2018)

### 5.3.3. Aktivasyon fonksiyonları

Aktivasyon fonksiyonları kendisine gelen girişleri işlev özelliklerine göre çıkışlara dönüştüren araçlardır. Söz konusu fonksiyon giriş verisinin bir kısmını kesip kalan kısmını doğrudan veya dönüştürerek çıkışa verebilir. Ayrıca, özelliğine göre giriş



verisinin tamamını da dönüştürerek çıkışa gönderebilir. Dönüştürme işlemi doğrusal olabileceği gibi eğrisel veya adımsal da olabilir.

Adım fonksiyonu, tanjant hiperbolik fonksiyonu, ReLU fonksiyonu, softmax fonksiyonu, sigmoid fonksiyonu kullanımı yaygın aktivasyon fonksiyonlarıdır. Eşitlik (5.8)'de adım, Eşitlik (5.9)'da tanjant hiperbolik, Eşitlik (5.10)'da ReLU, Eşitlik (5.11)'de softmax ve Eşitlik (5.12)'de sigmoid fonksiyonlarının matematiksel eşitlikleri yer almaktadır.

$$y(x) = \begin{cases} 1 & \text{eğer } x \geq 0 \\ 0 & \text{eğer } x < 0 \end{cases} \quad (5.8)$$

$$y(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (5.9)$$

$$y(x) = \begin{cases} x & \text{eğer } x \geq 0 \\ 0 & \text{eğer } x < 0 \end{cases} \quad (5.10)$$

$$y(x_i) = \frac{e_i^x}{\sum_i e_i^x}; i = 0, 1, 2, \dots, k \quad (5.11)$$

$$y(x) = \frac{1}{1 + e^{-x}} \quad (5.12)$$

#### 5.3.4. Havuzlama

ESA mimarilerinde evrişim katmanlarının doğrudan kullanılması durumunda hesaplama yükü artacağı için havuzlama yapılarak evrişim katmanlarının boyutları azaltılır. Havuzlama, evrişim katmanının boyutları indirgenmiş örneklerinin oluşturulmasıdır. 2B havuzlama işlemi 2×2, 3×3 gibi boş çerçeveler tanımlanarak gerçekleştirilir. Evrişim katmanı aynı büyüklüğe eşlenecek şekilde parçalara ayrılır. Her parçanın havuzlama karşılığı boş çerçevenin ilgili elemanına yazılır. Havuzlama işlemi ortalama değeri dikkate alma şeklinde yapılabileceği gibi maksimum değeri dikkate alma şeklinde de gerçekleştirilebilir. Şekil 5.5'de 4×4 boyutlarında bir 2B evrişim katmanının ortalama ve maksimum havuzlama ile elde edilen boyutları azaltılmış çıkış matrisinin hesaplanması yer almaktadır. Havuzlama işlemi 3B evrişim katmanları ve 3B boş çerçeveler kullanılarak kolaylıkla 3B'ye genişletilebilir.


130	125	141	154		
140	117	147	146		
151	149	154	130	128	147
138	146	132	140	146	139

**Evrişim Özellik Matrisi**      **Ortalama Havuzlama**      **Maksimum Havuzlama**

Şekil 5.5. Örnek bir 2B ortalama havuzlama ve maksimum havuzlama işlemi

### 5.3.5. Düzleştirme

Evrişim katmanı, normalizasyon katmanı, aktivasyon fonksiyonu ve havuzlama işlemleri sonucunda elde edilen görüntü özellikleri matris formundadır. Bu aşamadan sonra tam bağlı katmana geçiş yapılabilmesi için söz konusu özellik matrislerinin özellik vektörlerine çevrilmesi yani düzleştirilmesi gerekmektedir. Şekil 5.6'da  $3 \times 3$  boyutlarında örnek bir 2B özellik matrisinin düzleştirilerek özellik vektörüne çevrilmesi görülmektedir. 3B ESA uygulamalarında 3B özellik matrisleri de aynı şekilde düzleştirilerek vektör formuna çevrilir.

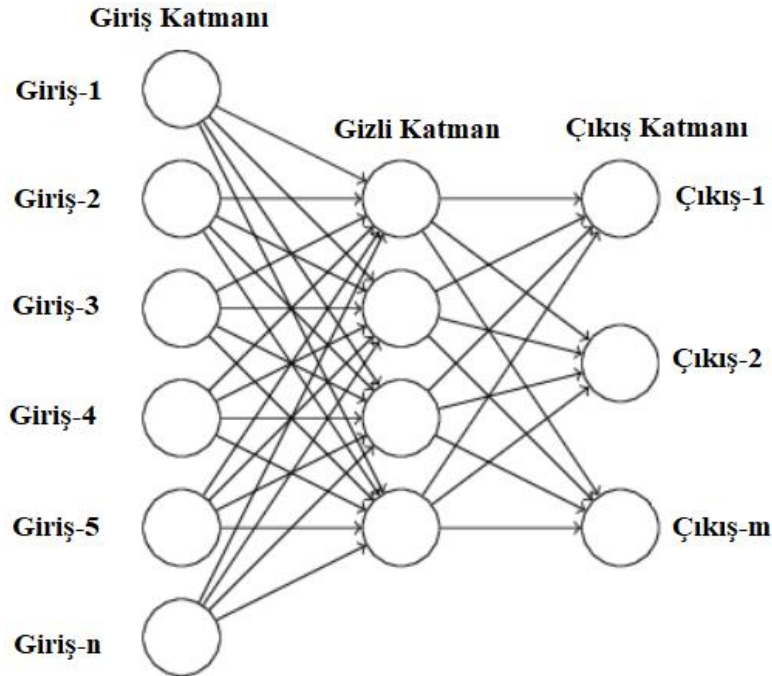


Şekil 5.6. Örnek bir düzleştirme işlemi

### 5.3.6. Tam bağı katman

Evrişim katmanı, normalizasyon katmanı, aktivasyon fonksiyonu, havuzlama ve düzleştirme sonucu elde edilen özellik vektörleri kullanılarak eğitim işlemleri tam bağı katmanda gerçekleştirilir. Tam bağı katman DVM, k-EYK veya yapay sinir ağı gibi bir makine öğrenmesi yönteminden seçilebilir. Ancak, uygulamalarda genellikle tam bağı katman olarak geri yayılım ileri besleme yapay sinir ağları kullanılmaktadır.

Yapay sinir ağları giriş katmanı, gizli katman ve çıkış katmanı olmak üzere üç temel bileşenden oluşmaktadır. Giriş katmanı, yapay sinir ağlarına dış dünyadan gelen girişlerin verildiği katmandır. Giriş katmanının nöron sayısı giriş verisinin büyüklüğüne eşittir. Giriş katmanının çıkışı gizli katmana bağlıdır. Gizli katman tek bir katmandan olabileceği gibi birden fazla katmanın arka arkaya sıralanmasıyla da oluşabilir. Gizli katmanda yer alan nöron sayıları giriş verisi ve çıkış büyüklüğüne bağı değildir. Kullanıcı tasarımına göre belirlenmektedir. Gizli katman içinde yer alan katman dizileri birbirilerinden farklı nöron sayılarına sahip olabilirler. Çıkış katmanı, gizli katmandan gelen verilerin yapay sinir ağından dışarıya aktarıldığı katmandır. Şekil 5.7’de bir yapay sinir ağının genel katman yapısı görülmektedir.



Şekil 5.7. Yapay sinir ağı katman yapısı

Geri yayılım ileri besleme yapay sinir ağlarının eğitiminde rastgele atanan başlangıç ağırlıkları ile ileri besleme yapılarak çıkışlar elde edilir. Daha sonra giriş verileri için elde edilen çıkışlar ile gerçek sonuçların arasındaki fark yani hata hesaplanır. Üçüncü aşamada hata miktarına göre geri yayılım yapılır ve ağırlıkların güncellenmesi gerçekleştirilir. Söz konusu süreç belirli bir hata hedefine veya başlangıçta belirlenen maksimum iterasyon sayısına ulaşıncaya kadar tekrarlanır. Bu sayede ağırlık eğitimi aşama aşama ilerletilir. Eşitlik (5.13) geri yayılım ileri besleme yapay sinir ağlarında hatanın matematiksel olarak hesaplanmasını göstermektedir. Eşitlik (5.13)'de  $H$  hatayı,  $mn$  eğitimde kullanılan eleman sayısını,  $B_{çıkış}$  ağdan alınması beklenen çıkışı ve  $G_{çıkış}$  ise ağdan alınan gerçek çıkışı temsil etmektedir.

$$H = \frac{1}{mn} \sum_{i=1}^{mn} (B_{çıkış(i)} - G_{çıkış(i)})^2 \quad (5.13)$$

Eşitlik (5.14) ise  $H$  hatayı,  $\omega_i$  mevcut ağırlığı,  $\eta$  öğrenme oranını ve  $\omega$  hesaplanan yeni ağırlığı temsil etmek üzere ağırlıkların güncellenmesini göstermektedir.

$$\omega = \omega_i - \eta \frac{dH}{d\omega} \quad (5.14)$$

### 5.3.7. Unutturma

Unutturma, tam bağlı katmanda kullanılan yapay sinir ağı mimarisinde yer alan bazı nöronların eğitim işlemleri sırasında düşürülmesi bir başka deyişle 0 değerine eşitlenmesi ile gerçekleştirilir. Söz konusu unutturma her iterasyonda rastgele yapılır. Unutturma işleminin kullanılmasının temel amacı, ağırlık eğitimi sırasında ezberlemenin yani aşırı uyum sorununun önüne geçilmesidir. Bu sayede geri yayılım tüm ağırlıkları etkileyecek şekilde daha efektif olarak gerçekleştirilmektedir. Ayrıca; gerçekleştirilen eğitim, ağırlık ilk katmanlarına kadar ulaşmaktadır.

### 5.3.8. ESA hiperparametreleri

ESA mimarilerinin eğitiminde, sürecin yönetilmesi için bazı değişkenler kullanılmaktadır. Bu değişkenler, doğrudan ESA mimarisinin bir parçası değildir. Yani, aynı ESA mimarisinin farklı değişkenler kullanılarak farklı farklı eğitilmesi mümkündür. Ancak, eğitimlerde farklı değişkenler kullanılması ESA mimarilerinden elde edilen sonuçları doğrudan etkilemektedir. Söz konusu değişkenler öğrenme oranı, momentum,

optimizasyon algoritması, küme boyutu, hata hedefi ve maksimum iterasyon sayısı olarak sıralanabilir.

Eğitim süreçlerinde yapay sinir ağı ağırlıklarının güncellenmesi için hatanın türevi alınarak geri yayılım işlemi gerçekleştirilmektedir. Eşitlik 5.14’de görüldüğü gibi hatanın türevi öğrenme oranı olarak adlandırılan bir değişkenle çarpılarak etkisi ayarlanabilmektedir. Öğrenme oranının yüksek seçilmesi yerel minimumların kaçırılmasına neden olurken küçük seçilmesi hedefe yaklaşmayı geciktirmekte yani eğitim işlemlerini uzatmaktadır.

Yapay sinir ağı eğitiminde iterasyonlar arasında hata miktarındaki değişime bağlı olarak bazı salınımların olması muhtemeldir. Söz konusu salınımların azaltılması için ağı tarafından üretilen değerler belirli bir momentum katsayısı ile çarpılarak dikkate alınır. Bu şekilde eğitim sürecinin daha efektif ilerlemesi sağlanmaktadır.

Eğitimlerde hata fonksiyonunun minimize edilmesi için bazı optimizasyon yaklaşımları kullanılır. Bu kapsamda en çok tercih edilen optimizasyon yaklaşımı stokastik gradyan iniş yöntemidir (Amari, 1993).

Yapay sinir ağı eğitiminde, kullanılan bütün verilerin aynı anda ağı verilerek sonuç üretilmesi ve hatanın hesaplanması donanımsal olarak oldukça ağır bir yük oluşturmaktadır. Söz konusu işlemlerin maliyetini hafifletmek için giriş verileri belirli boyutlarda kümelere bölünerek ağı verilir. Elde edilen küme çıkışları için ağırlık güncellemesi yapılarak eğitim süresi kısaltılır.

Yapay sinir ağı eğitimi, başlangıçta belirlenen hedef değerinin daha aşağısında bir hata sonucu elde edilmesi durumunda otomatik olarak durdurulur. Hedeflenen hata miktarlarına ulaşılamaması durumunda belirlenen maksimum iterasyon sayısına ulaşıldığında eğitim işlemleri sonlandırılmaktadır. Hata hedefinin aşırı düşük seçildiği durumlarda maksimum iterasyon sayısının belirlenmemesi eğitim işleminin sonsuz döngülere girmesine sebep olabilir. Bu sebeple eğitim işlemleri, belirlenen hata hedefine veya maksimum iterasyon sayısına ulaşılması durumunda otomatik olarak sonlandırılır. Hata hedeflerinin aşırı düşük seçilmesi ağı aşırı uyum sorunu ile karşılaşmasına neden olabilir. Bu sebeple, hata hedefi ve maksimum iterasyon sayısının uygulama ihtiyacına göre doğru şekilde belirlenmesi ağı başarısı için önemlidir.

#### **5.4. Tez Çalışmasında Kullanılan ESA Mimarileri**

Tez çalışmasında kullanılan bazı ESA mimarileri uygulamaya özel olarak oluşturulmuş ve kullanılmıştır. Bazı ESA mimarileri ise daha önce başka araştırmacılar

tarafından oluşturulan ESA mimarilerinden transfer edilmiştir. Bu aşamada sadece mimari transferi yapılmış olup herhangi bir başlangıç ağırlık transferi gerçekleştirilmemiştir. Tez çalışmasında ESA mimarileri MATLAB programı kullanılarak oluşturulmuş veya transfer edilmiştir.

## 5.5. Tez Çalışmasında Özel Olarak Oluşturulan ESA Mimarileri

Tez çalışmasında 23 katmanlı 2B ESA, 24 katmanlı 2B ESA, 54 katmanlı 2B ESA ve 24 katmanlı 3B ESA olmak üzere toplam dört adet ESA mimarisi oluşturulmuştur. ESA mimarilerinde varsayılan olarak kullanılan parametrelerin anlamlarına ve değerlerine MathWorks sayfası (MathWorks, 2022(a)) üzerinden ulaşılması mümkündür.

### 5.5.1. 23 katmanlı 2B ESA mimarisi

Tez çalışmasının birinci ve beşinci uygulamasında kullanılmak üzere 23 katmanlı bir 2B ESA mimarisi tasarlanmıştır. Bu uygulamalarda birbirinden farklı boyutlarda birçok giriş görüntüsü için işlemler gerçekleştirilmiştir. Bu sebeple 23 katmanlı 2B ESA mimarisinin görüntü giriş katmanının boyutları değişkenlik göstermektedir. Söz konusu görüntü giriş katmanı tez çalışmasının birinci uygulamasında  $448 \times 448 \times 1$ ,  $448 \times 448 \times 2$ ,  $448 \times 448 \times 3$  ve  $448 \times 448 \times 4$  olmak üzere dört farklı; tez çalışmasının beşinci uygulamasında ise  $448 \times 448 \times 1$ ,  $224 \times 224 \times 1$ ,  $224 \times 224 \times 2$ ,  $224 \times 224 \times 3$  ve  $224 \times 224 \times 6$  olmak üzere beş farklı versiyona sahiptir. 23 katmanlı 2B ESA mimarisi birbiri ardına sıralanan dört grup 2B evrişim, toplu normalizasyon, ReLU ve 2B havuzlama katmanından oluşmaktadır. 2B evrişim katmanında kullanılan filtre boyutları  $3 \times 3$ 'dür. Filtre sayısı ise ilk 2B evrişim katmanında 4 olarak seçilmiş olup her evrişim katmanında 2 ile çarpılarak kademeli olarak artırılmıştır. Bu sayede genel özelliklerden yerel özelliklere doğru etkili bir özellik çıkarma yapılması hedeflenmiştir. Son olarak içinde havuzlama katmanı yer almayan 2B evrişim, toplu normalizasyon, ReLU katman grubu mimariye yerleştirilmiştir. Bu katman grubundan sonra ise yapay sinir ağı içeren tam bağlı katman eklenmiştir. Tez çalışmasının birinci ve beşinci uygulamasında iki sınıflı sınıflandırma yapıldığı için çıkış büyüklüğü 2 olarak belirlenmiştir. Tam bağlı katmanının çıkışında aktivasyon fonksiyonu olarak softmax kullanılmıştır. Son olarak sınıflandırma katmanı eklenerek 23 katmanlı 2B ESA

mimarisinin tasarımı tamamlanmıştır. 23 katmanlı 2B ESA mimarisinin katmanları ve parametreleri MATLAB program kodlamasına uygun olarak Çizelge 5.1’de yer almaktadır.

**Çizelge 5.1.** 23 katmanlı 2B ESA mimarisi

Katman Numarası	Katman İsmi	Katman Parametreleri (MATLAB)
1	imageInputLayer	[448 448 1], [448 448 2], [448 448 3], [448 448 4], [224 224 1], [224 224 2], [224 224 3], [224 224 6]
2	convolution2dLayer	(3,4,'Padding','same')
3	batchNormalizationLayer	default
4	reluLayer	default
5	maxPooling2dLayer	(2,'Stride',2)
6	convolution2dLayer	(3,8,'Padding','same')
7	batchNormalizationLayer	default
8	reluLayer	default
9	maxPooling2dLayer	(2,'Stride',2)
10	convolution2dLayer	(3,16,'Padding','same')
11	batchNormalizationLayer	default
12	reluLayer	default
13	maxPooling2dLayer	(2,'Stride',2)
14	convolution2dLayer	(3,32,'Padding','same')
15	batchNormalizationLayer	default
16	reluLayer	default
17	maxPooling2dLayer	(2,'Stride',2)
18	convolution2dLayer	(3,64,'Padding','same')
19	batchNormalizationLayer	default
20	reluLayer	default
21	fullyConnectedLayer	2
22	softmaxLayer	default
23	classificationLayer	default

### 5.5.2. 24 katmanlı 2B ESA mimarisi

Tez çalışmasının ikinci uygulamasında 24 katmanlı 2B ESA mimarisi kullanılmıştır. Söz konusu mimarinin 23 katmanlı 2B ESA mimarisinden birinci farklılığı tam bağlı katmandan önce unutturma katmanı eklenmiş olmasıdır. Unutturma katmanı, ağız ezberlemesi yani aşırı uyum sorununa karşı bir önlem olarak mimariye eklenmiştir. İkinci farklı yönü ise uygulamanın ihtiyacına göre giriş görüntü büyüklüklerinin yeniden düzenlenmesidir. Tez çalışmasının ikinci uygulamasında giriş görüntüleri  $448 \times 448 \times 1$ ,  $224 \times 224 \times 1$ ,  $224 \times 224 \times 2$ ,  $224 \times 224 \times 3$ ,  $112 \times 112 \times 1$ ,  $112 \times 112 \times 2$  ve  $112 \times 112 \times 3$  olmak üzere yedi farklı versiyona sahiptir. 24 katmanlı 2B ESA mimarisinin katmanları ve parametreleri MATLAB program kodlamasına uygun olarak Çizelge 5.2’de verilmiştir.

Çizelge 5.2. 24 katmanlı 2B ESA mimarisi

Katman Numarası	Katman İsmi	Katman Parametreleri (MATLAB)
1	imageInputLayer	[448 448 1], [224 224 1], [224 224 2], [224 224 3], [112 112 1], [112 112 2], [112 112 3]
2	convolution2dLayer	(3,4,'Padding','same')
3	batchNormalizationLayer	default
4	reluLayer	default
5	maxPooling2dLayer	(2,'Stride',2)
6	convolution2dLayer	(3,8,'Padding','same')
7	batchNormalizationLayer	default
8	reluLayer	default
9	maxPooling2dLayer	(2,'Stride',2)
10	convolution2dLayer	(3,16,'Padding','same')
11	batchNormalizationLayer	default
12	reluLayer	default
13	maxPooling2dLayer	(2,'Stride',2)
14	convolution2dLayer	(3,32,'Padding','same')
15	batchNormalizationLayer	default
16	reluLayer	default
17	maxPooling2dLayer	(2,'Stride',2)
18	convolution2dLayer	(3,64,'Padding','same')
19	batchNormalizationLayer	default
20	reluLayer	default
21	dropoutLayer	0,5
22	fullyConnectedLayer	2
23	softmaxLayer	default
24	classificationLayer	default

### 5.5.3. 54 katmanlı 2B ESA mimarisi

Tez çalışmasının beşinci uygulamasında 54 katmanlı bir 2B ESA mimarisi kullanılmıştır. Söz konusu ESA mimarisi temel olarak 2B VGG-16 ESA (Simonyan ve Zisserman, 2014) mimarisi üzerinden tasarlanmıştır. Ancak, söz konusu mimari doğrudan transfer edilmeyip bazı katmanlar ilave edildiği ve parametrelerde değişiklikler yapıldığı için yeniden isimlendirilmiştir. 54 katmanlı 2B ESA mimarisinin katmanları ve parametreleri MATLAB program kodlamasına uygun olarak Çizelge 5.3'de yer almaktadır. 54 katmanlı 2B ESA mimarisinde 2B VGG-16 ESA mimarisinde yer alan 2B evrişim katmanlarının arkasına toplu normalizasyon katmanları eklenmiştir. Tez çalışmasının beşinci uygulamasında KDDD kullanılarak elde edilen görüntü alt bantları da giriş olarak kullanılmıştır. Söz konusu alt bantlar çeşitli seviyede frekans bilgisi içerdiği için ağırlıkta normalize edilerek kullanılması gerekmektedir. Bu kapsamda 54 katmanlı 2B ESA mimarisine 2B VGG-16 ESA mimarisine göre 11 yeni toplu normalizasyon katmanı eklenmiştir. VGG-16 ESA mimarisinde evrişim işlemlerinde kullanılan filtre sayıları yüksek olduğu için işlem maliyeti artmaktadır.



Çizelge 5.3. 54 katmanlı 2B ESA mimarisi

Katman Numarası	Katman İsmi	Katman Parametreleri (MATLAB)
1	imageInputLayer	[448 448 1], [224 224 1], [224 224 2], [224 224 3], [224 224 6]
2	convolution2dLayer	(3,8,'Padding','same')
3	batchNormalizationLayer	default
4	reluLayer	default
5	convolution2dLayer	(3,8,'Padding','same')
6	batchNormalizationLayer	default
7	reluLayer	default
8	maxPooling2dLayer	(2,'Stride',2)
9	convolution2dLayer	(3,16,'Padding','same')
10	batchNormalizationLayer	default
11	reluLayer	default
12	convolution2dLayer	(3,16,'Padding','same')
13	batchNormalizationLayer	default
14	reluLayer	default
15	maxPooling2dLayer	(2,'Stride',2)
16	convolution2dLayer	(3,32,'Padding','same')
17	batchNormalizationLayer	default
18	reluLayer	default
19	convolution2dLayer	(3,32,'Padding','same')
20	batchNormalizationLayer	default
21	reluLayer	default
22	convolution2dLayer	(3,32,'Padding','same')
23	batchNormalizationLayer	default
24	reluLayer	default
25	maxPooling2dLayer	(2,'Stride',2)
26	convolution2dLayer	(3,64,'Padding','same')
27	batchNormalizationLayer	default
28	reluLayer	default
29	convolution2dLayer	(3,64,'Padding','same')
30	batchNormalizationLayer	default
31	reluLayer	default
32	convolution2dLayer	(3,64,'Padding','same')
33	batchNormalizationLayer	default
34	reluLayer	default
35	maxPooling2dLayer	(2,'Stride',2)
36	convolution2dLayer	(3,64,'Padding','same')
37	batchNormalizationLayer	default
38	reluLayer	default
39	convolution2dLayer	(3,64,'Padding','same')
40	batchNormalizationLayer	default
41	reluLayer	default
42	convolution2dLayer	(3,64,'Padding','same')
43	batchNormalizationLayer	default
44	reluLayer	default
45	maxPooling2dLayer	(2,'Stride',2)
46	fullyConnectedLayer	512
47	reluLayer	default
48	dropoutLayer	0,5
49	fullyConnectedLayer	512
50	reluLayer	default
51	dropoutLayer	0,5
52	fullyConnectedLayer	2
53	softmaxLayer	default
54	classificationLayer	default

54 katmanlı 2B ESA mimarisinde işlem maliyetlerinin azaltılması için filtre sayıları her 2B evrişim katmanında 8’de 1 oranında azaltılmıştır. Tam bağlı katman çıkışları da buna uygun olarak revize edilmiştir. Tez çalışmasının beşinci uygulamasında görüntü girişleri  $448 \times 448 \times 1$ ,  $224 \times 224 \times 1$ ,  $224 \times 224 \times 2$ ,  $224 \times 224 \times 3$  ve  $224 \times 224 \times 6$  olmak üzere beş farklı versiyona sahip olduğu için 54 katmanlı 2B ESA mimarisinin görüntü giriş katmanı buna uygun olarak yeniden düzenlenmiştir. Ayrıca, 2B VGG-16 mimarisinin tam bağlı katman çıkış büyüklüğü 1000’dir. Tez çalışmasının beşinci uygulamasında iki sınıflı sınıflandırma yapıldığı için çıkış büyüklüğü 2 olarak yeniden düzenlenmiştir.

#### 5.5.4. 24 katmanlı 3B ESA mimarisi

Tez çalışmasının altıncı uygulamasında  $224 \times 224 \times 24 \times 1$  boyutlarında 3B giriş görüntüleri oluşturularak sınıflandırma işlemi gerçekleştirilmiştir. Bu kapsamda 24 katmanlı bir 3B ESA mimarisi oluşturulmuştur. Söz konusu mimari daha önce detayları açıklanan 24 katmanlı 2B ESA mimarisinin 2B giriş, evrişim ve havuzlama katmanlarının 3B versiyonları ile değiştirilmesi ile oluşturulmuştur. 24 katmanlı 3B ESA mimarisinin katmanları ve parametreleri Çizelge 5.4’de yer almaktadır.

Çizelge 5.4. 24 katmanlı 3B ESA mimarisi

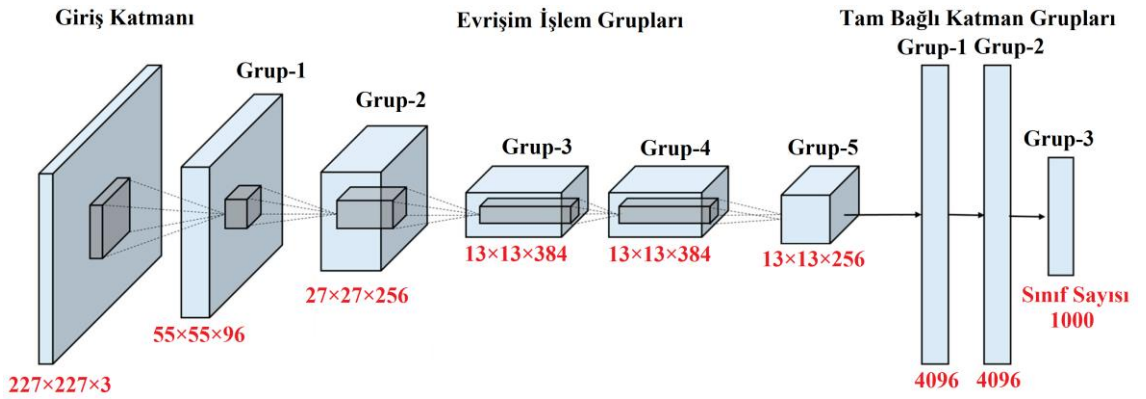
Katman Numarası	Katman İsmi	Katman Parametreleri (MATLAB)
1	Image3dInputLayer	[224 224 24 1]
2	Convolution3dLayer	(3,4,'Padding','same')
3	batchNormalizationLayer	default
4	reluLayer	default
5	maxPooling3dLayer	(2,'Stride',2)
6	Convolution3dLayer	(3,8,'Padding','same')
7	batchNormalizationLayer	default
8	reluLayer	default
9	maxPooling3dLayer	(2,'Stride',2)
10	Convolution3dLayer	(3,16,'Padding','same')
11	batchNormalizationLayer	default
12	reluLayer	default
13	maxPooling3dLayer	(2,'Stride',2)
14	Convolution3dLayer	(3,32,'Padding','same')
15	batchNormalizationLayer	default
16	reluLayer	default
17	maxPooling3dLayer	(2,'Stride',2)
18	Convolution3dLayer	(3,64,'Padding','same')
19	batchNormalizationLayer	default
20	reluLayer	default
21	dropoutLayer	0,5
22	fullyConnectedLayer	2
23	softmaxLayer	default
24	classificationLayer	default

## 5.6. Tez Çalışmasında Transfer Edilerek Kullanılan ESA Mimarileri

Tez çalışmasında 2B AlexNet, 2B MobileNetV2, 2B ResNet-101, 2B GoogleNet, 2B InceptionV3, 2B Xception, 2B DenseNet-201, 2B EfficientNetB0 ve 2B DarkNet-53 olmak üzere toplam dokuz adet 2B ESA mimarisi transfer edilmiş ve kullanılmıştır. Bu aşamada sadece mimari transferi yapılmış olup herhangi bir başlangıç ağırlık transferi gerçekleştirilmemiştir. Tez çalışmasında ESA mimarileri MATLAB programı kullanılarak transfer edilmiştir. Söz konusu ESA mimarisinin katmanları ve parametreleri hakkındaki ayrıntılı bilgilerin sırasıyla ilgili MathWorks sayfalarından (MathWorks, 2022(b)-MathWorks, 2022(j)) incelenmesi mümkündür.

### 5.6.1. 2B AlexNet ESA mimarisi

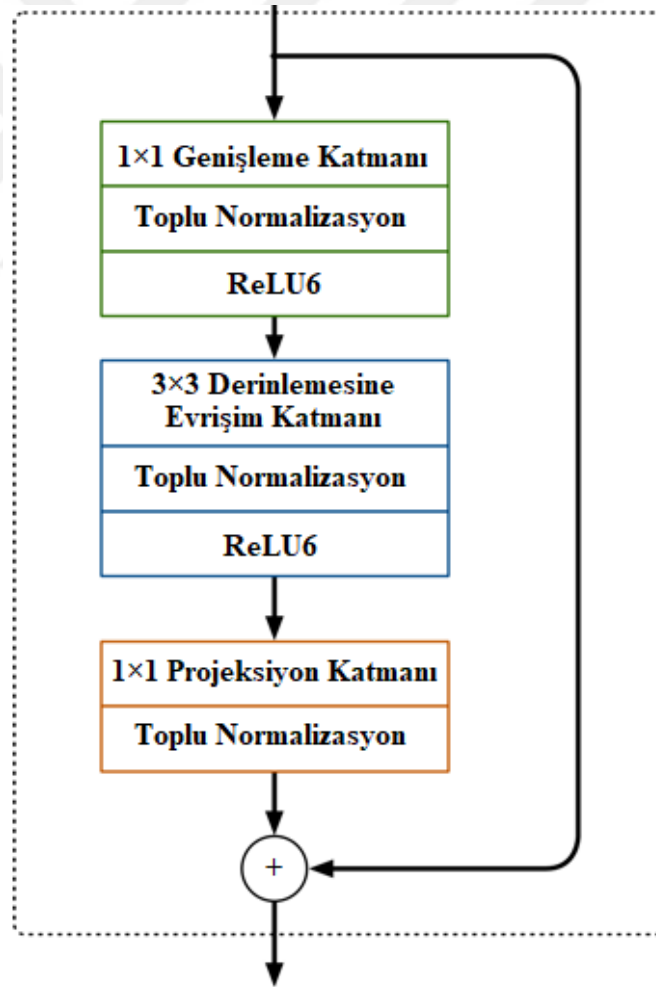
2B AlexNet ESA mimarisi 2012 yılında Alex Krizhevsky ve arkadaşları tarafından tasarlanmıştır (Krizhevsky ve ark., 2012). 2B AlexNet ESA mimarisinde katmanlar birbiri ardına dizilerek bağlantılanmıştır. Yani, mimari seri bir katman dizilim yapısına sahiptir. 2B AlexNet ESA mimarisi giriş katmanı, arka arkaya sıralanmış beş adet evrişim işlem gurubu ve üç adet tam bağlı katman grubundan oluşmaktadır. Giriş görüntü boyutları  $227 \times 227 \times 3$  ve tam bağlı katman çıkış büyüklüğü 1000'dir. Şekil 5.8'de 2B AlexNet ESA mimarisinin genel yapısı yer almaktadır.



Şekil 5.8. 2B AlexNet ESA mimarisinin genel yapısı (Han ve ark., 2017)

### 5.6.2. 2B MobileNetV2 ESA mimarisi


2B MobileNetV2 ESA mimarisi 2018 yılında Mark Sandler ve arkadaşları tarafından önerilmiştir (Sandler ve ark., 2018). Söz konusu mimari genel olarak mobil cihazlarda etkili kullanım sunmayı amaçlamaktadır. 2B MobileNetV2 ESA mimarisi darboğaz kalıntı katmanı ismi verilen genişleme, derinlemesine evrişim ve projeksiyon katman bileşenlerinden oluşan grupların arka arkaya dizilmesi ile oluşturulmuştur. Şekil 5.9, 2B MobileNetV2 ESA mimarisinde kullanılan darboğaz kalıntı katman gruplarının iç yapısını göstermektedir. 2B MobileNetV2 ESA mimarisinde giriş görüntü boyutları  $224 \times 224 \times 3$  ve tam bağlı katman çıkış büyüklüğü 1000'dir. 2B MobileNetV2 ESA giriş katmanı, evrişim katmanı, yedi adet darboğaz kalıntı katmanı, bu grupların arkasından gelen iki adet evrişim katmanı ve tam bağlı katmandan meydana gelmektedir.



Şekil 5.9. 2B MobileNetV2 ESA mimarisinde kullanılan darboğaz kalıntı katmanlarının iç yapısı (Endachev ve ark., 2019)

### 5.6.3. 2B ResNet-101 ESA mimarisi


2B ResNet-101 ESA mimarisi 2016 yılında He ve arkadaşları tarafından tasarlanmıştır (He ve ark., 2016). 2B ESA mimarilerinde katman sayısının belirli bir noktadan sonra aşırı artırılması sınıflandırma doğruluğunun buna paralel olarak artacağı anlamına gelmemektedir. Bunun temel sebebi ağ büyüklüğü arttıkça ağırlıkların optimize edilmesi probleminin daha da zorlaşmasıdır. 2B ResNet-101 ESA mimarisi seri bağlanmış çok sayıda katmanı artık bloklar olarak isimlendirilen katman grupları kullanarak birbirleri ile ilişkilendirmektedir. Bu mimarinin giriş görüntü boyutları  $224 \times 224 \times 3$  ve tam bağlı katman çıkış büyüklüğü 1000'dir. Şekil 5.10'da 2B ResNet-101 ESA mimarisinin genel yapısı yer almaktadır.



Şekil 5.10. 2B ResNet-101 ESA mimarisinin genel yapısı

#### 5.6.4. 2B GoogleNet ESA mimarisi

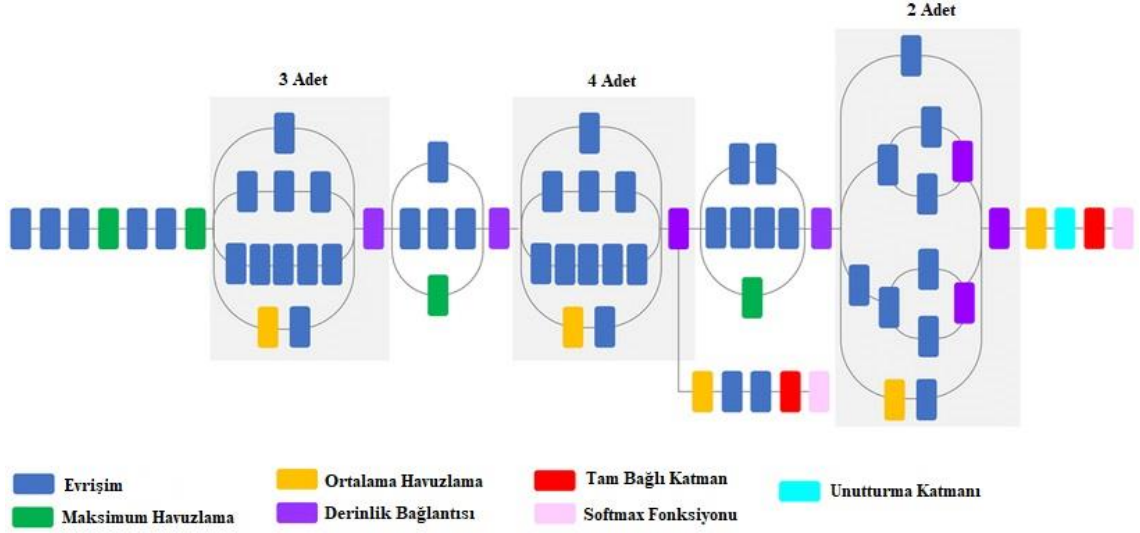
2B GoogleNet ESA mimarisi 2B Inception ESA mimarisinin birinci versiyonu olarak da bilinmektedir. 2B GoogleNet, Google şirketi bünyesinde Szegedy ve arkadaşları tarafından gerçekleştirilen araştırmalar sonucu 2015 yılında ortaya çıkmıştır (Szegedy ve ark., 2015). Söz konusu mimarinin temeli giriş modülü olarak isimlendirilen ve evrişim işlemlerinin aynı anda paralel şekilde yürütüldüğü katman gruplarına dayanmaktadır. 2B GoogleNet ESA mimarisi birçok giriş modülünün birbirine bağlandığı toplam 22 katman seviyesinden meydana gelmektedir. Kullanılan parametre sayısı 4 milyon civarında olup bu sayı diğer 2B ESA mimarilerine göre oldukça düşüktür. 2B GoogleNet ESA mimarisinin giriş görüntü boyutları  $224 \times 224 \times 3$  ve tam bağlı katman çıkış büyüklüğü 1000'dir. Şekil 5.11'de 2B GoogleNet ESA mimarisinde kullanılan giriş modüllerinin iç yapısı yer almaktadır.



Şekil 5.11. 2B GoogleNetV2 ESA mimarisinde kullanılan giriş modüllerinin iç yapısı

#### 5.6.5. 2B InceptionV3 ESA mimarisi

2B InceptionV3 ESA mimarisi, 2B GoogleNet ESA mimarisinin süreç içinde geliştirilmiş yeni versiyonudur (Szegedy ve ark., 2016). 2B InceptionV3 ESA mimarisinin temelleri de benzer şekilde giriş modüllerine dayanmaktadır. Ancak, giriş modülleri 2B GoogleNet ESA mimarisine göre daha fazla eleman içerecek şekilde ve daha karmaşık bir yapıda tasarlanmıştır. 2B InceptionV3 ESA mimarisinin giriş görüntü boyutları  $299 \times 299 \times 3$  ve tam bağlı katman çıkış büyüklüğü 1000'dir. Şekil 5.12'de 2B InceptionV3 ESA mimarisinin genel yapısı yer almaktadır.




Şekil 5.12. 2B InceptionV3 ESA mimarisinin genel yapısı (Mahdianpari ve ark., 2018)

### 5.6.6. 2B Xception ESA mimarisi

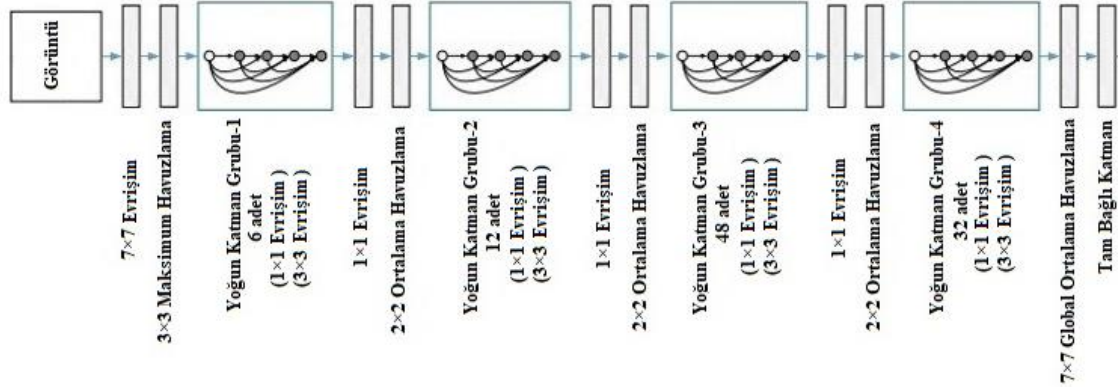
2B Xception ESA mimarisi Chollet tarafından 2017 yılında ortaya atılmıştır (Chollet, 2017). Genel olarak 2B InceptionV3 ESA mimarisinden esinlenerek tasarlanmıştır. 2B Xception ESA mimarisinin 2B InceptionV3 ESA mimarisinden temel farklılığı noktasal evrişim katmanının evrişim katmanından sonra değil önce gelmesidir. 2B Xception ESA mimarisinin giriş görüntü boyutları  $299 \times 299 \times 3$  ve tam bağlı katman çıkış büyüklüğü 1000'dir.

### 5.6.7. 2B DenseNet-201 ESA mimarisi

2B DenseNet-201 ESA mimarisi Huang ve arkadaşları tarafından 2017 yılında ortaya atılmıştır (Huang ve ark., 2017). 2B DenseNet-201 ESA mimarisinde eğitim işlemlerin ilk katmanlara kadar derinlemesine gerçekleştirilebilmesi için yoğun katman grupları tanımlanmıştır. Buna göre standart ESA mimarilerine benzer şekilde her yoğun katman grubunun çıkış matrisi bir sonraki yoğun katman grubunun giriş matrisidir. Ancak, yoğun katman grubu içinde yer alan her katman önündeki katman blokları ile ayrı ayrı bağlantılıdır. 2B DenseNet-201 ESA mimarisinin giriş görüntü boyutları  $224 \times 224 \times 3$  ve tam bağlı katman çıkış büyüklüğü 1000'dir. Şekil 5.13'de beş katmanlı bir yoğun katman grubunun iç yapısı yer almaktadır. Şekil 5.14'de ise 2B DenseNet-201 ESA mimarisinin genel yapısı görülmektedir.



Şekil 5.13. 2B DenseNet ESA mimarisinde kullanılan örnek bir yoğun katman grubunun (beş katmanlı) iç yapısı (Huang ve ark., 2017)




Şekil 5.14. 2B DenseNet-201 ESA mimarisinin genel yapısı (Huang ve ark., 2017)

### 5.6.8. 2B EfficientNetB0 ESA mimarisi

2B EfficientNetB0 ESA mimarisi Tan ve Le tarafından 2019 yılında ortaya atılmıştır (Tan ve Le, 2019). 2B EfficientNetB0 ESA mimarisi ağ genişliği, derinliği ve çözünürlüğü ölçeklendirilebilir bir tasarım hedeflemektedir. Bu sayede değişen koşullarda eğitimlerin efektif yapılması amaçlanmaktadır. 2B EfficientNetB0 ESA mimarisi sıkma ve uyarma bloklarına ilave olarak 2B MobileNetV2 ESA mimarisinde kullanılan darboğaz kalıntı katman gruplarından oluşan ve MB evrişim olarak




isimlendirilen katman gruplarından yararlanmaktadır. 2B EfficientNetB0 mimarisinin giriş görüntü boyutları  $224 \times 224 \times 3$  ve tam bağlı katman çıkış büyüklüğü 1000'dir. Şekil 5.15'de 2B EfficientNetB0 ESA mimarisinin genel yapısı yer almaktadır.



Şekil 5.15. 2B EfficientNetB0 ESA mimarisinin genel yapısı (Tan ve Le, 2019)

### 5.6.9. 2B DarkNet-53 ESA mimarisi

2B DarkNet-53 ESA mimarisi Redmon tarafından 2013 yılında oluşturulmuştur (Redmon, 2013). DarkNet mimarisi nesne tespiti için yaygın kullanıma sahip YOLO (You Only Look Once) yaklaşımının sınıflandırma aşamasında da kullanılmaktadır. 2B DarkNet-53 ESA mimarisinde her havuzlama adımından sonra kanal sayısı iki katına çıkarılmaktadır. Ayrıca, 2B ResNet-101 ESA mimarisinde kullanılan artık bloklardan da yararlanılmaktadır. 2B DarkNet-53 mimarisinin giriş görüntü boyutları  $256 \times 256 \times 3$  ve tam bağlı katman çıkış büyüklüğü 1000'dir. Şekil 5.16'da 2B DarkNet-53 ESA mimarisinin genel yapısı yer almaktadır.



Şekil 5.16. 2B DarkNet-53 ESA mimarisinin genel yapısı (Redmon, 2013)

## 6. EĞİTİM VE TEST PROSEDÜRLERİ İLE DEĞERLENDİRME KRİTERLERİ


### 6.1. Eğitim ve Test Prosedürleri

Sınıflandırma işlemlerinde kullanılacak eğitim ve test kümesinin belirlenmesine yönelik bazı yaklaşımlar mevcuttur. Bu kapsamda kullanılan ilk yaklaşım veri setinin eğitim ve test olmak üzere ikiye bölünmesidir. Söz konusu yöntem veri seti içindeki eleman sayısının tatmin edici seviyede olması durumunda kullanılmaya oldukça elverişlidir. Veri setinin ayrılmasında %80 eğitim ve %20 test, %70 eğitim ve %30 test, %50 eğitim ve %50 test gibi oranlamalar kullanılabilir. Bu kapsamda genel yaklaşım, eğitim için ayrılan miktarın test için ayrılan miktara eşit veya bu miktardan daha fazla olması yönündedir. Bu prosedürde eğitim işlemleri yeterli sayıda veri ile gerçekleştirildiği için test sonuçlarının tutarlılığı konusunda tereddüt yaşanmamaktadır.

Çoğu durumda çalışma setleri daha kısıtlı sayıda veriler içermektedir. Bu sebeple, hem eğitim işlemlerinde olabildiğince daha fazla veriden yararlanmak hem de test sonuçlarının tutarlılığını ve güvenilirliğini artırmak için k kat çapraz doğrulama prosedürü kullanılmaktadır. Bu prosedür veri setinin ihtiyaca göre belirlenecek k adet eşit veya yaklaşık eşit parçaya bölünmesi adımıyla başlar. Daha sonra her bir parça sırasıyla test ve kalan k-1 adet parça ise eğitim seti olarak belirlenerek eğitim ve test işlemleri gerçekleştirilir. Seçilen k değeri kadar parça için işlemlerin tekrarlanmasıyla çapraz doğrulama prosedürü tamamlanmış olur. Şekil 6.1'de k değerinin on olarak seçilmesi durumu için on kat çapraz doğrulama prosedürünün adım adım işletilmesi görsel olarak anlatılmaktadır.

Sınıflandırmada kullanılacak veri setinin çok daha kısıtlı olması durumunda k değeri veri seti eleman sayısına eşit olarak seçilebilir. Bu durumda k kat çapraz doğrulamanın özel bir alt prosedürü olan birini dışarda bırak çapraz doğrulama gerçekleştirilmiş olur. Yani veri seti içinde yer alan her bir elemanın test işlemi, kalan diğer bütün elemanlarla eğitim yapılarak gerçekleştirilmektedir.

Tez çalışmasındaki uygulamalarda k kat çapraz doğrulama prosedürüne göre eğitim ve test işlemleri gerçekleştirilmiştir. Seçilen k değeri her uygulamanın ihtiyacına göre farklılık göstermektedir.



Şekil 6.1. On kat çapraz doğrulama prosedürünün adımları

## 6.2. Değerlendirme Kriterleri

Tez çalışmasında iki sınıflı ve çok sınıflı sınıflandırma uygulamaları gerçekleştirilmiştir.

### 6.2.1. İki sınıflı sınıflandırma

Tez çalışmasında sonuçları değerlendirmek ve karşılaştırmak için en temel değerlendirme yöntemlerinden biri olan karmaşıklık matrisi kullanılmıştır. Karmaşıklık matrisi, iki sınıftan oluşan bir sınıflandırma için DP (Doğru Pozitif), YP (Yanlış Pozitif), DN (Doğru Negatif) ve YN (Yanlış Negatif) olmak üzere toplam dört sayısal bileşenden oluşur. DP ve DN, gerçek durumları sırasıyla hasta ve normal olan küme elemanlarının sınıflandırma sonucunda sırasıyla hasta ve normal olarak etiketlenme sayısıdır. YP, sınıflandırma sonucunda hasta olarak etiketlenen ve gerçekte normal olan küme elemanlarının sayısıdır. YN ise normal olarak etiketlenen ve gerçekte hasta olan küme elemanlarının sayısıdır. Çizelge 6.1’de iki sınıflı sınıflandırma için karmaşıklık matrisi ve DP, YP, DN ve YN parametrelerinin matris içindeki gösterimi yer almaktadır.

Çizelge 6.1. İki sınıflı sınıflandırma için karmaşıklık matrisi

		Gerçek Sınıf	
		Hasta	Normal
Tahmin Edilen Sınıf	Hasta	DP (Doğru Pozitif)	YP (Yanlış Pozitif)
	Normal	YN (Yanlış Negatif)	DN (Doğru Negatif)

Duyarlılık, özgüllük, kesinlik, yaygınlık, negatif tahmin değeri, pozitif tahmin değeri, doğruluk ve F-1 skoru gibi birçok değerlendirme parametresi, karmaşıklık matrisi bileşenleri (DP, YP, DN ve YN) kullanılarak hesaplanmaktadır. Bu sebeple tez çalışmasında verilen sonuçlarda, en temel değerlendirme parametresi olan ve diğer birçok değerlendirme parametrenin hesaplanmasında kullanılan karmaşıklık matrisi bileşenlerine özellikle yer verilmiştir. Bu sayede, tez çalışmasında verilmemiş olsa bile ihtiyaç duyulması halinde diğer tüm değerlendirme parametrelerinin hesaplanabilmesi amaçlanmıştır.

Tez çalışmasında karmaşıklık matrisi elemanlarından duyarlılık, özgüllük, doğruluk ve F-1 skoru parametreleri hesaplanmıştır. Duyarlılık, özgüllük, doğruluk ve F-1 skoru parametreleri matematiksel olarak sırasıyla Eşitlik (6.1) ile Eşitlik (6.4) arasında yer alan eşitlikler kullanılarak hesaplanabilir.

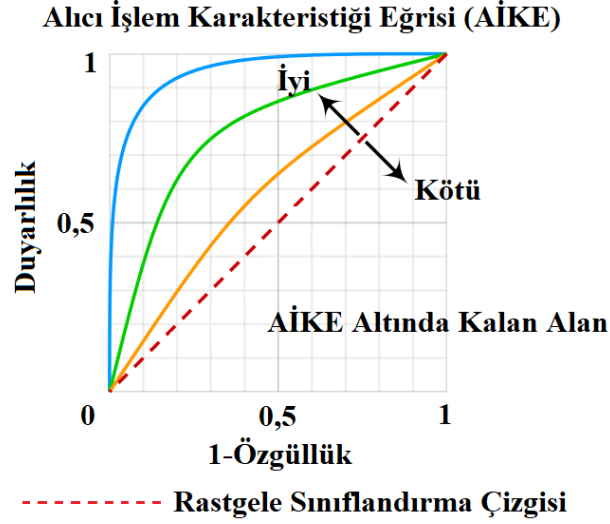
$$\text{Duyarlılık} = DP / (DP + YN) \quad (6.1)$$

$$\text{Özgüllük} = DN / (DN + YP) \quad (6.2)$$

$$\text{Doğruluk} = (DP + DN) / (DP + DN + YP + YN) \quad (6.3)$$

$$F_1 - \text{Skoru} = (2 \times DP) / (2 \times DP + YP + YN) \quad (6.4)$$

Tez çalışmasında kullanılan bir diğer karşılaştırma parametresi ise alıcı işlem karakteristiği eğrisi (AİKE) ve bu eğri altında kalan alan (AİKE-AKA) değerleridir. Şekil 6.2'de örnek bir AİKE görülmektedir. AİKE, ayrışım değeri (eşik değeri) minimum değerden maksimum değere doğru hareket ederken doğru pozitif oranının (duyarlılık) yanlış negatif oranına (1-özgüllük) göre değişimini göstermektedir. Karmaşıklık matrisi ve Eşitlik (6.1) ile Eşitlik (6.4) arasında yer alan değerlendirme parametreleri tek bir ayrışım değerine göre hesaplanmaktadır. AİKE ise muhtemel bütün ayrışım değerlerine göre bir görünüm kazanmaktadır. Yani, AİKE sınıflandırma sonucunda sınıflandırılan küme elemanlarının birbirinden ne kadar uzaklaştırılarak sınıflandırıldığını göstermektedir. Söz konusu eğri altında kalan alanın 1 değerine yaklaşması sınıflandırma ayrışım başarısının maksimuma yaklaştığına işaret etmektedir.



Şekil 6.2. Örnek bir alıcı işlem karakteristiği eğrisi

### 6.2.2. Çok sınıflı sınıflandırma

Tez çalışmasında iki sınıflı sınıflandırmanın yanı sıra üç ve dört sınıflı sınıflandırma uygulamaları da gerçekleştirilmiştir. Çok sınıflı sınıflandırma için karmaşıklık matrisi Çizelge 6.2’de yer almaktadır. Çizelge 6.2’de  $C_{11}$  ile  $C_{nn}$  arasında yer alan değerler çok sınıflı sınıflandırma sonucunda gerçek sınıf ile tahmin edilen sınıf arasındaki durumu yansıtmaktadır. Örneğin  $C_{32}$ , gerçekte Sınıf-2 üyesi olan elemanların sınıflandırma sonucunda Sınıf-3 olarak etiketlenme sayısıdır.

Çizelge 6.2. Çok sınıflı sınıflandırma için karmaşıklık matrisi

		Gerçek Sınıf			
		Sınıf-1	Sınıf-2	Sınıf-3	Sınıf-n
Tahmin Edilen Sınıf	Sınıf-1	$C_{11}$	$C_{12}$	$C_{13}$	$C_{1n}$
	Sınıf-2	$C_{21}$	$C_{22}$	$C_{23}$	$C_{2n}$
	Sınıf-3	$C_{31}$	$C_{32}$	$C_{33}$	$C_{3n}$
	Sınıf-n	$C_{n1}$	$C_{n2}$	$C_{n3}$	$C_{nn}$

Çok sınıflı sınıflandırmada DP, YP, DN ve YN değerleri her sınıf için karmaşıklık matrisi üzerinden ayrı ayrı hesaplanmaktadır. Eşitlik (6.5) ile Eşitlik (6.8) arasında  $i$  parametreleri hesaplanan sınıf ve  $n$  toplam sınıf sayısı olmak üzere DP, YN, YP ve DN parametrelerinin her sınıf için matematiksel olarak hesaplanması verilmiştir.

$$DP_i = C_{ii} \quad (6.5)$$

$$YN_i = \sum_{l=1}^n C_{li} - DP_i \quad (6.6)$$

$$YP_i = \sum_{l=1}^n C_{il} - DP_i \quad (6.7)$$

$$DN_i = \sum_{l=1}^n \sum_{k=1}^n C_{lk} - DP_i - YN_i - YP_i \quad (6.8)$$

Eşitlik (6.9) ile Eşitlik (6.12) arasında ise  $i$  parametreleri hesaplanan sınıf ve  $n$  toplam sınıf sayısı olmak üzere duyarlılık, özgüllük, doğruluk ve F-1 skoru parametrelerinin her sınıf için matematiksel olarak hesaplanması görülmektedir.

$$Duyarlılık_i = DP_i / (DP_i + YN_i) \quad (6.9)$$

$$Özgüllük_i = DN_i / (DN_i + YP_i) \quad (6.10)$$

$$Doğruluk_i = (DP_i + DN_i) / (DP_i + DN_i + YP_i + YN_i) \quad (6.11)$$

$$F_1 - Skoru_i = (2 \times DP_i) / (2 \times DP_i + YP_i + YN_i) \quad (6.12)$$

Çok sınıflı sınıflandırmada her sınıf için duyarlılık, özgüllük, doğruluk ve F-1 skoru parametreleri hesaplandıktan sonra, bu parametreler genelleştirilerek sınıflandırmanın geneli için mikro, makro veya ağırlıklı sonuçların elde edilmesi mümkündür (Grandini ve ark., 2020). Tez çalışmasının çok sınıflı sınıflandırma yapılan uygulamalarında; her sınıf için duyarlılık, özgüllük, doğruluk ve F-1 skoru sonuçlarına yer verilmiştir. Bunun yanı sıra söz konusu parametrelerin sınıflandırmanın geneli için ağırlıklı olarak hesaplanmış halleri de paylaşılmıştır. Genel ağırlıklı parametreler, her sınıf için elde edilen sonuçların sınıftaki eleman sayısı ile orantılı olacak şekilde birleştirilmesiyle oluşturulmuştur. Eşitlik (6.13) ile Eşitlik (6.16) arasında  $i$  parametreleri hesaplanmış sınıf,  $n$  toplam sınıf sayısı,  $m_i$   $i$  sınıfının eleman sayısı ve  $m$  toplam eleman sayısı olmak üzere ağırlıklı genel duyarlılık, özgüllük, doğruluk ve F-1 skoru parametrelerinin matematiksel olarak hesaplanması yer almaktadır.

$$Ağırlıklı - Duyarlılık = \sum_{i=1}^n (m_i / m) \times Duyarlilik_i \quad (6.13)$$

$$Ağırlıklı - Özgüllük = \sum_{i=1}^n (m_i / m) \times Özgüllük_i \quad (6.14)$$

$$Ağırlıklı - Doğruluk = \sum_{i=1}^n (m_i / m) \times Doğruluk_i \quad (6.15)$$

$$\text{Ağırlıklı} - F_1 - \text{Skoru} = \sum_{i=1}^n (m_i / m) \times F_1 - \text{Skoru}_i \quad (6.16)$$

Ağırlıklı doğruluk parametresinin yanında sınıflandırma sonucunda doğru olarak sınıflandırılan eleman sayısının, toplam eleman sayısına oranlanmasıyla genel doğruluk parametresinin hesaplanması mümkündür. Eşitlik (6.17) genel doğruluk parametresinin matematiksel olarak hesaplanmasını göstermektedir.

$$\text{Genel} - \text{Doğruluk} = \frac{\sum_{i=1}^n C_{ii}}{\sum_{l=1}^n \sum_{k=1}^n C_{lk}} \quad (6.17)$$

Çok sınıflı sınıflandırmada alıcı işlem karakteristiği eğrileri her sınıf için ayrı ayrı çizdirilir. Alıcı işlem karakteristiği eğrileri altında kalan alanlar ise söz konusu sınıflar için AİKE-AKA parametresini ifade etmektedir. Diğer parametrelere benzer şekilde her sınıfa ait AİKE-AKA değerlerinin küme eleman sayılarına göre ağırlıklandırılmasıyla sınıflandırmanın geneline ait ağırlıklı AİKE-AKA parametresinin hesaplanması mümkündür. Eşitlik (6.18),  $i$  parametreleri hesaplanmış sınıf,  $n$  toplam sınıf sayısı,  $m_i$   $i$  sınıfının eleman sayısı ve  $m$  toplam eleman sayısı olmak üzere ağırlıklı AİKE-AKA parametresinin matematiksel olarak hesaplanmasını göstermektedir.

$$\text{Ağırlıklı} - \text{AİKE} - \text{AKA} = \sum_{i=1}^n (m_i / m) \times \text{AİKE} - \text{AKA}_i \quad (6.18)$$

## 7. BT GÖRÜNTÜLER ÜZERİNDEN COVID-19 VE COVID-19 DEĞİL SINIFLANDIRMASI

Tez çalışmasının birinci uygulamasında BT görüntüler üzerinden otomatik COVID-19 ve COVID-19 değil sınıflandırması gerçekleştirilmiştir. Söz konusu uygulama sonuçları Yaşar ve Ceylan tarafından (Yaşar ve Ceylan, 2021(a)) yayınlanmıştır.

### 7.1. Uygulamada Kullanılan Veriler

Tez çalışmasının birinci uygulamasında kullanılan COVID-19 hastalarına ait BT akciğer görüntüleri Cohen ve arkadaşları (Cohen ve ark., 2020) ile Zhao ve arkadaşları (Zhao ve ark., 2020(b)) tarafından oluşturularak GitHub platformu üzerinden açık erişime açılan ve meta data şeklinde biriktirilen iki veri setinden alınmıştır. Bu uygulamada toplam 386 adet BT akciğer görüntüsü kullanılmıştır. Söz konusu görüntülerin boyutları 115×98 ile 2024×1523 arasında oldukça farklı değerlerdedir. Görüntüler üzerindeki ilgi alanının netleştirilmesi için öncelikle akciğer bölgesini içine alacak şekilde çerçeveleme gerçekleştirilmiştir. Bu işlemin arkasından bütün görüntülerin boyutları yeniden düzenlenerek 448×448 olarak ayarlanmıştır. Bu süreçte görüntüler üzerinde yer alan radyolojik bölümlerde bir veri kaybı yaşanmamıştır. Çalışmada ayrıca 1.010 adet COVID-19 değil BT akciğer görüntüsünden yararlanılmıştır. Söz konusu görüntüler daha önce yayınlanmış bir veri seti olan LIDC-IDRI'den elde edilmiştir (Armato ve ark., 2011; Clark ve ark., 2013; Armato ve ark., 2015). COVID-19 görüntülere uygulanan ön işlemler aynı şekilde COVID-19 değil görüntülere de uygulanmıştır.

### 7.2. Veri Artırma

Tez çalışmasının birinci uygulamasında ESA eğitiminde kullanılan görüntü sayısındaki artışın uygulama sonuçları üzerindeki etkileri de incelenmiştir. 1.396 BT akciğer görüntü sayısı (386 COVID-19 ve 1.010 COVID-19 değil), geleneksel veri artırma yöntemleri kullanılarak beş kat, on kat ve yirmi kat artırılmıştır. Bu kapsamda, orijinal görüntüler üzerinde kontrast değiştirme, parlaklık değiştirme, distorsiyon ve gürültü ekleme yöntemleri kullanılmıştır. Veri artırma sürecinin bazı adımlarında,



Bloice ve arkadaşları tarafından oluşturulan yazılım araçlarından yararlanılmıştır (Bloice ve ark., 2017; Bloice ve ark., 2019(a); Bloice ve ark., 2019(b)).

Veri artırma yapılırken ilk olarak orijinal görüntülerin piksel değerleri sırasıyla 0,8 ve 0,6 ile çarpılmıştır. Bu sayede kontrast değiştirme yapılarak ikinci ve üçüncü görüntüler elde edilmiştir. Daha sonra ikinci ve üçüncü görüntülerin her bir pikselinin değeri 7 artırılarak parlaklıkları değiştirilmiştir. Bu sayede dördüncü ve beşinci görüntüler oluşturulmuştur. Bu ilk aşama işlemlerin sonunda görüntü sayısı beş katına çıkarılmıştır.

Veri artırma işlemlerinde ikinci olarak, orijinal görüntülere distorsiyon uygulanarak aşındırılmıştır. Daha sonra ilk aşamada gerçekleştirilen işlemler aşınmış görüntülere de uygulanmıştır. Yani, ikinci aşamanın sonunda görüntü sayısı on katına çıkarılmıştır.

Veri artırma işlemlerinde üçüncü olarak orijinal görüntüye ve bu görüntüden elde edilen ilk dokuz görüntüye 0,03 yoğunlukta tuz ve biber gürültüsü eklenerek görüntü sayısı yirmi katına çıkarılmıştır. Eklenecek gürültü türünün ve veri artırma işlemlerinde kullanılan parametre büyüklüklerinin seçimi, başarılı sonuçlara sahip literatür çalışmaları (Örnek ve ark., 2019; Örnek ve Ceylan, 2019) dikkate alınarak gerçekleştirilmiştir. Bu kapsamda farklı parametre büyüklükleri ve gürültü türleri seçmek ve diğer veri artırma yöntemlerini kullanmak mümkündür. Veri artırma yöntemleri kullanılarak, orijinal görüntülerin yanı sıra YİD, LE ve GSEM görüntülerinin miktarı da beş kat, on kat ve yirmi kat artırılmıştır. Bu aşamada orijinal görüntülere uygulanan veri artırma işlemleri, kaynak görüntü olarak orijinal görüntü yerine bu görüntüler kullanılarak gerçekleştirilmiştir.

### 7.3. Özellik Çıkarma, ESA Modifikasyonları ve Hiperparametreler

Tez çalışmasının birinci uygulamasında YİD yönteminin işletilmesinde kullanılan yarıçap değeri 2 olarak seçilmiştir. YİD işlemi sonunda görüntü boyutlarında azalma olması sebebiyle, MATLAB *imresize* fonksiyonu kullanılarak görüntü boyutları yeniden düzenlenmiştir. LE görüntülerinin elde edilmesinde MATLAB *entropyfilt* fonksiyonu kullanılmıştır. Fonksiyonun işletilmesi varsayılan parametrelerle yapılmıştır. LE görüntülerinin piksel değerleri MATLAB *rescale* fonksiyonu kullanılarak 0 ile 255 arasına normalize edilerek uygulamada kullanılmıştır. GSEM görüntülerinin elde edilmesinde MATLAB *graycomatrix* fonksiyonundan

yararlanılmıştır. Uygulamada kullanılan GSEM görüntüsü doğrudan özellik matrisinin kendisi değil özellik matrisinin hesaplanmasında kullanılan ölçeklenmiş dönüş görüntüsüdür. Fonksiyonun işletilmesi, varsayılan parametrelerle yapılmıştır. GSEM görüntülerinin piksel değerleri MATLAB *rescale* fonksiyonu ile 0 ile 255 arasına normalize edilerek uygulamada kullanılmıştır.

Uygulamada makine öğrenmesi sınıflandırıcısı olarak iki sınıflı DVM kullanılmıştır. MATLAB *fitcsvm* fonksiyonu kullanılarak işlemler gerçekleştirilmiş olup DVM çekirdek fonksiyonu olarak radyal temel fonksiyonu tercih edilmiştir. Kutu kısıtlaması, çekirdek ölçeği, polinom sırası, ön bellek boyutu gibi diğer tüm parametreler ise varsayılan olarak seçilmiştir. Uygulamada ayrıca iki sınıflı k-EYK kullanılmıştır. MATLAB *fitcknn* kullanılarak işlemler gerçekleştirilmiş olup k-EYK'nin komşu sayısı 21 olarak belirlenmiştir. Kova boyutu, maliyet, üs, büzülme süresi, iterasyon limiti gibi diğer tüm parametreler ise varsayılan olarak kullanılmıştır.

Uygulamada transfer öğrenme 2B AlexNet ESA ve 2B MobileNetV2 ESA mimarilerinin kullanılabilmesi için üzerlerinde bazı modifikasyonların yapılması gerekmektedir. Giriş görüntüsündeki satır ve sütun büyüklüğü özgün mimarideki değerler olarak korunmuştur. Ancak giriş verilerinin üçüncü boyutu çalışmanın gereksinimlerine göre 1, 2, 3 ve 4 olarak yeniden düzenlenmiştir. Bu kapsamda modifiye edilmiş 2B AlexNet ESA mimarisinin yeni giriş görüntü boyutları  $227 \times 227 \times 1$ ,  $227 \times 227 \times 2$ ,  $227 \times 227 \times 3$ ,  $227 \times 227 \times 4$ ; modifiye edilmiş 2B MobileNetV2 ESA mimarisinin yeni giriş görüntü boyutları ise  $224 \times 224 \times 1$ ,  $224 \times 224 \times 2$ ,  $224 \times 224 \times 3$ ,  $224 \times 224 \times 4$ 'tür. Bu nedenle 2B AlexNet ve 2B MobileNetV2 ESA mimarisiyle gerçekleştirilen işlemlerde kullanılan görüntülerin boyutları, 23 katmanlı 2B ESA mimarisi ve makine öğrenmesi sınıflandırıcılarda kullanılanlardan ( $448 \times 448 \times 1$ ,  $448 \times 448 \times 2$ ,  $448 \times 448 \times 34$ ,  $48 \times 448 \times 4$ ) farklıdır. 2B AlexNet ve 2B MobileNetV2 ESA mimarisi kullanılarak gerçekleştirilen sınıflandırmalarda bütün görüntüler MATLAB *imresize* fonksiyonu kullanılarak yeniden boyutlandırılmıştır. Uygulamada COVID-19 ve COVID-19 değil olmak üzere iki sınıflı sınıflandırma yapıldığı için her iki transfer öğreme 2B ESA mimarisinde de tam bağlı katman çıkış boyutu 2 olarak yeniden düzenlenmiştir.

Eğitimler sırasında ilk ağırlık transferi yapılmamıştır. Yani tüm ESA mimarileri baştan rastgele atanan ağırlıklarla eğitilmiştir. Uygulamanın yazılımları MATLAB 2019(a) programı kullanılarak oluşturulmuştur. ESA eğitiminde ağ çözücü olarak momentumlu stokastik gradyan inişi seçilmiştir. Maksimum iterasyon sayısı program

tarafından varsayılan değer kabul edilen 30 olarak belirlenmiştir. Bu tercihin temel nedeni aşırı uyum probleminden kaçınmaktır. Yani, bu değeri yüksek seçmek yerine varsayılan değer kullanılarak erken durdurma yapılmıştır. Küme boyutu program tarafından varsayılan değer kabul edilen 128 olarak ayarlanmıştır. Öğrenme oranı ise 0,001 olarak belirlenmiştir. Momentum, gradyan bozunma faktörü, sıra doldurma gibi diğer tüm parametreler varsayılan değerler olarak ayarlanmıştır. MathWorks sayfasından (MathWorks, 2022(a)) eğitim parametreleri açıklamalarının ve varsayılan değerlerin incelenmesi mümkündür.

#### 7.4. Deneyler

Tez çalışmasının birinci uygulamasında COVID-19 hastalığının erken teşhisi için BT akciğer görüntülerinin otomatik sınıflandırılmasını amaçlayan makine öğrenmesi ve derin öğrenme temelli bir yapay zekâ uygulaması gerçekleştirilmiştir. Uygulamada COVID-19 tanısı konulmuş hastalara ait 386 adet ve COVID-19 hastalığı olmayan kişilere ait 1.010 adet olmak üzere toplam 1.396 adet BT akciğer görüntüsünden yararlanılmıştır.

Uygulamada öncelikle söz konusu görüntülerin ilgi alanlarının netleştirilmesi için akciğer bölgesini içine alacak şekilde çerçeveleme işlemi gerçekleştirilmiştir. Kullanılan görüntülerin çok değişik boyutlarda olması sebebiyle görüntüler yeniden düzenlenmiş ve boyutları 448×448 olarak ayarlanmıştır. Daha sonra söz konusu görüntüler 8 bit derinlikte gri seviye ve png formatında kaydedilmiştir. Söz konusu işlemlerin bir ön işleme aşaması olarak isimlendirilmesi mümkündür.

Uygulamanın ikinci aşamasında COVID-19 ve COVID-19 değil orijinal görüntülere YİD, LE ve GSEM uygulanarak yeni görüntüler oluşturulmuş ve orijinal görüntüler ile aynı boyut, format ve renk derinliğinde kaydedilmiştir. Bu şekilde özellik desenlerini içeren yeni görüntüler oluşturulmuş, görüntü tipi ve sayısı zenginleştirilmiştir. Çalışmada ESA eğitiminde kullanılan görüntü sayısındaki artışın çalışma sonuçları üzerindeki etkileri de incelenmiştir. Çalışmanın ikinci aşamasında daha önce detayları açıklanan kontrast değiştirme, parlaklık değiştirme, distorsiyon ve gürültü ekleme yöntemleri kullanılarak veri artırma işlemi yapılmıştır. Bu veri artırma işlemi orijinal görüntülerin yanı sıra YİD, LE ve GSEM uygulanmış görüntüler için de gerçekleştirilmiştir. Birinci aşamada olduğu gibi bu görüntüler de 8 bit derinlikte gri

seviye ve png formatında kaydedilmiştir. İkinci aşamanın sonunda veri artırmaya esas orijinal görüntüler dâhil olmak üzere görüntü sayısı beş, on ve yirmi katına çıkarılmıştır.

Uygulamanın üçüncü aşamasında orijinal görüntüler ile YİD, LE ve GSEM görüntüleri tek başlarına, orijinal görüntü her grup içinde olmak üzere ikili, üçlü ve dörtlü kombinasyonlar şeklinde DVM ve k-EYK kullanılarak COVID-19 ve COVID-19 değil sınıflandırmasına tabi tutulmuştur. Eğitim ve test görüntü sayısı dengesindeki değişimin sonuçlar üzerindeki etkilerini gözlemleyebilmek için iki kat çapraz doğrulama ve on kat çapraz doğrulama olmak üzere iki farklı şekilde eğitim ve test işlemleri gerçekleştirilmiştir.

Uygulamanın dördüncü aşamasında daha önce detayları açıklanan 23 katmanlı 2B ESA mimarisi kullanılarak bütün deneyler tekrarlanmıştır. Bu aşamada, bir önceki aşamada oluşturulan görüntü grupları 23 katmanlı 2B ESA mimarisi kullanılarak sınıflandırılmıştır. Sınıflandırmada eğitim ve test işlemleri için önceki aşamada olduğu gibi iki kat çapraz doğrulama ve on kat çapraz doğrulama kullanılmıştır. 23 katmanlı 2B ESA mimarisinde kullanılan bazı başlangıç ağırlık ve parametrelerinin rastgele atanması sebebiyle sonuçların kararlı hale getirilebilmesi için her deney kendi içinde beş kez tekrarlanmıştır. Beş tekrar sonucunda elde edilen test sonuçlarının ortalamaları verilmiştir.

Uygulamanın beşinci aşamasında daha önce detayları açıklanan veri artırma teknikleri kullanılarak görüntü sayısının artırılması ve 23 katmanlı 2B ESA mimarisinin eğitiminde kullanılması durumu için uygulama sonuçları hesaplanmıştır. Beş kat, on kat ve yirmi kat olmak üzere üç farklı miktarda artırım yapılması için eğitim ve test işlemleri gerçekleştirilmiştir. Bu eğitim ve test işlemlerinde işlem sürelerinin uzunluğu sebebiyle sadece iki kat çapraz doğrulama yaklaşımı kullanılmıştır. Orijinal görüntüler kendilerinden türetilen bütün görüntüler ile aynı grupta olacak şekilde ikiye bölünmüştür. Yani, orijinal görüntü eğitim grubundayken bu görüntüden elde edilen türetilmiş bir görüntünün test grubunda olması veya tam tersi bir durum olmasının önüne geçilmiştir. Eğitim işlemleri veri artırma yapılarak gerçekleştirilirken test işlemleri sadece orijinal görüntüler için yapılmıştır.

Uygulamanın altıncı bölümünde daha önce detayları açıklanan modifiye işlemleri gerçekleştirilmiş 2B AlexNet ve 2B MobileNetV2 ESA mimarileri kullanılarak sınıflandırma yapılmıştır. Bu aşamada üçüncü ve dördüncü aşamada olduğu gibi iki kat çapraz doğrulama ve on kat çapraz doğrulama kullanılarak eğitim ve test işlemleri gerçekleştirilmiştir. Ancak, bu aşamalardan farklı olarak giriş görüntülerinin

boyutları 448×448 yerine 2B AlexNet için 227×227 ve 2B MobileNetV2 için 224×224 olarak kullanılmıştır.

Uygulama kapsamında bir görüntünün sınıflandırılması için ihtiyaç duyulan süreler (Central Processing Unit (CPU) süresi) saniye cinsinden ölçülmüştür. Deneyler; 64 GB RAM, Intel(R) Xeon (R) CPU E5-2680 2.7 GHz (32 CPUs) bilgisayar üzerinde çalışan MATLAB 2019(a) yazılımı kullanılarak gerçekleştirilmiştir. Uygulamada verilen tüm CPU çalışma süreleri saniye cinsinden zamanı göstermektedir.

### 7.5. Deney Sonuçları

Uygulamada ilk olarak DVM kullanılarak COVID-19 ve COVID-19 değil sınıflandırması gerçekleştirilmiştir. Bu deney için giriş görüntülerinin boyutları Orijinal, GSEM, YİD ve LE için 448×448×1; Orijinal+GSEM, Orijinal+YİD ve Orijinal+LE için 448×448×2; Orijinal+GSEM+YİD, Orijinal+GSEM+LE ve Orijinal+YİD+LE için 448×448×3; Orijinal+GSEM+YİD+LE için 448×448×4'dür. Bu görüntü matrisleri, görüntü vektörlerine dönüştürüldükten sonra DVM'ye giriş olarak verilmiştir. Elde edilen uygulama sonuçları iki kat çapraz doğrulama için Çizelge 7.1 ve on kat çapraz doğrulama için Çizelge 7.2'de verilmiştir. Çizelge 7.1 ve Çizelge 7.2'deki en yüksek parametre değerleri koyu olarak belirtilmiştir. Bu işaretleme devam eden diğer çizelgeler içinde yapılmıştır.

**Çizelge 7.1.** İki kat çapraz doğrulama için DVM kullanılarak elde edilen sonuçlar

Giriş Görüntü Tipi	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AIKE-AKA	CPU Süresi (saniye)
Orijinal	342	44	968	42	0,8860	0,9584	0,9384	0,8883	0,9777	1,5857
GSEM	341	45	981	29	0,8834	0,9713	<b>0,9470</b>	<b>0,9021</b>	<b>0,9815</b>	1,6846
YİD	85	301	1010	0	0,2202	<b>1,0000</b>	0,7844	0,3609	0,7995	4,1768
LE	319	67	972	38	0,8264	0,9624	0,9248	0,8587	0,9642	2,2867
Orijinal +GSEM	342	44	969	41	0,8860	0,9594	0,9391	0,8895	0,9800	3,1503
Orijinal +YİD	335	51	971	39	0,8679	0,9614	0,9355	0,8816	0,9744	3,6905
Orijinal +LE	340	46	965	45	0,8808	0,9554	0,9348	0,8820	0,9777	3,4185
Orijinal +GSEM+YİD	337	49	971	39	0,8731	0,9614	0,9370	0,8845	0,9784	5,2163
Orijinal +GSEM+LE	344	42	970	40	<b>0,8912</b>	0,9604	0,9413	0,8935	0,9801	4,9756
Orijinal +YİD+LE	335	51	969	41	0,8679	0,9594	0,9341	0,8793	0,9768	5,6864
Orijinal +GSEM+YİD+LE	341	45	971	39	0,8834	0,9614	0,9398	0,8903	0,9795	7,0295

Çizelge 7.2. On kat çapraz doğrulama için DVM kullanılarak elde edilen sonuçlar

Giriş Görüntü Tipi	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AIKE-AKA	CPU Süresi (saniye)
Orijinal	354	32	976	34	<b>0,9171</b>	0,9663	0,9527	0,9147	0,9853	9,2526
GSEM	349	37	989	21	0,9041	0,9792	<b>0,9585</b>	<b>0,9233</b>	<b>0,9874</b>	9,6001
YİD	94	292	1010	0	0,2435	<b>1,0000</b>	0,7908	0,3917	0,8554	25,4466
LE	321	65	991	19	0,8316	0,9812	0,9398	0,8843	0,9751	13,0530
Orijinal +GSEM	351	35	978	32	0,9093	0,9683	0,9520	0,9129	0,9866	18,3973
Orijinal +YİD	344	42	977	33	0,8912	0,9673	0,9463	0,9017	0,9840	21,4024
Orijinal +LE	346	40	977	33	0,8964	0,9673	0,9477	0,9046	0,9849	19,8091
Orijinal +GSEM+YİD	346	40	977	33	0,8964	0,9673	0,9477	0,9046	0,9860	30,1233
Orijinal +GSEM+LE	348	38	978	32	0,9016	0,9683	0,9499	0,9086	0,9866	28,7369
Orijinal +YİD+LE	342	44	980	30	0,8860	0,9703	0,9470	0,9024	0,9853	32,7798
Orijinal +GSEM+YİD+LE	346	40	981	29	0,8964	0,9713	0,9506	0,9093	0,9868	41,9181

Uygulamada DVM kullanılarak elde edilen sonuçların yer aldığı Çizelge 7.1 ve Çizelge 7.2 incelendiğinde en yüksek duyarlılık, özgüllük, doğruluk, F-1 skoru ve AIKE-AKA parametrelerinin iki kat çapraz doğrulama için sırasıyla 0,8912; 1,0000; 0,9470; 0,9021; 0,9815; on kat çapraz doğrulama için sırasıyla 0,9171; 1,0000; 0,9585; 0,9233; 0,9874 olarak hesaplandığı görülmektedir. En yüksek özgüllük parametresi 1,0000 olarak elde edilmesine rağmen, bu değer elde edildiği deneylerde duyarlılık, doğruluk, F-1 skoru ve AIKE-AKA parametrelerinde ciddi düşüşler olduğu görülmektedir. DVM kullanılarak elde edilen ikinci en yüksek özgüllük parametresi iki kat çapraz doğrulama için 0,9713 ve on kat çapraz doğrulama için 0,9812'dir. Söz konusu en yüksek değerlerin, iki kat çapraz doğrulama için GSEM ve Orijinal+GSEM+LE; on kat çapraz doğrulama için Orijinal, GSEM ve LE giriş görüntüleri kullanılarak elde edildiği görülmektedir. Eğitim ve test dahil görüntü başına sonuç elde etme süreleri incelendiğinde iki kat çapraz doğrulama için 1,5857 ile 7,0295 saniye arasında ve on kat çapraz doğrulama için 9,2526 ile 41,9181 saniye arasında değişen süreler gerektiği anlaşılmaktadır. Bu kapsamda çapraz doğrulamada kullanılan çapraz katlama sayısının ve veri boyutlarının söz konusu sonuç elde etme sürelerindeki farklılıklarda etkili olduğu görülmektedir.

Uygulamada ikinci olarak k-EYK kullanılarak COVID-19 ve COVID-19 değil sınıflandırması yapılmıştır. Bu deney için giriş görüntülerinin boyutları, DVM için kullanılanlarla aynıdır. Görüntü matrisleri, görüntü vektörlerine dönüştürüldükten sonra k-EYK'ye giriş olarak verilmiştir. Elde edilen uygulama sonuçları iki kat çapraz doğrulama için Çizelge 7.3 ve on kat çapraz doğrulama için Çizelge 7.4'de verilmiştir.

Çizelge 7.3. İki kat çapraz doğrulama için k-EYK kullanılarak elde edilen sonuçlar

Giriş Görüntü Tipi	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AİKE-AKA	CPU Süresi (saniye)
Orijinal	300	86	975	35	<b>0,7772</b>	0,9653	0,9133	0,8322	0,9800	2,4588
GSEM	267	119	997	13	0,6917	0,9871	0,9054	0,8018	0,9872	2,5106
YİD	116	270	929	81	0,3005	0,9198	0,7486	0,3979	0,6987	2,5268
LE	160	226	1010	0	0,4145	<b>1,0000</b>	0,8381	0,5861	0,9806	2,5013
Orijinal +GSEM	292	94	990	20	0,7565	0,9802	0,9183	0,8367	0,9862	5,4448
Orijinal +YİD	298	88	979	31	0,7720	0,9693	0,9148	0,8336	0,9830	5,4867
Orijinal +LE	291	95	992	18	0,7539	0,9822	0,9191	0,8374	0,9867	5,4456
Orijinal +GSEM+YİD	286	100	993	17	0,7409	0,9832	0,9162	0,8302	0,9868	7,9491
Orijinal +GSEM+LE	282	104	999	11	0,7306	0,9891	0,9176	0,8306	0,9885	8,1147
Orijinal +YİD+LE	292	94	993	17	0,7565	0,9832	<b>0,9205</b>	<b>0,8403</b>	0,9875	8,3712
Orijinal +GSEM+YİD+LE	282	104	998	12	0,7306	0,9881	0,9169	0,8294	<b>0,9888</b>	11,0160

Çizelge 7.4. On kat çapraz doğrulama için k-EYK kullanılarak elde edilen sonuçlar

Giriş Görüntü Tipi	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AİKE-AKA	CPU Süresi (saniye)
Orijinal	311	75	980	30	<b>0,8057</b>	0,9703	0,9248	0,8556	0,9809	3,9970
GSEM	286	100	998	12	0,7409	0,9881	0,9198	0,8363	0,9893	4,0297
YİD	119	267	994	16	0,3083	0,9842	0,7973	0,4568	0,6979	4,1210
LE	179	207	1008	2	0,4637	<b>0,9980</b>	0,8503	0,6314	0,9828	4,0515
Orijinal +GSEM	299	87	993	17	0,7746	0,9832	0,9255	0,8519	0,9885	10,0065
Orijinal +YİD	308	78	981	29	0,7979	0,9713	0,9234	0,8520	0,9841	9,6495
Orijinal +LE	301	85	992	18	0,7798	0,9822	0,9262	0,8539	0,9881	9,8070
Orijinal +GSEM+YİD	294	92	994	16	0,7617	0,9842	0,9226	0,8448	0,9888	15,6017
Orijinal +GSEM+LE	292	94	999	11	0,7565	0,9891	0,9248	0,8476	0,9895	15,6487
Orijinal +YİD+LE	299	87	997	13	0,7746	0,9871	<b>0,9284</b>	<b>0,8567</b>	0,9888	15,9042
Orijinal +GSEM+YİD+LE	289	97	1000	10	0,7487	0,9901	0,9234	0,8438	<b>0,9903</b>	22,7328

Uygulamada k-EYK kullanılarak elde edilen sonuçların yer aldığı Çizelge 7.3 ve Çizelge 7.4 incelendiğinde en yüksek duyarlılık, özgüllük, doğruluk, F-1 skoru ve AİKE-AKA parametrelerinin iki kat çapraz doğrulama için sırasıyla 0,7772; 1,0000; 0,9205; 0,8403; 0,9888; on kat çapraz doğrulama için sırasıyla 0,8057; 0,9980; 0,9284; 0,8567; 0,9903 olarak hesaplandığı görülmektedir. DVM’de olduğu gibi k-EYK için de en yüksek özgüllük parametreleri sırasıyla 1,0000 ve 0,9980 olarak elde edilmesine rağmen, bu değerler elde edildiği deneylerde duyarlılık, doğruluk, F-1 skoru ve AİKE-AKA parametrelerinde ciddi düşüşler olduğu görülmektedir. k-EYK kullanılarak elde edilen ikinci en yüksek özgüllük parametresi iki kat çapraz doğrulama için 0,9891 ve on kat çapraz doğrulama için 0,9901’dir. Söz konusu en yüksek değerlerin, iki kat çapraz doğrulama için Orijinal, Orijinal+GSEM+LE, Orijinal+YİD+LE ve

Orijinal+GSEM+YİD+LE; on kat çapraz doğrulama için Orijinal, Orijinal+YİD+LE ve Orijinal+GSEM+YİD+LE giriş görüntüleri kullanılarak elde edildiği görülmektedir. Eğitim ve test dahil görüntü başına sonuç elde etme süreleri incelendiğinde iki kat çapraz doğrulama için 2,4588 ile 11,0160 saniye arasında ve on kat çapraz doğrulama için 3,9970 ile 22,7328 saniye arasında değişen süreler gerektiği anlaşılmaktadır.

Uygulamada üçüncü olarak 23 katmanlı 2B ESA kullanılarak COVID-19 ve COVID-19 değil sınıflandırması gerçekleştirilmiştir. Bu deney için giriş görüntülerinin boyutları Orijinal, GSEM, YİD ve LE için  $448 \times 448 \times 1$ ; Orijinal+GSEM, Orijinal+YİD ve Orijinal+LE için  $448 \times 448 \times 2$ ; Orijinal+GSEM+YİD, Orijinal+GSEM+LE ve Orijinal+YİD+LE için  $448 \times 448 \times 3$ ; Orijinal+GSEM+YİD+LE için  $448 \times 448 \times 4$ 'dür. Elde edilen uygulama sonuçları iki kat çapraz doğrulama için Çizelge 7.5 ve on kat çapraz doğrulama için Çizelge 7.6'da verilmiştir. ESA mimarisinin yapısında kullanılan bazı başlangıç ağırlıklarının ve parametrelerin rastgele atanması nedeniyle sonuçların kararlı hale getirilmesi için her deney kendi içinde beş kez tekrarlanmıştır. Uygulamada beş tekrarda elde edilen test sonuçlarının ortalaması verilmiştir. Bu durum bu aşamadan sonra yapılan tüm deneyler için geçerlidir.

Çizelge 7.5. İki kat çapraz doğrulama için 23 katmanlı 2B ESA kullanılarak elde edilen sonuçlar

Giriş Görüntü Tipi	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AİKE-AKA	CPU Süresi (saniye)
Orijinal	340,6	45,4	952,0	58,0	0,8824	0,9426	0,9259	0,8681	0,9664	0,1322
GSEM	339,8	46,2	954,2	55,8	0,8803	0,9448	0,9269	0,8696	<b>0,9727</b>	0,1307
YİD	301,8	84,2	985,4	24,6	0,7819	<b>0,9756</b>	0,9221	0,8470	0,9676	0,1312
LE	332,4	53,6	979,0	31,0	0,8611	0,9693	<b>0,9394</b>	<b>0,8871</b>	0,9726	0,1307
Orijinal +GSEM	339,2	46,8	944,6	65,4	0,8788	0,9352	0,9196	0,8581	0,9631	0,2001
Orijinal +YİD	330,4	55,6	950,4	59,6	0,8560	0,9410	0,9175	0,8515	0,9644	0,1998
Orijinal +LE	340,0	46,0	950,6	59,4	0,8808	0,9412	0,9245	0,8657	0,9648	0,1999
Orijinal +GSEM+YİD	341,6	44,4	949,8	60,2	0,8850	0,9404	0,9251	0,8672	0,9714	0,2690
Orijinal +GSEM+LE	339,0	47,0	948,8	61,2	0,8782	0,9394	0,9225	0,8624	0,9664	0,2686
Orijinal +YİD+LE	338,6	47,4	949,4	60,6	0,8772	0,9400	0,9226	0,8625	0,9696	0,2693
Orijinal +GSEM+YİD+LE	342,2	43,8	950,8	59,2	<b>0,8865</b>	0,9414	0,9262	0,8693	0,9686	0,3391



Çizelge 7.6. On kat çapraz doğrulama için 23 katmanlı 2B ESA kullanılarak elde edilen sonuçlar

Giriş Görüntü Tipi	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AİKE-AKA	CPU Süresi (saniye)
Orijinal	357,0	29,0	978,4	31,6	<b>0,9249</b>	0,9687	0,9566	<b>0,9217</b>	0,9845	1,1252
GSEM	349,4	36,6	986,6	23,4	0,9052	0,9768	<b>0,9570</b>	0,9209	<b>0,9902</b>	1,1235
YİD	322,4	63,6	996,4	13,6	0,8352	<b>0,9865</b>	0,9447	0,8931	0,9814	1,1242
LE	340,4	45,6	991,8	18,2	0,8819	0,9820	0,9543	0,9143	0,9849	1,1236
Orijinal+GSEM	354,0	32,0	974,2	35,8	0,9171	0,9646	0,9514	0,9126	0,9789	1,7136
Orijinal+YİD	349,8	36,2	979,2	30,8	0,9062	0,9695	0,9520	0,9126	0,9854	1,7178
Orijinal+LE	349,4	36,6	977,0	33,0	0,9052	0,9673	0,9501	0,9094	0,9818	1,7174
Orijinal+GSEM+YİD	350,4	35,6	980,8	29,2	0,9078	0,9711	0,9536	0,9153	0,9873	2,3014
Orijinal+GSEM+LE	350,6	35,4	980,2	29,8	0,9083	0,9705	0,9533	0,9149	0,9843	2,3003
Orijinal+YİD+LE	349,4	36,6	983,4	26,6	0,9052	0,9737	0,9547	0,9171	0,9873	2,3034
Orijinal+GSEM+YİD+LE	348,6	37,4	981,4	28,6	0,9031	0,9717	0,9527	0,9136	0,9849	2,8945

Uygulamada 23 katmanlı 2B ESA kullanılarak elde edilen sonuçların yer aldığı Çizelge 7.5 ve Çizelge 7.6 incelendiğinde en yüksek ortalama duyarlılık, özgüllük, doğruluk, F-1 skoru ve AİKE-AKA parametrelerinin iki kat çapraz doğrulama için sırasıyla 0,8865; 0,9756; 0,9394; 0,8871; 0,9727; on kat çapraz doğrulama için sırasıyla 0,9249; 0,9865; 0,9570; 0,9217; 0,9902 olarak hesaplandığı görülmektedir. Söz konusu en yüksek ortalama değerlerin, iki kat çapraz doğrulama için GSEM, YİD, LE ve Orijinal+GSEM+YİD+LE; on kat çapraz doğrulama için Orijinal, GSEM ve YİD giriş görüntüleri kullanılarak elde edildiği görülmektedir. Eğitim ve test dahil görüntü başına sonuç elde etme süreleri incelendiğinde iki kat çapraz doğrulama için 0,1307 ile 0,3391 saniye arasında ve on kat çapraz doğrulama için 1,1235 ile 2,8945 saniye arasında değişen süreler gerektiği anlaşılmaktadır.

Uygulamada dördüncü olarak 23 katmanlı 2B ESA ve veri artırma (beş kat, on kat ve yirmi kat) kullanılarak COVID-19 ve COVID-19 değil sınıflandırması yapılmıştır. Bu deney için giriş görüntülerinin boyutları Orijinal, GSEM, YİD ve LE için  $448 \times 448 \times 1$ ; Orijinal+GSEM, Orijinal+YİD ve Orijinal+LE için  $448 \times 448 \times 2$ ; Orijinal+GSEM+YİD, Orijinal+GSEM+LE ve Orijinal+YİD+LE için  $448 \times 448 \times 3$ ; Orijinal+GSEM+YİD+LE için  $448 \times 448 \times 4$ 'dür. Bu deneyde, eğitim setindeki artışa paralel olarak sonuç üretme süresinin de artması nedeniyle sadece iki kat çapraz doğrulama kullanılarak eğitim ve test işlemleri gerçekleştirilmiştir. Deneylerde elde edilen sonuçlar beş kat veri artırma için Çizelge 7.7, on kat veri artırma için Çizelge 7.8 ve yirmi kat veri artırma için Çizelge 7.9'da verilmiştir.

**Çizelge 7.7.** İki kat çapraz doğrulama için 23 katmanlı 2B ESA ve veri artırma (beş kat) kullanılarak elde edilen sonuçlar

Giriş Görüntü Tipi	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AIKE-AKA	CPU Süresi (saniye)
Orijinal	333,6	52,4	934,8	75,2	0,8642	0,9255	0,9086	0,8397	0,9545	0,6499
GSEM	330,0	56,0	951,8	58,2	0,8549	0,9424	0,9182	0,8526	0,9598	0,6438
YİD	275,8	110,2	977,2	32,8	0,7145	<b>0,9675</b>	0,8976	0,7940	0,9580	0,6448
LE	326,6	59,4	974,6	35,4	0,8461	0,9650	<b>0,9321</b>	0,8734	0,9703	0,6479
Orijinal +GSEM	339,0	47,0	940,0	70,0	0,8782	0,9307	0,9162	0,8528	0,9604	0,9850
Orijinal +YİD	338,0	48,0	953,4	56,6	0,8756	0,9440	0,9251	0,8659	0,9685	0,9868
Orijinal +LE	338,0	48,0	949,0	61,0	0,8756	0,9396	0,9219	0,8610	0,9696	0,9858
Orijinal +GSEM+YİD	338,8	47,2	951,2	58,8	0,8777	0,9418	0,9241	0,8647	0,9668	1,3134
Orijinal +GSEM+LE	331,6	54,4	945,8	64,2	0,8591	0,9364	0,9150	0,8484	0,9603	1,3129
Orijinal +YİD+LE	341,8	44,2	959,4	50,6	<b>0,8855</b>	0,9499	<b>0,9321</b>	<b>0,8782</b>	<b>0,9736</b>	1,3140
Orijinal +GSEM+YİD+LE	339,0	47,0	957,2	52,8	0,8782	0,9477	0,9285	0,8717	0,9691	1,6378

**Çizelge 7.8.** İki kat çapraz doğrulama için 23 katmanlı 2B ESA ve veri artırma (on kat) kullanılarak elde edilen sonuçlar

Giriş Görüntü Tipi	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AIKE-AKA	CPU Süresi (saniye)
Orijinal	334,2	51,8	938,6	71,4	0,8658	0,9293	0,9117	0,8444	0,9565	1,2964
GSEM	327,6	58,4	956,4	53,6	0,8487	0,9469	0,9198	0,8542	0,9617	1,2972
YİD	291,6	94,4	979,6	30,4	0,7554	<b>0,9699</b>	0,9106	0,8235	0,9597	1,2998
LE	330,6	55,4	978,6	31,4	0,8565	0,9689	0,9378	0,8840	0,9709	1,3060
Orijinal +GSEM	336,2	49,8	948,6	61,4	0,8710	0,9392	0,9203	0,8580	0,9625	1,9531
Orijinal +YİD	335,0	51,0	957,0	53,0	0,8679	0,9475	0,9255	0,8656	0,9695	1,9568
Orijinal +LE	334,6	51,4	951,6	58,4	0,8668	0,9422	0,9213	0,8591	0,9636	1,9528
Orijinal +GSEM+YİD	342,0	44,0	958,2	51,8	0,8860	0,9487	0,9314	0,8771	0,9723	2,6482
Orijinal +GSEM+LE	345,8	40,2	948,6	61,4	<b>0,8959</b>	0,9392	0,9272	0,8719	0,9707	2,6338
Orijinal +YİD+LE	339,8	46,2	966,2	43,8	0,8803	0,9566	0,9355	0,8830	0,9724	2,6160
Orijinal +GSEM+YİD+LE	339,2	46,8	974,4	35,6	0,8788	0,9648	<b>0,9410</b>	<b>0,8917</b>	<b>0,9780</b>	3,5341

**Çizelge 7.9.** İki kat çapraz doğrulama için 23 katmanlı 2B ESA ve veri artırma (yirmi kat) kullanılarak elde edilen sonuçlar

Giriş Görüntü Tipi	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AİKE-AKA	CPU Süresi (saniye)
Orijinal	329,6	56,4	939,2	70,8	0,8539	0,9299	0,9089	0,8382	0,9566	2,6773
GSEM	332,6	53,4	934,0	76,0	0,8617	0,9248	0,9073	0,8372	0,9566	2,6038
YİD	299,8	86,2	971,0	39,0	0,7767	0,9614	0,9103	0,8272	0,9634	2,6043
LE	333,0	53,0	974,6	35,4	0,8627	<b>0,9650</b>	<b>0,9367</b>	<b>0,8828</b>	0,9731	2,6017
Orijinal +GSEM	336,6	49,4	945,2	64,8	0,8720	0,9358	0,9182	0,8549	0,9648	4,1130
Orijinal +YİD	335,6	50,4	960,0	50,0	0,8694	0,9505	0,9281	0,8699	0,9700	3,9790
Orijinal +LE	340,0	46,0	959,0	51,0	0,8808	0,9495	0,9305	0,8752	0,9668	4,0007
Orijinal +GSEM+YİD	335,8	50,2	965,0	45,0	0,8699	0,9554	0,9318	0,8759	0,9745	12,6129
Orijinal +GSEM+LE	338,2	47,8	966,4	43,6	0,8762	0,9568	0,9345	0,8809	0,9743	12,6575
Orijinal +YİD+LE	342,4	43,6	961,4	48,6	<b>0,8870</b>	0,9519	0,9340	0,8813	0,9753	11,4009
Orijinal +GSEM+YİD+LE	341,8	44,2	960,4	49,6	0,8855	0,9509	0,9328	0,8793	<b>0,9835</b>	16,3373

Uygulamada 23 katmanlı 2B ESA ve veri artırma kullanılarak iki kat çapraz doğrulama için gerçekleştirilen deneylerde elde edilen sonuçlar Çizelge 7.7 ile Çizelge 7.9 arasında yer almaktadır. Söz konusu çizelgeler incelendiğinde en yüksek ortalama duyarlılık, özgüllük, doğruluk, F-1 skoru ve AİKE-AKA parametrelerinin beş kat veri artırma için sırasıyla 0,8855; 0,9675; 0,9321; 0,8782; 0,9736; on kat veri artırma için sırasıyla 0,8959; 0,9699; 0,9410; 0,8917; 0,9780 ve yirmi kat veri artırma için sırasıyla 0,8870; 0,9650; 0,9367; 0,8828; 0,9835 olarak hesaplandığı görülmektedir. Söz konusu en yüksek ortalama değerlerin beş kat veri artırma için YİD, LE ve Orijinal+YİD+LE; on kat veri artırma için YİD, Orijinal+GSEM+LE ve Orijinal+GSEM+YİD+LE; yirmi kat veri artırma için LE, Orijinal+YİD+LE ve Orijinal+GSEM+YİD+LE giriş görüntüleri kullanılarak elde edildiği görülmektedir. Eğitim ve test dahil görüntü başına sonuç elde etme süreleri incelendiğinde beş kat veri artırma için 0,6438 ile 1,6378 saniye arasında, on kat veri artırma için 1,2964 ile 3,5341 saniye arasında ve yirmi kat veri artırma için 2,6017 ile 16,3373 saniye arasında değişen süreler gerektiği anlaşılmaktadır.

Çalışmada beşinci olarak 2B AlexNet ESA kullanılarak COVID-19 ve COVID-19 değil sınıflandırması gerçekleştirilmiştir. Bu deney için giriş görüntülerinin boyutları Orijinal, GSEM, YİD ve LE için  $227 \times 227 \times 1$ ; Orijinal+GSEM, Orijinal+YİD ve Orijinal+LE için  $227 \times 227 \times 2$ ; Orijinal+GSEM+YİD, Orijinal+GSEM+LE ve Orijinal+YİD+LE için  $227 \times 227 \times 3$ ; Orijinal+GSEM+YİD+LE için  $227 \times 227 \times 4$ 'dür. Elde edilen uygulama sonuçları iki kat çapraz doğrulama için Çizelge 7.10 ve on kat çapraz doğrulama için Çizelge 7.11'de verilmiştir.

Çizelge 7.10. İki kat çapraz doğrulama için 2B AlexNet ESA kullanılarak elde edilen sonuçlar

Giriş Görüntü Tipi	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AIKE-AKA	CPU Süresi (saniye)
Orijinal	334,4	51,6	932,2	77,8	0,8663	0,9230	0,9073	0,8381	0,9518	0,0557
GSEM	336,6	49,4	929,2	80,8	0,8720	0,9200	0,9067	0,8381	0,9558	0,0516
YİD	316,8	69,2	944,6	65,4	0,8207	0,9352	0,9036	0,8237	0,9482	0,0517
LE	348,6	37,4	971,6	38,4	0,9031	<b>0,9620</b>	<b>0,9457</b>	<b>0,9020</b>	<b>0,9767</b>	0,0518
Orijinal +GSEM	342,2	43,8	934,4	75,6	0,8865	0,9251	0,9145	0,8514	0,9557	0,0704
Orijinal +YİD	338,4	47,6	924,2	85,8	0,8767	0,9150	0,9044	0,8355	0,9480	0,0700
Orijinal +LE	346,4	39,6	928,8	81,2	0,8974	0,9196	0,9135	0,8518	0,9586	0,0687
Orijinal +GSEM+YİD	346,0	40,0	918,8	91,2	0,8964	0,9097	0,9060	0,8406	0,9545	0,0885
Orijinal +GSEM+LE	348,0	38,0	936,4	73,6	0,9016	0,9271	0,9201	0,8622	0,9603	0,0882
Orijinal +YİD+LE	349,0	37,0	920,2	89,8	<b>0,9041</b>	0,9111	0,9092	0,8466	0,9538	0,0881
Orijinal +GSEM+YİD+LE	343,0	43,0	914,0	96,0	0,8886	0,9050	0,9004	0,8318	0,9470	0,1062

Çizelge 7.11. On kat çapraz doğrulama için 2B AlexNet ESA kullanılarak elde edilen sonuçlar

Giriş Görüntü Tipi	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AIKE-AKA	CPU Süresi (saniye)
Orijinal	350,6	35,4	965,6	44,4	0,9083	0,9560	0,9428	0,8978	0,9738	0,4070
GSEM	345,2	40,8	974,4	35,6	0,8943	0,9648	0,9453	0,9003	0,9774	0,4026
YİD	338,2	47,8	970,0	40,0	0,8762	0,9604	0,9371	0,8851	0,9731	0,4027
LE	347,2	38,8	991,2	18,8	0,8995	<b>0,9814</b>	<b>0,9587</b>	<b>0,9234</b>	<b>0,9820</b>	0,4003
Orijinal +GSEM	353,2	32,8	970,0	40,0	0,9150	0,9604	0,9479	0,9066	0,9738	0,5537
Orijinal +YİD	356,0	30,0	964,6	45,4	0,9223	0,9550	0,9460	0,9042	0,9740	0,5550
Orijinal +LE	353,2	32,8	971,4	38,6	0,9150	0,9618	0,9489	0,9082	0,9788	0,5542
Orijinal +GSEM+YİD	356,4	29,6	959,6	50,4	0,9233	0,9501	0,9427	0,8991	0,9723	0,7096
Orijinal +GSEM+LE	351,6	34,4	967,0	43,0	0,9109	0,9574	0,9446	0,9008	0,9729	0,7082
Orijinal +YİD+LE	359,0	27,0	962,0	48,0	<b>0,9301</b>	0,9525	0,9463	0,9054	0,9720	0,7082
Orijinal +GSEM+YİD+LE	354,8	31,2	956,8	53,2	0,9192	0,9473	0,9395	0,8937	0,9676	0,8628

Uygulamada 2B AlexNet ESA kullanılarak elde edilen sonuçların yer aldığı Çizelge 7.10 ve Çizelge 7.11 incelendiğinde en yüksek ortalama duyarlılık, özgüllük, doğruluk, F-1 skoru ve AIKE-AKA parametreleri iki kat çapraz doğrulama için sırasıyla 0,9041; 0,9620; 0,9457; 0,9020; 0,9767; on kat çapraz doğrulama için sırasıyla 0,9301; 0,9814; 0,9587; 0,9234; 0,9820 olarak hesaplandığı görülmektedir. Söz konusu en yüksek ortalama değerlerin, iki kat çapraz doğrulama ve on kat çapraz doğrulama için LE ve Orijinal+YİD+LE görüntüleri kullanılarak elde edildiği görülmektedir. Eğitim ve test dahil görüntü başına sonuç elde etme süreleri incelendiğinde iki kat çapraz doğrulama için 0,0516 ile 0,1062 saniye arasında ve on kat çapraz doğrulama için 0,4003 ile 0,8628 saniye arasında değişen süreler gerektiği anlaşılmaktadır.

Çalışmada son olarak 2B MobileNetV2 ESA kullanılarak COVID-19 ve COVID-19 değil sınıflandırması yapılmıştır. Bu deney için giriş görüntülerinin boyutları Orijinal, GSEM, YİD ve LE için  $224 \times 224 \times 1$ ; Orijinal+GSEM, Orijinal+YİD ve Orijinal+LE için  $224 \times 224 \times 2$ ; Orijinal+GSEM+YİD, Orijinal+GSEM+LE ve Orijinal+YİD+LE için  $224 \times 224 \times 3$ ; Orijinal+GSEM+YİD+LE için  $224 \times 224 \times 4$ 'dür. Elde edilen uygulama sonuçları iki kat çapraz doğrulama için Çizelge 7.12 ve on kat çapraz doğrulama için Çizelge 7.13'de verilmiştir.

**Çizelge 7.12.** İki kat çapraz doğrulama için 2B MobileNetV2 ESA kullanılarak elde edilen sonuçlar

Giriş Görüntü Tipi	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AİKE-AKA	CPU Süresi (saniye)
Orijinal	355,0	31,0	964,8	45,2	<b>0,9197</b>	0,9552	0,9454	0,9031	0,9759	0,7444
GSEM	336,4	49,6	967,8	42,2	0,8715	0,9582	0,9342	0,8799	0,9775	0,7382
YİD	262,4	123,6	952,6	57,4	0,6798	0,9432	0,8703	0,7431	0,9217	0,7395
LE	270,0	116,0	978,8	31,2	0,6995	<b>0,9691</b>	0,8946	0,7855	0,9379	0,7366
Orijinal +GSEM	353,6	32,4	968,8	41,2	0,9161	0,9592	<b>0,9473</b>	<b>0,9058</b>	<b>0,9783</b>	0,7595
Orijinal +YİD	319,6	66,4	960,2	49,8	0,8280	0,9507	0,9168	0,8461	0,9604	0,7516
Orijinal +LE	333,8	52,2	962,0	48,0	0,8648	0,9525	0,9282	0,8695	0,9628	0,7622
Orijinal +GSEM+YİD	326,2	59,8	959,2	50,8	0,8451	0,9497	0,9208	0,8551	0,9693	0,7743
Orijinal +GSEM+LE	337,4	48,6	965,0	45,0	0,8741	0,9554	0,9330	0,8782	0,9627	0,7790
Orijinal +YİD+LE	323,2	62,8	972,6	37,4	0,8373	0,9630	0,9282	0,8656	0,9666	0,7725
Orijinal +GSEM+YİD+LE	323,4	62,6	967,0	43,0	0,8378	0,9574	0,9244	0,8596	0,9643	0,7987

**Çizelge 7.13.** On kat çapraz doğrulama için 2B MobileNetV2 ESA kullanılarak elde edilen sonuçlar

Giriş Görüntü Tipi	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AİKE-AKA	CPU Süresi (saniye)
Orijinal	363,0	23,0	977,0	33,0	<b>0,9404</b>	0,9673	<b>0,9599</b>	<b>0,9284</b>	0,9833	6,6215
GSEM	352,2	33,8	983,4	26,6	0,9124	0,9737	0,9567	0,9210	<b>0,9860</b>	6,6210
YİD	285,8	100,2	967,0	43,0	0,7404	0,9574	0,8974	0,7996	0,9452	6,5895
LE	307,8	78,2	988,0	22,0	0,7974	<b>0,9782</b>	0,9282	0,8600	0,9677	6,6118
Orijinal +GSEM	360,0	26,0	974,0	36,0	0,9326	0,9644	0,9556	0,9207	0,9858	6,7781
Orijinal +YİD	349,4	36,6	976,0	34,0	0,9052	0,9663	0,9494	0,9082	0,9794	6,8004
Orijinal +LE	348,4	37,6	972,6	37,4	0,9026	0,9630	0,9463	0,9028	0,9789	6,7878
Orijinal +GSEM+YİD	351,6	34,4	977,2	32,8	0,9109	0,9675	0,9519	0,9127	0,9841	6,9414
Orijinal +GSEM+LE	358,2	27,8	975,2	34,8	0,9280	0,9655	0,9552	0,9196	0,9816	6,9408
Orijinal +YİD+LE	341,6	44,4	972,6	37,4	0,8850	0,9630	0,9414	0,8931	0,9745	6,9451
Orijinal +GSEM+YİD+LE	346,4	39,6	976,2	33,8	0,8974	0,9665	0,9474	0,9041	0,9838	7,1508

Uygulamada 2B MobileNetV2 ESA kullanılarak elde edilen sonuçların yer aldığı Çizelge 7.12 ve Çizelge 7.13 incelendiğinde en yüksek ortalama duyarlılık, özgüllük, doğruluk, F-1 skoru ve AİKE-AKA parametrelerinin iki kat çapraz doğrulama

için sırasıyla 0,9197; 0,9691; 0,9473; 0,9058; 0,9783; on kat çapraz doğrulama için sırasıyla 0,9404; 0,9782; 0,9599; 0,9284; 0,9860 olarak hesaplandığı görülmektedir. Söz konusu en yüksek ortalama değerlerin, iki kat çapraz doğrulama için Orijinal, LE ve Orijinal+GSEM; on kat çapraz doğrulama için Orijinal, GSEM ve LE giriş görüntüleri kullanılarak elde edildiği görülmektedir. Eğitim ve test dahil görüntü başına sonuç elde etme süreleri incelendiğinde iki kat çapraz doğrulama için 0,7366 ile 0,7987 saniye arasında ve on kat çapraz doğrulama için 6,5895 ile 7,1508 saniye arasında değişen süreler gerektiği anlaşılmaktadır.

## **7.6. BT Görüntüler Üzerinden COVID-19 ve COVID-19 Değil Sınıflandırma Sonuçlarının Değerlendirilmesi**

Akciğer BT görüntülerinden otomatik COVID-19 ve COVID-19 değil sınıflandırmasını konu alan ve doku analiz yöntemleri, makine öğrenmesi ve derin öğrenme yöntemlerinden yararlanan tez çalışmasının birinci uygulamasında önemli sonuçlar elde edilmiştir. Uygulama kapsamında doku analizi yöntemlerinin birçok kombinasyonu, makine öğrenmesi ve derin öğrenme yöntemlerinin sınıflandırma başarısı kapsamlı bir şekilde ortaya çıkarılmıştır.

Tez çalışmasının birinci uygulamasında makine öğrenmesi yöntemleri DVM ve k-EYK kullanılarak elde edilen sonuçlar kendi aralarında karşılaştırıldığında DVM'nin k-EYK'ya göre daha başarılı olduğu görülmektedir. Görüntü başına sınıflandırma süresi olarak ise iki kat çapraz doğrulama için DVM'nin, on kat çapraz doğrulama için ise k-EYK'nin daha hızlı sınıflandırma sonucu ürettiği anlaşılmaktadır. DVM ve k-EYK için sadece orijinal görüntülerin kullanılmasıyla elde edilen sınıflandırma sonuçları ile doku özellik görüntülerinin tek başlarına veya orijinal görüntülere eklenerek kullanılmasıyla elde edilen sınıflandırma sonuçları karşılaştırıldığında birçok karşılaştırma parametresinde önemli iyileşmeler sağlandığı anlaşılmaktadır. Doku özellik görüntüleri kullanılarak DVM ve iki kat çapraz doğrulama için duyarlılık, özgüllük, doğruluk, F-1 skoru ve AİKE-AKA parametrelerinde sırasıyla %0,5181; %1,2871 (ikinci en yüksek sonuca göre); %0,8596; %1,3805; %0,3817 oranında iyileşme sağlandığı görülmektedir. DVM ve on kat çapraz doğrulama için özgüllük, doğruluk, F-1 skoru ve AİKE-AKA parametrelerindeki iyileşmeler ise sırasıyla %1,4851 (ikinci en yüksek sonuca göre); %0,5731; %0,8552; %0,2096'dir. k-EYK kullanılarak iki kat çapraz doğrulama ve on kat çapraz doğrulama için en yüksek duyarlılık değerleri orijinal görüntüler kullanılarak

elde edilmiştir. Ancak, doku özellik görüntüleri kullanılmasının diğer karşılaştırma parametrelerine olumlu yansıdığı görülmektedir. Doku özellik görüntüleri kullanılarak k-EYK ve iki kat çapraz doğrulama için özgüllük, doğruluk, F-1 skoru ve AİKE-AKA parametrelerinde sırasıyla %2,3762 (ikinci en yüksek sonuca göre); %0,7163; %0,8110; %0,8871 oranında ve on kat çapraz doğrulama için sırasıyla %1,9802 (ikinci en yüksek sonuca göre); %0,3582; %0,1163; %0,9370 oranında iyileşme sağlandığı görülmektedir. Bu kapsamda DVM kullanılarak gerçekleştirilen sınıflandırma sonuçlarının iyileştirilmesinde GSEM ve LE doku özellik çıkarma yöntemlerinin doğrudan kullanılmasının, k-EYK kullanılarak gerçekleştirilen sınıflandırma sonuçların iyileştirilmesinde ise YİD ve LE doku özellik çıkarma yöntemlerinin orijinal görüntülerle kombine edilerek kullanılmasının en etkin faydayı sağladığı anlaşılmaktadır.

Uygulamada veri artırma yapılarak eğitimlerde kullanılan görüntü sayısının artırılmasının ESA için sınıflandırma sonuçlarına etkisi incelenmiştir. Veri artırmaya bağlı olarak eğitim yükünde ve sınıflandırma süresinde önemli artışlar söz konusu olduğu için deneyler sadece 23 katmanlı 2B ESA ve iki kat çapraz doğrulama kullanılması durumu için gerçekleştirilmiştir. Uygulama sonuçları veri artırma yapılmasının sınıflandırma üzerinde kısmi olumlu katkıları olduğunu göstermektedir. Ancak, sınıflandırma sürelerinde de aynı oranlarda artışlara sebep olduğu anlaşılmaktadır. Ayrıca, diğer deneylerde olduğu gibi 23 katmanlı 2B ESA içinde sadece orijinal görüntülerin kullanılmasıyla elde edilen sınıflandırma sonuçları ile doku özellik görüntülerinin tek başlarına veya orijinal görüntülere eklenerek kullanılmasıyla elde edilen sonuçlar karşılaştırıldığında doku özellik görüntülerinin birçok karşılaştırma parametresinde önemli iyileşmeler sağladığı anlaşılmaktadır.

Uygulamada kullanılan 2B ESA mimarileri kendi içinde karşılaştırıldığında en başarılı sonuçların 2B MobileNetV2 kullanılarak elde edildiği görülmektedir. Sınıflandırma süreleri açısından ise en hızlı sonuçların 2B AlexNet ve 23 katmanlı 2B ESA kullanılarak sağlandığı anlaşılmaktadır. Sonuç elde etme hızı açısından 2B AlexNet ile 2B MobileNetV2 arasında 7 katlık bir fark olduğu görülmektedir. DVM ve k-EYK'ya benzer şekilde doku özellik görüntülerinin sınıflandırmaya dâhil edilmesinin 2B ESA'lar için de sınıflandırma sonuçları üzerinde olumlu etkileri olduğu anlaşılmaktadır.

2B ESA'lar için sadece orijinal görüntülerin kullanılmasıyla elde edilen sınıflandırma sonuçları ile doku özellik görüntülerinin tek başlarına veya orijinal

görüntülere eklenerek kullanılmasıyla elde edilen sonuçlar karşılaştırılarak bazı çıkarımlara ulaşılmıştır. Doku özellik görüntüleri kullanılarak 23 katmanlı 2B ESA ve iki kat çapraz doğrulama için duyarlılık, özgüllük, doğruluk, F-1 skoru ve AİKE-AKA parametrelerinde sırasıyla %0,4145; %3,3069, %1,3467; %1,8929 ve %0,6367 oranında iyileşme sağlandığı görülmektedir. 23 katmanlı 2B ESA kullanılarak on kat çapraz doğrulama için en yüksek duyarlılık ve F-1 skoru değerleri orijinal görüntüler kullanılarak elde edilmiştir. Ancak, doku özellik görüntüleri kullanılmasının diğer karşılaştırma parametrelerine olumlu yansıdığı görülmektedir. Bu kapsamda doku özellik görüntüleri kullanılarak 23 katmanlı 2B ESA ve on kat çapraz doğrulama için özgüllük, doğruluk ve AİKE-AKA parametrelerinde sırasıyla %1,7822; %0,0430 ve %0,5768 oranında iyileşme sağlanmıştır.

2B AlexNet için iyileşmeler daha da yüksek miktarlarda gerçekleşmiştir. Doku özellik görüntüleri ve 2B AlexNet kullanılarak özgüllük, doğruluk, F-1 skoru ve AİKE-AKA parametrelerinde iki kat çapraz doğrulama için sırasıyla %3,7824; %3,9010; %3,8395; %6,3918; %2,4969 oranında ve on kat çapraz doğrulama için sırasıyla %2,1762; %2,5347; %1,5903; %2,5606; %0,8262 oranında iyileşme sağlandığı görülmektedir.

2B MobileNetV2 kullanılarak iki kat çapraz doğrulama için en yüksek duyarlılık değeri orijinal görüntüler kullanılarak elde edilmiştir. Ancak, doku özellik görüntüleri kullanılmasının diğer karşılaştırma parametrelerine olumlu yansıdığı görülmektedir. Doku özellik görüntüleri kullanılarak 2B MobileNetV2 ESA ve iki kat çapraz doğrulama için özgüllük, doğruluk, F-1 skoru ve AİKE-AKA parametrelerinde sırasıyla %1,3861; %0,1862; %0,2644 ve %0,2356 oranında iyileşme sağlanmıştır. Ayrıca, doku özellik görüntüleri kullanılarak 2B MobileNetV2 ESA ve on kat çapraz doğrulama için duyarlılık, özgüllük, doğruluk, F-1 skoru ve AİKE-AKA parametrelerinde sırasıyla %0,4145; %3,3069; %1,3467; %1,8929; %0,6367 oranında iyileşme sağlanmıştır.

Çizelge 7.14'de literatürde yer alan çalışmalarda elde edilen sonuçlar ile uygulamada elde edilen sonuçların karşılaştırması yer almaktadır. Çizelge 7.14'den de anlaşılacağı üzere çalışmada elde edilen en yüksek ortalama duyarlılık, özgüllük, doğruluk, F-1 skoru ve AİKE-AKA parametreleri iki kat çapraz doğrulama için sırasıyla 0,9197; 0,9891 (ikinci en yüksek); 0,9473; 0,9058; 0,9888 ve on kat çapraz doğrulama için sırasıyla 0,9404; 0,9901 (ikinci en yüksek); 0,9599; 0,9284; 0,9903'dir.



**Çizelge 7.14.** Tez çalışmasının birinci uygulamasında BT görüntülerden COVID-19 ve COVID-19 değil sınıflandırması için elde edilen sonuçların literatürde yer alan çalışmalarda elde edilen sonuçlar ile karşılaştırılması

Çalışma	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AİKE-AKA
Ni ve ark., 2020	1,00	0,25	0,94	0,97	X
Wang ve ark., 2020(a)	X	X	0,847-0,901	X	0,9590
Han ve ark., 2020	0,968-0,979	X	0,968-0,979	0,968-0,979	0,982-0,990
Ardakani ve ark., 2020	0,7843-1,000	0,6863-1,000	0,7892-0,9951	X	0,894-0,994
Harmon ve ark., 2020	0,751-0,853	0,901-0,951	0,889-0,908	X	0,938-0,949
Jaiswal ve ark., 2021	0,9206-0,9735	0,8972-0,9621	0,909-0,9625	0,9109-0,9629	0,97
Horry ve ark., 2020	0,81-0,83	X	X	0,81-0,83	X
Pathak ve ark., 2020	0,9146	0,9478	0,9302	X	X
Ouyang ve ark., 2020	0,869	0,901	0,875	0,820	0,944
Sakagianni ve ark., 2020	0,8831	X	X	0,8831	X
Hu ve ark., 2020	0,8330	0,9560	0,9060	X	0,9430
Ragab ve Attallah, 2020	0,99	X	0,99	0,99	1,00
Sen ve ark., 2021	0,8406-0,9778	X	0,90-0,9839	0,8855-0,98	0,9414-0,9952
Konar ve ark., 2021	0,935	X	0,944	0,948	0,983
Kaur ve ark., 2021	0,9960	X	0,9918-0,9938	0,992-0,994	0,9916-0,9958
Goel ve ark., 2021	0,9978	0,9778	0,9922	0,9879	X
Zhu ve ark., 2021(a)	0,93	0,92	0,93	0,93	0,93
Saad ve ark., 2021	0,985	X	0,989	0,9892	X
Liang ve ark., 2021	0,999	0,97	0,985	X	0,999
Alshazly ve ark., 2021	0,937-0,998	0,922-0,996	0,929-0,994	0,925-0,994	X
Chaudhary ve Pachori, 2021	0,97-0,976	0,965-0,9836	0,976	0,97-0,98	X
Lacerda ve ark., 2021	0,97	X	0,88	X	X
Singh ve ark., 2021	X	X	0,957	0,953	0,958
İki kat çapraz doğrulama	0,9197	0,9891	0,9473	0,9058	0,9888
On kat çapraz doğrulama	0,9404	0,9901	0,9599	0,9284	0,9903

Uygulamada elde edilen sayısal sonuçlarının daha önce yapılmış çalışmaların sayısal sonuçlarıyla doğrudan karşılaştırılması doğru bir yaklaşım değildir. Çünkü, kullanılan toplam görüntü sayısı, test ve eğitim yaklaşımı, test ve eğitim görüntü sayısındaki farklılıklar sonuçlar üzerinde doğrudan etkili faktörlerdir. Ancak, uygulamada elde edilen ve Çizelge 7.14’de özet bilgisi verilen uygulama sonuçları ile literatürde daha önce gerçekleştirilen çalışmalarda elde edilen sonuçları karşılaştırmak gerekirse başarılı sonuçlara ulaşıldığı görülmektedir. Bu kapsamda Ni ve arkadaşları (2020), Wang ve arkadaşları (2020(a)), Harmon ve arkadaşları (2020), Horry ve arkadaşları (2020), Pathak ve arkadaşları (2020), Ouyang ve arkadaşları (2020), Sakagianni ve arkadaşları (2020), Hu ve arkadaşları (2020), Konar ve arkadaşları (2021), Zhu ve arkadaşları (2021(a)), Lacerda ve arkadaşları (2021), Singh ve

arkadaşları (2021) tarafından gerçekleştirilen çalışmalarda elde edilen sonuçlardan daha yüksek sonuçlar elde edildiği anlaşılmaktadır. Çalışma sonuçları Jaiswal ve arkadaşları (2021) tarafından gerçekleştirilen çalışmada elde edilen sonuçlara genel olarak denk, Han ve arkadaşları (2020), Ardakani ve arkadaşları (2020), Ragab ve Attallah (2020), Sen ve arkadaşları (2021), Kaur ve arkadaşları (2021), Goel ve arkadaşları (2021), Saad ve arkadaşları (2021), Liang ve arkadaşları (2021), Alshazly ve arkadaşları (2021), Chaudhary ve Pachori (2021) tarafından gerçekleştirilen çalışmaların ise gerisindedir. Ancak daha doğru karşılaştırılma yapılması için Ardakani ve arkadaşları (2020) tarafından gerçekleştirilen çalışma da görüntü üzerinde 60×60 büyüklüğünde ilgi alanlarının belirlenmesinin manuel olarak yapıldığı ve yoğun alanların işaretlendiği hususunun dikkate alınması gerekmektedir. Nitekim, Jaiswal ve arkadaşları (2021) tarafından benzer transfer öğrenme yaklaşımları kullanılmasına rağmen görüntü bir bütün olarak kullanıldığı için daha düşük sonuçlar elde edilmiştir. Tez çalışmasının birinci uygulamasında görüntü bir bütün halinde sınıflandırmaya tabi tutulmuştur.

## 8. BT GÖRÜNTÜLER ÜZERİNDEN COVID-19 VE COVID-19 DEĞİL İLE COVID-19 ZATÜRRESİ VE DİĞER ZATÜRRE SINIFLANDIRMASI

Tez çalışmasının ikinci uygulamasında BT görüntüler üzerinden COVID-19 ve COVID-19 değil ile COVID-19 zatürresi ve diğer zatürre olmak üzere iki başlıkta iki sınıflı sınıflandırma gerçekleştirilmiştir. Söz konusu uygulama sonuçları Yaşar ve Ceylan tarafından (Yaşar ve Ceylan, 2022(a)) yayınlanmıştır.

### 8.1. Uygulamada Kullanılan Veriler

Tez çalışmasının ikinci uygulamasında birçok kaynaktan toplanan görüntülerden yararlanılmıştır. İlk olarak Cohen ve arkadaşları (Cohen ve ark., 2020) ile Zhao ve arkadaşları (Zhao ve ark., 2020(b)) tarafından oluşturularak GitHub platformu üzerinden açık erişime açılan ve meta data şeklinde biriktirilen iki veri seti birleştirilerek uygulamaya dahil edilmiştir. Birleştirme işlemi sırasında görüntüler ve ilgili klinik notlar dikkate alınmıştır. Sonuç olarak, 386 BT akciğer görüntüsünü içeren birleştirilmiş bir COVID-19 görüntü veri seti oluşturulmuştur. Veri setinde aynı hastadan alınan görüntüler, hastalık seyrinin farklı günlerinde ve farklı görüntüleme çekimleri ile elde edilmiştir. Uygulamaya ikinci olarak, Angelov ve Almeida Soares (Angelov ve Almeida Soares, 2020) tarafından toplanan COVID-19 BT görüntüleri dahil edilmiştir. Söz konusu görüntüler Sao Paulo Kamu Çalışanları Devlet Hastanesinden ve Lapa Metropolitan Hastanesinden toplanmış olup TT-PZR testi ile doğrulanmıştır. Uygulamaya 2.168 COVID-19 BT görüntüsü daha eklenerek COVID-19 BT görüntü sayısı 2.554'e yükselmiştir.

COVID-19 BT görüntülerinin yatay ve dikey görüntü boyutları ve kayıt biçimleri incelendiğinde, boyutlarının 115×98 ile 2024×1523 arasında değiştiği; kayıt biçimlerinin ise png, jpg ve jpeg gibi farklı uzantılar olduğu görülmektedir. Görüntülerin önemli bir kısmı 24 bit derinlikte RGB formatında iken küçük bir kısmı 8 bit gri seviye formatındadır. Görüntü özellikleri farklılıklar gösterdiği için uygulamada kullanılabilirliği için standardize edilmeleri gerekmektedir. Bu kapsamda ilk olarak, COVID-19 BT akciğer görüntüleri 8 bit gri seviyeye dönüştürülmüştür. Daha sonra görüntüler akciğer bölgesi sınırlarını içine alacak şekilde çerçevelenmiş ve çalışma alanı belirlenmiştir. Bu standardizasyon işlemlerinden sonra tüm görüntüler yeniden düzenlenerek 448×448 boyutlarına ayarlanmış ve png formatında kaydedilmiştir.

Uygulamada kullanılan COVID-19 değil BT görüntülerinin bir kısmı, kanser arařtırmalarında kullanılmak üzere oluřturulan LIDC-IDRI (Armato ve ark., 2011; Clark ve ark., 2013; Armato ve ark., 2015) veri setinden alınmıřtır. Veri seti 2015 yılında tamamlanmıř ve arařtırmacıların aık eriřimine aılmıřtır. Veri seti normal akcięer BT görüntülerinin yanı sıra kanser nodülüne sahip akcięer BT görüntülerini içermektedir. Yani, veri seti normal akcięer ve yoęun kanserli akcięer görüntülerini içeren birleřtirilmiř bir veri setidir. Uygulamaya LIDR-IDRI veri setinden tüm hastalardan bir adet alınmak üzere 1.010 BT akcięer görüntüsü COVID-19 değil etiketi ile dahil edilmiřtir. Ayrıca, Angelov ve Almeida Soares (Angelov ve Almeida Soares, 2020) tarafından yayınlanan veri setinden 756 saęlıklı BT akcięer görüntüsü COVID-19 değil olarak uygulamaya eklenmiř ve uygulamada kullanılan COVID-19 değil görüntü sayısı 1.766'ya yükselmiřtir.

Uygulamada COVID-19 ve COVID-19 değil sınıflandırmasına ek olarak COVID-19 zatürresi ve dięer zatürre sınıflandırması yapılmıřtır. Dięer zatürre sınıfı için kullanılan 1.247 adet BT görüntüsü Angelov ve Almeida Soares (Angelov ve Almeida Soares, 2020) tarafından oluřturulan veri setinden alınmıřtır. COVID-19 BT akcięer görüntülerine uygulanan iřlemlerin aynısı COVID-19 değil ve dięer zatürre görüntülerine de uygulanmıř ve bu görüntüler de standardize edilmiřtir. Uygulamada kullanılan COVID-19, COVID-19 değil ve dięer zatürre BT görüntülerine iliřkin özet bilgiler izelge 8.1'de yer almaktadır. Uygulamada kullanılan toplam görüntü sayısı ile literatürde daha önce yapılmıř alıřmalarda kullanılan görüntü sayıları arasında bir karřılařtırma yapılırsa, COVID-19 ve COVID-19 değil sınıflandırması için daha önce gerekleřtirilen yirmi dört alıřmada kullanılan ortalama görüntü sayısı 1.896'dır. Uygulamada, bu sınıflandırma bařlığında kullanılan görüntü sayısı 2.254 COVID-19 ve 1.766 COVID-19 değil olmak üzere toplam 4.320'dir. Yani, uygulamada kullanılan görüntü sayısı ortalamanın iki katından daha fazladır. Daha önce gerekleřtirilen yirmi dört alıřmanın yirmi üçünden daha fazla ve yirmi dördüncüsü ile hemen hemen eřit sayıda görüntü kullanılmıřtır. COVID-19 zatürre ve dięer zatürre sınıflandırması için literatürde daha önce gerekleřtirilen yedi alıřmada ortalama 1.011 görüntü kullanılırken, bu uygulamada 2.254 COVID-19 zatürresi ve 1.247 dięer zatürre olmak üzere toplam 3.801 görüntü kullanılmıřtır. Yani, uygulamada kullanılan görüntü sayısı ortalama sayının yaklařık dört katıdır. COVID-19 ve COVID-19 değil sınıflandırması için görüntülerin %91'den fazlası, COVID-19 zatürresi ve dięer zatürre sınıflandırması için görüntülerin %90'ından fazlası doęrudan gerek dünyadan alınmıřtır. Görüntü

sayısının yüksek tutulmasının temel amacı ESA eğitiminde karşılaşılabilecek aşırı uyum problemini en aza indirmektir.

**Çizelge 8.1.** Tez çalışmasının ikinci uygulamasında kullanılan COVID-19, COVID-19 değil ve diğer zatürre BT görüntülerine ilişkin bilgiler

Kaynak	COVID-19	COVID-19 Değil	Diğer Zatürre
Cohen ve ark.,2020 ile Zhao ve ark., 2020(b)	386	X	X
Angelov ve Almeida Soares, 2020	2.168	756	1.247
LIDC-IDRI	X	1.010	X
Toplam	2.554	1.766	1.247

## 8.2. Özellik Çıkarma, ESA Modifikasyonları ve Hiperparametreler

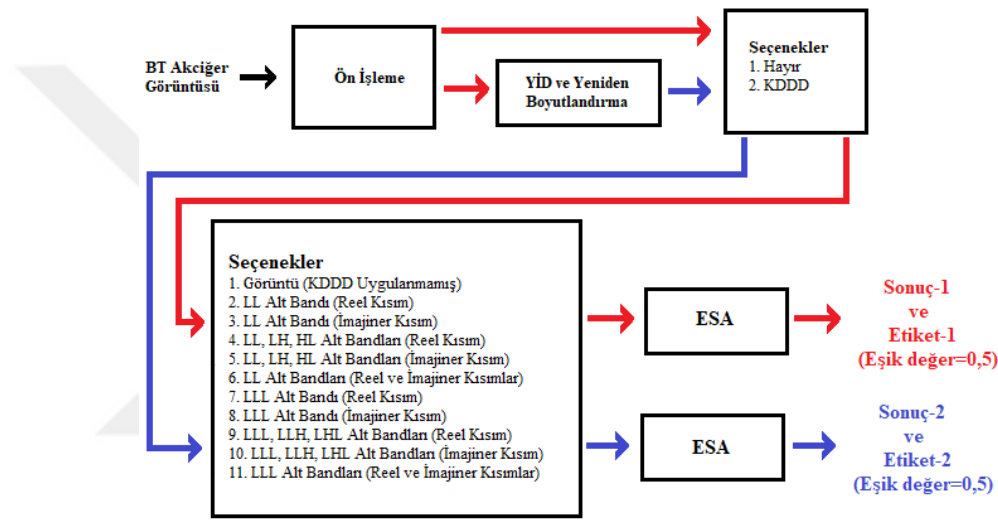
Tez çalışmasının ikinci uygulamasında yararlanılan YİD yönteminin işletilmesinde kullanılan yarıçap değeri 1, 2 ve 3 olarak seçilmiştir. YİD işlemi sonunda görüntü boyutlarında azalma olması sebebiyle, MATLAB *imresize* fonksiyonu kullanılarak görüntü boyutları yeniden düzenlenmiştir.

Uygulamada kullanılan KDDD işleminin ölçek değeri 1 ve 2 olarak seçilmiştir. KDDD işleminin görüntüye her uygulanması sonucu elde edilen görüntü alt matrislerinin boyutları giriş görüntü boyutlarının yarısı kadardır.

Eğitimler sırasında ilk ağırlık transferi yapılmamıştır. Yani tüm ESA mimarileri baştan rastgele atanan ağırlıklarla eğitilmiştir. Uygulamanın yazılımları MATLAB 2019(a) programı kullanılarak oluşturulmuştur. ESA eğitiminde ağ çözücü olarak momentumlu stokastik gradyan inişi seçilmiştir. Maksimum iterasyon sayısı program tarafından varsayılan değer kabul edilen 30 olarak belirlenmiştir. Bu tercihin temel nedeni aşırı uyum probleminde kaçınmaktır. Yani bu değeri yüksek seçmek yerine varsayılan değer kullanılarak erken durdurma yapılmıştır. Küme boyutu program tarafından varsayılan değer kabul edilen 128 olarak ayarlanmıştır. Aşırı uyum problemine karşı önlem olarak veri karıştırma seçenekleri her iterasyon olarak belirlenmiştir. Benzer şekilde öğrenme oranı program tarafından varsayılan değer kabul edilen 0,01 olarak seçilmiştir. Momentum, gradyan bozunma faktörü, sıra doldurma gibi diğer tüm parametreler varsayılan değerler olarak ayarlanmıştır. MathWorks sayfasından (MathWorks, 2022(a)) parametrelerin açıklamalarının ve varsayılan değerlerin incelenmesi mümkündür.

### 8.3. Uygulamada Kullanılan VAH Yaklaşımları

Uygulamada öncelikle, orijinal BT akciğer görüntüleri doğrudan ve bu orijinal görüntülere YİD uygulanarak elde edilen özellik görüntüleri kullanılarak deney sonuçları hesaplanmıştır. Daha sonra, sınıflandırma işlemlerinde ara işlem olarak KDDD kullanılarak elde edilen alt görüntü matrislerinin bazı kombinasyonları için sonuçlar hesaplanmıştır. Bu şekilde YİD işlemi uygulanarak ve YİD işlemi uygulanmadan bütün deney sonuçları elde edilmiştir. Şekil 8.1, bu yaklaşımla gerçekleştirilen deneylerin bir özetini göstermektedir.

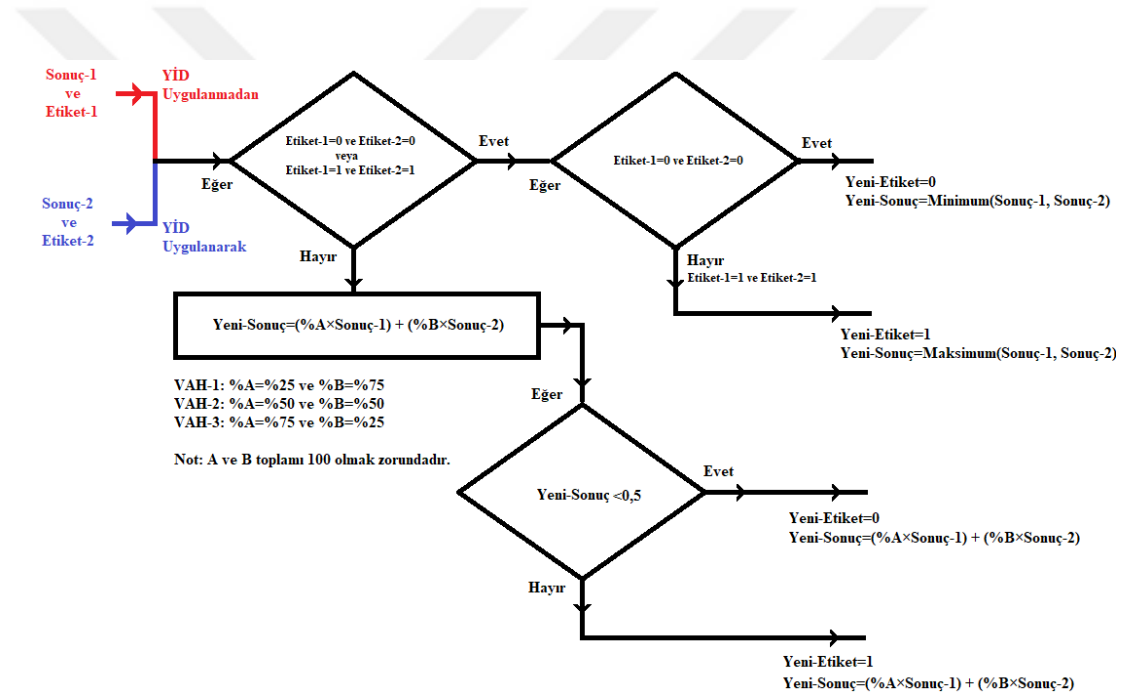


Şekil 8.1. Tez çalışmasının ikinci uygulamasında gerçekleştirilen deneylerin özeti (Yaşar ve Ceylan, 2022(a))

Uygulamada ikinci olarak, ilk aşamada elde edilen sonuçların birleştirilmesini sağlayan VAH yaklaşımları önerilmiş ve başarıları test edilmiştir. Uygulamada toplam beş adet VAH yaklaşımı kullanılmıştır. Şekil 8.2’de görüldüğü üzere birinci, ikinci ve üçüncü VAH yaklaşımları, birbiriyle ilişkili iki deneyde elde edilen sonuç etiketlerinin birbirinden farklı olması durumunda sayısal sonuçların belirli oranlarda birleştirilmesi ve yeni sınıflandırma sonuçlarının oluşturulmasına dayanmaktadır. İlk üç VAH yaklaşımında ağırlık oranlarının toplamı %100 olmak üzere, %25-%75 (VAH-1), %50-%50 (VAH-2) ve %75-%25(VAH-3) şeklinde üç farklı ağırlık kombinasyonu için yeni sayısal sonuçlar elde edilmiştir. Daha sonra, yeni sınıflandırma sonucunun tanısal etiketlemesi gerçekleştirilmiştir. Bu VAH yaklaşımlarında, YİD uygulanarak ve YİD uygulanmadan elde edilen tanı etiketleri aynı ve bu etiketler COVID-19 ise minimum

sayısal sonuç, bu etiketler COVID-19 değilse maksimum sayısal sonuç yeni sınıflandırma sonucu olarak kabul edilmiştir.

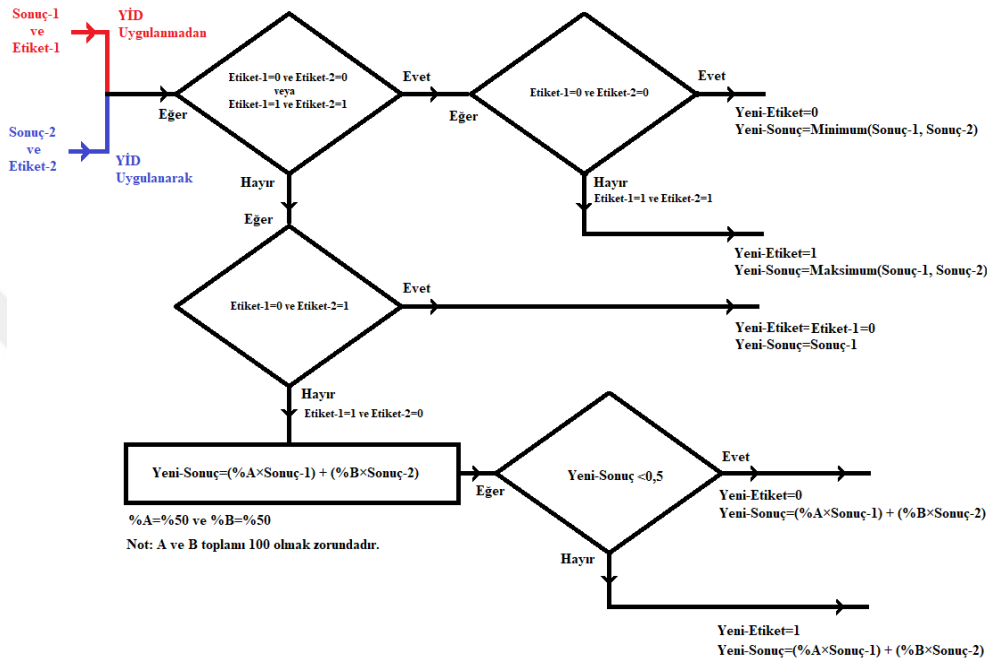
Benzer şekilde COVID-19 zatürresi ve diğer zatürre sınıflandırması için, YİD uygulanarak ve YİD uygulanmadan elde edilen tanı etiketleri aynı ve bu etiketler COVID-19 zatürresi ise minimum sayısal sonuç; bu etiketler diğer zatürre ise maksimum sayısal sonuç yeni sınıflandırma sonucu olarak kabul edilmiştir. Bunun temel nedeni, COVID-19 ve COVID-19 değil sınıflandırmasının eğitim işlemlerinde COVID-19 görüntüleri için hedef olarak 0, COVID-19 değil görüntüler için hedef olarak 1 değerinin atanmasıdır. Benzer şekilde, COVID-19 zatürre ve diğer zatürre sınıflandırmasının eğitim işlemlerinde COVID-19 zatürre görüntüleri için hedef olarak 0, diğer zatürre görüntüleri için hedef olarak 1 değeri atanmıştır.



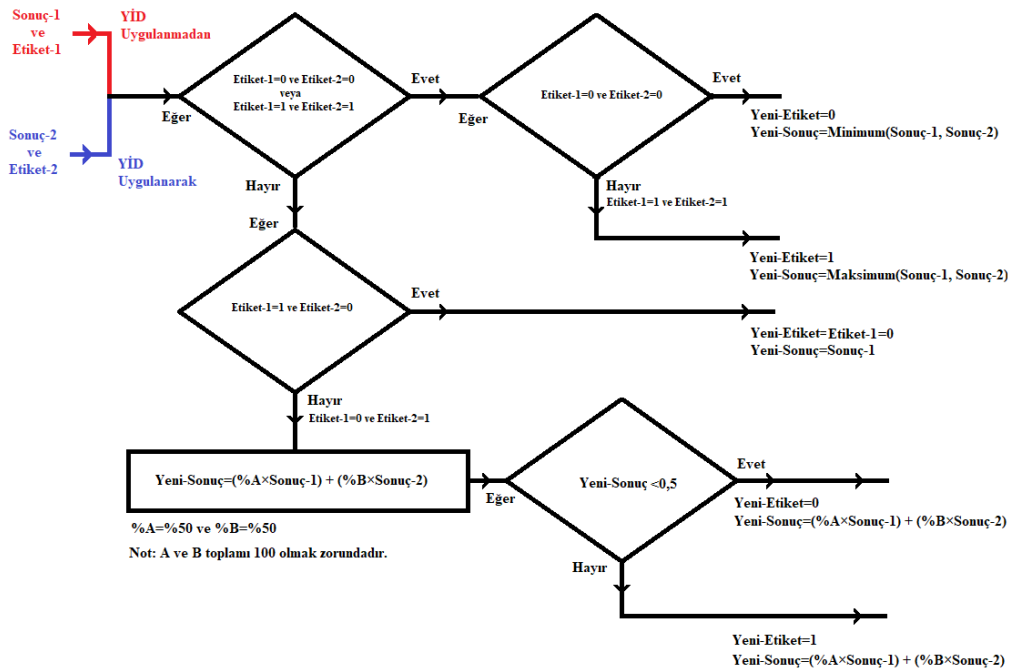
**Şekil 8.2.** Tez çalışmasının ikinci uygulamasında kullanılan VAH-1, VAH-2 ve VAH-3 yaklaşımları (Yaşar ve Ceylan, 2022(a))

Uygulamada kullanılan dördüncü ve beşinci VAH yaklaşımları Şekil 8.3 ve Şekil 8.4'de açıklanmıştır. Bu yaklaşımların ilk üç VAH yaklaşımından temel farkı, YİD uygulanarak ve YİD uygulanmadan elde edilen tanı etiketleri farklıysa, tek yönlü yeni sayısal sonuç hesaplamalarının yapılmış olmasıdır. Örneğin, dördüncü VAH yaklaşımında iki sınıflandırma etiketinin birbirinden farklı ve YİD uygulanmadan elde edilen etiket sonucunun COVID-19 olması durumunda sonuç COVID-19 kabul edilmiştir. Beşinci VAH yaklaşımında ise iki sınıflandırma etiketinin birbirinden farklı

ve YİD uygulanmadan elde edilen etiket sonucu COVID-19 değil olması durumunda sonuç COVID-19 değil olarak kabul edilmiştir. Benzer durumlar, COVID-19 zatürresi ve diğer zatürre sınıflandırması için de geçerlidir. Dördüncü ve beşinci VAH yaklaşımında gerçekleştirilen birleştirme işleminde %50-%50 ağırlık kombinasyonu kullanılmaktadır.



Şekil 8.3. Tez çalışmasının ikinci uygulamasında kullanılan VAH-4 yaklaşımı (Yaşar ve Ceylan, 2022(a))



Şekil 8.4. Tez çalışmasının ikinci uygulamasında kullanılan VAH-5 yaklaşımı (Yaşar ve Ceylan, 2022(a))



Diğer sayısal sonuç hesaplama ve etiketlendirme prosedürleri ilk üç VAH yaklaşımına benzer şekilde gerçekleştirilmektedir. VAH yaklaşımlarının çalışma süreleri, saniyenin binde birinden daha azdır. Yani; VAH yaklaşımlarının toplam çalışma süresi, giriş olarak kullanılan sonuçları elde etmek için gereken sürelerin toplamına yaklaşık olarak eşittir.

#### 8.4. Deneyleler

Tez çalışmasının ikinci uygulamasında BT görüntüleri üzerinden COVID-19 ve COVID-19 değil ile COVID-19 zatürresi ve diğer zatürre olmak üzere iki başlıkta iki sınıflı sınıflandırma gerçekleştirilmiştir. Sınıflandırma işlemlerinde yapay zekâ yaklaşımlarından biri olan derin öğrenme kullanılmıştır. Uygulamada COVID-19 ve COVID-19 değil sınıflandırması için, üç veri setinin birleştirilmesiyle elde edilen 2.554 COVID-19 BT görüntüsü ve iki veri setinin birleştirilmesiyle elde edilen normal ile aşırı yoğun seviyeli nodüllere sahip 1.766 COVID-19 değil BT görüntüsü kullanılmıştır. Benzer şekilde COVID-19 zatürresi ve diğer zatürre sınıflandırması için, üç veri kümesinin birleştirilmesiyle elde edilen 2.554 COVID-19 BT görüntüsü ve bir adet veri setinden alınan 1.247 diğer zatürre BT görüntüsünden yararlanılmıştır.

Uygulamada ilk olarak BT görüntüleri ilgi alanlarının belirlenmesi için çerçevelenmiştir. Çerçeveleme yapılırken akciğer bölgesinin sınırlarının maksimum düzeyde kapsanması için titizlik gösterilmiştir. Uygulamada derin öğrenme yöntemlerinden biri olan ESA'nın kullanılabilmesi için tüm görüntülerin aynı boyuta ayarlanması gerekmektedir. Çerçeveleme işleminden sonra görüntüler yeniden boyutlandırılmış ve boyutları 448×448 olarak düzenlenmiştir. Ön işleme bölümünün son aşamasında ise görüntüler png formatında 8 bit gri seviye olarak kaydedilmiştir.

Uygulamada ayrıntıları daha önce açıklanan 24 katmanlı 2B ESA mimarisinden yararlanılmıştır. Bu ESA mimarisi uygulamadaki tüm eğitim ve test işlemlerinde kullanılmıştır. Ancak, uygulamada farklı boyutlardaki görüntü ve özellik matrisleri için işlemler gerçekleştirildiği için ESA girişine verilen görüntü boyutları farklılık göstermektedir.

Uygulamanın deneylerinde on kat çapraz doğrulama prosedürü kullanılmıştır. Bu kapsamda COVID-19 ve COVID-19 değil sınıflandırması için test işlemlerinde kullanılan 431/441 görüntü (431 görüntüden oluşan dokuz grup ve 441 görüntüden oluşan bir grup) dışında kalan 3.889/3.879 görüntüden eğitim işlemlerinde

yararlanılmıştır. Bu eğitim ve test işlemleri on kez çalıştırılarak tüm görüntülerin sınıflandırılmasına yönelik sonuçlar elde edilmiştir. Eğitim işlemlerinde COVID-19 görüntüleri için hedef olarak 0 değeri atanırken, COVID-19 değil görüntüler için 1 değeri atanmıştır. Sayısal sonuçlardan COVID-19 ve COVID-19 değil etiketlemesi yapılırken eşik değeri 0,5 olarak kabul edilmiştir. Bu eşik değerinin altındaki sayısal sonuçlar COVID-19 olarak, bu değer üzerinde sayısal sonuçlar ise COVID-19 değil olarak etiketlenmiştir.

COVID-19 zatürresi ve diğer zatürre sınıflandırması için test işlemlerinde kullanılan 379/390 görüntü (379 görüntüden oluşan dokuz grup ve 390 görüntüden oluşan bir grup) dışında kalan 3.422/3.411 görüntüden eğitim işlemlerinde yararlanılmıştır. Bu eğitim ve test işlemleri on kez çalıştırılarak tüm görüntülerin sınıflandırılmasına yönelik sonuçlar elde edilmiştir. Eğitim işlemlerinde COVID-19 zatürre görüntüleri için hedef olarak 0 değeri atanırken, diğer zatürre görüntüleri için 1 değeri atanmıştır. COVID-19 zatürre ve diğer zatürre etiketlemelerinde eşik değeri 0,5 olarak kabul edilmiştir. Bu eşik değerinin altındaki sayısal sonuçlar COVID-19 zatürresi, bu değer üzerinde sayısal sonuçlar ise diğer zatürre olarak etiketlenmiştir.

Yukarıda açıklanan deneyler hem YİD uygulanan hem de YİD uygulanmayan görüntüler için gerçekleştirilmiş ve sonuçlar elde edilmiştir. Daha sonra, deney sonuçlarının birleştirilmesini sağlayan VAH yaklaşımları devreye alınmıştır. Uygulamada daha önce detayları açıklanan beş farklı VAH yaklaşımının başarısı test edilmiştir. ESA'nın eğitiminde başlangıç ağırlıkları için herhangi bir transfer yapılmamıştır. Başka bir deyişle, eğitim işlemleri en baştan rastgele atanan başlangıç ağırlıkları kullanılarak çalıştırılmıştır. Bu kapsamda, program tarafından rastgele atanan başlangıç ağırlıklarının sonuçlara etkisini sınırlandırmak ve çalışma sonuçlarını stabilize etmek için her deney kendi içinde beş kez tekrarlanmıştır. Deneysel tekrarların ortalamaları sonuç olarak verilmiştir.

Uygulama kapsamında bir görüntünün sınıflandırılması için ihtiyaç duyulan süreler (CPU süresi) saniye cinsinden ölçülmüştür. Deneyler; 64 GB RAM, Intel(R) Xeon (R) CPU E5-2680 2.7 GHz (32 CPUs) bilgisayar üzerinde çalışan MATLAB 2019(a) yazılımı kullanılarak gerçekleştirilmiştir. Uygulamada verilen tüm CPU çalışma süreleri saniye cinsinden zamanı göstermektedir.

## 8.5. Deney Sonuçları

Uygulamada ilk olarak gri seviye BT akciğer görüntülerine YİD işlemi uygulanmadan yani orijinal görüntüler ve YİD uygulanarak elde edilen görüntüler kullanılarak (ara işlem olarak KDDD kullanılmadan) eğitim ve test işlemleri gerçekleştirilmiştir. Bu deneylerde 24 katmanlı 2B ESA mimarisine giriş olarak verilen görüntü matrislerinin boyutu  $448 \times 448 \times 1$ 'dir. Daha sonra, bu iki deneyin sonuçları detayları daha önce açıklanan beş farklı VAH yaklaşımı yardımıyla birleştirilmiş ve yeni sonuçlar hesaplanmıştır. Birinci aşama deneylerde, YİD işleminde kullanılan yarıçap değerindeki değişimin sonuçlara etkisi de incelenmiştir. Bu nedenle 1, 2 ve 3 olmak üzere üç farklı yarıçap değeri için sonuçlar ayrı ayrı verilmiştir. COVID-19 ve COVID-19 değil sınıflandırma için sonuçlar Çizelge 8.2 ile Çizelge 8.4 arasında, COVID-19 zatürresi ve diğer zatürre sınıflandırması için sonuçlar Çizelge 8.5 ile Çizelge 8.7 arasında yer almaktadır. Kullanılan VAH yaklaşımları değerlendirmede kullanılan tüm parametre sonuçlarını artırmıştır. Çizelgelerde en yüksek parametre değerleri koyu olarak belirtilmiştir. Bu işaretleme devam eden diğer çizelgelerde de yapılmıştır.

**Çizelge 8.2.** COVID-19 ve COVID-19 değil sınıflandırmasında doğrudan BT akciğer görüntüleri kullanılarak elde edilen sonuçlar (YİD yarıçap değeri 1)

Yöntem	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AIKE-AKA	CPU Süresi (saniye)
Orijinal	2446,40	107,60	1605,60	160,40	<b>0,9579</b>	<b>0,9092</b>	<b>0,9380</b>	<b>0,9481</b>	<b>0,9833</b>	1,1872
YİD	2429,20	124,80	1588,20	177,80	0,9511	0,8993	0,9300	0,9414	0,9806	1,1915
VAH-1	2439,20	114,80	1606,60	159,40	0,9551	0,9097	0,9365	0,9468	0,9886	2,3788
VAH-2	2466,40	87,60	1637,40	128,60	0,9657	0,9272	<b>0,9500</b>	<b>0,9580</b>	<b>0,9897</b>	2,3788
VAH-3	2455,60	98,40	1626,60	139,40	0,9615	0,9211	0,9450	0,9538	0,9894	2,3788
VAH-4	2497,60	56,40	1555,00	211,00	<b>0,9779</b>	0,8805	0,9381	0,9492	0,9882	2,3788
VAH-5	2415,20	138,80	1688,00	78,00	0,9457	<b>0,9558</b>	0,9498	0,9571	0,9886	2,3788

**Çizelge 8.3.** COVID-19 ve COVID-19 değil sınıflandırmasında doğrudan BT akciğer görüntüleri kullanılarak elde edilen sonuçlar (YİD yarıçap değeri 2)

Yöntem	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AIKE-AKA	CPU Süresi (saniye)
Orijinal	2446,40	107,60	1605,60	160,40	<b>0,9579</b>	<b>0,9092</b>	<b>0,9380</b>	<b>0,9481</b>	<b>0,9833</b>	1,1872
YİD	2423,40	130,60	1565,60	200,40	0,9489	0,8865	0,9234	0,9361	0,9767	1,1909
VAH-1	2436,40	117,60	1586,00	180,00	0,9540	0,8981	0,9311	0,9424	0,9870	2,3782
VAH-2	2466,00	88,00	1625,40	140,60	0,9655	0,9204	0,9471	0,9557	<b>0,9885</b>	2,3782
VAH-3	2454,60	99,40	1619,40	146,60	0,9611	0,9170	0,9431	0,9523	0,9884	2,3782
VAH-4	2496,20	57,80	1547,20	218,80	<b>0,9774</b>	0,8761	0,9360	0,9475	0,9874	2,3782
VAH-5	2416,20	137,80	1683,80	82,20	0,9460	<b>0,9535</b>	<b>0,9491</b>	<b>0,9565</b>	0,9878	2,3782

**Çizelge 8.4.** COVID-19 ve COVID-19 değil sınıflandırmasında doğrudan BT akciğer görüntüleri kullanılarak elde edilen sonuçlar (YİD yarıçap değeri 3)

Yöntem	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AIKE-AKA	CPU Süresi (saniye)
Orijinal	2446,40	107,60	1605,60	160,40	<b>0,9579</b>	<b>0,9092</b>	<b>0,9380</b>	<b>0,9481</b>	<b>0,9833</b>	1,1872
YİD	2406,00	148,00	1519,80	246,20	0,9421	0,8606	0,9088	0,9244	0,9697	1,1893
VAH-1	2422,00	132,00	1565,80	200,20	0,9483	0,8866	0,9231	0,9359	0,9839	2,3766
VAH-2	2460,20	93,80	1620,80	145,20	0,9633	0,9178	0,9447	0,9537	0,9865	2,3766
VAH-3	2454,00	100,00	1621,60	144,40	0,9608	0,9182	0,9434	0,9526	<b>0,9868</b>	2,3766
VAH-4	2492,80	61,20	1542,40	223,60	<b>0,9760</b>	0,8734	0,9341	0,9460	0,9860	2,3766
VAH-5	2413,80	140,20	1684,00	82,00	0,9451	<b>0,9536</b>	<b>0,9486</b>	<b>0,9560</b>	0,9865	2,3766

**Çizelge 8.5.** COVID-19 zatürresi ve diğer zatürre sınıflandırmasında doğrudan BT akciğer görüntüleri kullanılarak elde edilen sonuçlar (YİD yarıçap değeri 1)

Yöntem	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AIKE-AKA	CPU Süresi (saniye)
Orijinal	2401,60	152,40	818,40	428,60	0,9403	0,6563	0,8471	0,8921	0,9019	1,1729
YİD	2419,40	134,60	856,00	391,00	<b>0,9473</b>	<b>0,6864</b>	<b>0,8617</b>	<b>0,9020</b>	<b>0,9251</b>	1,1733
VAH-1	2440,40	113,60	865,60	381,40	0,9555	0,6941	0,8698	0,9079	0,9447	2,3463
VAH-2	2493,20	60,80	883,80	363,20	0,9762	0,7087	<b>0,8885</b>	<b>0,9216</b>	<b>0,9477</b>	2,3463
VAH-3	2445,60	108,40	846,80	400,20	0,9576	0,6791	0,8662	0,9058	0,9428	2,3463
VAH-4	2517,60	36,40	725,60	521,40	<b>0,9857</b>	0,5819	0,8532	0,9003	0,9342	2,3463
VAH-5	2377,20	176,80	976,60	270,40	0,9308	<b>0,7832</b>	0,8823	0,9140	0,9412	2,3463

**Çizelge 8.6.** COVID-19 zatürresi ve diğer zatürre sınıflandırmasında doğrudan BT akciğer görüntüleri kullanılarak elde edilen sonuçlar (YİD yarıçap değeri 2)

Yöntem	DP	YN	DN	YP	Duyarluluk	Özgüllük	Doğruluk	F-1 Skoru	AIKE-AKA	CPU Süresi (saniye)
Orijinal	2401,60	152,40	818,40	428,60	<b>0,9403</b>	<b>0,6563</b>	<b>0,8471</b>	<b>0,8921</b>	0,9019	1,1729
YİD	2392,20	161,80	795,00	452,00	0,9366	0,6375	0,8385	0,8863	<b>0,9024</b>	1,1727
VAH-1	2430,00	124,00	818,00	429,00	0,9514	0,6560	0,8545	0,8979	0,9334	2,3456
VAH-2	2478,80	75,20	868,60	378,40	0,9706	0,6966	<b>0,8807</b>	<b>0,9162</b>	<b>0,9388</b>	2,3456
VAH-3	2438,80	115,20	845,20	401,80	0,9549	0,6778	0,8640	0,9042	0,9357	2,3456
VAH-4	2506,00	48,00	725,20	521,80	<b>0,9812</b>	0,5816	0,8501	0,8980	0,9289	2,3456
VAH-5	2374,40	179,60	961,80	285,20	0,9297	<b>0,7713</b>	0,8777	0,9108	0,9340	2,3456

**Çizelge 8.7.** COVID-19 zatürresi ve diğer zatürre sınıflandırmasında doğrudan BT akciğer görüntüleri kullanılarak elde edilen sonuçlar (YİD yarıçap değeri 3)

Yöntem	DP	YN	DN	YP	Duyarluluk	Özgüllük	Doğruluk	F-1 Skoru	AIKE-AKA	CPU Süresi (saniye)
Orijinal	2401,60	152,40	818,40	428,60	<b>0,9403</b>	<b>0,6563</b>	<b>0,8471</b>	<b>0,8921</b>	<b>0,9019</b>	1,1729
YİD	2379,40	174,60	795,00	452,00	0,9316	0,6375	0,8351	0,8837	0,9007	1,1744
VAH-1	2419,60	134,40	812,20	434,80	0,9474	0,6513	0,8502	0,8948	0,9346	2,3473
VAH-2	2474,00	80,00	856,20	390,80	0,9687	0,6866	<b>0,8761</b>	<b>0,9131</b>	<b>0,9400</b>	2,3473
VAH-3	2437,40	116,60	840,60	406,40	0,9543	0,6741	0,8624	0,9031	0,9374	2,3473
VAH-4	2500,80	53,20	724,40	522,60	<b>0,9792</b>	0,5809	0,8485	0,8968	0,9276	2,3473
VAH-5	2374,80	179,20	950,20	296,80	0,9298	<b>0,7620</b>	0,8748	0,9089	0,9358	2,3473

Uygulamada ikinci olarak, BT akciğer görüntülerine YİD işlemi uygulanmadan yani orijinal görüntülere ve YİD uygulanarak elde edilen görüntülere ara işlem olarak KDDD uygulanarak elde edilen LL ve LLL alt bantlarının reel kısmının kullanılmasıyla sonuçlar elde edilmiştir. İlk aşama deneylerde en yüksek sonuçlar YİD yarıçap değerinin 1 olarak seçilmesi durumunda elde edilmiştir. Bu sebeple, bu aşamadan sonraki deneylerde sadece bu yarıçap değerine ait sonuçlar verilmiştir. Bu deneylerde 24 katmanlı 2B ESA mimarisine giriş olarak verilen görüntü matrislerinin boyutu LL alt bandı için  $224 \times 224 \times 1$  ve LLL alt bandı için  $112 \times 112 \times 1$  olmuştur. COVID-19 ve COVID-19 değil sınıflandırma için sonuçlar Çizelge 8.8 ile Çizelge 8.9 arasında, COVID-19 zatürresi ve diğer zatürre sınıflandırması için sonuçlar Çizelge 8.10 ile Çizelge 8.11 arasında verilmiştir.

**Çizelge 8.8.** COVID-19 ve COVID-19 değil sınıflandırmasında BT akciğer görüntülerine KDDD uygulanarak elde edilen LL alt bandının reel kısmının kullanılması durumu için sonuçlar

Yöntem	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AIKE-AKA	CPU Süresi (saniye)
Orijinal	2471,2	82,8	1598,6	167,4	<b>0,9676</b>	<b>0,9052</b>	<b>0,9421</b>	<b>0,9518</b>	<b>0,9884</b>	0,3347
YİD	2445,4	108,6	1588,4	177,6	0,9575	0,8994	0,9338	0,9447	0,9828	0,3366
VAH-1	2457,8	96,2	1598,2	167,8	0,9623	0,9050	0,9389	0,9490	0,9906	0,6712
VAH-2	2488,8	65,2	1636,6	129,4	0,9745	0,9267	0,9550	0,9624	<b>0,9918</b>	0,6712
VAH-3	2475,4	78,6	1615,6	150,4	0,9692	0,9148	0,9470	0,9558	0,9915	0,6712
VAH-4	2510,2	43,8	1549,8	216,2	<b>0,9829</b>	0,8776	0,9398	0,9508	0,9913	0,6712
VAH-5	2449,8	104,2	1685,4	80,6	0,9592	<b>0,9544</b>	<b>0,9572</b>	<b>0,9636</b>	0,9911	0,6712

**Çizelge 8.9.** COVID-19 ve COVID-19 değil sınıflandırmasında BT akciğer görüntülerine KDDD uygulanarak elde edilen LLL alt bandının reel kısmının kullanılması durumu için sonuçlar

Yöntem	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AIKE-AKA	CPU Süresi (saniye)
Orijinal	2450,2	103,8	1565,6	200,4	<b>0,9594</b>	0,8865	<b>0,9296</b>	<b>0,9416</b>	<b>0,9839</b>	0,1270
YİD	2428,4	125,6	1581,2	184,8	0,9508	<b>0,8954</b>	0,9281	0,9399	0,9810	0,1269
VAH-1	2441,6	112,4	1596,2	169,8	0,9560	0,9039	0,9347	0,9454	0,9882	0,2539
VAH-2	2482,4	71,6	1620,4	145,6	0,9720	0,9176	<b>0,9497</b>	<b>0,9581</b>	<b>0,9894</b>	0,2539
VAH-3	2456,8	97,2	1584,4	181,6	0,9619	0,8972	0,9355	0,9463	0,9886	0,2539
VAH-4	2505,2	48,8	1524,4	241,6	<b>0,9809</b>	0,8632	0,9328	0,9452	0,9884	0,2539
VAH-5	2427,4	126,6	1661,6	104,4	0,9504	<b>0,9409</b>	0,9465	0,9546	0,9881	0,2539

**Çizelge 8.10.** COVID-19 zatürresi ve diğer zatürre sınıflandırmasında BT akciğer görüntülerine KDDD uygulanarak elde edilen LL alt bandının reel kısmının kullanılması durumu için sonuçlar

Yöntem	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AIKE-AKA	CPU Süresi (saniye)
Orijinal	2440,6	113,4	889,2	357,8	<b>0,9556</b>	<b>0,7131</b>	<b>0,8760</b>	<b>0,9120</b>	<b>0,9322</b>	0,3326
YİD	2416,6	137,4	874,8	372,2	0,9462	0,7015	0,8659	0,9046	0,9286	0,3330
VAH-1	2441,0	113,0	891,0	356,0	0,9558	0,7145	0,8766	0,9124	0,9543	0,6656
VAH-2	2508,4	45,6	918,2	328,8	0,9821	0,7363	<b>0,9015</b>	<b>0,9306</b>	<b>0,9588</b>	0,6656
VAH-3	2467,0	87,0	901,6	345,4	0,9659	0,7230	0,8862	0,9194	0,9567	0,6656
VAH-4	2525,6	28,4	805,4	441,6	<b>0,9889</b>	0,6459	0,8763	0,9149	0,9493	0,6656
VAH-5	2423,4	130,6	1002,0	245,0	0,9489	<b>0,8035</b>	0,9012	0,9281	0,9556	0,6656

**Çizelge 8.11.** COVID-19 zatürresi ve diğer zatürre sınıflandırmasında BT akciğer görüntülerine KDDD uygulanarak elde edilen LLL alt bandının reel kısmının kullanılması durumu için sonuçlar

Yöntem	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AIKE-AKA	CPU Süresi (saniye)
Orijinal	2416,8	137,2	861,8	385,2	<b>0,9463</b>	<b>0,6911</b>	<b>0,8626</b>	<b>0,9025</b>	<b>0,9198</b>	0,1252
YİD	2374,8	179,2	809,2	437,8	0,9298	0,6489	0,8377	0,8850	0,9063	0,1251
VAH-1	2400,4	153,6	827,2	419,8	0,9399	0,6634	0,8491	0,8933	0,9379	0,2503
VAH-2	2482,4	71,6	882,2	364,8	0,9720	0,7075	<b>0,8852</b>	<b>0,9192</b>	<b>0,9449</b>	0,2503
VAH-3	2439,0	115,0	866,6	380,4	0,9550	0,6949	0,8697	0,9078	0,9433	0,2503
VAH-4	2510,4	43,6	768,8	478,2	<b>0,9829</b>	0,6165	0,8627	0,9059	0,9370	0,2503
VAH-5	2388,8	165,2	975,2	271,8	0,9353	<b>0,7820</b>	0,8850	0,9162	0,9420	0,2503

Uygulamada üçüncü olarak, BT akciğer görüntülerine YİD işlemi uygulanmadan yani orijinal görüntülere ve YİD uygulanarak elde edilen görüntülere ara işlem olarak KDDD uygulanarak elde edilen LL ve LLL alt bantlarının imajiner kısmı kullanılarak sonuçlar elde edilmiştir. Bu deneylerde 24 katmanlı 2B ESA mimarisine giriş olarak verilen görüntü matrislerinin boyutları LL alt bandı için  $224 \times 224 \times 1$  ve LLL alt bandı için  $112 \times 112 \times 1$ 'dir. COVID-19 ve COVID-19 değil sınıflandırma için sonuçlar Çizelge 8.12 ile Çizelge 8.13 arasında, COVID-19 zatürresi ve diğer zatürre sınıflandırması için sonuçlar Çizelge 8.14 ile Çizelge 8.15 arasında verilmiştir.

**Çizelge 8.12.** COVID-19 ve COVID-19 değil sınıflandırmasında BT akciğer görüntülerine KDDD uygulanarak elde edilen LL alt bandının imajiner kısmının kullanılması durumu için sonuçlar

Yöntem	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AIKE-AKA	CPU Süresi (saniye)
Orijinal	2463,6	90,4	1621,4	144,6	<b>0,9646</b>	<b>0,9181</b>	<b>0,9456</b>	<b>0,9545</b>	<b>0,9890</b>	0,3348
YİD	2438,2	115,8	1593,8	172,2	0,9547	0,9025	0,9333	0,9442	0,9825	0,3363
VAH-1	2451,4	102,6	1612,0	154,0	0,9598	0,9128	0,9406	0,9503	0,9910	0,6711
VAH-2	2483,8	70,2	1651,8	114,2	0,9725	0,9353	0,9573	<b>0,9642</b>	<b>0,9923</b>	0,6711
VAH-3	2470,0	84,0	1634,4	131,6	0,9671	0,9255	0,9501	0,9582	0,9921	0,6711
VAH-4	2509,2	44,8	1574,0	192,0	<b>0,9825</b>	0,8913	0,9452	0,9550	0,9922	0,6711
VAH-5	2438,2	115,8	1699,2	66,8	0,9547	<b>0,9622</b>	<b>0,9577</b>	0,9639	0,9916	0,6711

**Çizelge 8.13.** COVID-19 ve COVID-19 değil sınıflandırmasında BT akciğer görüntülerine KDDD uygulanarak elde edilen LLL alt bandının imajiner kısmının kullanılması durumu için sonuçlar

Yöntem	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AIKE-AKA	CPU Süresi (saniye)
Orijinal	2450,2	103,8	1566,2	199,8	<b>0,9594</b>	0,8869	<b>0,9297</b>	<b>0,9417</b>	<b>0,9829</b>	0,1270
YİD	2428,8	125,2	1578,8	187,2	0,9510	<b>0,8940</b>	0,9277	0,9396	0,9811	0,1257
VAH-1	2442,8	111,2	1590,2	175,8	0,9565	0,9005	0,9336	0,9445	0,9880	0,2527
VAH-2	2480,8	73,2	1621,6	144,4	0,9713	0,9182	<b>0,9496</b>	<b>0,9580</b>	<b>0,9893</b>	0,2527
VAH-3	2459,0	95,0	1583,6	182,4	0,9628	0,8967	0,9358	0,9466	0,9884	0,2527
VAH-4	2504,8	49,2	1529,6	236,4	<b>0,9807</b>	0,8661	0,9339	0,9461	0,9882	0,2527
VAH-5	2426,2	127,8	1658,2	107,8	0,9500	<b>0,9390</b>	0,9455	0,9537	0,9877	0,2527

**Çizelge 8.14.** COVID-19 zatürresi ve diğer zatürre sınıflandırmasında BT akciğer görüntülerine KDDD uygulanarak elde edilen LL alt bandının imajiner kısmının kullanılması durumu için sonuçlar

Yöntem	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AIKE-AKA	CPU Süresi (saniye)
Orijinal	2451,4	102,6	898,0	349,0	<b>0,9598</b>	<b>0,7201</b>	<b>0,8812</b>	<b>0,9157</b>	<b>0,9325</b>	0,3323
YİD	2410,0	144,0	880,6	366,4	0,9436	0,7062	0,8657	0,9043	0,9315	0,3323
VAH-1	2434,6	119,4	894,6	352,4	0,9532	0,7174	0,8759	0,9117	0,9556	0,6646
VAH-2	2502,2	51,8	921,4	325,6	0,9797	0,7389	0,9007	<b>0,9299</b>	<b>0,9603</b>	0,6646
VAH-3	2469,6	84,4	904,8	342,2	0,9670	0,7256	0,8878	0,9205	0,9589	0,6646
VAH-4	2527,8	26,2	814,0	433,0	<b>0,9897</b>	0,6528	0,8792	0,9168	0,9498	0,6646
VAH-5	2425,8	128,2	1005,4	241,6	0,9498	<b>0,8063</b>	<b>0,9027</b>	0,9292	0,9580	0,6646

**Çizelge 8.15.** COVID-19 zatürresi ve diğer zatürre sınıflandırmasında BT akciğer görüntülerine KDDD uygulanarak elde edilen LLL alt bandının imajiner kısmının kullanılması durumu için sonuçlar

Yöntem	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AIKE-AKA	CPU Süresi (saniye)
Orijinal	2444,0	110,0	853,8	393,2	<b>0,9569</b>	<b>0,6847</b>	<b>0,8676</b>	<b>0,9067</b>	<b>0,9227</b>	0,1261
YİD	2371,0	183,0	812,4	434,6	0,9283	0,6515	0,8375	0,8848	0,9057	0,1244
VAH-1	2396,6	157,4	829,4	417,6	0,9384	0,6651	0,8487	0,8929	0,9373	0,2505
VAH-2	2491,8	62,2	872,8	374,2	0,9756	0,6999	0,8852	0,9195	<b>0,9445</b>	0,2505
VAH-3	2459,6	94,4	861,8	385,2	0,9630	0,6911	0,8738	0,9112	0,9441	0,2505
VAH-4	2521,0	33,0	756,8	490,2	<b>0,9871</b>	0,6069	0,8624	0,9060	0,9389	0,2505
VAH-5	2414,8	139,2	969,8	277,2	0,9455	<b>0,7777</b>	<b>0,8904</b>	<b>0,9206</b>	0,9429	0,2505

Uygulamada dördüncü olarak, BT akciğer görüntülerine YİD işlemi uygulanmadan yani orijinal görüntülere ve YİD uygulanarak elde edilen görüntülere ara işlem olarak KDDD uygulanarak elde edilen LL, LH, HL alt bantlarının reel kısımları ile LLL, LLH, LHL alt bantlarının reel kısımları kullanılarak sonuçlar elde edilmiştir.



Bu deneylerde 24 katmanlı 2B ESA mimarisine giriş olarak verilen görüntü matrislerinin boyutu LL, LH, HL alt bantları için 224×224×3 ve LLL, LLH, LHL alt bantları için 112×112×3 olmuştur. COVID-19 ve COVID-19 değil sınıflandırma için sonuçlar Çizelge 8.16 ile Çizelge 8.17 arasında, COVID-19 zatürresi ve diğer zatürre sınıflandırması için sonuçlar Çizelge 8.18 ile Çizelge 8.19 arasında verilmiştir.

**Çizelge 8.16.** COVID-19 ve COVID-19 değil sınıflandırmasında BT akciğer görüntülerine KDDD uygulanarak elde edilen LL, LH, HL alt bantlarının reel kısımlarının kullanılması durumu için sonuçlar

Yöntem	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AIKE-AKA	CPU Süresi (saniye)
Orijinal	2468,8	85,2	1599,8	166,2	<b>0,9666</b>	<b>0,9059</b>	<b>0,9418</b>	<b>0,9516</b>	<b>0,9882</b>	0,6488
YİD	2432,6	121,4	1593,8	172,2	0,9525	0,9025	0,9320	0,9431	0,9815	0,6460
VAH-1	2440,4	113,6	1604,8	161,2	0,9555	0,9087	0,9364	0,9467	0,9903	1,2948
VAH-2	2480,2	73,8	1641,8	124,2	0,9711	0,9297	0,9542	0,9616	<b>0,9916</b>	1,2948
VAH-3	2478,4	75,6	1620,4	145,6	0,9704	0,9176	0,9488	0,9573	0,9915	1,2948
VAH-4	2505,2	48,8	1552,8	213,2	<b>0,9809</b>	0,8793	0,9394	0,9503	0,9914	1,2948
VAH-5	2443,8	110,2	1688,8	77,2	0,9569	<b>0,9563</b>	<b>0,9566</b>	<b>0,9631</b>	0,9912	1,2948

**Çizelge 8.17.** COVID-19 ve COVID-19 değil sınıflandırmasında BT akciğer görüntülerine KDDD uygulanarak elde edilen LLL, LLH, LHL alt bantlarının reel kısımlarının kullanılması durumu için sonuçlar

Yöntem	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AIKE-AKA	CPU Süresi (saniye)
Orijinal	2449,6	104,4	1581,2	184,8	<b>0,9591</b>	<b>0,8954</b>	<b>0,9331</b>	<b>0,9443</b>	<b>0,9846</b>	0,2038
YİD	2408,6	145,4	1575,4	190,6	0,9431	0,8921	0,9222	0,9348	0,9778	0,2043
VAH-1	2425,0	129,0	1589,8	176,2	0,9495	0,9002	0,9294	0,9408	0,9873	0,4080
VAH-2	2475,0	79,0	1629,6	136,4	0,9691	0,9228	<b>0,9501</b>	<b>0,9583</b>	<b>0,9890</b>	0,4080
VAH-3	2459,0	95,0	1596,2	169,8	0,9628	0,9039	0,9387	0,9489	0,9887	0,4080
VAH-4	2499,6	54,4	1538,6	227,4	<b>0,9787</b>	0,8712	0,9348	0,9467	0,9888	0,4080
VAH-5	2425,0	129,0	1672,2	93,8	0,9495	<b>0,9469</b>	0,9484	0,9561	0,9883	0,4080

**Çizelge 8.18.** COVID-19 zatürresi ve diğer zatürre sınıflandırmasında BT akciğer görüntülerine KDDD uygulanarak elde edilen LL, LH, HL alt bantlarının reel kısımlarının kullanılması durumu için sonuçlar

Yöntem	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AIKE-AKA	CPU Süresi (saniye)
Orijinal	2455,6	98,4	906,6	340,4	<b>0,9615</b>	<b>0,7270</b>	<b>0,8846</b>	<b>0,9180</b>	<b>0,9370</b>	0,6367
YİD	2412,4	141,6	874,2	372,8	0,9446	0,7010	0,8647	0,9037	0,9321	0,6396
VAH-1	2439,6	114,4	897,2	349,8	0,9552	0,7195	0,8779	0,9131	0,9565	1,2763
VAH-2	2509,6	44,4	929,0	318,0	0,9826	0,7450	0,9047	<b>0,9327</b>	<b>0,9615</b>	1,2763
VAH-3	2476,4	77,6	915,2	331,8	0,9696	0,7339	0,8923	0,9236	0,9604	1,2763
VAH-4	2532,4	21,6	820,6	426,4	<b>0,9915</b>	0,6581	0,8821	0,9187	0,9539	1,2763
VAH-5	2432,8	121,2	1015,0	232,0	0,9525	<b>0,8140</b>	<b>0,9071</b>	0,9323	0,9592	1,2763

**Çizelge 8.19.** COVID-19 zatürresi ve diğer zatürre sınıflandırmasında BT akciğer görüntülerine KDDD uygulanarak elde edilen LLL, LLH, LHL alt bantlarının reel kısımlarının kullanılması durumu için sonuçlar

Yöntem	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AIKE-AKA	CPU Süresi (saniye)
Orijinal	2428,4	125,6	847,6	399,4	<b>0,9508</b>	<b>0,6797</b>	<b>0,8619</b>	<b>0,9025</b>	<b>0,9223</b>	0,2033
YİD	2327,4	226,6	797,6	449,4	0,9113	0,6396	0,8222	0,8732	0,8909	0,2026
VAH-1	2358,6	195,4	812,2	434,8	0,9235	0,6513	0,8342	0,8822	0,9316	0,4058
VAH-2	2474,6	79,4	859,8	387,2	0,9689	0,6895	0,8772	0,9139	0,9411	0,4058
VAH-3	2444,2	109,8	859,2	387,8	0,9570	0,6890	0,8691	0,9076	<b>0,9414</b>	0,4058
VAH-4	2512,8	41,2	742,0	505,0	<b>0,9839</b>	0,5950	0,8563	0,9020	0,9374	0,4058
VAH-5	2390,2	163,8	965,4	281,6	0,9359	<b>0,7742</b>	<b>0,8828</b>	<b>0,9148</b>	0,9398	0,4058

Uygulamada beşinci olarak, BT akciğer görüntülerine YİD işlemi uygulanmadan yani orijinal görüntülere ve YİD uygulanarak elde edilen görüntülere ara işlem olarak KDDD uygulanarak elde edilen LL, LH, HL alt bantlarının imajiner kısımları ile LLL, LLH, LHL alt bantlarının imajiner kısımları kullanılarak sonuçlar elde edilmiştir. Bu deneylerde 24 katmanlı 2B ESA mimarisine giriş olarak verilen görüntü matrislerinin boyutu LL, LH, HL alt bantları için  $224 \times 224 \times 3$  ve LLL, LLH, LHL alt bantları için  $112 \times 112 \times 3$  olmuştur. COVID-19 ve COVID-19 değil sınıflandırma için sonuçlar Çizelge 8.20 ile Çizelge 8.21 arasında, COVID-19 zatürresi ve diğer zatürre sınıflandırması için sonuçlar Çizelge 8.22 ile Çizelge 8.23 arasında verilmiştir.

**Çizelge 8.20.** COVID-19 ve COVID-19 değil sınıflandırmasında BT akciğer görüntülerine KDDD uygulanarak elde edilen LL, LH, HL alt bantlarının imajiner kısımlarının kullanılması durumu için sonuçlar

Yöntem	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AIKE-AKA	CPU Süresi (saniye)
Orijinal	2466,2	87,8	1590,4	175,6	<b>0,9656</b>	0,9006	<b>0,9390</b>	<b>0,9493</b>	<b>0,9878</b>	0,6440
YİD	2431,8	122,2	1596,6	169,4	0,9522	<b>0,9041</b>	0,9325	0,9434	0,9831	0,6448
VAH-1	2445,4	108,6	1612,2	153,8	0,9575	0,9129	0,9393	0,9491	0,9905	1,2888
VAH-2	2483,0	71,0	1650,8	115,2	0,9722	0,9348	<b>0,9569</b>	<b>0,9639</b>	<b>0,9918</b>	1,2888
VAH-3	2475,6	78,4	1611,4	154,6	0,9693	0,9125	0,9461	0,9551	0,9914	1,2888
VAH-4	2507,6	46,4	1555,6	210,4	<b>0,9818</b>	0,8809	0,9406	0,9513	0,9912	1,2888
VAH-5	2441,6	112,4	1685,6	80,4	0,9560	<b>0,9545</b>	0,9554	0,9620	0,9910	1,2888

**Çizelge 8.21.** COVID-19 ve COVID-19 değil sınıflandırmasında BT akciğer görüntülerine KDDD uygulanarak elde edilen LLL, LLH, LHL alt bantlarının imajiner kısımlarının kullanılması durumu için sonuçlar

Yöntem	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AIKE-AKA	CPU Süresi (saniye)
Orijinal	2450,2	103,8	1548,2	217,8	<b>0,9594</b>	<b>0,8767</b>	<b>0,9256</b>	<b>0,9385</b>	<b>0,9820</b>	0,2037
YİD	2405,0	149,0	1541,4	224,6	0,9417	0,8728	0,9135	0,9279	0,9741	0,2043
VAH-1	2423,0	131,0	1554,0	212,0	0,9487	0,8800	0,9206	0,9339	0,9851	0,4080
VAH-2	2470,4	83,6	1594,6	171,4	0,9673	0,9029	<b>0,9410</b>	<b>0,9509</b>	<b>0,9871</b>	0,4080
VAH-3	2454,8	99,2	1560,0	206,0	0,9612	0,8834	0,9294	0,9415	0,9868	0,4080
VAH-4	2499,0	55,0	1500,6	265,4	<b>0,9785</b>	0,8497	0,9258	0,9398	0,9867	0,4080
VAH-5	2421,6	132,4	1642,2	123,8	0,9482	<b>0,9299</b>	0,9407	0,9498	0,9862	0,4080

**Çizelge 8.22.** COVID-19 zatürresi ve diğer zatürre sınıflandırmasında BT akciğer görüntülerine KDDD uygulanarak elde edilen LL, LH, HL alt bantlarının imajiner kısımlarının kullanılması durumu için sonuçlar

Yöntem	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AIKE-AKA	CPU Süresi (saniye)
Orijinal	2442,6	111,4	881,0	366,0	<b>0,9564</b>	<b>0,7065</b>	<b>0,8744</b>	<b>0,9110</b>	<b>0,9279</b>	0,6388
YİD	2404,4	149,6	857,6	389,4	0,9414	0,6877	0,8582	0,8992	0,9258	0,6409
VAH-1	2430,2	123,8	873,0	374,0	0,9515	0,7001	0,8690	0,9071	0,9491	1,2797
VAH-2	2504,6	49,4	906,6	340,4	0,9807	0,7270	0,8974	<b>0,9278</b>	<b>0,9542</b>	1,2797
VAH-3	2467,0	87,0	894,6	352,4	0,9659	0,7174	0,8844	0,9182	0,9526	1,2797
VAH-4	2525,4	28,6	794,2	452,8	<b>0,9888</b>	0,6369	0,8733	0,9130	0,9460	1,2797
VAH-5	2421,8	132,2	993,4	253,6	0,9482	<b>0,7966</b>	<b>0,8985</b>	0,9262	0,9515	1,2797

**Çizelge 8.23.** COVID-19 zatürresi ve diğer zatürre sınıflandırmasında BT akciğer görüntülerine KDDD uygulanarak elde edilen LLL, LLH, LHL alt bantlarının imajiner kısımlarının kullanılması durumu için sonuçlar

Yöntem	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AİKE-AKA	CPU Süresi (saniye)
Orijinal	2423,6	130,4	874,8	372,2	<b>0,9489</b>	<b>0,7015</b>	<b>0,8678</b>	<b>0,9060</b>	<b>0,9235</b>	0,2029
YİD	2337,8	216,2	781,2	465,8	0,9153	0,6265	0,8206	0,8727	0,8863	0,2035
VAH-1	2369,8	184,2	800,6	446,4	0,9279	0,6420	0,8341	0,8826	0,9305	0,4064
VAH-2	2477,0	77,0	869,6	377,4	0,9699	0,6974	0,8805	0,9160	0,9411	0,4064
VAH-3	2439,8	114,2	886,0	361,0	0,9553	0,7105	0,8750	0,9113	<b>0,9414</b>	0,4064
VAH-4	2509,0	45,0	767,6	479,4	<b>0,9824</b>	0,6156	0,8620	0,9054	0,9368	0,4064
VAH-5	2391,6	162,4	976,8	270,2	0,9364	<b>0,7833</b>	<b>0,8862</b>	<b>0,9171</b>	0,9404	0,4064

Uygulamada altıncı olarak, BT akciğer görüntülerine YİD işlemi uygulanmadan yani orijinal görüntülere ve YİD uygulanarak elde edilen görüntülere ara işlem olarak KDDD uygulanarak elde edilen LL, LLL alt bantlarının reel ve imajiner kısımları kullanılarak sonuçlar elde edilmiştir. Bu deneylerde 24 katmanlı 2B ESA mimarisine giriş olarak verilen görüntü matrislerinin boyutu LL alt bandı için  $224 \times 224 \times 2$ , LLL alt bandı için  $112 \times 112 \times 2$  olmuştur. COVID-19 ve COVID-19 değil sınıflandırma için sonuçlar Çizelge 8.24 ile Çizelge 8.25 arasında, COVID-19 zatürresi ve diğer zatürre sınıflandırması için sonuçlar Çizelge 8.26 ile Çizelge 8.27 arasında verilmiştir.

**Çizelge 8.24.** COVID-19 ve COVID-19 değil sınıflandırmasında BT akciğer görüntülerine KDDD uygulanarak elde edilen LL alt bandının reel ve imajiner kısımlarının kullanılması durumu için sonuçlar

Yöntem	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AİKE-AKA	CPU Süresi (saniye)
Orijinal	2469,8	84,2	1607,4	158,6	<b>0,9670</b>	<b>0,9102</b>	<b>0,9438</b>	<b>0,9532</b>	<b>0,9889</b>	0,4912
YİD	2447,4	106,6	1581,0	185,0	0,9583	0,8952	0,9325	0,9438	0,9826	0,4919
VAH-1	2456,6	97,4	1596,0	170,0	0,9619	0,9037	0,9381	0,9484	0,9908	0,9830
VAH-2	2490,2	63,8	1633,0	133,0	0,9750	0,9247	0,9544	0,9620	<b>0,9920</b>	0,9830
VAH-3	2475,0	79,0	1619,8	146,2	0,9691	0,9172	0,9479	0,9565	0,9918	0,9830
VAH-4	2511,0	43,0	1552,2	213,8	<b>0,9832</b>	0,8789	0,9406	0,9514	0,9918	0,9830
VAH-5	2449,0	105,0	1688,2	77,8	0,9589	<b>0,9559</b>	<b>0,9577</b>	<b>0,9640</b>	0,9916	0,9830

**Çizelge 8.25.** COVID-19 ve COVID-19 değil sınıflandırmasında BT akciğer görüntülerine KDDD uygulanarak elde edilen LLL alt bandının reel ve imajiner kısımlarının kullanılması durumu için sonuçlar

Yöntem	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AIKE-AKA	CPU Süresi (saniye)
Orijinal	2448,0	106,0	1560,6	205,4	<b>0,9585</b>	0,8837	0,9279	0,9402	<b>0,9821</b>	0,1661
YİD	2439,0	115,0	1582,2	183,8	0,9550	<b>0,8959</b>	<b>0,9308</b>	<b>0,9423</b>	0,9820	0,1660
VAH-1	2453,2	100,8	1595,0	171,0	0,9605	0,9032	0,9371	0,9475	0,9886	0,3321
VAH-2	2483,4	70,6	1612,6	153,4	0,9724	0,9131	<b>0,9481</b>	<b>0,9568</b>	<b>0,9894</b>	0,3321
VAH-3	2459,0	95,0	1574,0	192,0	0,9628	0,8913	0,9336	0,9449	0,9885	0,3321
VAH-4	2506,2	47,8	1515,8	250,2	<b>0,9813</b>	0,8583	0,9310	0,9439	0,9881	0,3321
VAH-5	2425,2	128,8	1657,4	108,6	0,9496	<b>0,9385</b>	0,9450	0,9533	0,9878	0,3321

**Çizelge 8.26.** COVID-19 zatürresi ve diğer zatürre sınıflandırmasında BT akciğer görüntülerine KDDD uygulanarak elde edilen LL alt bandının reel ve imajiner kısımlarının kullanılması durumu için sonuçlar

Yöntem	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AIKE-AKA	CPU Süresi (saniye)
Orijinal	2441,6	112,4	859,0	388,0	<b>0,9560</b>	0,6889	<b>0,8684</b>	<b>0,9071</b>	<b>0,9281</b>	0,4854
YİD	2411,0	143,0	869,8	377,2	0,9440	<b>0,6975</b>	0,8631	0,9026	0,9255	0,4863
VAH-1	2434,6	119,4	879,2	367,8	0,9532	0,7051	0,8718	0,9091	0,9486	0,9717
VAH-2	2505,2	48,8	904,6	342,4	0,9809	0,7254	<b>0,8971</b>	<b>0,9276</b>	<b>0,9530</b>	0,9717
VAH-3	2469,8	84,2	872,2	374,8	0,9670	0,6994	0,8792	0,9150	0,9509	0,9717
VAH-4	2525,0	29,0	782,4	464,6	<b>0,9886</b>	0,6274	0,8701	0,9110	0,9450	0,9717
VAH-5	2421,8	132,2	981,2	265,8	0,9482	<b>0,7868</b>	0,8953	0,9241	0,9499	0,9717

**Çizelge 8.27.** COVID-19 zatürresi ve diğer zatürre sınıflandırmasında BT akciğer görüntülerine KDDD uygulanarak elde edilen LLL alt bandının gerçek ve imajiner kısımlarının kullanılması durumu için sonuçlar

Yöntem	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AIKE-AKA	CPU Süresi (saniye)
Orijinal	2424,6	129,4	861,6	385,4	<b>0,9493</b>	<b>0,6909</b>	<b>0,8646</b>	<b>0,9040</b>	<b>0,9225</b>	0,1653
YİD	2374,0	180,0	830,4	416,6	0,9295	0,6659	0,8430	0,8884	0,9122	0,1652
VAH-1	2404,4	149,6	845,0	402,0	0,9414	0,6776	0,8549	0,8971	0,9415	0,3305
VAH-2	2493,2	60,8	890,6	356,4	0,9762	0,7142	0,8902	<b>0,9228</b>	<b>0,9486</b>	0,3305
VAH-3	2445,8	108,2	873,4	373,6	0,9576	0,7004	0,8732	0,9103	0,9465	0,3305
VAH-4	2518,8	35,2	765,6	481,4	<b>0,9862</b>	0,6140	0,8641	0,9070	0,9401	0,3305
VAH-5	2399,0	155,0	986,6	260,4	0,9393	<b>0,7912</b>	<b>0,8907</b>	0,9203	0,9453	0,3305

## 8.6. BT Görüntüler Üzerinden COVID-19 ve COVID-19 Değil ile COVID-19 Zatürresi ve Diğer Zatürre Sınıflandırma Sonuçlarının Değerlendirilmesi

Tez çalışmasının ikinci uygulamasında gerçekleştirilen COVID-19 ve COVID-19 değil ile COVID-19 zatürresi ve diğer zatürre sınıflandırmalarına yönelik deneylerin sonuçları Çizelge 8.2 ile Çizelge 8.27 arasında verilmiştir. Bu bölümde söz konusu sonuçların değerlendirilmesi yapılmıştır.

COVID-19 ve COVID-19 değil sınıflandırması için YİD'in görüntülere ön işlem olarak uygulanmasının uygulama sonuçlarına bazı etkilerinin olduğu anlaşılmaktadır. YİD ön işlem olarak kullanılmadığında yani orijinal görüntülerle, özgüllük parametresi için bazı istisnalar hariç olmak üzere, daha iyi sonuçlar elde edildiği görülmektedir. Ayrıca, YİD işleminde kullanılan yarıçap değerlerinin artması sonuçları olumsuz etkilemiştir. Bu nedenle çalışmanın uzunluğu dikkate alınarak birinci aşamadan sonra yapılan deneylerde sadece yarıçap değerinin 1 olarak seçilmesine ilişkin sonuçlar paylaşılmıştır. COVID-19 ve COVID-19 değil sınıflandırması için ön işlem olarak YİD uygulanarak ve YİD uygulanmadan elde edilen deney sonuçlarının özet bilgileri Çizelge 8.28'de yer almaktadır. COVID-19 zatürresi ve diğer zatürre sınıflandırması için ön işlem olarak YİD uygulanarak ve YİD uygulanmadan elde edilen deney sonuçlarının özet bilgileri ise Çizelge 8.29'de verilmiştir.

**Çizelge 9.28.** COVID-19 ve COVID-19 değil sınıflandırmasında YİD uygulanarak ve YİD uygulanmadan elde edilen uygulama sonuçlarının özet bilgileri

Yöntem	Minimum/ Maksimum	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AIKE-AKA
YİD Yok	Minimum	0,9579	0,8767	0,9256	0,9385	0,9820
YİD Yok	Maksimum	0,9676	0,9181	0,9456	0,9545	0,9890
YİD Var	Minimum	0,9417	0,8728	0,9135	0,9279	0,9741
YİD Var	Maksimum	0,9583	0,9041	0,9338	0,9447	0,9831

**Çizelge 8.29.** COVID-19 zatürresi ve diğer zatürre sınıflandırmasında YİD uygulanarak ve YİD uygulanmadan elde edilen uygulama sonuçlarının özet bilgileri

Yöntem	Minimum/ Maksimum	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AIKE-AKA
YİD Yok	Minimum	0,9403	0,6563	0,8471	0,8921	0,9019
YİD Yok	Maksimum	0,9615	0,7270	0,8846	0,9180	0,9370
YİD Var	Minimum	0,9113	0,6265	0,8206	0,8727	0,8863
YİD Var	Maksimum	0,9473	0,7062	0,8659	0,9046	0,9321

KDDD'nin ikincil işlem olarak kullanılmasının sonuçlara etkisi, üzerinde durulması gereken bir diğer husustur. COVID-19 ve COVID-19 değil sınıflandırması için KDDD kullanılarak (ölçek değerleri 1 ve 2) ve KDDD kullanılmadan elde edilen sonuçların özet bilgileri Çizelge 8.30'da yer almaktadır. KDDD'nin ikincil işlem olarak kullanılması durumunda sonuçlarda bir miktar değişiklik olduğu görülmektedir. Ancak bu değişimler, ölçek değerinin 1 olması durumu için sınırlıdır. Ölçek değerindeki artışa bağlı olarak değişimlerin miktarı artmaktadır. Görüntü başına sonuç üretme süresi açısından bir karşılaştırma yapılırsa, KDDD kullanımına bağlı olarak çalışma sürelerinde önemli bir azalma olduğu görülmektedir. COVID-19 zatürresi ve diğer zatürre sınıflandırması için özet bilgiler Çizelge 8.31'de yer almakta olup, bu sınıflandırma başlığı için de benzer bir durum olduğu görülmektedir.

**Çizelge 8.30.** COVID-19 ve COVID-19 değil sınıflandırmasında KDDD kullanılarak ve KDDD kullanılmadan elde edilen uygulama sonuçlarının özet bilgileri

Yöntem		Minimum/ Maksimum	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AIKE-AKA	CPU Süresi (saniye)
YİD Yok	KDDD Yok	Tek Sonuç	0,9579	0,9092	0,9380	0,9481	0,9833	1,1872
YİD Yok	KDDD Var (Ölçek=1)	Minimum	0,9646	0,9006	0,9390	0,9493	0,9878	0,3347
YİD Yok	KDDD Var (Ölçek =1)	Maksimum	0,9676	0,9181	0,9456	0,9545	0,9890	0,6488
YİD Yok	KDDD Var (Ölçek =2)	Minimum	0,9585	0,8767	0,9256	0,9385	0,9820	0,1270
YİD Yok	KDDD Var (Ölçek =2)	Maksimum	0,9594	0,8954	0,9331	0,9443	0,9846	0,2038
YİD Var	KDDD Yok	Tek Sonuç	0,9511	0,8993	0,9300	0,9414	0,9806	1,1915
YİD Var	KDDD Var (Ölçek =1)	Minimum	0,9522	0,8952	0,9320	0,9431	0,9815	0,3363
YİD Var	KDDD Var (Ölçek =1)	Maksimum	0,9583	0,9041	0,9338	0,9447	0,9831	0,6460
YİD Var	KDDD Var (Ölçek =2)	Minimum	0,9417	0,8728	0,9135	0,9279	0,9741	0,1257
YİD Var	KDDD Var (Ölçek =2)	Maksimum	0,9550	0,8959	0,9308	0,9423	0,9820	0,2043

**Çizelge 8.31.** COVID-19 zatürresi ve diğer zatürre sınıflandırmasında KDDD kullanılarak ve KDDD kullanılmadan elde edilen uygulama sonuçlarının özet bilgileri

Yöntem		Minimum/ Maksimum	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AIKE-AKA	CPU Süresi (saniye)
YİD Yok	KDDD Yok	Tek Sonuç	0,9403	0,6563	0,8471	0,8921	0,9019	1,1729
YİD Yok	KDDD Var (Ölçek=1)	Minimum	0,9556	0,6889	0,8684	0,9071	0,9279	0,3323
YİD Yok	KDDD Var (Ölçek =1)	Maksimum	0,9615	0,7270	0,8846	0,9180	0,9370	0,6388
YİD Yok	KDDD Var (Ölçek =2)	Minimum	0,9463	0,6797	0,8619	0,9025	0,9198	0,1252
YİD Yok	KDDD Var (Ölçek =2)	Maksimum	0,9569	0,7015	0,8678	0,9067	0,9235	0,2033
YİD Var	KDDD Yok	Tek Sonuç	0,9473	0,6864	0,8617	0,9020	0,9251	1,1733
YİD Var	KDDD Var (Ölçek =1)	Minimum	0,9414	0,6877	0,8582	0,8992	0,9255	0,3323
YİD Var	KDDD Var (Ölçek =1)	Maksimum	0,9462	0,7062	0,8659	0,9046	0,9321	0,6409
YİD Var	KDDD Var (Ölçek =2)	Minimum	0,9113	0,6265	0,8206	0,8727	0,8863	0,1244
YİD Var	KDDD Var (Ölçek =2)	Maksimum	0,9298	0,6659	0,8430	0,8884	0,9122	0,2035

Uygulamada VAH yaklaşımları kullanılarak sonuçlarda önemli iyileşmeler elde edilmiştir. Çizelge 8.32’de, COVID-19 ve COVID-19 değil sınıflandırması için VAH yaklaşımlarını kullanmadan önce ve kullandıktan sonra elde edilen en iyi YN, YP, YN+YP ve 1-(AIKE-AKA) değerleri ve değişim oranları verilmiştir. Çizelge 8.32’de görüldüğü gibi COVID-19 ve COVID-19 değil sınıflandırması için VAH yaklaşımları yardımıyla; YN parametresinde %42,7 ile %54,9 arasında, YP parametresinde %40,9 ile %53,8 arasında, YN+YP parametresinde %17,1 ile %29,3 arasında, 1-(AIKE-AKA) parametresinde %20,9 ile %41,1 arasında değişen oranlarda iyileştirmeler sağlanmıştır.

Çizelge 8.33, benzer bilgiler ve değişim oranlarını COVID-19 zatürresi ve diğer zatürre sınıflandırması için özetlemektedir. Çizelge 8.33’de görüldüğü gibi COVID-19 zatürresi ve diğer zatürre sınıflandırmasında; YN parametresinde %65,1 ile %78 arasında, YP parametresinde %27,4 ile %33,5 arasında, YN+YP parametresinde %13,9 ile %21,9 arasında, 1-(AIKE-AKA) parametresinde %23,5 ve %41,2 arasında değişen oranlarda iyileştirmeler elde edilmiştir.



**Çizelge 8.32.** COVID-19 ve COVID-19 değil sınıflandırmasında VAH yaklaşımları kullanılmadan önce ve kullanıldıktan sonra elde edilen en iyi YN, YP, YN+YP ve 1-(AİKE-AKA) değerleri hakkında bilgiler

Yöntem	Aşama	YN	YP	YN+YP	1-(AİKE- AKA)
Doğrudan BT akciğer görüntü (YİD yarıçap 1)	VAH yaklaşımından önce	107,6	160,4	268,0	0,0167
	VAH yaklaşımından sonra	56,4	78,0	216,2	0,0103
	Değişim Oranı (%)	47,6	51,4	19,3	38,3
Doğrudan BT akciğer görüntü (YİD yarıçap 2)	VAH yaklaşımından önce	107,6	160,4	268,0	0,0167
	VAH yaklaşımından sonra	57,8	82,2	220,0	0,0115
	Değişim Oranı (%)	46,3	48,8	17,9	30,9
Doğrudan BT akciğer görüntü (YİD yarıçap 3)	VAH yaklaşımından önce	107,6	160,4	268,0	0,0167
	VAH yaklaşımından sonra	61,2	82,0	222,2	0,0132
	Değişim Oranı (%)	43,1	48,9	17,1	20,9
Reel Kısım-LL	VAH yaklaşımından önce	82,8	167,4	250,2	0,0116
	VAH yaklaşımından sonra	43,8	80,6	184,8	0,0082
	Değişim Oranı (%)	47,1	51,9	26,1	28,8
Reel Kısım-LLL	VAH yaklaşımından önce	103,8	184,8	304,2	0,0161
	VAH yaklaşımından sonra	48,8	104,4	217,2	0,0106
	Değişim Oranı (%)	53,0	43,5	28,6	34,2
İmajiner Kısım-LL	VAH yaklaşımından önce	90,4	144,6	235,0	0,0110
	VAH yaklaşımından sonra	44,8	66,8	182,6	0,0077
	Değişim Oranı (%)	50,4	53,8	22,3	30,1
İmajiner Kısım-LLL	VAH yaklaşımından önce	103,8	187,2	303,6	0,0171
	VAH yaklaşımından sonra	49,2	107,8	217,6	0,0107
	Değişim Oranı (%)	52,6	42,4	28,3	37,1
Reel Kısım-LL, LH, HL	VAH yaklaşımından önce	85,2	166,2	251,4	0,0118
	VAH yaklaşımından sonra	48,8	77,2	187,4	0,0084
	Değişim Oranı (%)	42,7	53,5	25,5	28,7
Reel Kısım-LLL, LLH, LHL	VAH yaklaşımından önce	104,4	184,8	289,2	0,0154
	VAH yaklaşımından sonra	54,4	93,8	215,4	0,0110
	Değişim Oranı (%)	47,9	49,2	25,5	28,8
İmajiner Kısım-LL, LH, HL	VAH yaklaşımından önce	87,8	169,4	263,4	0,0122
	VAH yaklaşımından sonra	46,4	80,4	186,2	0,0082
	Değişim Oranı (%)	47,2	52,5	29,3	32,6
İmajiner Kısım-LLL, LLH, LHL	VAH yaklaşımından önce	103,8	217,8	321,6	0,0180
	VAH yaklaşımından sonra	55,0	123,8	255,0	0,0129
	Değişim Oranı (%)	47,0	43,2	20,7	28,2
Reel ve imajiner kısımları-LL	VAH yaklaşımından önce	84,2	158,6	242,8	0,0111
	VAH yaklaşımından sonra	43,0	77,8	182,8	0,0080
	Değişim Oranı (%)	48,9	50,9	24,7	27,4
Reel ve imajiner kısımları-LLL	VAH yaklaşımından önce	106,0	183,8	298,8	0,0179
	VAH yaklaşımından sonra	47,8	108,6	224,0	0,0106
	Değişim Oranı (%)	54,9	40,9	25,0	41,1

**Çizelge 8.33.** COVID-19 zatürresi ve diğer zatürre sınıflandırmasında VAH yaklaşımları kullanılmadan önce ve kullanıldıktan sonra elde edilen en iyi YN, YP, YN+YP ve 1-(AİKE-AKA) değerleri hakkında bilgiler

Yöntem	Aşama	YN	YP	YN+YP	1-(AİKE-AKA)
Doğrudan BT akciğer görüntü (YİD yarıçap 1)	VAH yaklaşımından önce	134,6	391,0	525,6	0,0749
	VAH yaklaşımından sonra	36,4	270,4	424,0	0,0523
	Değişim Oranı (%)	73,0	30,8	19,3	30,3
Doğrudan BT akciğer görüntü (YİD yarıçap 2)	VAH yaklaşımından önce	152,4	428,6	581,0	0,0976
	VAH yaklaşımından sonra	48,0	285,2	453,6	0,0612
	Değişim Oranı (%)	68,5	33,5	21,9	37,3
Doğrudan BT akciğer görüntü (YİD yarıçap 3)	VAH yaklaşımından önce	152,4	428,6	581,0	0,0981
	VAH yaklaşımından sonra	53,2	296,8	470,8	0,0600
	Değişim Oranı (%)	65,1	30,8	19,0	38,8
Reel Kısım-LL	VAH yaklaşımından önce	113,4	357,8	471,2	0,0678
	VAH yaklaşımından sonra	28,4	245,0	374,4	0,0412
	Değişim Oranı (%)	75,0	31,5	20,5	39,2
Reel Kısım-LLL	VAH yaklaşımından önce	137,2	385,2	522,4	0,0802
	VAH yaklaşımından sonra	43,6	271,8	436,4	0,0551
	Değişim Oranı (%)	68,2	29,4	16,5	31,3
İmajiner Kısım-LL	VAH yaklaşımından önce	102,6	349,0	451,6	0,0675
	VAH yaklaşımından sonra	26,2	241,6	369,8	0,0397
	Değişim Oranı (%)	74,5	30,8	18,1	41,2
İmajiner Kısım-LLL	VAH yaklaşımından önce	110,0	393,2	503,2	0,0773
	VAH yaklaşımından sonra	33,0	277,2	416,4	0,0555
	Değişim Oranı (%)	70,0	29,5	17,2	28,2
Reel Kısım-LL, LH, HL	VAH yaklaşımından önce	98,4	340,4	438,8	0,0630
	VAH yaklaşımından sonra	21,6	232,0	353,2	0,0385
	Değişim Oranı (%)	78,0	31,8	19,5	38,9
Reel Kısım-LLL, LLH, LHL	VAH yaklaşımından önce	125,6	399,4	525,0	0,0777
	VAH yaklaşımından sonra	41,2	281,6	445,4	0,0586
	Değişim Oranı (%)	67,2	29,5	15,2	24,7
İmajiner Kısım-LL, LH, HL	VAH yaklaşımından önce	111,4	366,0	477,4	0,0721
	VAH yaklaşımından sonra	28,6	253,6	385,8	0,0458
	Değişim Oranı (%)	74,3	30,7	19,2	36,6
İmajiner Kısım-LLL, LLH, LHL	VAH yaklaşımından önce	130,4	372,2	502,6	0,0765
	VAH yaklaşımından sonra	45,0	270,2	432,6	0,0586
	Değişim Oranı (%)	65,5	27,4	13,9	23,5
Reel ve imajiner kısımları-LL	VAH yaklaşımından önce	112,4	377,2	500,4	0,0719
	VAH yaklaşımından sonra	29,0	265,8	391,2	0,0470
	Değişim Oranı (%)	74,2	29,5	21,8	34,6
Reel ve imajiner kısımları-LLL	VAH yaklaşımından önce	129,4	385,4	514,8	0,0775
	VAH yaklaşımından sonra	35,2	260,4	415,4	0,0514
	Değişim Oranı (%)	72,8	32,4	19,3	33,7

Uygulamada COVID-19 ve COVID-19 değil sınıflandırması için elde edilen en iyi sonuçların literatürde yer alan çalışmalarda elde edilen sonuçlarla karşılaştırılması Çizelge 8.34’de verilmiştir. Çizelge 8.34’den görüldüğü üzere COVID-19 ve COVID-19 değil sınıflandırması için VAH yaklaşımı kullanılmadan önce elde edilen en yüksek duyarlılık, özgüllük, doğruluk, F-1 skoru ve AİKE-AKA parametreleri sırasıyla 0,9676; 0,9181; 0,9456; 0,9545 ve 0,9890 olarak hesaplanmıştır. Aynı sınıflandırma başlığında VAH yaklaşımı kullanıldıktan sonra elde edilen en yüksek duyarlılık, özgüllük, doğruluk, F-1 skoru ve AİKE-AKA parametreleri sırasıyla 0,9832; 0,9622; 0,9577;

0,9642 ve 0,9923'tür. Uygulamada en yüksek duyarlılık değeri, LL alt bandının gerçek ve imajiner kısımları giriş verisi olarak ve VAH-4 yaklaşımı kullanılarak elde edilmiştir. En yüksek özgüllük ve doğruluk değerleri, VAH-5 yaklaşımı yardımıyla LL alt bandının imajiner kısmının giriş verisi olarak kullanılmasıyla elde edilmiştir. Aynı giriş verileri kullanılarak en yüksek F-1 skoru ve AİKE-AKA değerlerine VAH-2 yaklaşımı yardımıyla ulaşılmıştır.

**Çizelge 8.34.** Tez çalışmasının ikinci uygulamasında BT görüntülerden COVID-19 ve COVID-19 değil sınıflandırması için elde edilen sonuçların literatürde yer alan çalışmalarda elde edilen sonuçlar ile karşılaştırması

Çalışma	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AİKE-AKA
Birinci Uygulama	0,9197-0,9404	0,9891-0,9901	0,9473-0,9599	0,9058-0,9284	0,9888-0,9903
Ni ve ark., 2020	1,00	0,25	0,94	0,97	X
Wang ve ark., 2020(a)	X	X	0,847-0,901	X	0,9590
Han ve ark., 2020	0,968-0,979	X	0,968-0,979	0,968-0,979	0,982-0,990
Ardakani ve ark., 2020	0,7843-1,000	0,6863-1,000	0,7892-0,9951	X	0,894-0,994
Harmon ve ark., 2020	0,751-0,853	0,901-0,951	0,889-0,908	X	0,938-0,949
Jaiswal ve ark., 2021	0,9206-0,9735	0,8972-0,9621	0,909-0,9625	0,9109-0,9629	0,97
Horry ve ark., 2020	0,81-0,83	X	X	0,81-0,83	X
Pathak ve ark., 2020	0,9146	0,9478	0,9302	X	X
Ouyang ve ark., 2020	0,869	0,901	0,875	0,820	0,944
Sakagianni ve ark., 2020	0,8831	X	X	0,8831	X
Hu ve ark., 2020	0,8330	0,9560	0,9060	X	0,9430
Ragab ve Attallah, 2020	0,99	X	0,99	0,99	1,00
Sen ve ark., 2021	0,8406-0,9778	X	0,90-0,9839	0,8855-0,98	0,9414-0,9952
Konar ve ark., 2021	0,935	X	0,944	0,948	0,983
Kaur ve ark., 2021	0,9960	X	0,9918-0,9938	0,992-0,994	0,9916-0,9958
Goel ve ark., 2021	0,9978	0,9778	0,9922	0,9879	X
Zhu ve ark., 2021(a)	0,93	0,92	0,93	0,93	0,93
Saad ve ark., 2021	0,985	X	0,989	0,9892	X
Liang ve ark., 2021	0,999	0,97	0,985	X	0,999
Alshazly ve ark., 2021	0,937-0,998	0,922-0,996	0,929-0,994	0,925-0,994	X
Chaudhary ve Pachori, 2021	0,97-0,976	0,965-0,9836	0,976	0,97-0,98	X
Lacerda ve ark., 2021	0,97	X	0,88	X	X
Singh ve ark., 2021	X	X	0,957	0,953	0,958
VAH yaklaşımından önce	<b>0,9676</b>	0,9052	0,9421	0,9518	0,9884
VAH yaklaşımından önce	0,9646	<b>0,9181</b>	<b>0,9456</b>	<b>0,9545</b>	<b>0,9890</b>
VAH yaklaşımından sonra	<b>0,9832</b>	0,8789	0,9406	0,9514	0,9918
VAH yaklaşımından sonra	0,9547	<b>0,9622</b>	<b>0,9577</b>	0,9639	0,9916
VAH yaklaşımından sonra	0,9725	0,9353	0,9573	<b>0,9642</b>	<b>0,9923</b>

Uygulamada COVID-19 zatürresi ve diğer zatürre sınıflandırması için elde edilen en iyi sonuçların literatürde yer alan çalışmalarda elde edilen sonuçlarla karşılaştırılması Çizelge 8.35'de görülmektedir. VAH yaklaşımı kullanılmadan önce COVID-19 zatürresi ve diğer zatürre sınıflandırması için elde edilen en yüksek duyarlılık, özgüllük, doğruluk, F-1 skoru ve AİKE-AKA parametreleri sırasıyla 0,9615; 0,7270; 0,8846; 0,9180 ve 0,9370'dir. Aynı sınıflandırma başlığında VAH yaklaşımı kullanıldıktan sonra elde edilen en yüksek duyarlılık, özgüllük, doğruluk, F-1 skoru ve

AİKE-AKA parametreleri sırasıyla 0,9915; 0,8140; 0,9071; 0,9327 ve 0,9615'dir. VAH yaklaşımlarıyla en yüksek duyarlılık değeri; giriş verisi olarak LL, LH, HL alt bantlarının reel kısmı kullanılarak ve VAH-4 yaklaşımı yardımıyla elde edilmiştir. Aynı giriş verileri kullanılarak VAH-5 yaklaşımı yardımıyla en yüksek özgüllük ve doğruluk değerlerine, VAH-2 yaklaşımı yardımıyla en yüksek F-1 skoru ve AİKE-AKA değerlerine ulaşılmıştır.

**Çizelge 8.35.** Tez çalışmasının ikinci uygulamasında BT görüntülerden COVID-19 zatürresi ve diğer zatürre sınıflandırması için elde edilen sonuçların literatürde yer alan çalışmalarda elde edilen sonuçlar ile karşılaştırması

Çalışma	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AİKE-AKA
Wu ve ark., 2020(b)	0,622-0,811	0,615	0,620-0,760	X	0,634-0,819
Yan ve ark., 2020	0,891	0,857	0,875	X	0,934
Zhang ve ark., 2021	0,879	0,887-0,9	X	X	0,922-0,959
Song ve ark., 2021	0,96	0,77	0,86	0,87	0,95
Kang ve ark., 2021	0,85-0,925	0,75-0,975	0,8125-0,912	X	X
Giordano ve ark., 2021	0,63-0,87	0,51-0,74	0,7	X	0,84
Saba ve ark., 2021	0,5097-0,9899	0,9099-0,9964	X	0,622-0,9899	0,993
VAH yaklaşımından önce	<b>0,9615</b>	<b>0,7270</b>	<b>0,8846</b>	<b>0,9180</b>	<b>0,9370</b>
VAH yaklaşımından sonra	<b>0,9915</b>	0,6581	0,8821	0,9187	0,9539
VAH yaklaşımından sonra	0,9525	<b>0,8140</b>	<b>0,9071</b>	0,9323	0,9592
VAH yaklaşımından sonra	0,9826	0,7450	0,9047	<b>0,9327</b>	<b>0,9615</b>

Uygulamada elde edilen sayısal sonuçlarının daha önce yapılmış çalışmaların sayısal sonuçlarıyla doğrudan karşılaştırılması doğru bir yaklaşım değildir. Çünkü, kullanılan toplam görüntü sayısı, test ve eğitim yaklaşımı, test ve eğitim görüntü sayısındaki farklılıklar sonuçlar üzerinde doğrudan etkili faktörlerdir. Ancak; COVID-19 ve COVID-19 değil sınıflandırması sonuçlarının bilgileri Çizelge 8.34'de verilen literatürde yer alan çalışmalarda elde edilen sonuçlarla karşılaştırılması gerekirse, tez çalışmasının ikinci uygulamasında önemli sonuçların elde edildiği görülmektedir. Bu kapsamda, literatürde yer alan çalışmaların üçte ikisinden daha iyi sonuçların elde edildiği anlaşılmaktadır. COVID-19 zatürresi ve diğer zatürre sınıflandırması sonuçlarının bilgileri Çizelge 9.35'de verilen literatürde yer alan çalışmalarda elde edilen sonuçlarla karşılaştırılması gerekirse, literatürde yapılan yedi çalışmanın altısından daha yüksek sonuçlar elde edildiği görülmektedir. Bu uygulamada kullanılan görüntü sayısı diğer çalışmalara göre oldukça fazla olduğu için sonuçların daha geçerli olduğu değerlendirilmektedir.

## 9. BT GÖRÜNTÜLER ÜZERİNDEN COVID-19 ZATÜRRESİ, SAĞLIKLI VE DİĞER ZATÜRRE SINIFLANDIRMASI

Tez çalışmasının üçüncü uygulamasında BT görüntüler üzerinden COVID-19 zatürresi, sağlıklı ve diğer zatürre olmak üzere üç sınıflı otomatik sınıflandırma gerçekleştirilmiştir. Söz konusu uygulama sonuçları Yaşar ve arkadaşları tarafından (Yaşar ve ark., 2022) yayınlanmıştır.

### 9.1. Uygulamada Kullanılan Veriler

Uygulamada kullanılan BT görüntüleri, görüntü sayısını en üst düzeye çıkarmak için birçok kaynaktan toplanmıştır. Uygulamaya dahil edilen 386 COVID-19 zatürre BT görüntüsü Cohen ve arkadaşları (Cohen ve ark., 2020) ile Zhao ve arkadaşları (Zhao ve ark., 2020(b)) tarafından oluşturularak araştırmacıların kullanımına sunulan veri setlerinden alınmıştır. Görüntülerin uygulamaya eklenmesi sırasında görüntüler ve ilgili klinik notlar dikkate alınmıştır. Sonuç olarak, 386 BT akciğer görüntüsünü içeren birleştirilmiş bir COVID-19 görüntü veri seti oluşturulmuştur. Veri setinde aynı hastadan alınan görüntüler, hastalığın seyrinin farklı günlerinde ve farklı görüntüleme çekimleri ile elde edilmiştir. Uygulamaya ikinci olarak Angelov ve Almeida Soares (Angelov ve Almeida Soares, 2020) tarafından toplanan COVID-19 görüntüleri dahil edilmiştir. Söz konusu BT görüntüleri Sao Paulo Kamu Çalışanları Devlet Hastanesinden ve Lapa Metropolitan Hastanesinden toplanmış olup TT-PZR testi ile doğrulanmışlardır. Uygulamaya bu veri setinden 2.168 COVID-19 BT görüntüsü eklenmiştir. Son olarak Konya Selçuk Üniversitesi Tıp Fakültesi Hastanesi'nden (27.07.2020 tarih ve 220/326 sayılı etik kurul kararı) alınan 810 COVID-19 BT görüntüsü uygulamaya dahil edilmiştir. Böylece, uygulamada kullanılan COVID-19 zatürre BT görüntü sayısı toplam 3.364'e çıkarılmıştır.

Uygulamada sağlıklı BT görüntüleri iki farklı veri seti birleştirilerek elde edilmiştir. Uygulamada kullanılan 1.766 görüntüden 1.010'u LIDC-IDRI (Armato ve ark., 2011; Clark ve ark., 2013; Armato ve ark., 2015) veri setinden alınmıştır. Söz konusu görüntüler hem normal hem de kanser hastalarına ait BT görüntüleridir ve herhangi bir zatürre içermemektedir. Yani, zatürre açısından normal ve sağlıklı niteliktedir. Uygulamada kullanılan 756 sağlıklı BT görüntüsü ise Angelov ve Almeida

Soares (Angelov ve Almeida Soares, 2020) tarafından oluşturulan veri setinden alınmıştır.

Uygulamada kullanılan 1.247 diğer zatürre BT görüntüsü, Angelov ve Almeida Soares (Angelov ve Almeida Soares, 2020) tarafından oluşturulan açık erişim veri setinden alınmıştır. Uygulamada kullanılan görüntü sayılarına ilişkin sayısal bilgiler Çizelge 9.1’de özetlenmiştir.

**Çizelge 9.1.** Tez çalışmasının üçüncü uygulamasında kullanılan COVID-19, sağlıklı ve diğer zatürre BT görüntülerine ilişkin bilgiler

<b>Kaynak</b>	<b>COVID-19</b>	<b>Sağlıklı</b>	<b>Diğer Zatürre</b>
Cohen ve ark.,2020 ile Zhao ve ark., 2020(b)	386	X	X
Angelov ve Almeida Soares, 2020	2.168	756	1.247
LIDC-IDRI	X	1.010	X
Selçuk Üniversitesi Tıp Fakültesi Hastanesi	810	X	X
<b>Toplam</b>	<b>3.364</b>	<b>1.766</b>	<b>1.247</b>
		<b>6.377</b>	

Uygulamada kullanılan görüntüler birçok kaynaktan alındığı için çok farklı boyutlarda, veri tiplerinde ve veri derinliklerindedir. Bu nedenle, görüntülerin standart hale getirilmesi için ön işleme tabi tutulması gerekmektedir. Bu kapsamda öncelikli olarak görüntüler akciğer bölgesini içine alacak şekilde çerçevelenmiştir. Bu şekilde görüntüler üzerinde asıl radyolojik bilgileri içeren ilgi alanları belirlenmiş ve gereksiz görüntü parçaları temizlenmiştir. Daha sonra görüntüler 8 bit derinlikte gri seviyeye dönüştürülmüştür. Son olarak ise görüntü boyutları yeniden düzenlenmiştir. Uygulamada yedi farklı transfer öğrenme 2B ESA mimarisi kullanılmıştır. Söz konusu bu mimarilerin giriş görüntü boyutları bazı farklılıklar göstermektedir. Bu nedenle görüntü boyutları kullanılan transfer öğrenme 2B ESA mimarisine uygun olarak düzenlenmiştir. Çizelge 9.2’de uygulamada kullanılan transfer öğrenme 2B ESA mimarileri ve bu mimarilere göre BT görüntülerinin ayarlandığı boyutlar görülmektedir.

**Çizelge 9.2.** Tez çalışmasının üçüncü uygulamasında kullanılan farklı transfer öğrenme 2B ESA mimarilerine göre yeniden düzenlenen BT görüntü boyutları

<b>Transfer Öğrenme 2B ESA Mimarisi</b>	<b>BT Görüntü Boyutları</b>
MobileNetV2	224×224×1
ResNet-101	224×224×1
Xception	299×299×1
InceptionV3	299×299×1
GoogleNet	224×224×1
EfficientNetB0	224×224×1
DenseNet-201	224×224×1

## 9.2. Özellik Çıkarma, ESA Modifikasyonları ve Hiperparametreler

Tez çalışmasının üçüncü uygulamasında yararlanılan YİD yönteminin işletilmesinde kullanılan yarıçap değeri 1 olarak seçilmiştir. YİD işlemi sonunda görüntü boyutlarında azalma olması sebebiyle, görüntülerin boyutları Çizelge 9.2'ye uygun şekilde MATLAB *imresize* fonksiyonu kullanılarak yeniden ayarlanmıştır.

Uygulamada yararlanılan transfer öğrenme 2B ESA mimarilerinin kullanıma uygun hale getirilmesi için üzerlerinde bazı değişiklikler yapılması gerekmektedir. Bu kapsamda ilk olarak, giriş görüntü boyutları Çizelge 9.2'de görüldüğü gibi yeniden düzenlenmiştir. Ayrıca, uygulamada üç sınıflı bir sınıflandırma yapıldığı için transfer öğrenme 2B ESA mimarilerinin üç sınıflı sonuçlar üretmesini sağlayacak değişiklikler gerçekleştirilmiş ve tam bağlı katman çıktısı üç olacak şekilde yeniden düzenlenmiştir. MATLAB programı kullanılarak transfer öğrenme 2B ESA mimarilerinde yapılan modifikasyonlar hakkındaki detaylı bilgiler Çizelge 9.3'de verilmiştir. Çizelge 9.3'de yer alan modifikasyonlar dışında transfer öğrenme 2B ESA mimarilerinin orijinal versiyonlarının katmanlarında veya parametrelerinde herhangi bir değişiklik yapılmamıştır.

**Çizelge 9.3.** Tez çalışmasının üçüncü uygulamasında kullanılan transfer öğrenme 2B ESA mimarilerinde yapılan modifikasyonlar hakkındaki bilgiler

Transfer Öğrenme 2B ESA Mimarisi	Katman İsmi	Orijinal Versiyonu	Modifiye Versiyonu
MobileNetV2	ImageInputLayer.InputSize	[224 224 3]	[224 224 1]
	FullyConnectedLayer.OutputSize	1000	3
ResNet-101	ImageInputLayer.InputSize	[224 224 3]	[224 224 1]
	FullyConnectedLayer.OutputSize	1000	3
Xception	ImageInputLayer.InputSize	[299 299 3]	[299 299 1]
	FullyConnectedLayer.OutputSize	1000	3
InceptionV3	ImageInputLayer.InputSize	[299 299 3]	[299 299 1]
	FullyConnectedLayer.OutputSize	1000	3
GoogleNet	ImageInputLayer.InputSize	[224 224 3]	[224 224 1]
	FullyConnectedLayer.OutputSize	1000	3
EfficientNetB0	ImageInputLayer.InputSize	[224 224 3]	[224 224 1]
	FullyConnectedLayer.OutputSize	1000	3
DenseNet-201	ImageInputLayer.InputSize	[224 224 3]	[224 224 1]
	FullyConnectedLayer.OutputSize	1000	3


Eğitimler sırasında ilk ağırlık transferi yapılmamıştır. Yani tüm transfer öğrenme 2B ESA mimarileri baştan rastgele atanan ağırlıklarla eğitilmiştir. Uygulamada ESA mimarilerin eğitiminde ağ çözücü olarak momentumlu stokastik gradyan inişi kullanılmıştır. Uygulamada, aşırı uyum sorunundan kaçınmak için başlangıç öğrenme

oranı varsayılan değer yani 0,01 olarak bırakılmıştır. Aşırı uyumu önlemek için alınan bir diğer önlem ise her iterasyonda veri setinin karıştırılmasıdır. Bu kapsamda, veri karıştırma seçeneği her iterasyon olarak ayarlanmıştır. Ayrıca, yüksek yineleme sayısına bağlı olarak ortaya çıkabilecek aşırı uyumu önlemek için maksimum iterasyon sayısı varsayılan değer yani 30 olarak bırakılmıştır. Uygulamada gerçekleştirilen eğitimler sonucunda elde edilen eğitim doğrulukları da hesaplanmış ve paylaşılmıştır. Diğer transfer öğrenme 2B ESA mimarileri için bir sorun olmamasına rağmen 2B GoogleNet ESA mimarisi için maksimum iterasyon sayısının 30 olarak seçilmesinin eğitimi istenilen düzeyde tamamlamak için yeterli olmadığı sonucuna varılmıştır. Bu nedenle bu mimari için maksimum iterasyon sayısı 100 olacak şekilde eğitim işlemleri tekrarlanmış ve sonuçlar hesaplanmıştır. Eğitim seçeneklerinde küme boyutu 32 olarak ayarlanmıştır. Momentum, gradyan bozunma faktörü, sıra doldurma gibi diğer tüm parametreler varsayılan değerler olarak ayarlanmıştır. MathWorks sayfasından (MathWorks, 2022(a)) parametrelerin açıklamalarının ve varsayılan değerlerin incelenmesi mümkündür.

### 9.3. Uygulamada Kullanılan VAH Yaklaşımları

Uygulamada orijinal BT görüntüleri kullanılarak otomatik sınıflandırma sonuçları hesaplanmıştır. Ayrıca, orijinal BT görüntülerine YİD uygulanarak elde edilen özellik görüntüleri için de benzer sınıflandırma sonuçları elde edilmiştir. Uygulamada söz konusu bu sonuçları birleştirmek için bir VAH yaklaşımı kullanılmıştır. VAH yaklaşımı, orijinal BT görüntüleri kullanılarak ve YİD özellik görüntüleri kullanılarak elde edilen sonuçları yarı yarıya birleştirmektedir. Diğer bir deyişle, bir transfer öğrenme 2B ESA mimarisi kullanılarak her sınıf için elde edilen uygunluk değerleri (tüm sınıflar için toplamı 1'dir) sınıf bazında karşılıklı olarak birleştirilmiştir. Örneğin, bir test görüntüsü için orijinal BT görüntüleri kullanılması durumunda COVID-19 zatürresi, sağlıklı ve diğer zatürre sınıfları için elde edilen uygunluk değerleri sırasıyla 0,75; 0,15 ve 0,10; aynı test görüntüsü için YİD özellik görüntüsü kullanarak elde edilen uygunluk değerleri ise sırasıyla 0,45; 0,25 ve 0,30 olduğunu varsayıldığında; söz konusu test görüntüsü için VAH yaklaşımı kullanılarak elde edilen uygunluk değerleri sırasıyla 0,60; 0,20 ve 0,20 olacaktır. VAH yaklaşımı kullanılarak her sınıf için birleştirme işlemi Şekil 9.1'de hesaplamalı olarak gösterilmiştir.





Şekil 9.1. Tez çalışmasının üçüncü uygulamasında kullanılan VAH yaklaşımı (Yaşar ve ark., 2022)

Uygulamada en yüksek başarıyı gösteren VAH yaklaşımlarının sonuçları aynı VAH yaklaşımı kullanılarak tekrar bir araya getirilmiştir. Bu sayede, uygulama için mümkün olan en yüksek sonuçlar elde edilmiştir. VAH yaklaşımlarının çalışma süreleri, saniyenin binde birinden daha azdır. Yani; VAH yaklaşımlarının toplam çalışma süresi, giriş olarak kullanılan sonuçları elde etmek için gereken sürelerin toplamına yaklaşık olarak eşittir.

#### 9.4. Deneyler

Tez çalışmasının üçüncü uygulamasında BT görüntüleri üzerinden COVID-19 zatürresi, sağlıklı ve diğer zatürre olmak üzere üç sınıflı sınıflandırma gerçekleştirilmiştir. Söz konusu sınıflandırmanın otomatik olarak yapılması için yapay zekâ yaklaşımlarından biri olan derin öğrenme kullanılmıştır. Uygulamada dört veri setinin birleştirilmesiyle elde edilen 3.364 COVID-19 zatürre BT görüntüsü, iki veri setinin birleştirilmesiyle elde edilen normal ile aşırı yoğun seviyeli nodüllere sahip 1.766 sağlıklı BT görüntüsü ve bir adet veri seti içinden alınan 1.247 diğer zatürre BT görüntüsünden yararlanılmıştır.

Uygulamada ilk olarak BT görüntüleri akciğer görüntülerinin ilgi alanlarını belirlemek için çerçeveleme yapılmıştır. Çerçeveleme yapılırken akciğer bölgesinin sınırlarının maksimum düzeyde kapsanması için titizlik gösterilmiştir. Çerçeveleme işleminden sonra görüntüler yeniden boyutlandırılmıştır. Uygulamada kullanılan transfer öğrenme 2B ESA mimarileri için görüntü boyutlarının ayarlandığı büyüklükler daha önce Çizelge 9.2’de verilmiştir.

Uygulamada 2B MobileNetV2, 2B ResNet-101, 2B Xception, 2B InceptionV3, 2B GoogleNet, 2B EfficientNetB0 ve 2B DenseNet-201 olmak üzere toplam yedi adet transfer öğrenme 2B ESA mimari kullanılmıştır. Uygulamada sınıflandırma sonuçları, doğrudan BT görüntüleri kullanılarak ve görüntülere YİD işlemi uygulanarak elde edilen özellik görüntüleri kullanılarak ayrı ayrı hesaplanmıştır. Daha sonra VAH

yaklaşımı kullanılarak sonuçlar birleştirilmiştir. Son olarak VAH yaklaşımı kullanılarak en yüksek sonuçları sağlayan en iyi ilk iki transfer öğrenme 2B ESA mimarisinin sonuçları aynı VAH yaklaşımı ile tekrar birleştirilmiştir. Uygulamada birçok transfer öğrenme 2B ESA mimarisi, farklı giriş görüntü türü ve iki aşamalı VAH yaklaşımı kullanılarak derinlemesine karşılaştırmalar yapılmasına olanak sağlayan kapsamlı sonuçlar elde edilmiştir.

Uygulamanın eğitim ve test işlemleri, dört kat çapraz doğrulama prosedürüne göre gerçekleştirilmiştir. Uygulama kapsamında bir görüntünün sınıflandırılması için ihtiyaç duyulan süreler (CPU süresi) saniye cinsinden ölçülmüştür. Deneyler; 64 GB RAM, Intel(R) Xeon (R) CPU E5-2680 2.7 GHz (32 CPUs) bilgisayar üzerinde çalışan MATLAB 2020(b) yazılımı kullanılarak gerçekleştirilmiştir. Uygulamada verilen tüm CPU çalışma süreleri saniye cinsinden zamanı göstermektedir.

### 9.5. Deney Sonuçları

Uygulamada 2B MobileNetV2, 2B ResNet-101, 2B Xception, 2B InceptionV3, 2B GoogleNet, 2B EfficientNetB0 ve 2B DenseNet-201 olmak üzere toplam yedi adet transfer öğrenme 2B ESA mimarisi kullanılarak üç sınıflı sınıflandırma sonuçları hesaplanmıştır. Transfer öğrenme 2B ESA mimarilerinin giriş görüntü boyutlarına ilişkin bilgiler daha önce Çizelge 9.2’de verilmiştir. Orijinal BT görüntüleri ve YİD özellik görüntüleri kullanılarak söz konusu transfer öğrenme 2B ESA mimarileri için elde edilen eğitim doğrulukları sırasıyla Çizelge 9.4’de ve Çizelge 9.5’de yer almaktadır.

**Çizelge 9.4.** COVID-19 zatürresi, sağlıklı ve diğer zatürre sınıflandırmasında orijinal BT görüntüleri kullanılarak elde edilen eğitim doğruluğu sonuçları

Transfer Öğrenme 2B ESA Mimarisi	Maksimum İterasyon Sayısı	Eğitim Doğruluğu				
		1. kat	2. kat	3. kat	4. kat	Ortalama
MobileNetV2	30	0,9962	0,9960	0,9981	0,9929	0,9958
ResNet-101	30	0,9977	0,9960	0,9856	0,9803	0,9899
Xception	30	1,0000	1,0000	1,0000	0,9948	0,9987
InceptionV3	30	0,9992	0,9977	0,9941	0,9893	0,9951
GoogleNet	30	0,9852	0,8980	0,9384	0,9330	0,9386
GoogleNet	100	1,0000	1,0000	1,0000	0,9948	0,9987
EfficientNetB0	30	1,0000	1,0000	0,9996	0,9943	0,9985
DenseNet-201	30	0,9981	1,0000	1,0000	0,9948	0,9982

**Çizelge 9.5.** COVID-19 zatürresi, sağlıklı ve diğer zatürre sınıflandırmasında YİD özellik görüntüleri kullanılarak elde edilen eğitim doğruluğu sonuçları

Transfer Öğrenme 2B ESA Mimarisi	Maksimum İterasyon Sayısı	Eğitim Doğruluğu				
		1. kat	2. kat	3. kat	4. kat	Ortalama
MobileNetV2	30	0,9981	0,9994	0,9996	0,9943	0,9979
ResNet-101	30	0,9983	0,9985	0,9927	0,9874	0,9943
Xception	30	1,0000	1,0000	0,9977	0,9925	0,9975
InceptionV3	30	0,9983	0,9983	0,9990	0,9937	0,9973
GoogleNet	30	0,9346	0,9053	0,9616	0,9579	0,9398
GoogleNet	100	1,0000	1,0000	1,0000	0,9948	0,9987
EfficientNetB0	30	1,0000	0,9969	1,0000	0,9948	0,9979
DenseNet-201	30	1,0000	0,9998	1,0000	0,9948	0,9986

Uygulamada orijinal BT görüntüleri ve YİD özellik görüntüleri kullanılarak transfer öğrenme 2B ESA mimarileri için elde edilen test sonuçları sırasıyla Çizelge 9.6'da ve Çizelge 9.7'de yer almaktadır. Çizelge 9.6 ve Çizelge 9.7'de yer alan test sonuçlarının VAH yaklaşımı kullanılarak birleştirilmesiyle elde edilen yeni test sonuçları ise Çizelge 9.8'de verilmiştir. Bir görüntünün sınıflandırılması için gereken CPU çalışma sürelerinin karşılaştırması ise Çizelge 9.9'da yer almaktadır.

**Çizelge 9.6.** COVID-19 zatürresi, sağlıklı ve diğer zatürre sınıflandırmasında orijinal BT görüntüleri kullanılarak elde edilen deney sonuçları

Transfer Öğrenme 2B ESA Mimarisini	Sınıf	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AIKE-AKA	Genel Doğruluk
MobileNetV2 (İterasyon=30)	COVID-19	2724	640	2450	563	0,8098	0,8131	0,8114	0,8191	0,8960	0,7380
	Sağlıklı	1368	398	4029	582	0,7746	0,8738	0,8463	0,7363	0,9185	
	Diğer Zat.	614	633	4604	526	0,4924	0,8975	0,8183	0,5145	0,8235	
	Genel (ağırlıklı)					0,738	0,8464	0,8224	0,7366	0,8881	
ResNet-101 (İterasyon=30)	COVID-19	2660	704	2534	479	0,7907	0,8410	0,8145	0,8181	0,8939	0,7358
	Sağlıklı	1487	279	3918	693	0,8420	0,8497	0,8476	0,7537	0,9257	
	Diğer Zat.	545	702	4617	513	0,4370	0,9000	0,8095	0,4729	0,7991	
	Genel (ağırlıklı)					0,7358	0,855	0,8227	0,7327	0,8842	
Xception (İterasyon=30)	COVID-19	2825	539	2454	559	0,8398	0,8145	0,8278	0,8373	0,9122	0,7552
	Sağlıklı	1372	394	4103	508	0,7769	0,8898	0,8586	0,7526	0,9308	
	Diğer Zat.	619	628	4636	494	0,4964	0,9037	0,8241	0,5246	0,8377	
	Genel (ağırlıklı)					0,7552	0,8528	0,8356	0,7527	0,9028	
InceptionV3 (İterasyon=30)	COVID-19	2789	575	2593	420	0,8291	0,8606	0,8440	0,8486	0,9172	0,7795
	Sağlıklı	1408	358	4299	312	0,7973	0,9323	0,8949	0,8078	0,9534	
	Diğer Zat.	774	473	4456	674	0,6207	0,8686	0,8201	0,5744	0,8559	
	Genel (ağırlıklı)					0,7795	0,882	0,8534	0,7837	0,9152	
GoogleNet (İterasyon=30)	COVID-19	2641	723	2551	462	0,7851	0,8467	0,8142	0,8168	0,8942	0,7380
	Sağlıklı	1445	321	4009	602	0,8182	0,8694	0,8553	0,7579	0,9330	
	Diğer Zat.	620	627	4523	607	0,4972	0,8817	0,8065	0,5012	0,8182	
	Genel (ağırlıklı)					0,738	0,8598	0,8241	0,7388	0,8901	
GoogleNet (İterasyon=100)	COVID-19	2791	573	2429	584	0,8297	0,8062	0,8186	0,8283	0,8934	0,7491
	Sağlıklı	1398	368	4052	559	0,7916	0,8788	0,8546	0,7510	0,9258	
	Diğer Zat.	588	659	4673	457	0,4715	0,9109	0,8250	0,5131	0,8292	
	Genel (ağırlıklı)					0,7491	0,8468	0,8298	0,7453	0,8898	
EfficientNetB0 (İterasyon=30)	COVID-19	2719	645	2458	555	0,8083	0,8158	0,8118	0,8192	0,8938	0,7414
	Sağlıklı	1355	411	4107	504	0,7673	0,8907	0,8565	0,7476	0,9160	
	Diğer Zat.	654	593	4540	590	0,5245	0,8850	0,8145	0,5251	0,8203	
	Genel (ağırlıklı)					0,7414	0,8501	0,8247	0,7419	0,8856	
DenseNet-201 (İterasyon=30)	COVID-19	2835	529	2569	444	0,8427	0,8526	0,8474	0,8535	0,9305	0,7845
	Sağlıklı	1476	290	4175	436	0,8358	0,9054	0,8862	0,8026	0,9502	
	Diğer Zat.	692	555	4636	494	0,5549	0,9037	0,8355	0,5688	0,8604	
	Genel (ağırlıklı)					0,7845	0,8772	0,8558	0,7838	0,9223	

**Çizelge 9.7.** COVID-19 zatürresi, sağlıklı ve diğer zatürre sınıflandırmasında orijinal YİD özellik görüntüleri kullanılarak elde edilen deney sonuçları

Transfer Öğrenme 2B ESA Mimarisi	Sınıf	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AIKE-AKA	Genel Doğruluk
MobileNetV2 (İterasyon=30)	COVID-19	2643	721	2367	646	0,7857	0,7856	0,7856	0,7945	0,8644	0,6845
	Sağlıklı	1338	428	3779	832	0,7576	0,8196	0,8024	0,6799	0,8811	
	Diğer Zat.	384	863	4596	534	0,3079	0,8959	0,7809	0,3547	0,7200	
	Genel (ağırlıklı)					0,6845	0,8166	0,7894	0,6768	0,8408	
ResNet-101 (İterasyon=30)	COVID-19	2648	716	2398	615	0,7872	0,7959	0,7913	0,7992	0,8724	0,6872
	Sağlıklı	1303	463	3831	780	0,7378	0,8308	0,8051	0,6771	0,8877	
	Diğer Zat.	431	816	4530	600	0,3456	0,8830	0,7780	0,3784	0,7324	
	Genel (ağırlıklı)					0,6872	0,8226	0,7925	0,6831	0,8493	
Xception (İterasyon=30)	COVID-19	2739	625	2416	597	0,8142	0,8019	0,8084	0,8176	0,8953	0,7154
	Sağlıklı	1417	349	3861	750	0,8024	0,8373	0,8277	0,7206	0,9130	
	Diğer Zat.	406	841	4662	468	0,3256	0,9088	0,7947	0,3828	0,7716	
	Genel (ağırlıklı)					0,7154	0,8326	0,8110	0,7057	0,8760	
InceptionV3 (İterasyon=30)	COVID-19	2952	412	2581	432	0,8775	0,8566	0,8676	0,8749	0,9411	0,7894
	Sağlıklı	1504	262	4129	482	0,8516	0,8955	0,8833	0,8017	0,9504	
	Diğer Zat.	578	669	4701	429	0,4635	0,9164	0,8278	0,5129	0,8437	
	Genel (ağırlıklı)					0,7894	0,8791	0,8642	0,7838	0,9246	
GoogleNet (İterasyon=30)	COVID-19	2629	735	2415	598	0,7815	0,8015	0,7910	0,7978	0,8777	0,6817
	Sağlıklı	1232	534	3891	720	0,6976	0,8439	0,8034	0,6627	0,8752	
	Diğer Zat.	486	761	4418	712	0,3897	0,8612	0,7690	0,3975	0,7480	
	Genel (ağırlıklı)					0,6817	0,8249	0,7901	0,6821	0,8517	
GoogleNet (İterasyon=100)	COVID-19	2708	656	2518	495	0,8050	0,8357	0,8195	0,8247	0,8952	0,7116
	Sağlıklı	1314	452	3937	674	0,7441	0,8538	0,8234	0,7001	0,8945	
	Diğer Zat.	516	731	4460	670	0,4138	0,8694	0,7803	0,4242	0,7698	
	Genel (ağırlıklı)					0,7116	0,8473	0,8129	0,7119	0,8705	
EfficientNetB0 (İterasyon=30)	COVID-19	2582	782	2264	779	0,7675	0,7514	0,7599	0,7713	0,8408	0,6754
	Sağlıklı	1349	417	3770	841	0,7639	0,8176	0,8027	0,6820	0,8831	
	Diğer Zat.	376	871	4650	480	0,3015	0,9064	0,7881	0,3576	0,7410	
	Genel (ağırlıklı)					0,6754	0,8001	0,7773	0,6657	0,8330	
DenseNet-201 (İterasyon=30)	COVID-19	2941	423	2568	445	0,8743	0,8523	0,8639	0,8714	0,9381	0,7764
	Sağlıklı	1440	326	4050	561	0,8154	0,8783	0,8609	0,7645	0,9329	
	Diğer Zat.	570	677	4710	420	0,4571	0,9181	0,8280	0,5096	0,8421	
	Genel (ağırlıklı)					0,7764	0,8724	0,8560	0,7711	0,9179	

**Çizelge 9.8.** COVID-19 zatürresi, sağlıklı ve diğer zatürre sınıflandırmasında VAH yaklaşımı kullanılarak elde edilen deney sonuçları

VAH ve Transfer Öğrenme 2B ESA Mimarisi	Sınıf	DP	YN	DN	YP	Duyarluluk	Özgünlük	Doğruluk	F-1 Skoru	AIKE-AKA	Genel Doğruluk
VAH (MobileNetV2/ Orijinal-YİD) (İterasyon=30)	COVID-19	2847	517	2465	548	0,8463	0,8181	0,8330	0,8424	0,9078	0,7507
	Sağlıklı	1453	313	3951	660	0,8228	0,8569	0,8474	0,7492	0,9246	
	Diğer Zat.	487	760	4748	382	0,3905	0,9255	0,8209	0,4603	0,8158	
	Genel (ağırlıklı)					0,7507	0,8499	0,8346	0,7419	0,8945	
VAH (ResNet101/ Orijinal-YİD) (İterasyon=30)	COVID-19	2804	560	2508	505	0,8335	0,8324	0,8330	0,8404	0,9109	0,7477
	Sağlıklı	1503	263	3894	717	0,8511	0,8445	0,8463	0,7541	0,9296	
	Diğer Zat.	461	786	4743	387	0,3697	0,9246	0,8161	0,4401	0,8083	
	Genel (ağırlıklı)					0,7477	0,8538	0,8334	0,7382	0,8960	
VAH (Xception/ Orijinal-YİD) (İterasyon=30)	COVID-19	2904	460	2484	529	0,8633	0,8244	0,8449	0,8545	0,9206	0,7662
	Sağlıklı	1458	308	4011	600	0,8256	0,8699	0,8576	0,7626	0,9380	
	Diğer Zat.	524	723	4768	362	0,4202	0,9294	0,8299	0,4913	0,8388	
	Genel (ağırlıklı)					0,7662	0,8575	0,8455	0,7580	0,9094	
VAH (InceptionV3/ Orijinal-YİD) (İterasyon=30)	COVID-19	3012	352	2666	347	0,8954	0,8848	0,8904	0,8960	0,9544	0,8248
	Sağlıklı	1540	226	4260	351	0,8720	0,9239	0,9095	0,8422	0,9673	
	Diğer Zat.	708	539	4711	419	0,5678	0,9183	0,8498	0,5965	0,8791	
	Genel (ağırlıklı)					0,8248	0,9022	0,8877	0,8225	0,9432	
VAH (GoogleNet/ Orijinal-YİD) (İterasyon=30)	COVID-19	2895	469	2540	473	0,8606	0,8430	0,8523	0,8601	0,9186	0,7786
	Sağlıklı	1480	286	4071	540	0,8381	0,8829	0,8705	0,7818	0,9344	
	Diğer Zat.	590	657	4731	399	0,4731	0,9222	0,8344	0,5277	0,8249	
	Genel (ağırlıklı)					0,7786	0,8695	0,8538	0,7734	0,9047	
VAH (GoogleNet/ Orijinal-YİD) (İterasyon=100)	COVID-19	2923	441	2503	510	0,8689	0,8307	0,8509	0,8601	0,9222	0,7687
	Sağlıklı	1429	337	4018	593	0,8092	0,8714	0,8542	0,7545	0,9290	
	Diğer Zat.	550	697	4758	372	0,4411	0,9275	0,8324	0,5071	0,8301	
	Genel (ağırlıklı)					0,7687	0,8609	0,8482	0,7618	0,9061	
VAH (EfficientNetB0/ Orijinal-YİD) (İterasyon=30)	COVID-19	2754	610	2395	618	0,8187	0,7949	0,8074	0,8177	0,8895	0,7351
	Sağlıklı	1427	339	3969	642	0,8080	0,8608	0,8462	0,7442	0,9185	
	Diğer Zat.	507	740	4701	429	0,4066	0,9164	0,8167	0,4645	0,8151	
	Genel (ağırlıklı)					0,7351	0,8369	0,8200	0,7283	0,8830	
VAH (DenseNet-201/ Orijinal-YİD) (İterasyon=30)	COVID-19	2988	376	2638	375	0,8882	0,8755	0,8822	0,8884	0,9489	0,8139
	Sağlıklı	1533	233	4156	455	0,8681	0,9013	0,8921	0,8167	0,9609	
	Diğer Zat.	669	578	4773	357	0,5365	0,9304	0,8534	0,5886	0,8823	
	Genel (ağırlıklı)					0,8139	0,8934	0,8793	0,8099	0,9392	

**Çizelge 9.9.** COVID-19 zatürresi, sağlıklı ve diğer zatürre sınıflandırması için gereken CPU çalışma sürelerinin (saniye) karşılaştırması

Transfer Öğrenme 2B ESA Mimarisi	Maksimum İterasyon Sayısı	Orijinal	YİD	VAH (Orijinal-YİD)
MobileNetV2	30	1,3644	1,3848	2,7492
ResNet-101	30	3,1879	3,1905	6,3784
Xception	30	1,7827	1,7871	3,5698
InceptionV3	30	3,2504	3,2468	6,4972
GoogleNet	30	0,6874	0,6921	1,3795
GoogleNet	100	2,3012	2,3277	4,6289
EfficientNetB0	30	8,4497	8,4274	16,8771
DenseNet-201	30	8,0568	8,0859	16,1427

## 9.6. BT Görüntüler Üzerinden COVID-19 Zatürresi, Sağlıklı ve Diğer Zatürre Sınıflandırma Sonuçlarının Değerlendirilmesi

Tez çalışmasının üçüncü uygulamasında orijinal BT görüntüleri ve YİD özellik görüntüleri kullanılarak üç sınıflı sınıflandırma sonuçları Çizelge 9.6 ve Çizelge 9.7’de verilmiştir. Ayrıca, bu sonuçların VAH yaklaşımlarıyla birleştirilmesiyle elde edilen sınıflandırma sonuçları Çizelge 9.8’de yer almaktadır. Bu bölümde söz konusu sonuçların değerlendirilmesi yapılmıştır.

Uygulamada yararlanılan tüm transfer öğrenme 2B ESA mimarileri için, VAH yaklaşımı kullanılmadan önce ve VAH yaklaşımı kullandıktan sonra elde edilen sonuçlar Çizelge 9.10’da verilmiştir. Çizelge 9.10’da parametredeki değişim (%) satırları, ilgili transfer öğrenme 2B ESA mimarisi için VAH yaklaşımı kullanılmadan önce orijinal görüntüler veya YİD özellik görüntüleri kullanılarak elde edilen en yüksek ağırlıklı sonuçlar ile VAH yaklaşımı kullanıldıktan sonra elde edilen sonuçlar arasındaki değişim miktarını göstermektedir. Çizelge 9.10 incelendiğinde 2B EfficientNetB0 ESA mimarisi haricinde diğer tüm transfer öğrenme 2B ESA mimarileri için VAH yaklaşımının sonuçlar üzerinde iyileştirici bir etkiye sahip olduğu görülmektedir. Uygulamada 2B EfficientNetB0 ESA mimarisi haricindeki diğer transfer öğrenme 2B ESA mimarileri için VAH yaklaşımının kullanılması ağırlıklı duyarlılık parametresinde %1,10 ile %4,06 arasında değişen bir artış sağlamıştır. Ağırlıklı özgüllük parametresinde 2B ResNet-101 ESA mimarisi için -%0,12’lik bir düşüşe neden olurken diğer transfer öğrenme 2B ESA mimarileri için %0,34 ile %2,31 arasında değişen iyileştirmeler sağlanmıştır. Ağırlıklı doğruluk parametresinde ise %0,99 ile %2,98 arasında değişen miktarlarda artış olmuştur. Ağırlıklı F-1 skoru parametresinde %0,53 ile %3,87 arasında ve ağırlıklı AİKE-AKA parametresinde %0,64 ile %1,86 arasında bir iyileştirme sağlanmıştır.

Uygulamada orijinal görüntüler ile YİD özellik görüntüleri kullanılarak elde edilen sonuçların birleştirilmesinde VAH yaklaşımları kullanılması sonuçların performansının artırmasında önemli katkılar sağlamıştır. Uygulamada bu durumu daha iyi analiz etmek için bir deney daha yapılmıştır. Orijinal BT görüntüleri kullanılarak en yüksek sonuçları sağlayan 2B InceptionV3 ve 2B DenseNet-201 ESA mimarilerinin sonuçları VAH yaklaşımıyla birleştirilmiştir. Bu deneyde elde edilen sonuçlar karşılaştırmalı olarak Çizelge 9.11’de verilmiştir.

**Çizelge 9.10.** COVID-19 zatürresi, sağlıklı ve diğer zatürre sınıflandırmasında VAH yaklaşımları kullanılmadan önce ve kullanıldıktan sonra elde edilen sonuçların özet bilgileri

Yöntem	Maksimum İterasyon Sayısı	Ağırlıklı					Genel Doğruluk
		Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AİKE-AKA	
MobileNetV2/Orijinal		0,7380	0,8464	0,8224	0,7366	0,8881	0,7380
VAH (MobileNetV2/Orijinal-YİD)	30	0,7507	0,8499	0,8346	0,7419	0,8945	0,7507
Parametredeki Değişim (%)		1,2702	0,3431	1,2241	0,5275	0,6396	1,2702
ResNet-101/Orijinal		0,7358	0,8550	0,8227	0,7327	0,8842	0,7358
VAH (ResNet-101/Orijinal-YİD)	30	0,7477	0,8538	0,8334	0,7382	0,8960	0,7477
Parametredeki Değişim (%)		1,1918	-0,1191	1,0702	0,5490	1,1801	1,1918
Xception/Orijinal		0,7552	0,8528	0,8356	0,7527	0,9028	0,7552
VAH (Xception/Orijinal-YİD)	30	0,7662	0,8575	0,8455	0,7580	0,9094	0,7662
Parametredeki Değişim (%)		1,0977	0,4759	0,9891	0,5331	0,6643	1,0977
InceptionV3/YİD		0,7894	0,8791	0,8642	0,7838	0,9246	0,7894
VAH (InceptionV3/Orijinal-YİD)	30	0,8248	0,9022	0,8877	0,8225	0,9432	0,8248
Parametredeki Değişim (%)		3,5440	2,3131	2,3540	3,8699	1,8630	3,5440
GoogleNet/Orijinal		0,7380	0,8598	0,8241	0,7388	0,8901	0,7380
VAH (GoogleNet/Orijinal-YİD)	30	0,7786	0,8695	0,8538	0,7734	0,9047	0,7786
Parametredeki Değişim (%)		4,0615	0,9726	2,9772	3,4649	1,4574	4,0615
GoogleNet/Orijinal		0,7491	0,8468	0,8298	0,7453	0,8898	0,7491
VAH (GoogleNet/Orijinal-YİD)	100	0,7687	0,8609	0,8482	0,7618	0,9061	0,7687
Parametredeki Değişim (%)		1,9602	1,4154	1,8352	1,6562	1,6242	1,9602
EfficientNetB0/Orijinal		0,7414	0,8501	0,8247	0,7419	0,8856	0,7414
VAH (EfficientNetB0/Orijinal-YİD)	30	0,7351	0,8369	0,8200	0,7283	0,8830	0,7351
Parametredeki Değişim (%)		-0,6273	-1,3181	-0,4753	-1,3592	-0,2623	-0,6273
DenseNet-201/Orijinal		0,7845	0,8772	0,8558	0,7838	0,9223	0,7845
VAH (DenseNet-201/Orijinal-YİD)	30	0,8139	0,8934	0,8793	0,8099	0,9392	0,8139
Parametredeki Değişim (%)		2,9324	1,6162	2,3510	2,6156	1,6952	2,9324

**Çizelge 9.11.** COVID-19 zatürresi, sağlıklı ve diğer zatürre sınıflandırmasında InceptionV3/Orijinal ve DenseNet-201/Orijinal sonuçlarının VAH yaklaşımıyla birleştirilmesiyle elde edilen sonuçlar

Yöntem	Sınıf	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AİKE-AKA	Genel Doğruluk
	Sağlıklı	1408	358	4299	312	0,7973	0,9323	0,8949	0,8078	0,9534	0,7795
	Diğer Zat.	774	473	4456	674	0,6207	0,8686	0,8201	0,5744	0,8559	
	Genel (ağırlıklı)					0,7795	0,8820	0,8534	0,7837	0,9152	
DenseNet-201 (Orijinal)	COVID-19	2835	529	2569	444	0,8427	0,8526	0,8474	0,8535	0,9305	
	Sağlıklı	1476	290	4175	436	0,8358	0,9054	0,8862	0,8026	0,9502	0,7845
	Diğer Zat.	692	555	4636	494	0,5549	0,9037	0,8355	0,5688	0,8604	
	Genel (ağırlıklı)					0,7845	0,8772	0,8558	0,7838	0,9223	
VAH (InceptionV3-DenseNet-201)	COVID-19	2883	481	2639	374	0,8570	0,8759	0,8659	0,8709	0,9345	
	Sağlıklı	1492	274	4267	344	0,8448	0,9254	0,9031	0,8284	0,9574	0,8027
	Diğer Zat.	744	503	4590	540	0,5966	0,8947	0,8364	0,5879	0,8728	
	Genel (ağırlıklı)					0,8027	0,8933	0,8705	0,8038	0,9288	



Çizelge 9.11’de verilen sonuçlar ile Çizelge 9.8’de 2B InceptionV3 ve 2B DenseNet-201 ESA mimarileri için elde edilen sonuçlar karşılaştırıldığında, VAH yaklaşımının verimliliği için YİD kullanımının önemi ortaya çıkmaktadır. Bu kapsamda, VAH yaklaşımında YİD kullanımının genel sonuçları %2,5 oranında ek bir iyileştirme yaptığı görülmektedir. Çizelge 9.12’de birinci aşama VAH yaklaşımı kullanılarak sağlanan en iyi ilk iki sonuçların aynı VAH yaklaşımı kullanılarak tekrar birleştirilmesiyle elde edilen sonuçlar yer almaktadır.

**Çizelge 9.12.** COVID-19 zatürresi, sağlıklı ve diğer zatürre sınıflandırmasında birinci aşama VAH yaklaşımı kullanılarak sağlanan en başarılı ilk iki sonucun VAH yaklaşımıyla tekrar birleştirilmesiyle elde edilen sonuçlar

Yöntem	Sınıf	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AİKE-AKA	Genel Doğruluk
Birinci Aşama VAH (InceptionV3)	COVID-19	3012	352	2666	347	0,8954	0,8848	0,8904	0,8960	0,9544	0,8248
	Sağlıklı	1540	226	4260	351	0,8720	0,9239	0,9095	0,8422	0,9673	
	Diğer Zat.	708	539	4711	419	0,5678	0,9183	0,8498	0,5965	0,8791	
Orijinal-YİD	Genel (ağırlıklı)					0,8248	0,9022	0,8877	0,8225	0,9432	
Birinci Aşama VAH (DenseNet-201)	COVID-19	2988	376	2638	375	0,8882	0,8755	0,8822	0,8884	0,9489	0,8139
	Sağlıklı	1533	233	4156	455	0,8681	0,9013	0,8921	0,8167	0,9609	
	Diğer Zat.	669	578	4773	357	0,5365	0,9304	0,8534	0,5886	0,8823	
Orijinal-YİD	Genel (ağırlıklı)					0,8139	0,8934	0,8793	0,8099	0,9392	
İkinci Aşama VAH	COVID-19	3029	335	2682	331	0,9004	0,8901	0,8956	0,9010	0,9600	0,8332
	Sağlıklı	1568	198	4239	372	0,8879	0,9193	0,9106	0,8462	0,9705	
	Diğer Zat.	716	531	4769	361	0,5742	0,9296	0,8601	0,6162	0,8963	
Orijinal-YİD	Genel (ağırlıklı)					0,8332	0,9059	0,8928	0,8301	0,9504	

Uygulamada orijinal BT görüntüleri kullanılarak, birinci aşama VAH kullanılarak ve ikinci aşama VAH kullanılarak elde edilen en yüksek ağırlıklı sonuçların literatürde yer alan çalışmalarda elde edilen sonuçlarla karşılaştırması Çizelge 9.13’de yer almaktadır. Çizelge 9.14’de ise sadece COVID-19 zatürre sınıfı için elde edilen sonuçların karşılaştırmaları görülmektedir.

**Çizelge 9.13.** Tez çalışmasının üçüncü uygulamasında COVID-19 zatürresi, sağlıklı ve diğer zatürre sınıflandırmasında elde edilen genel sonuçların literatürde yer alan çalışmalarda elde edilen sonuçlar ile karşılaştırması

Çalışma	Duyarlılık	Özgüllük	Ağırlıklı Doğruluk/ Genel Doğruluk	F-1 Skoru	AİKE-AKA
Xu ve ark., 2020	X	X	0,867	X	X
Hasan ve ark., 2020	X	X	0,953-0,9968	X	X
Wang ve ark., 2020(b)	X	X	0,778-0,897	X	X
Li ve ark., 2020(a)	0,939	0,964	X	X	0,98
Han ve ark., 2020	0,841-0,905	X	0,897-0,943	0,861-0,923	0,971-0,988
Ko ve ark., 2020	X	X	0,626-0,995	X	X
Sharma, 2020	0,921	0,9029	0,91	X	X
Hu ve ark., 2020	X	X	X	X	X
Amyar ve ark., 2020	0,96	0,92	0,9467	X	X
Jin ve ark., 2020	X	X	0,8483	X	0,927-0,933
Yousefzadeh ve ark., 2021	0,956-0,988	0,954-0,982	X	0,954-0,986	0,993-0,999
Mishra ve ark., 2021	X	X	0,8674-0,8852	X	X
Shi ve ark., 2021	X	X	0,8798	X	X
Peng ve ark., 2021	0,723	0,852	X	0,696	0,879
Song ve ark., 2021	0,93	0,93	0,93	0,93	X
Xiao ve ark., 2021	0,9894	0,9516	0,9429	X	X
DenseNet-201/Orijinal	0,7845	0,8772	0,8558/0,7845	0,7838	0,9223
Birinci Aşama VAH InceptionV3 Orijinal-YİD	0,8248	0,9022	0,8877/0,8248	0,8225	0,9432
İkinci Aşama VAH	0,8332	0,9059	0,8928/0,8332	0,8301	0,9504

**Çizelge 9.13.** Tez çalışmasının üçüncü uygulamasında COVID-19 zatürresi, sağlıklı ve diğer zatürre sınıflandırmasında COVID-19 zatürre sınıfı için elde edilen sonuçların literatürde yer alan çalışmalarda elde edilen sonuçlar ile karşılaştırması

Çalışma	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AİKE-AKA
Xu ve ark., 2020	0,867	X	X	0,839	X
Hasan ve ark., 2020	X	X	0,932-1,000	X	X
Wang ve ark., 2020(b)	0,797-0,934	0,707-0,955	0,769-0,933	0,698-0,878	0,921-0,973
Li ve ark., 2020(a)	0,898	0,958	X	X	0,96
Han ve ark., 2020	X	X	X	X	X
Ko ve ark., 2020	0,8828-1,000	0,9768-1,000	0,9487-0,9987	X	0,97-1,000
Sharma, 2020	X	X	X	X	X
Hu ve ark., 2020	0,764-0,886	0,826-0,898	0,81-0,892	X	0,816-0,923
Amyar ve ark., 2020	X	X	X	X	X
Jin ve ark., 2020	0,7706-0,7893	0,9315-0,9397	X	X	0,9175-0,9255
Yousefzadeh ve ark., 2021	X	X	X	X	X
Mishra ve ark., 2021	X	X	X	X	X
Shi ve ark., 2021	0,8649	X	X	0,8828	X
Peng ve ark., 2021	0,597	0,895	X	0,699	0,855
Song ve ark., 2021	X	X	X	X	X
Xiao ve ark., 2021	X	X	X	X	X
DenseNet-201/Orijinal	0,8427	0,8526	0,8474	0,8535	0,9305
Birinci Aşama VAH InceptionV3 Orijinal-YİD	0,8954	0,8848	0,8904	0,8960	0,9544
İkinci Aşama VAH	0,9004	0,8901	0,8956	0,9010	0,9600

Çizelge 9.13 incelendiğinde, ikinci aşama VAH işleminin sonunda en yüksek ağırlıklı duyarlılık parametresinin %4,87; en yüksek ağırlıklı özgüllük parametresinin %2,87; en yüksek ağırlıklı doğruluk parametresinin %3,7 artış gösterdiği görülmektedir.

Benzer şekilde en yüksek ağırlıklı F-1 skoru parametresinde %4,63 ve en yüksek ağırlıklı AİKE-AKA parametresinde %2,81 iyileşme sağlanmıştır. Ayrıca, genel doğruluk parametresi %4,87 artmıştır. Çizelge 9.14 incelendiğinde COVID-19 zatürre sınıfı için, ikinci aşama VAH işleminin sonunda en yüksek duyarlılık parametresinin %5,75; en yüksek özgüllük parametresinin %3,75; en yüksek doğruluk parametresinin %4,82; en yüksek F-1 skoru parametresinin %4,75 ve en yüksek AİKE-AKA parametresinin %2,95 oranında iyileştiği görülmektedir.

VAH yaklaşımının ilk aşama için uygulanması bile bazı ağırlıklı parametrelerde %4,06 oranında artışa neden olmuştur. Uygulamadaki VAH yaklaşımlarında YİD özellik görüntüleri ile elde edilen sonuçların kullanılması önemli bir avantaj sağlamıştır. Bu avantajı daha iyi anlamak için, aynı transfer öğrenme 2B ESA mimarisi için orijinal görüntüler ve YİD özellik görüntüleri kullanılarak elde edilen sonuçlar yerine, farklı transfer öğrenme 2B ESA mimarileri için orijinal görüntüler kullanılarak elde edilen sonuçlar birleştirilmiştir. Orijinal görüntüler kullanılarak en yüksek ilk iki sonucun elde edilmesini sağlayan InceptionV3/Orijinal (genel doğruluk 0,7795) ve DenseNet-201/Orijinal (genel doğruluk 0,7845) sonuçları birleştirildiğinde, genel doğruluk parametresi 0,8027 düzeyine yükselmiştir. Ancak, 2B InceptionV3 ESA mimarisi için orijinal görüntüleri kullanılarak elde edilen sonuçlar (genel doğruluk 0,7795) ve YİD özellik görüntüleri kullanılarak elde edilen sonuçlar (genel doğruluk 0,7894) birleştirildiğinde genel doğruluk parametresinin 0,8248 seviyesine yükseldiği görülmektedir. Bunun temel sebebi, transfer öğrenme 2B ESA mimarileri arasında bazı farklılıklar olmasına rağmen yanlış sınıflandırılan görüntü kümelerinin genellikle örtüşmesidir. Başka bir deyişle, transfer öğrenme 2B ESA mimarileri değişse bile inatçı sayılabilecek görüntüler iki mimariden biri tarafından dahi doğru sınıflandırılmamaktadır. Bununla birlikte, giriş görüntülerinin özelliklerindeki değişiklik, yanlış sınıflandırılan görüntülerin sayısını artırmakta ancak inatçı olarak kabul edilen görüntülerin örtüşme miktarında azalma sağlamaktadır.

Uygulamada farklı transfer öğrenme 2B ESA mimarileri için orijinal görüntüler kullanılarak elde edilen sınıflandırma sonuçları (Çizelge 9.6) incelendiğinde, genel doğruluk parametresinin 0,7358 ile 0,7845 arasında değiştiği görülmektedir. Bu durum, kullanılan transfer öğrenme 2B ESA mimarisinin genel doğruluk sonuçları üzerinde maksimum %4,88'lik bir etkiye sahip olduğunu göstermektedir. Ancak, Çizelge 9.9'da yer alan CPU çalışma süreleri karşılaştırıldığında en hızlı (0,6874 saniye) ve en yavaş mimari (8,4487 saniye) arasında yaklaşık on iki katlık bir fark olduğu görülmektedir.

Çizelge 9.13 incelendiğinde iki aşamalı VAH yaklaşımı sonucunda genel doğruluk parametresinin %4,87 oranında arttığı anlaşılmaktadır. İki aşamalı VAH yaklaşımının toplam CPU çalışma süresi orijinal görüntüler kullanılarak sonuç elde etmek için gereken CPU çalışma süresinin maksimum dört katıdır. Bu durum, VAH kullanılması üzerine geliştirici araştırmalar yapılmasının en az transfer öğrenme 2B ESA mimari tasarımı geliştirilmesi kadar etkili ve önemli bir konu başlığı olduğunu göstermektedir.

Uygulamada, transfer öğrenme 2B ESA mimarilerinin VAH yaklaşımı kullanılmadan önce ve kullanıldıktan sonraki başarıları karşılaştırıldığında, en iyi ilk iki transfer öğrenme 2B ESA mimarisinin sırasıyla 2B InceptionV3 ve 2B DenseNet-201 ESA olduğu görülmektedir. Uygulamada elde edilen sayısal sonuçlarının daha önce yapılmış çalışmaların sayısal sonuçlarıyla doğrudan karşılaştırılması doğru bir yaklaşım değildir. Çünkü, kullanılan toplam görüntü sayısı, test ve eğitim yaklaşımı, test ve eğitim görüntü sayısındaki farklılıklar sonuçlar üzerinde doğrudan etkili faktörlerdir. Uygulamada kullanılan transfer öğrenme 2B ESA mimari sayısının bu kadar geniş tutulmasının bir diğer nedeni geçmiş çalışmalarla kısmi de olsa bir karşılaştırma yapılmasının amaçlanmasıdır. Xu ve arkadaşları (2020) tarafından yapılan çalışmada ResNet mimarisinden yararlanılmıştır. Jin ve arkadaşları (2020), Mishra ve arkadaşları (2021), Saharma (2020) ile Ko ve arkadaşları (2020) tarafından gerçekleştirilen çalışmalarda VGG-16, ResNet-50, InceptionV3 ve Xception mimarileri kullanılmıştır. Ayrıca Yousefzadeh ve arkadaşları (2021) ile Xiao ve arkadaşları (2021) tarafından yapılan çalışmalarda sırasıyla EfficientNetB3 ve DenseNet mimarilerinden yararlanılmıştır. Söz konusu çalışmalarda kullanılan ESA mimarilerinin önemli bir kısmı uygulama deneylerine dahil edilmiştir. Uygulamada VAH yaklaşımları ile orijinal BT görüntüleri kullanılmasına göre daha yüksek sonuçlar elde edilmiştir. Bu nedenle, uygulamada elde edilen sonuçların daha önce gerçekleştirilen çalışmalarda elde edilen sonuçlardan sayısal olarak daha düşük olsa bile daha başarılı olduğu açık şekilde söylenebilir. Ayrıca, uygulamada kullanılan BT görüntülerinin toplam sayısı (6.377) daha önce en yüksek görüntü ile gerçekleştirilen çalışmada kullanılan toplam sayının yaklaşık bir buçuk katıdır. Uygulamada kullanılan COVID-19 zatürre BT görüntü sayısı açısından karşılaştırma yapıldığında, daha önce en yüksek COVID-19 zatürre BT görüntü sayısı ile gerçekleştirilen çalışmada kullanılan toplam sayının yaklaşık üç katı olduğu anlaşılmaktadır. Bu sebeple uygulamada elde edilen sonuçların daha geçerli olduğu değerlendirilmektedir.

## 10. BT GÖRÜNTÜLER ÜZERİNDEN COVID-19 ZATÜRRE SEVİYESİ SINIFLANDIRMASI

Tez çalışmasının dördüncü uygulamasında COVID-19 zatürre seviyesinin sınıflandırılmasına odaklanılmıştır. Uygulamada BT görüntüler üzerinden COVID-19 zatürresinin hafif, orta ve şiddetli olmak üzere üç sınıflı; şiddetli değil ve şiddetli olmak üzere iki sınıflı otomatik sınıflandırılması gerçekleştirilmiştir.

### 10.1. Uygulamada Kullanılan Veriler


Uygulamada kullanılan BT görüntüleri Selçuk Üniversitesi Tıp Fakültesi Hastanesi'nden (27.07.2020 tarih ve 220/327 sayılı etik kurul kararı) alınmıştır. Veri seti içinde bazı hastaların birden fazla BT çekim seti bulunmaktadır. Bu çekimler hastalık sürecinin farklı günlerinde gerçekleştirilmiştir. Her bir BT çekim setinden üç BT görüntü dilimi seçilmiştir. Dört uzman radyolog tarafından BT görüntülerdeki COVID-19 zatürre seviyesi etiketlenmiştir. Akciğer lob tutulumu %1 ile %25 arasında ise hafif, %25 ile %50 arasında ise orta ve %50'dan fazla ise şiddetli olarak etiketleme yapılmıştır. Uygulamada kullanılan verilere ilişkin hastaların cinsiyeti, BT çekimin yapıldığı gün ve zatürre seviyesi gibi detaylı bilgiler Çizelge 10.1'de yer almaktadır. Çizelge 10.1'de E kısaltması erkek, K kısaltması kadın, H kısaltması hafif, O kısaltması orta ve Ş kısaltması şiddetli anlamına gelmektedir.

Uygulamada otomatik COVID-19 zatürre seviye sınıflandırması, üç sınıflı (hafif, orta ve şiddetli) ve iki sınıflı (şiddetli değil ve şiddetli) olmak üzere iki başlıkta gerçekleştirilmiştir. Uygulamada 267 tanesi hafif, 156 tanesi orta ve 60 tanesi şiddetli olmak üzere toplam 483 COVID-19 BT görüntü dilimi kullanılmıştır. Bu görüntüler ve etiketlerden doğrudan üç sınıflı sınıflandırmada yararlanılmıştır. İki sınıflı sınıflandırmada hafif ve orta dereceli görüntüler şiddetli değil olarak kabul edilmiştir. Uygulamada kullanılan COVID-19 BT görüntüleri örnekleri Şekil 10.1'de verilmiştir.

Uygulamada kullanılan BT görüntüleri dicom formatındadır. Her BT çekim setinden seçilen üç BT dilimi jpg formatına dönüştürülmüştür. Daha sonra BT görüntüleri akciğer bölgesini içine alacak şekilde çerçevelenmiş ve gerçek radyolojik bilgileri içeren kısım elde edilmiştir. Bu aşamadan sonra görüntü boyutları düzenlenmiş ve 8 bit gri seviye olarak kaydedilmiştir.

**Çizelge 10.1.** Tez çalışmasının dördüncü uygulamasında kullanılan COVID-19 zatürre BT görüntülerine ilişkin bilgiler

Hasta	Cinsiyet	1. BT	2. BT	3. BT	4. BT	5. BT
Hasta-1	E	O (1. gün)	Ş (5. gün)	Ş (10. gün)	Ş (15. gün)	O (45. gün)
Hasta-2	E	O (1. gün)	O (5. gün)	Ş (10. gün)	X	X
Hasta-3	E	H (1. gün)	H (5. gün)	H (10. gün)	H (30. gün)	X
Hasta-4	E	Ş (1. gün)	Ş (7. gün)	X	X	X
Hasta-5	K	H (1. gün)	H (5. gün)	H (10. gün)	H (30. gün)	X
Hasta-6	K	H (1. gün)	H (5. gün)	X	X	X
Hasta-7	K	H (1. gün)	H (5. gün)	H (10. gün)	X	X
Hasta-8	K	H (1. gün)	H (5. gün)	H (20. gün)	X	X
Hasta-9	E	O (1. gün)	Ş (5. gün)	O (20. gün)	X	X
Hasta-10	E	H (1. gün)	O (7. gün)	O (15. gün)	X	X
Hasta-11	E	H (1. gün)	H (5. gün)	X	X	X
Hasta-12	K	O (1. gün)	O (5. gün)	X	X	X
Hasta-13	K	Ş (1. gün)	Ş (5. gün)	O (15. gün)	X	X
Hasta-14	K	O (1. gün)	Ş (5. gün)	Ş (15. gün)	X	X
Hasta-15	K	H (1. gün)	H (10. gün)	H (15. gün)	X	X
Hasta-16	E	H (1. gün)	Ş (5. gün)	O (10. gün)	H (30. gün)	X
Hasta-17	E	H (1. gün)	H (5. gün)	X	X	X
Hasta-18	K	H (1. gün)	O (5. gün)	O (10. gün)	X	X
Hasta-19	E	H (1. gün)	H (7. gün)	H (10. gün)	X	X
Hasta-20	E	H (1. gün)	H (5. gün)	X	X	X
Hasta-21	E	O (1. gün)	Ş (7. gün)	O (15. gün)	O (45. gün)	X
Hasta-22	E	O (1. gün)	O (10. gün)	O (15. gün)	X	X
Hasta-23	E	O (1. gün)	O (5. gün)	X	X	X
Hasta-24	K	H (1. gün)	O (5. gün)	X	X	X
Hasta-25	E	Ş (1. gün)	Ş (5. gün)	X	X	X
Hasta-26	K	H (1. gün)	H (10. gün)	H (15. gün)	X	X
Hasta-27	E	H (1. gün)	O (10. gün)	O (15. gün)	O (20. gün)	X
Hasta-28	K	H (1. gün)	H (5. gün)	H (15. gün)	H (22. gün)	X
Hasta-29	E	H (1. gün)	O (5. gün)	X	X	X
Hasta-30	E	H (1. gün)	H (10. gün)	X	X	X
Hasta-31	K	H (1. gün)	H (5. gün)	O (10. gün)	H (15. gün)	H (30. gün)
Hasta-32	E	O (1. gün)	O (5. gün)	H (10. gün)	X	X
Hasta-33	E	H (1. gün)	H (7. gün)	H (10. gün)	X	X
Hasta-34	E	O (1. gün)	O (5. gün)	O (10. gün)	O (15. gün)	X
Hasta-35	E	H (1. gün)	O (5. gün)	X	X	X
Hasta-36	K	H (1. gün)	H (5. gün)	H (10. gün)	X	X
Hasta-37	K	H (1. gün)	O (5. gün)	X	X	X
Hasta-38	K	H (1. gün)	O (10. gün)	X	X	X
Hasta-39	K	H (1. gün)	O (5. gün)	H (10. gün)	X	X
Hasta-40	K	H (1. gün)	H (5. gün)	H (10. gün)	X	X
Hasta-41	K	H (1. gün)	O (5. gün)	O (10. gün)	X	X
Hasta-42	E	O (5. gün)	X	X	X	X
Hasta-43	E	O (1. gün)	Ş (7. gün)	X	X	X
Hasta-44	E	H (1. gün)	H (5. gün)	X	X	X
Hasta-45	E	H (1. gün)	O (5. gün)	H (10. gün)	X	X
Hasta-46	K	Ş (1. gün)	O (10. gün)	X	X	X
Hasta-47	E	H (1. gün)	Ş (5. gün)	X	X	X
Hasta-48	K	H (1. gün)	H (8. gün)	H (30. gün)	X	X
Hasta-49	K	H (1. gün)	H (7. gün)	X	X	X
Hasta-50	K	H (1. gün)	H (5. gün)	X	X	X
Hasta-51	K	H (1. gün)	H (7. gün)	H (15. gün)	H (30. gün)	X
Hasta-52	K	H (7. gün)	X	X	X	X
Hasta-53	K	Ş (1. gün)	Ş (5. gün)	O (10. gün)	X	X
Hasta-54	K	H (1. gün)	H (5. gün)	O (15. gün)	X	X
Hasta-55	E	H (1. gün)	O (5. gün)	X	X	X
Hasta-56	E	H (1. gün)	O (5. gün)	O (10. gün)	H (30. gün)	X
Hasta-57	E	H (1. gün)	O (10. gün)	X	X	X
Hasta-58	K	H (1. gün)	O (5. gün)	H (15. gün)	X	X



**Şekil 10.1.** Tez çalışmasının dördüncü uygulamasında kullanılan a) hafif, b) orta, c) şiddetli COVID-19 zatürre BT görüntü örnekleri

Uygulamada 2B MobileNetV2, 2B ResNet-101, 2B Xception, 2B InceptionV3, 2B GoogleNet, 2B EfficientNetB0, 2B DenseNet-201 ve 2B DarkNet-53 olmak üzere toplam sekiz adet transfer öğrenme 2B ESA mimarisi kullanılmıştır. Uygulamada kullanılan bu transfer öğrenme 2B ESA mimarilerinin giriş görüntü boyutlarında bazı farklılıklar bulunmaktadır. Bu nedenle BT görüntü boyutları kullanılan transfer öğrenme 2B ESA mimarisine uygun olarak yeniden düzenlenmiştir. Çizelge 10.2, BT görüntülerinin transfer öğrenme 2B ESA mimarilerine göre ayarlandığı boyutları göstermektedir.

**Çizelge 10.2.** Tez çalışmasının dördüncü uygulamasında kullanılan farklı transfer öğrenme 2B ESA mimarilerine göre yeniden düzenlenen BT görüntü boyutları

Transfer Öğrenme 2B ESA Mimarisi	BT Görüntü Boyutları
MobileNetV2	224×224×1
ResNet-101	224×224×1
Xception	299×299×1
InceptionV3	299×299×1
GoogleNet	224×224×1
EfficientNetB0	224×224×1
DenseNet-201	224×224×1
DarkNet-53	256×256×1

## 10.2. Özellik Çıkarma, ESA Modifikasyonları ve Hiperparametreler


Tez çalışmasının dördüncü uygulamasında toplam sekiz adet transfer öğrenme 2B ESA mimarisi kullanılmıştır. Bu mimariler; 2B MobileNetV2, 2B Resnet-101, 2B GoogleNet, 2B Xception, 2B DarkNet-53, 2B DenseNet-201, 2B EfficientNetB0, 2B InceptionV3'dür. Söz konusu transfer öğrenme 2B ESA mimarilerinin uygulamada kullanılabilmesi için üzerlerinde bazı modifikasyonların yapılması gerekmektedir. Bu bağlamda giriş görüntüsünün satır ve sütun büyüklüğü özgün mimarideki değerler olarak korunmuştur. Ancak, uygulamada kullanılan görüntüler 8 bit gri seviye formatında olduğu için giriş verilerinin üçüncü boyutu uygulamanın gereksinimine göre 1 olarak yeniden düzenlenmiştir. Uygulamada giriş görüntü boyutları 2B MobileNetV2, 2B ResNet-101, 2B GoogleNet, 2B DenseNet-201 ve 2B EfficientNetB0 mimarileri için  $224 \times 224 \times 1$ ; 2B DarkNet-53 mimarisi için  $256 \times 256 \times 1$ ; 2B Xception ve 2B InceptionV3 mimarileri için  $299 \times 299 \times 1$ 'dir. Ayrıca, bu transfer öğrenme mimarilerin orijinal versiyonlarında tam bağlı katman çıkış boyutları 1000'dir. Uygulamada iki sınıflı ve üç sınıflı sınıflandırma yapılması sebebiyle tam bağlı katman çıkışı 2 ve 3 olacak şekilde yeniden düzenlenmiştir.

Eğitimler sırasında ilk ağırlık transferi yapılmamıştır. Yani tüm transfer öğrenme 2B ESA mimarileri baştan rastgele atanan ağırlıklarla eğitilmiştir. Uygulamada yararlanılan yazılım MATLAB 2020(b) kullanılarak oluşturulmuştur. Uygulamada ESA mimarilerin eğitiminde ağ çözücü olarak momentumlu stokastik gradyan inişi kullanılmıştır. Maksimum iterasyon sayısı program tarafından varsayılan değer kabul edilen 30 olarak seçilmiştir. Bu tercihin temel nedeni aşırı uyum probleminden kaçınmaktır. Yani, bu değeri yüksek seçmek yerine varsayılan değer kullanılarak erken durdurma yapılmıştır. Küme boyutu 16 olarak ayarlanmıştır. Aşırı uyumu önlemek için alınan bir diğer önlem ise her iterasyonda veri setinin karıştırılmasıdır. Bu kapsamda, veri karıştırma seçeneği her iterasyon olarak ayarlanmıştır. Benzer şekilde öğrenme oranı program tarafından varsayılan değer kabul edilen 0,01 olarak seçilmiştir. Momentum, gradyan bozunma faktörü, sıra doldurma gibi diğer tüm parametreler varsayılan değerler olarak ayarlanmıştır. MathWorks sayfasından (MathWorks, 2022(a)) parametrelerin açıklamalarının ve varsayılan değerlerin incelenmesi mümkündür.



### 10.3. Uygulamada Kullanılan VAH Yaklaşımları

Uygulamada kullanılan VAH yaklaşımının iki girişi vardır. Söz konusu yaklaşımda girişlerin sayısal ortalaması (%50-%50) alınarak birleştirme yapılmakta ve yeni sonuç elde edilmektedir. Örneğin; bir görüntü için hafif, orta ve şiddetli olma olasılıklarının birinci transfer öğrenme 2B ESA mimarisi kullanılarak 0,16; 0,60 ve 0,24; ikinci transfer öğrenme 2B ESA mimarisi kullanılarak 0,70; 0,14 ve 0,16 olarak elde edildiği varsayıldığında VAH yaklaşımı kullanılarak birleştirme sonucu sırasıyla 0,43; 0,37 ve 0,20 olacaktır. Üç sınıflı sınıflandırmaya benzer şekilde, VAH yaklaşımının iki sınıflı sınıflandırma sonuçlarının birleştirilmesi için kullanılması da mümkündür. Örneğin, bir görüntü için şiddetli değil ve şiddetli olma olasılıklarının birinci transfer öğrenme 2B ESA mimarisi kullanılarak 0,56 ve 0,44; ikinci transfer öğrenme 2B ESA mimarisi kullanılarak 0,74 ve 0,26 olarak elde edildiği varsayıldığında VAH yaklaşımı kullanılarak birleştirme sonucu sırasıyla 0,65 ve 0,35 olacaktır. VAH yaklaşımının çalışma yapısı Şekil 10.2’de yer almaktadır.



Şekil 10.2. Tez çalışmasının dördüncü uygulamasında kullanılan VAH yaklaşımı

#### 10.4. Deneyler

COVID-19 zatürre seviyesinin sınıflandırılmasına odaklanılan uygulamada BT görüntüleri üzerinden COVID-19 zatürresinin hafif, orta ve şiddetli olmak üzere üç sınıflı; şiddetli değil ve şiddetli olmak üzere iki sınıflı otomatik sınıflandırılması gerçekleştirilmiştir. Uygulamada 267 tanesi hafif, 156 tanesi orta ve 60 tanesi şiddetli olmak üzere toplam 483 COVID-19 BT görüntü dilimi kullanılmıştır. Bu görüntüler ve etiketlerden doğrudan üç sınıflı sınıflandırmada yararlanılmıştır. İki sınıflı sınıflandırmada hafif ve orta dereceli görüntüler şiddetli değil olarak kabul edilmiştir.

Uygulamada ilk olarak BT görüntüleri düzenlenerek standardize edilmiştir. BT görüntüleri, akciğer bölgesini tamamen içine alınacak şekilde çerçevelenmiştir. Bu sayede BT görüntülerinde yer alan ilgisiz alanlar görüntülerden çıkarılmıştır. Daha sonra görüntüler, 8 bitlik derinlik ile gri seviye formatına dönüştürülmüştür. Son olarak, görüntüler Çizelge 10.2’de ayrıntıları verildiği şekilde yeniden boyutlandırılmıştır.

Uygulamada transfer öğrenme 2B ESA mimarileri kullanılarak sınıflandırma işlemleri yapılmıştır. Transfer öğrenme 2B ESA sınıflandırıcı olarak daha önce detayları ve üzerinde yapılan değişiklikler açıklanan 2B MobileNetV2, 2B ResNet-101, 2B GoogleNet, 2B Xception, 2B DarkNet-53, 2B DenseNet-201, 2B EfficientNetB0, 2B InceptionV3 mimarileri kullanılmıştır. Uygulamada eğitim ve test işlemleri on kat çapraz doğrulama prosedürüne göre gerçekleştirilmiştir. Eğitimler sırasında ilk ağırlık transferi yapılmamıştır. Tüm transfer öğrenme 2B ESA mimarileri baştan rastgele atanan ağırlıklarla eğitilmiştir. Uygulamanın tüm deneylerinde daha önce detaylandırılan eğitim seçenekleri kullanılmıştır. Bu aşamada, aynı BT çekim setinden alınan üç görüntü diliminin eğitim veya test setine birlikte dahil edilmesine özellikle dikkat edilmiştir. Başka bir deyişle, aynı BT çekim setinden alınmış görüntü dilimleri aynı anda hem eğitim hem test setinde yer almamaktadır.

Uygulama kapsamında bir görüntünün sınıflandırılması için ihtiyaç duyulan çalışma süreleri (CPU süresi) saniye cinsinden ölçülmüştür. Uygulamada, MATLAB 2020(b) yazılımı ve 16 GB RAM’e sahip Intel (R) Xeon (R) E-2274G 4.00 GHz bilgisayar kullanılmıştır. Uygulamada verilen tüm CPU çalışma süreleri saniye cinsinden zamanı göstermektedir.

## 10.5. Deney Sonuçları

Uygulamada üç sınıflı (hafif, orta ve şiddetli) ve iki sınıflı (şiddetli değil ve şiddetli) olmak üzere iki başlıkta otomatik COVID-19 zatürre seviyesi sınıflandırması yapılmıştır. Uygulamada üç sınıflı sınıflandırma için 2B MobileNetV2, 2B ResNet-101, 2B GoogleNet, 2B Xception, 2B DarkNet-53, 2B DenseNet-201, 2B EfficientNetB0, 2B InceptionV3 ESA mimarileri kullanılarak elde edilen sonuçlar Çizelge 10.3’de yer almaktadır.

**Çizelge 10.3.** COVID-19 zatürre seviyesinin BT görüntüler üzerinden üç sınıflı (hafif, orta ve şiddetli) sınıflandırılması için elde edilen deney sonuçları

Transfer Öğrenme 2B ESA Mimarisi	Sınıf	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AIKE-AKA	Genel Doğruluk
MobileNetV2	Hafif	224	43	156	60	0,8390	0,7222	0,7867	0,8131	0,8706	0,7039
	Orta	75	81	265	62	0,4808	0,8104	0,7039	0,5119	0,7478	
	Şiddetli	41	19	402	21	0,6833	0,9504	0,9172	0,6721	0,9472	
	Genel (ağırlıklı)					0,7039	0,7790	0,7762	0,6983	0,8405	
ResNet-101	Hafif	213	54	168	48	0,7978	0,7778	0,7888	0,8068	0,8681	0,7329
	Orta	98	58	256	71	0,6282	0,7829	0,7329	0,6031	0,7779	
	Şiddetli	43	17	413	10	0,7167	0,9764	0,9441	0,7611	0,9714	
	Genel (ağırlıklı)					0,7329	0,8041	0,7901	0,7353	0,8518	
Xception	Hafif	235	32	150	66	0,8801	0,6944	0,7971	0,8275	0,8981	0,7267
	Orta	70	86	283	44	0,4487	0,8654	0,7308	0,5185	0,7871	
	Şiddetli	46	14	401	22	0,7667	0,9480	0,9255	0,7188	0,9508	
	Genel (ağırlıklı)					0,7267	0,7812	0,7916	0,7142	0,8688	
InceptionV3	Hafif	234	33	169	47	0,8764	0,7824	0,8344	0,8540	0,9301	0,7785
	Orta	97	59	279	48	0,6218	0,8532	0,7785	0,6445	0,8573	
	Şiddetli	45	15	411	12	0,7500	0,9716	0,9441	0,7692	0,9673	
	Genel (ağırlıklı)					0,7785	0,8288	0,8299	0,7758	0,9112	
GoogleNet	Hafif	225	42	128	88	0,8427	0,5926	0,7308	0,7759	0,8044	0,6315
	Orta	46	110	261	66	0,2949	0,7982	0,6356	0,3433	0,6278	
	Şiddetli	34	26	399	24	0,5667	0,9433	0,8965	0,5763	0,9072	
	Genel (ağırlıklı)					0,6315	0,7026	0,7207	0,6114	0,7602	
EfficientNetB0	Hafif	223	44	157	59	0,8352	0,7269	0,7867	0,8124	0,8559	0,6977
	Orta	72	84	269	58	0,4615	0,8226	0,7060	0,5035	0,7357	
	Şiddetli	42	18	394	29	0,7000	0,9314	0,9027	0,6412	0,9475	
	Genel (ağırlıklı)					0,6977	0,7832	0,7751	0,6914	0,8285	
DenseNet-201	Hafif	228	39	157	59	0,8539	0,7269	0,7971	0,8231	0,8967	0,7308
	Orta	88	68	265	62	0,5641	0,8104	0,7308	0,5752	0,8014	
	Şiddetli	37	23	414	9	0,6167	0,9787	0,9337	0,6981	0,9571	
	Genel (ağırlıklı)					0,7308	0,7851	0,7927	0,7275	0,8734	
DarkNet-53	Hafif	218	49	176	40	0,8165	0,8148	0,8157	0,8305	0,8909	0,7702
	Orta	108	48	267	60	0,6923	0,8165	0,7764	0,6667	0,8151	
	Şiddetli	46	14	412	11	0,7667	0,9740	0,9482	0,7863	0,9571	
	Genel (ağırlıklı)					0,7702	0,8351	0,8195	0,7721	0,8746	

Benzer şekilde iki sınıflı sınıflandırma için elde edilen sonuçlar Çizelge 10.4’de görülmektedir. Çizelge 10.5’de ise iki sınıflı ve üç sınıflı sınıflandırma için eğitim ve testler dahil olmak üzere görüntü başına çalışma süreleri yer almaktadır. Bu sürelerin diğer çalışmalarda elde edilen sürelerle karşılaştırılmasında yazılım platformu (MATLAB 2020 (b)), eğitim ve test prosedürleri (on kat çapraz doğrulama) ile eğitim seçeneklerinin göz önünde bulundurulması gerekmektedir.

**Çizelge 10.4.** COVID-19 zatürre seviyesinin BT görüntüler üzerinden iki sınıflı (şiddetli değil ve şiddetli) sınıflandırılması için elde edilen deney sonuçları

Transfer Öğrenme 2B ESA Mimarisi	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AİKE-AKA
MobileNetV2	409	14	49	11	0,9669	0,8167	0,9482	0,9703	0,9744
ResNet-101	402	21	50	10	0,9504	0,8333	0,9358	0,9629	0,9781
Xception	411	12	45	15	0,9716	0,7500	0,9441	0,9682	0,9715
InceptionV3	406	17	51	9	0,9598	0,8500	0,9462	0,9690	0,9788
GoogleNet	392	31	29	31	0,9267	0,4833	0,8716	0,9267	0,8661
EfficientNetB0	412	11	38	22	0,9740	0,6333	0,9317	0,9615	0,9620
DenseNet-201	410	13	45	15	0,9693	0,7500	0,9420	0,9670	0,9734
DarkNet-53	404	19	49	11	0,9551	0,8167	0,9379	0,9642	0,9634

**Çizelge 10.5.** COVID-19 zatürre seviyesinin BT görüntüler üzerinden iki sınıflı ve üç sınıflı sınıflandırılma için çalışma süresinin karşılaştırılması

Transfer Öğrenme 2B ESA Mimarisi	İki Sınıflı Sınıflandırma	Üç Sınıflı Sınıflandırma
MobileNetV2	5,2469	5,2425
ResNet-101	13,9730	14,0405
Xception	8,9762	9,0075
InceptionV3	14,0511	13,4820
GoogleNet	3,3325	2,8096
EfficientNetB0	17,5531	15,9924
DenseNet-201	35,4577	34,7756
DarkNet-53	11,6518	11,6380

Hafif, orta ve şiddetli olmak üzere üç sınıflı sınıflandırma sonuçlarını içeren Çizelge 10.3 incelendiğinde, en başarılı ilk dört transfer öğrenme 2B ESA mimarisinin sırasıyla 2B InceptionV3, 2B DarkNet-53, 2B ResNet-101 ve 2B DenseNet-201 olduğu görülmektedir. Uygulamada üç sınıflı sınıflandırma için en başarılı transfer öğrenme 2B ESA mimarilerinin sonuçlarının VAH yaklaşımı kullanılarak birleştirilmesiyle elde edilen yeni sonuçlar Çizelge 10.6’de yer almaktadır. Şiddetli değil ve şiddetli olmak üzere iki sınıflı sınıflandırma sonuçlarını içeren Çizelge 10.4 incelendiğinde, en başarılı ilk dört transfer öğrenme 2B ESA mimarisinin sırasıyla 2B MobileNetV2, 2B

InceptionV3, 2B Xception ve 2B DenseNet-201 olduğu görülmektedir. Uygulamada iki sınıflı sınıflandırma için en başarılı transfer öğrenme 2B ESA mimari sonuçlarının VAH yaklaşımı kullanılarak birleştirilmesiyle elde edilen sınıflandırma sonuçları Çizelge 10.7’de görülmektedir.

**Çizelge 10.6.** COVID-19 zatürre seviyesinin BT görüntüler üzerinden üç sınıflı (hafif, orta ve şiddetli) sınıflandırılması için VAH yaklaşımı kullanıldıktan sonra elde edilen deney sonuçları

VAH Yaklaşımı Girişleri	Sınıf	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AIKE-AKA	Genel Doğruluk
InceptionV3 DarkNet-53	Hafif	240	27	177	39	0,8989	0,8194	0,8634	0,8791	0,9212	0,8095
	Orta	106	50	285	42	0,6795	0,8716	0,8095	0,6974	0,8574	
	Şiddetli	45	15	412	11	0,7500	0,9740	0,9462	0,7759	0,9782	
	Genel (ağırlıklı)					0,8095	0,8555	0,8563	0,8076	0,9077	
InceptionV3 ResNet-101	Hafif	240	27	170	46	0,8989	0,7870	0,8489	0,8680	0,9253	0,7971
	Orta	101	55	284	43	0,6474	0,8685	0,7971	0,6733	0,8538	
	Şiddetli	44	16	414	9	0,7333	0,9787	0,9482	0,7788	0,9786	
	Genel (ağırlıklı)					0,7971	0,8372	0,8445	0,7940	0,9089	
InceptionV3 DenseNet-201	Hafif	234	33	167	49	0,8764	0,7731	0,8302	0,8509	0,9252	0,7764
	Orta	97	59	278	49	0,6218	0,8502	0,7764	0,6424	0,8472	
	Şiddetli	44	16	413	10	0,7333	0,9764	0,9462	0,7719	0,9712	
	Genel (ağırlıklı)					0,7764	0,8233	0,8272	0,7737	0,9057	
Darknet-53 ResNet-101	Hafif	223	44	167	49	0,8352	0,7731	0,8075	0,8275	0,9105	0,7598
	Orta	100	56	267	60	0,6410	0,8165	0,7598	0,6329	0,8414	
	Şiddetli	44	16	416	7	0,7333	0,9835	0,9524	0,7928	0,9802	
	Genel (ağırlıklı)					0,7598	0,8133	0,8101	0,7603	0,8968	
DarkNet-53 DenseNet-201	Hafif	231	36	164	52	0,8652	0,7593	0,8178	0,8400	0,9067	0,7660
	Orta	97	59	273	54	0,6218	0,8349	0,7660	0,6319	0,8302	
	Şiddetli	42	18	416	7	0,7000	0,9835	0,9482	0,7706	0,9785	
	Genel (ağırlıklı)					0,7660	0,8115	0,8173	0,7642	0,8909	
ResNet-101 DenseNet-201	Hafif	232	35	162	54	0,8689	0,7500	0,8157	0,8391	0,9000	0,7619
	Orta	94	62	274	53	0,6026	0,8379	0,7619	0,6205	0,8086	
	Şiddetli	42	18	415	8	0,7000	0,9811	0,9462	0,7636	0,9800	
	Genel (ağırlıklı)					0,7619	0,8071	0,8146	0,7591	0,8804	

**Çizelge 10.7.** COVID-19 zatürre seviyesinin BT görüntüler üzerinden iki sınıflı (şiddetli değil ve şiddetli) sınıflandırılması için VAH yaklaşımı kullanıldıktan sonra elde edilen deney sonuçları

VAH Yaklaşımı Girişleri	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AIKE-AKA
MobileNetV2/InceptionV3	415	8	50	10	0,9811	0,8333	0,9627	0,9788	0,9851
MobileNetV2/Xception	412	11	47	13	0,9740	0,7833	0,9503	0,9717	0,9790
MobileNetV2/DenseNet-201	412	11	47	13	0,9740	0,7833	0,9503	0,9717	0,9797
InceptionV3/Xception	411	12	49	11	0,9716	0,8167	0,9524	0,9728	0,9776
InceptionV3/DenseNet-201	412	11	49	11	0,9740	0,8167	0,9545	0,9740	0,9816
Xception/DenseNet-201	411	12	45	15	0,9716	0,7500	0,9441	0,9682	0,9765

## 10.6. BT Görüntüler Üzerinden COVID-19 Zatürre Seviye Sınıflandırma Sonuçlarının Değerlendirilmesi

Uygulamada BT görüntüler üzerinden COVID-19 zatürre seviyesinin üç sınıflı ve iki sınıflı sınıflandırılması için elde edilen deneysel sonuçlar sırasıyla Çizelge 10.3 ve Çizelge 10.4'de yer almaktadır. Benzer şekilde VAH yaklaşımı kullanıldıktan sonra elde edilen deneysel sonuçlar sırasıyla Çizelge 10.6 ve Çizelge 10.7'de verilmiştir. Bu bölümde elde edilen deneysel sonuçların değerlendirilmesi gerçekleştirilmiştir.

Hafif, orta ve şiddetli olmak üzere üç sınıflı sınıflandırma sonuçlarını içeren Çizelge 10.3 incelendiğinde, en başarılı ilk dört transfer öğrenme 2B ESA mimarisinin sırasıyla 2B InceptionV3, 2B DarkNet-53, 2B ResNet-101 ve 2B DenseNet-201 olduğu görülmektedir. Deneyler sonucunda en yüksek ağırlıklı duyarlılık, doğruluk, F-1 skoru, AİKE-AKA ve genel doğruluk parametreleri 2B InceptionV3 ESA mimarisi kullanılarak elde edilmiş olup sırasıyla 0,7785; 0,8299; 0,7758; 0,9112 ve 0,7785'dir. En yüksek ağırlıklı özgüllük parametresi ise 0,8351 olarak 2B DarkNet-53 ESA mimarisi kullanılarak elde edilmiştir. Eğitim ve test süreçleri dahil olmak üzere görüntü başına çalışma süreleri en başarılı ilk dört transfer öğrenme 2B ESA mimarisi için karşılaştırıldığında, en hızlıdan en yavaşa doğru sırasıyla 2B DarkNet-53, 2B ResNet-101, 2B InceptionV3 ve 2B DenseNet-201 şeklindedir.

Şiddetli değil ve şiddetli olmak üzere iki sınıflı sınıflandırma sonuçlarını içeren Çizelge 10.4 incelendiğinde en başarılı ilk dört transfer öğrenme 2B ESA mimarisinin sırasıyla 2B MobileNetV2, 2B InceptionV3, 2B Xception ve 2B DenseNet-201 olduğu görülmektedir. 2B EfficientNetB0 mimarisi kullanılarak elde edilen en yüksek duyarlılık parametresi 0,9740 olarak gerçekleşmiştir. En yüksek özgüllük ve AİKE-AKA parametreleri sırasıyla 0,8500 ve 0,9788 olarak 2B InceptionV3 mimarisi kullanılarak elde edilmiştir. En yüksek doğruluk ve F-1 skoru parametreleri sırasıyla 0,9482 ve 0,9703 olarak 2B MobileNetV2 mimarisi kullanılarak sağlanmıştır. Eğitim ve test süreçleri dahil görüntü başına çalışma süreleri en başarılı ilk dört transfer öğrenme 2B ESA mimarisi için karşılaştırıldığında, en hızlıdan en yavaşa doğru sırasıyla 2B MobileNetv2, 2B Xception, 2B InceptionV3 ve 2B DenseNet-201 şeklindedir.

Uygulamada, üç sınıflı sınıflandırma için VAH yaklaşımı kullanılarak en başarılı transfer öğrenme 2B ESA mimari sonuçlarının birleştirilmesiyle elde edilen yeni sınıflandırma sonuçları Çizelge 10.6'da verilmiştir. Çizelge 10.6 incelendiğinde, en

başarılı ilk iki VAH giriş kombinasyonunun sırasıyla 2B InceptionV3 ve 2B DarkNet-53 ile 2B InceptionV3 ve 2B ResNet-101 olduğu anlaşılmaktadır. En yüksek ağırlıklı duyarlılık, özgüllük, doğruluk, F-1 skoru ve genel doğruluk parametreleri 2B InceptionV3 ve 2B DarkNet-53 giriş kombinasyonu kullanılarak elde edilmiş olup sırasıyla 0,8095; 0,8555; 0,8563; 0,8076 ve 0,8096'dir. En yüksek ağırlıklı AİKE-AKA parametresi ise 0,9089 olarak 2B InceptionV3 ve 2B ResNet-101 giriş kombinasyonu kullanılarak elde edilmiştir.

Uygulamada iki sınıflı sınıflandırma için VAH yaklaşımı kullanılarak en başarılı transfer öğrenme 2B ESA mimarilerinin sonuçlarının birleştirilmesiyle elde edilen yeni sınıflandırma sonuçları Çizelge 10.7'de verilmiştir. Çizelge 10.7 incelendiğinde, en başarılı giriş kombinasyonunun 2B MobileNetV2 ve 2B InceptionV3 olduğu görülmektedir. En yüksek duyarlılık, özgüllük, doğruluk, F-1 skoru ve AİKE-AKA parametreleri 2B MobileNetV2 ve 2B InceptionV3 giriş kombinasyonu kullanılarak elde edilmiş olup sırasıyla 0,9811; 0,8333; 0,9627; 0,9788 ve 0,9851'dir.

Uygulamada COVID-19 zatürre seviyesinin üç sınıflı sınıflandırılmasıyla elde edilen sonuçların literatürde yer alan çalışmalarda elde edilen sonuçlarla karşılaştırılması Çizelge 10.8'de yer almaktadır. Uygulamada elde edilen sayısal sonuçlarının daha önce yapılmış çalışmaların sayısal sonuçlarıyla doğrudan karşılaştırılması doğru bir yaklaşım değildir. Çünkü, kullanılan toplam görüntü sayısı, test ve eğitim yaklaşımı, test ve eğitim görüntü sayısındaki farklılıklar sonuçlar üzerinde doğrudan etkili faktörlerdir. Ancak bir karşılaştırma yapmak gerekirse, uygulamada elde edilen sonuçların aynı sınıf etiketlerini kullanan Carvalho ve arkadaşları (2020) tarafından gerçekleştirilen çalışmada elde edilen sonuçlardan daha yüksek olduğu görülmektedir. Uygulamada COVID-19 zatürre şiddetinin iki sınıflı sınıflandırmasıyla elde edilen sonuçların literatürde yer alan çalışmalarda elde edilen sonuçlarla karşılaştırılması Çizelge 10.9'da verilmiştir. Uygulamada elde edilen sonuçların aynı sınıf etiketlerini kullanan Li ve arkadaşları (2020(b)), Xiao ve arkadaşları (2020) ve Li ve arkadaşları (2020(c)) tarafından gerçekleştirilen çalışmalarda elde edilen sonuçlardan daha yüksek olduğu görülmektedir. Bununla birlikte, uygulama sonuçlarının Yu ve arkadaşları (2020) tarafından elde edilen sonuçlardan daha düşük olduğu anlaşılmaktadır. Yu ve arkadaşları (2020) tarafından en yüksek sonuçlar 2B DenseNet-201 mimarisi kullanılarak elde edilmiştir. Söz konusu 2B DenseNet-201 ESA mimarisi bu uygulamada da kullanılmış olup diğer bazı transfer öğrenme 2B ESA mimarileri ile daha yüksek sonuçlar elde edilmiştir.

**Çizelge 10.8.** Tez çalışmasının dördüncü uygulamasında COVID-19 zatürre seviyesinin üç sınıflı (hafif, orta ve şiddetli) sınıflandırması ile elde edilen sonuçların literatürde yer alan çalışmalarda elde edilen sonuçlar ile karşılaştırması

Çalışma	Sınıflar	Görüntü Sayısı	Test Yöntemi	Sonuçlar
Carvalho ve ark., 2020	3 Sınıf (Hafif, Orta ve Şiddetli)	1,000 İlgili Alanı Görüntüsü	Eğitim: 700, Doğrulama: 150 ve Test: 150	0,80 (Duyarlılık), 0,86 (Özgüllük), 0,82 (Doğruluk), 0,85 (F-1 Skoru), 0,90 (AİKE-AKA)
Huang ve ark., 2021	3 Sınıf (Normal, Hafif ve Şiddetli)	416 Görüntü (207 Normal, 194 Hafif ve 15 Şiddetli)	Eğitim: 300 Görüntü ve Test: 116 Görüntü	0,9483 (Doğruluk)
VAH'dan Önce	3 Sınıf (Hafif, Orta ve Şiddetli)	483 Görüntü (267 Hafif, 156 Orta ve 60 Şiddetli)	On Kat Çapraz Doğrulama	0,7785 (Duyarlılık), 0,8351 (Özgüllük), 0,8299 (Doğruluk), 0,7758 (F-1 Skoru), 0,9112 (AİKE-AKA), 0,7785 (Genel Doğruluk)
VAH'dan Sonra	3 Sınıf (Hafif, Orta ve Şiddetli)	483 Görüntü (267 Hafif, 156 Orta ve 60 Şiddetli)	On Kat Çapraz Doğrulama	0,8095 (Duyarlılık), 0,8555 (Özgüllük), 0,8563 (Doğruluk), 0,8076 (F-1 Skoru), 0,9089 (AİKE-AKA), 0,8095 (Genel Doğruluk)

**Çizelge 10.9.** Tez çalışmasının dördüncü uygulamasında COVID-19 zatürre seviyesinin iki sınıflı (şiddetli değil ve şiddetli) sınıflandırması ile elde edilen sonuçların literatürde yer alan çalışmalarda elde edilen sonuçlar ile karşılaştırması

Çalışma	Sınıflar	Görüntü Sayısı	Test Yöntemi	Sonuçlar
Li ve ark., 2020 (b)	2 Sınıf (Şiddetli ve Kritik)	217 Görüntü (82 Şiddetli ve 135 Kritik)	80% Eğitim-20% Test (Eğitim: 174 Görüntü, Test: 43 Görüntü)	0,750-0,875 (Duyarlılık), 0,741-0,778 (Özgüllük), 0,744-0,814 (Doğruluk), 0,787-0,861 (AİKE-AKA)
Xiao ve ark., 2020	2 Sınıf (Şiddetli Değil ve Şiddetli)	408 Görüntü	Eğitim: 303 Görüntü ve Test: 105 Görüntü	0,819 (Doğruluk), 0,892 (AİKE-AKA)
Li ve ark., 2020 (c)	2 Sınıf (Şiddetli Değil ve Şiddetli)	531 Görüntü (436 Şiddetli Değil ve 95 Şiddetli)	Belirtilmedi	0,9241 (Duyarlılık), 0,9049 (Özgüllük), 0,97 (AİKE-AKA)
Yu ve ark., 2020	2 Sınıf (Şiddetli Değil ve Şiddetli)	729 Görüntü (483 Şiddetli Değil ve 246 Şiddetli)	Bekletme Doğrulaması, On Kat Çapraz Doğrulama ve Birini Dışarıda Bırakma Doğrulaması	0,9187 (Duyarlılık), 0,9687 (Özgüllük), 0,9520 (Doğruluk), 0,99 (AİKE-AKA)
Meng ve ark., 2020	2 Sınıf (Şiddetli ve Kritik)	366 Görüntü (256 Şiddetli ve 110 Kritik)	Eğitim: 246 Görüntü ve Test: 120 Görüntü	0,917-1,000 (Duyarlılık), 0,802-0,864 (Özgüllük), 0,842-0,875 (Doğruluk), 0,943 (AİKE-AKA)
Ho ve ark., 2021	2 Sınıf (Düşük Risk ve Yüksek Risk)	297 Görüntü	Beş Kat Çapraz Doğrulama	0,694-0,783 (Duyarlılık), 0,927-0,965 (Özgüllük), 0,916-0,933 (Doğruluk), 0,814-0,900 (AİKE-AKA)
Zhu ve ark., 2021(b)	2 Sınıf (Şiddetli Değil ve Şiddetli)	408 Görüntü (322 Şiddetli Değil ve 86 Şiddetli)	Beş Kat Çapraz Doğrulama	0,7697 (Duyarlılık), 0,8802 (Özgüllük), 0,8569 (Doğruluk), 0,8591 (AİKE-AKA)
VAH'dan Önce	2 Sınıf (Şiddetli Değil ve Şiddetli)	483 Görüntü (423 Şiddetli Değil ve 60 Şiddetli)	On Kat Çapraz Doğrulama	0,9740 (Duyarlılık), 0,8500 (Özgüllük), 0,9482 (Doğruluk), 0,9703 (F-1 Skoru), 0,9788 (AİKE-AKA)
VAH'dan Sonra	2 Sınıf (Şiddetli Değil ve Şiddetli)	483 Görüntü (423 Şiddetli Değil ve 60 Şiddetli)	On Kat Çapraz Doğrulama	0,9811 (Duyarlılık), 0,8333 (Özgüllük), 0,9627 (Doğruluk), 0,9788 (F-1 Skoru), 0,9851 (AİKE-AKA)



Bu nedenle uygulama sonuçlarının Yu ve arkadaşları (2020) tarafından elde edilen sonuçlardan sayısal olarak daha düşük olsa bile daha başarılı olduğu açıkça söylenebilir. Söz konusu sayısal farklılıkların kullanılan görüntü sayısı, eğitim ve test prosedürleri, eğitim seçenekleri gibi hususlardan kaynaklandığı değerlendirilmektedir.

Uygulamada elde edilen bir diğer sonuç VAH yaklaşımı kullanılarak sonuçlarının önemli ölçüde iyileştirilebileceğidir. Örneğin, VAH yaklaşımı kullanmadan önce ve kullandıktan sonra COVID-19 zatürre seviyesinin üç sınıflı sınıflandırması için elde edilen sonuçlar incelendiğinde, VAH yaklaşımı sayesinde ağırlıklı sonuçların %3 oranında iyileştirildiği görülmektedir. Benzer şekilde COVID-19 zatürre seviyesinin iki sınıflı sınıflandırması için elde edilen sonuçlar incelendiğinde %1 düzeyinde iyileşme sağlandığı anlaşılmaktadır.



## 11. X-RAY GÖRÜNTÜLER ÜZERİNDEN COVID-19 VE COVID-19 DEĞİL SINIFLANDIRMASI

Tez çalışmasının beşinci uygulamasında X-ray görüntüler üzerinden COVID-19 ve COVID-19 değil sınıflandırılması gerçekleştirilmiştir. Söz konusu uygulama sonuçları Yaşar ve Ceylan tarafından (Yaşar ve Ceylan, 2021(b)) yayınlanmıştır.

### 11.1. Uygulamada Kullanılan Veriler

Uygulamada kullanılan COVID-19 X-ray görüntüleri Cohen ve arkadaşları (Cohen ve ark., 2020) tarafından oluşturulduktan sonra GitHub üzerinden ve Dadario (Dadario, 2020) tarafından oluşturulduktan sonra Kaggle üzerinden açık erişime açılan meta data veri setlerinin birleştirilmesiyle elde edilmiştir. Bu veri setlerinin ortak olarak içerdiği görüntüler ve bu görüntülere ilişkin klinik notlar dikkate alınarak 150 adet X-ray görüntüsünden oluşan karma bir COVID-19 görüntü veri seti oluşturulmuştur. Uygulamada hastaların yüzü doğrudan röntgen cihazına bakarken elde edilen görüntüler kullanılmıştır. Veri seti içinde yer alan ve aynı hastadan alınan görüntüler hastalığın seyrinin farklı günlerinde elde edilmiştir. Bu nedenle bire bir aynı içeriğe sahip değildirler. Söz konusu görüntülerin boyutları 255×249 ile 4280×3520 arasında oldukça farklılık göstermektedir. Ayrıca bu görüntüler png, jpg, jpeg gibi farklı veri biçimlerine; 8 bit (gri seviye) ve 24 bit (RGB) gibi iki farklı bit derinliğine sahiptir. Görüntülerin standardizasyonu, uygulamada kullanılabilmesi için önemli bir süreçtir. Öncelikle görüntülerin tamamı 8 bit gri seviyeye dönüştürülmüştür. Daha sonra görüntülerdeki ilgi alanını belirlemek için göğüs bölgesini kaplayacak şekilde çerçeveleme yapılmıştır. Bu işlemden sonra tüm görüntülerin boyutları 448×448 olarak yeniden düzenlenmiş ve png formatında kaydedilmiştir.

Uygulamada COVID-19 değil X-ray görüntüleri için Montgomery ve Shenzhen (Jaeger ve ark., 2014) olmak üzere iki farklı veri seti ayrı ayrı kullanılmıştır. Bu veri setleri sırasıyla 80 adet ve 326 adet COVID-19 değil X-ray görüntüsü içermektedir. Uygulamada kullanılan ilk eğitim ve test veri seti 150 tanesi COVID-19 ve 80 tanesi COVID-19 değil olmak üzere toplam 230 adet X-ray görüntüsü içerirken, ikinci eğitim ve test veri seti 150 tanesi COVID-19 ve 326 tanesi COVID-19 değil olmak üzere toplam 476 X-ray görüntüsü içermektedir. Böylece ağırlıklı olarak COVID-19 görüntüleri ve ağırlıklı olarak COVID-19 değil görüntüleri içeren iki veri seti için

sınıflandırma sonuçları elde edilmiştir. COVID-19 görüntülerine uygulanan işlemler, aynı şekilde COVID-19 değil görüntülerine de uygulanmıştır. Uygulamada kullanılan görüntü sayılarına ilişkin sayısal bilgiler Çizelge 11.1’de yer almaktadır.

**Çizelge 11.1.** Tez çalışmasının beşinci uygulamasında kullanılan COVID-19 ve COVID-19 değil X-ray görüntülerine ilişkin bilgiler

Veri Seti	COVID-19	COVID-19 Değil	Toplam
1. Veri Seti	150 (Cohen ve ark., 2020; Dadario, 2020)	80 (Jaeger ve ark., 2014)	230
2. Veri Seti	150 (Cohen ve ark., 2020; Dadario, 2020)	326 (Jaeger ve ark., 2014)	476

## 11.2. Özellik Çıkarma, ESA Modifikasyonları ve Hiperparametreler

Tez çalışmasının beşinci uygulamasında yararlanılan YİD yönteminin işletilmesinde kullanılan yarıçap değeri 2 olarak seçilmiştir. YİD işlemi sonunda görüntü boyutlarında azalma olması sebebiyle, MATLAB *imresize* fonksiyonu kullanılarak görüntü boyutları yeniden düzenlenmiştir.

Uygulamada kullanılan KDDD işleminin ölçek değeri 1 olarak seçilmiştir. KDDD işleminin görüntüye her uygulanması sonucu elde edilen görüntü alt matrislerinin boyutları giriş görüntü boyutlarının yarısı kadardır.

Eğitimler sırasında ilk ağırlık transferi yapılmamıştır. Yani tüm ESA mimarileri baştan rastgele atanan ağırlıklarla eğitilmiştir. Uygulamada yararlanılan yazılım MATLAB 2019(a) kullanılarak oluşturulmuştur. ESA eğitiminde ağ çözücü olarak momentumlu stokastik gradyan inişi seçilmiştir. Maksimum iterasyon sayısı program tarafından varsayılan değer kabul edilen 30 olarak seçilmiştir. Bu tercihin temel nedeni aşırı uyum probleminden kaçınmaktır. Yani bu değeri yüksek seçmek yerine varsayılan değer kullanılarak erken durdurma yapılmıştır. Küme boyutu program tarafından varsayılan değer kabul edilen 128 olarak ayarlanmıştır. Öğrenme oranı ise 0,001 olarak belirlenmiştir. Momentum, gradyan bozunma faktörü, sıra doldurma gibi diğer tüm parametreler varsayılan değerler olarak ayarlanmıştır. MathWorks sayfasından (MathWorks, 2022(a)) parametrelerin açıklamalarının ve varsayılan değerlerin incelenmesi mümkündür.

### 11.3. Uygulamada Kullanılan VAH Yaklaşımları

Uygulamada dört adet VAH yaklaşımı tasarlanmış ve kullanılmıştır. Bu yaklaşımlar, yeni sonuçlar elde etmek için önceki deneylerin sonuçlarını birleştirilmesine dayanmaktadır. Birinci VAH yaklaşımında, bir görüntü için YİD kullanılarak ve YİD kullanılmadan gerçekleştirilen deneylerde elde edilen etiketlemeler 0,5 eşik değeri için aynıysa VAH sonucu da aynı etiketi taşımaktadır. Örneğin, bir görüntü için YİD kullanılarak ve YİD kullanılmadan aynı anda sırasıyla COVID-19 veya COVID-19 değil etiketlemesi yapıldıysa VAH yaklaşımı sonucu sırasıyla COVID-19 veya COVID-19 değil olarak gerçekleşmektedir. Bu durumda VAH etiketleme sonucu COVID-19 ise deney sonucu 0 değerine en yakın olan, VAH etiketleme sonucu COVID-19 değil ise deney sonucu 1 değerine en yakın olan sonuç VAH deney sonucu olarak atanmaktadır. Bunun sebebi eğitim işlemlerinde COVID-19 görüntüler için hedef olarak 0 değerinin, COVID-19 değil görüntüler için ise hedef olarak 1 değerinin atanmasıdır. Bir görüntü için YİD kullanılarak ve YİD kullanılmadan 0,5 eşik değeri için elde edilen etiketlemelerin farklı olması durumunda iki sayısal sonuç belirli oranlarda (%50-%50 ve %75-%25) birleştirilerek yeni sonuç elde edilmektedir. Daha sonra yeni sonuç 0,5 eşik değerine göre COVID-19 veya COVID-19 değil olarak etiketlendirilmektedir. Uygulamada kullanılan ilk iki VAH yaklaşımının temel kodlaması Çizelge 11.2’de yer almaktadır.

**Çizelge 11.2.** Tez çalışmasının beşinci uygulamasında kullanılan VAH-1 ve VAH-2 yaklaşımlarının temel kodlaması

---

<i>Eğer Etiket-1==COVID-19 &amp;&amp; Etiket-2==COVID-19</i>
<i>Yeni-Etiket=COVID-19</i>
<i>Yeni-Sonuç=min(Sonuç-1,Sonuç-2)</i>
<b>Bitiş</b>
<i>Eğer Etiket-1==COVID-19 değil &amp;&amp; Etiket-2==COVID-19 değil</i>
<i>Yeni-Etiket=COVID-19 değil</i>
<i>Yeni-Sonuç=max(Sonuç-1,Sonuç-2)</i>
<b>Bitiş</b>
<i>Eğer (Etiket-1==COVID-19 değil &amp;&amp; Etiket-2==COVID-19)    (Etiket-1==COVID-19 &amp;&amp; Etiket-2==COVID-19 değil)</i>
<i>Yeni-Sonuç=Sonuç-1*0,5+Sonuç-2*0,5 (VAH-1)</i>
<i>Yeni-Sonuç =Sonuç-1*0,75+Sonuç-2*0,25 (VAH-2)</i>
<i>Eğer Yeni-Sonuç &lt;= 0,5</i>
<i>Yeni-Etiket=COVID-19</i>
<b>Değilse</b>
<i>Yeni-Etiket =COVID-19 değil</i>
<b>Bitiş</b>

---

Uygulamada kullanılan üçüncü ve dördüncü VAH yaklaşımının ilk iki VAH yaklaşımında farkı, YİD kullanılarak ve YİD kullanılmadan elde edilen etiketlerin birbirinden farklı olması durumunda YİD kullanılmadan elde edilen etiket sonucunun öncelikli olarak dikkate alınmasıdır. Buna göre üçüncü VAH yaklaşımında iki sınıflandırma etiketinin birbirinden farklı ve YİD kullanılmadan elde edilen etiket sonucunun COVID-19 olması durumunda sonuç COVID-19 kabul edilmiştir. Dördüncü VAH yaklaşımında ise iki sınıflandırma etiketinin birbirinden farklı ve YİD kullanılmadan elde edilen etiket sonucu COVID-19 değil olması durumunda sonuç COVID-19 değil olarak kabul edilmiştir. Diğer prosedürler, ilk iki VAH yaklaşımıyla aynıdır. Üçüncü ve dördüncü VAH yaklaşımında %50-%50 birleştirme oranı kullanılmıştır. Üçüncü ve dördüncü VAH yaklaşımlarının temel kodlaması sırasıyla Çizelge 11.3 ve Çizelge 11.4’de yer almaktadır. VAH yaklaşımlarının çalışma süreleri, saniyenin binde birinden daha azdır. Yani; VAH yaklaşımlarının toplam çalışma süresi, giriş olarak kullanılan sonuçları elde etmek için gereken sürelerin toplamına yaklaşık olarak eşittir.

**Çizelge 11.3.** Tez çalışmasının beşinci uygulamasında kullanılan VAH-3 yaklaşımının temel kodlaması

---

**Eğer** Etiket-1==COVID-19 && Etiket-2==COVID-19  
 Yeni-Etiket=COVID-19  
 Yeni-Sonuç=min(Sonuç-1,Sonuç-2)  
**Bitiş**

**Eğer** Etiket-1==COVID-19 değil && Etiket-2==COVID-19 değil  
 Yeni-Etiket=COVID-19 değil  
 Yeni-Sonuç=max(Sonuç-1,Sonuç-2)  
**Bitiş**

**Eğer** Etiket-1==COVID-19 && Etiket-2==COVID-19 değil  
 Yeni-Etiket=COVID-19  
 Yeni-Sonuç=Sonuç-1  
**Bitiş**

**Eğer** Etiket-1==COVID-19 değil && Etiket-2==COVID-19  
 Yeni-Sonuç=Sonuç-1\*0,5+Sonuç-2\*0,5  
**Eğer** Yeni-Sonuç <= 0,5  
 Yeni-Etiket=COVID-19  
**Değilse**  
 Yeni-Etiket=COVID-19 değil  
**Bitiş**

---

**Çizelge 11.4.** Tez çalışmasının beşinci uygulamasında kullanılan VAH-4 yaklaşımının temel kodlaması

---

*Eğer Etiket-1==COVID-19 && Etiket-2==COVID-19*  
*Yeni-Etiket=COVID-19*  
*Yeni-Sonuç=min(Sonuç-1,Sonuç-2)*  
**Bitiş**

*Eğer Etiket-1==COVID-19 değil && Etiket-2==COVID-19 değil*  
*Yeni-Etiket=COVID-19 değil*  
*Yeni-Sonuç=max(Sonuç-1,Sonuç-2)*  
**Bitiş**

*Eğer Etiket-1==COVID-19 değil && Etiket-2==COVID-19*  
*Yeni-Etiket=COVID-19 değil*  
*Yeni-Sonuç=Sonuç-1*  
**Bitiş**

*Eğer Etiket-1==COVID-19 && Etiket-2==COVID-19 değil*  
*Yeni-Sonuç=Sonuç-1\*0,5+Sonuç-2\*0,5*  
*Eğer Yeni-Sonuç <= 0,5*  
*Yeni-Etiket=COVID-19*  
**Değilse**  
*Yeni-Etiket=COVID-19 değil*  
**Bitiş**

---

**Bitiş**

---

#### 11.4. Deneyleler

Uygulamada X-ray görüntüler üzerinden otomatik COVID-19 sınıflandırmasında en güncel yapay zekâ yöntemlerinden biri olan derin öğrenmeden yararlanılmıştır. Uygulamada 2B ESA kullanılarak görüntülerin otomatik sınıflandırılması gerçekleştirilmiştir. Uygulamada kullanılan ilk eğitim ve test veri setinde 150 tanesi COVID-19 ve 80 tanesi COVID-19 değil olmak üzere toplam 230 adet X-ray görüntüsü yer alırken, ikinci eğitim ve test veri setinde 150 tanesi COVID-19 ve 326 tanesi COVID-19 değil olmak üzere toplam 476 adet X-ray görüntüsü yer almaktadır. Böylece, ağırlıklı olarak COVID-19 görüntüler ve ağırlıklı olarak COVID-19 değil görüntüler içeren iki veri seti için sınıflandırma sonuçları ayrı ayrı hesaplanmıştır.

Uygulamada öncelikle X-ray görüntüleri üzerlerindeki ilgi alanlarını belirlemek için akciğer bölgesini kapsayacak şekilde çerçeveleme yapılmıştır. Daha sonra, görüntülerin çok farklı boyut, format ve bit derinliğinde olması sebebiyle standardizasyon gerçekleştirilmiştir. Görüntüler üzerinde çerçevelenen ilgi alanları yeniden boyutlandırılarak 448×448 olarak düzenlenmiştir. Daha sonra söz konusu görüntüler gri seviye ve 8 bit derinlikte olacak şekilde png formatında kaydedilmiştir. Bu işlemler uygulamada kullanılan tüm COVID-19 ve COVID-19 değil görüntülere uygulanmıştır.

Uygulamanın devam eden kısmında detayları daha önce açıklanan 23 katmanlı 2B ESA mimarisi ve 54 katmanlı 2B ESA mimarisi kullanılmıştır. Bu 2B ESA mimarilerinden tüm deneylerde yararlanılmıştır. Uygulamada birden fazla deney gerçekleştirildiği için sadece 2B ESA girişinde kullanılan görüntülerin boyutları farklılık göstermektedir.

Uygulamada deneyler k kat çapraz doğrulama prosedürü kullanılarak gerçekleştirilmiştir. Bu kapsamda k değeri yirmi üç olarak seçilmiştir. Birinci eğitim ve test veri seti 230 görüntüden oluştuğu için her aşamada 10 görüntü test işlemlerinde, bu görüntüler haricindeki 220 görüntü ise eğitim işlemlerinde kullanılmıştır. İkinci veri seti 476 görüntüden oluşmakta olup, aynı şekilde test işlemlerinde kullanılan 20/21 (16 grup 21 görüntü ve 7 grup 20 görüntü) görüntü haricindeki 456/455 görüntü eğitim işlemlerinde kullanılmıştır. Bu kapsamda eğitim ve test işlemleri yirmi üç kez tekrarlanmış ve tüm görüntüler için sınıflandırma sonuçları elde edilmiştir. Eğitim işlemlerinde COVID-19 görüntüleri için hedef değer olarak 0 atanırken, COVID-19 değil görüntüler için 1 değeri atanmıştır. Sayısal sonuçlar üzerinden COVID-19 ve COVID-19 değil etiketleme yapıırken eşik değeri 0,5 olarak kabul edilmiştir. Bu eşik değerinin altındaki sayısal sonuçlar COVID-19 olarak, bu eşik değerinin üzerindeki sayısal sonuçlar ise COVID-19 değil olarak etiketlenmiştir.

Yukarıda açıklanan deneyler hem YİD uygulanan hem de YİD uygulanmayan görüntüler için gerçekleştirilmiş ve sonuçlar elde edilmiştir. Daha sonra, deneylerde elde edilen sonuçlarının birleştirilmesini sağlayan VAH yaklaşımları devreye alınmıştır. Uygulamalarda daha önce detayları açıklanan dört adet VAH yaklaşımının başarısı test edilmiştir. Uygulamada 2B ESA eğitimi sırasında başlangıç ağırlıkları için herhangi bir transfer yapılmamıştır. Başka bir deyişle, eğitim işlemleri en baştan rastgele atanan başlangıç ağırlıkları kullanılarak gerçekleştirilmiştir. Bu sebeple, program tarafından rastgele atanan başlangıç ağırlıklarının sonuçlara etkisini sınırlandırmak ve uygulama sonuçlarını stabilize etmek için her deney kendi içinde beş kez tekrarlanmıştır. Deneysel tekrarların ortalamaları sonuç olarak verilmiştir.

Uygulamada son olarak birinci ve ikinci veri seti yani tüm görüntüler birleştirilerek 150 adet COVID-19 ve 406 adet COVID değil olmak üzere toplam 556 adet X-ray görüntüsü için iki kat çaprazlama kullanılarak eğitim ve test işlemleri tekrarlanmıştır. Uygulamanın uzunluğu da göz önüne alınarak, bu deneyler sadece birinci ve ikinci veri setleri için en iyi sonuçları sağlayan giriş veri kombinasyonları için gerçekleştirilmiştir.

Uygulama kapsamında bir görüntünün sınıflandırılması için ihtiyaç duyulan süreler (CPU süresi) saniye cinsinden ölçülmüştür. Uygulamanın deneyleri 64 GB RAM ve Intel(R) Xeon (R) CPU E5-2680 2.7 GHz (32 CPU) bir bilgisayarda çalışan MATLAB 2019 (a) yazılımı kullanılarak gerçekleştirilmiştir. Uygulamada verilen tüm CPU çalışma süreleri saniye cinsinden zamanı göstermektedir.

### 11.5. Deney Sonuçları

Uygulamanın birinci deney grubunda ilk olarak orijinal X-ray görüntüleri doğrudan kullanılarak eğitim ve test işlemleri gerçekleştirilmiş ve sonuçlar hesaplanmıştır. Daha sonra söz konusu görüntülere YİD işlemi uygulanarak eğitim ve test işlemleri tekrarlanmıştır. Son olarak, detayları daha önce açıklanan VAH yaklaşımları kullanılarak sonuçlar hesaplanmıştır. Bu deneyler için ESA'ya giriş olarak verilen görüntü boyutları 448×448×1'dir. Deneylerde elde edilen sonuçlar Çizelge 11.5 (birinci veri seti) ve Çizelge 11.6'da (ikinci veri seti) verilmiştir. Çizelgelerde en yüksek parametre değerleri koyu olarak belirtilmiştir. Bu işaretleme devam eden diğer çizelgeler içinde yapılmıştır.

**Çizelge 11.5.** COVID-19 ve COVID-19 değil sınıflandırmasında doğrudan X-ray görüntüleri kullanılarak elde edilen sonuçlar (birinci veri seti)

2B ESA Tipi	Yöntem	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AIKE-AKA	CPU Süresi (saniye)
23 Katmanlı 2B ESA	YİD Yok	146,2	3,8	76,8	3,2	0,9747	<b>0,9600</b>	<b>0,9696</b>	<b>0,9766</b>	<b>0,9961</b>	1,8964
	YİD Var	147,8	2,2	71,6	8,4	<b>0,9853</b>	0,8950	0,9539	0,9655	0,9939	1,8226
	VAH-1	148,6	1,4	76,2	3,8	0,9907	0,9525	<b>0,9774</b>	<b>0,9828</b>	0,9968	3,7190
	VAH-2	146,8	3,2	76,6	3,4	0,9787	0,9575	0,9713	0,9780	0,9968	3,7190
	VAH-3	148,8	1,2	75,8	4,2	<b>0,9920</b>	0,9475	0,9765	0,9822	0,9968	3,7190
	VAH-4	146,0	4,0	77,2	2,8	0,9733	<b>0,9650</b>	0,9704	0,9772	<b>0,9969</b>	3,7190
54 Katmanlı 2B ESA	YİD Yok	144,2	5,8	76,6	3,4	<b>0,9613</b>	<b>0,9575</b>	<b>0,9600</b>	<b>0,9691</b>	<b>0,9949</b>	3,3105
	YİD Var	142,6	7,4	74,0	6,0	0,9507	0,9250	0,9417	0,9551	0,9815	3,6433
	VAH-1	147,2	2,8	78,4	1,6	0,9813	<b>0,9800</b>	<b>0,9809</b>	<b>0,9853</b>	<b>0,9977</b>	6,9538
	VAH-2	144,4	5,6	77,4	2,6	0,9627	0,9675	0,9643	0,9724	0,9973	6,9538
	VAH-3	148,0	2,0	76,6	3,4	<b>0,9867</b>	0,9575	0,9765	0,9821	0,9972	6,9538
	VAH-4	143,4	6,6	78,4	1,6	0,9560	<b>0,9800</b>	0,9643	0,9722	0,9958	6,9538



**Çizelge 11.6.** COVID-19 ve COVID-19 değil sınıflandırmasında doğrudan X-ray görüntüleri kullanılarak elde edilen sonuçlar (ikinci veri seti)

2B ESA Tipi	Yöntem	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AIKE-AKA	CPU Süresi (saniye)
23 Katmanlı 2B ESA	YİD Yok	144,4	5,6	322,0	4,0	<b>0,9627</b>	<b>0,9877</b>	<b>0,9798</b>	<b>0,9678</b>	<b>0,9975</b>	2,4878
	YİD Var	137,2	12,8	316,4	9,6	0,9147	0,9706	0,9529	0,9246	0,9899	2,4995
	VAH-1	146,0	4,0	322,0	4,0	0,9733	0,9877	0,9832	0,9733	0,9982	4,9872
	VAH-2	146,0	4,0	321,8	4,2	0,9733	0,9871	0,9828	0,9726	<b>0,9983</b>	4,9872
	VAH-3	147,0	3,0	321,0	5,0	<b>0,9800</b>	0,9847	<b>0,9832</b>	<b>0,9735</b>	0,9981	4,9872
VAH-4	143,4	6,6	323,0	3,0	0,9560	<b>0,9908</b>	0,9798	0,9676	0,9979	4,9872	
54 Katmanlı 2B ESA	YİD Yok	146,0	4,0	323,0	3,0	<b>0,9733</b>	<b>0,9908</b>	<b>0,9853</b>	<b>0,9766</b>	<b>0,9977</b>	5,1817
	YİD Var	133,8	16,2	315,6	10,4	0,8920	0,9681	0,9441	0,9096	0,9885	5,4239
	VAH-1	148,0	2,0	322,6	3,4	0,9867	0,9896	0,9887	0,9821	0,9987	10,6056
	VAH-2	147,0	3,0	323,2	2,8	0,9800	0,9914	0,9878	0,9806	0,9988	10,6056
	VAH-3	148,8	1,2	322,0	4,0	<b>0,9920</b>	0,9877	<b>0,9891</b>	<b>0,9828</b>	<b>0,9991</b>	10,6056
VAH-4	145,2	4,8	323,6	2,4	0,9680	<b>0,9926</b>	0,9849	0,9758	0,9975	10,6056	

Uygulamanın ikinci deney grubunda X-ray görüntülerine KDDD uygulanarak elde edilen LL alt görüntüsünün reel kısmı kullanılarak eğitim ve test işlemleri gerçekleştirilmiş ve sonuçlar hesaplanmıştır. Daha sonra X-ray görüntülerine sırasıyla YİD ve KDDD işlemleri uygulanarak elde edilen LL alt görüntüsünün reel kısmı kullanılarak eğitim ve test işlemleri gerçekleştirilmiştir. Son olarak, VAH yaklaşımları kullanılarak sonuçlar hesaplanmıştır. Bu deneyler için 2B ESA'ya giriş olarak verilen görüntü boyutları  $224 \times 224 \times 1$ 'dir. Deneylerde elde edilen sonuçlar Çizelge 11.7 (birinci veri seti) ve Çizelge 11.8'de (ikinci veri seti) verilmiştir.

**Çizelge 11.7.** COVID-19 ve COVID-19 değil sınıflandırmasında X-ray görüntülerine KDDD uygulanarak elde edilen LL alt bandının reel kısmının kullanılması durumu için sonuçlar (birinci veri seti)

2B ESA Tipi	Yöntem	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AIKE-AKA	CPU Süresi (saniye)
23 Katmanlı 2B ESA	YİD Yok	146,6	3,4	77,4	2,6	<b>0,9773</b>	<b>0,9675</b>	<b>0,9739</b>	<b>0,9800</b>	<b>0,9983</b>	0,6090
	YİD Var	146,0	4,0	72,6	7,4	0,9733	0,9075	0,9504	0,9624	0,9890	0,6252
	VAH-1	149,0	1,0	77,4	2,6	0,9933	0,9675	<b>0,9843</b>	<b>0,9881</b>	0,9988	1,2342
	VAH-2	147,0	3,0	77,4	2,6	0,9800	0,9675	0,9757	0,9813	0,9989	1,2342
	VAH-3	149,2	0,8	76,6	3,4	<b>0,9947</b>	<b>0,9575</b>	0,9817	0,9862	<b>0,9990</b>	1,2342
VAH-4	146,4	3,6	78,2	1,8	0,9760	<b>0,9775</b>	0,9765	0,9819	0,9986	1,2342	
54 Katmanlı 2B ESA	YİD Yok	141,8	8,2	77,8	2,2	<b>0,9453</b>	<b>0,9725</b>	<b>0,9548</b>	<b>0,9646</b>	<b>0,9934</b>	1,2146
	YİD Var	141,2	8,8	63,6	16,4	0,9413	0,7950	0,8904	0,9183	0,9580	1,2339
	VAH-1	146,6	3,4	77,6	2,4	0,9773	0,9700	0,9748	0,9806	<b>0,9963</b>	2,4485
	VAH-2	144,0	6,0	78,0	2,0	0,9600	0,9750	0,9652	0,9729	0,9962	2,4485
	VAH-3	147,4	2,6	77,2	2,8	<b>0,9827</b>	0,9650	<b>0,9765</b>	<b>0,9820</b>	0,9961	2,4485
VAH-4	141,0	9,0	78,2	1,8	0,9400	<b>0,9775</b>	0,9530	0,9631	0,9944	2,4485	

**Çizelge 11.8.** COVID-19 ve COVID-19 değil sınıflandırmasında X-ray görüntülerine KDDD uygulanarak elde edilen LL alt bandının reel kısmının kullanılması durumu için sonuçlar (ikinci veri seti)

2B ESA Tipi	Yöntem	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AIKE-AKA	CPU Süresi (saniye)
23 Katmanlı 2B ESA	YİD Yok	143,6	6,4	320,8	5,2	<b>0,9573</b>	<b>0,9840</b>	<b>0,9756</b>	<b>0,9611</b>	<b>0,9973</b>	0,7571
	YİD Var	135,2	14,8	311,2	14,8	0,9013	0,9546	0,9378	0,9013	0,9865	0,7569
	VAH-1	146,4	3,6	322,2	3,8	0,9760	0,9883	<b>0,9845</b>	<b>0,9753</b>	0,9978	1,5140
	VAH-2	145,0	5,0	321,6	4,4	0,9667	0,9865	0,9803	0,9685	0,9979	1,5140
	VAH-3	146,8	3,2	320,4	5,6	<b>0,9787</b>	0,9828	0,9815	0,9709	<b>0,9981</b>	1,5140
VAH-4	143,2	6,8	322,6	3,4	0,9547	<b>0,9896</b>	0,9786	0,9656	0,9973	1,5140	
54 Katmanlı 2B ESA	YİD Yok	146,0	4,0	322,0	4,0	<b>0,9733</b>	<b>0,9877</b>	<b>0,9832</b>	<b>0,9733</b>	<b>0,9983</b>	1,5029
	YİD Var	131,8	18,2	305,4	20,6	0,8787	0,9368	0,9185	0,8718	0,9770	1,8120
	VAH-1	147,6	2,4	321,6	4,4	0,9840	0,9865	<b>0,9857</b>	<b>0,9775</b>	0,9977	3,3149
	VAH-2	146,6	3,4	322,4	3,6	0,9773	0,9890	0,9853	0,9767	0,9980	3,3149
	VAH-3	148,2	1,8	320,8	5,2	<b>0,9880</b>	0,9840	0,9853	0,9770	<b>0,9984</b>	3,3149
VAH-4	145,4	4,6	322,8	3,2	0,9693	<b>0,9902</b>	0,9836	0,9739	0,9975	3,3149	

Uygulamanın üçüncü deney grubunda X-ray görüntülerine KDDD uygulanarak elde edilen LL alt görüntüsünün imajiner kısmı kullanılarak eğitim ve test işlemleri gerçekleştirilmiş ve sonuçlar hesaplanmıştır. Daha sonra X-ray görüntülerine sırasıyla YİD ve KDDD işlemleri uygulanarak elde edilen LL alt görüntüsünün imajiner kısmı kullanılarak eğitim ve test işlemleri gerçekleştirilmiştir. Son olarak, VAH yaklaşımları kullanılarak sonuçlar hesaplanmıştır. Bu deneyler için 2B ESA'ya giriş olarak verilen görüntü boyutları  $224 \times 224 \times 1$ 'dir. Deneylerde elde edilen sonuçlar Çizelge 11.9 (birinci veri seti) ve Çizelge 11.10'da (ikinci veri seti) verilmiştir.

**Çizelge 11.9.** COVID-19 ve COVID-19 değil sınıflandırmasında X-ray görüntülerine KDDD uygulanarak elde edilen LL alt bandının imajiner kısmının kullanılması durumu için sonuçlar (birinci veri seti)

2B ESA Tipi	Yöntem	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AIKE-AKA	CPU Süresi (saniye)
23 Katmanlı 2B ESA	YİD Yok	146,4	3,6	77,4	2,6	<b>0,9760</b>	<b>0,9675</b>	<b>0,9730</b>	<b>0,9792</b>	<b>0,9972</b>	0,6033
	YİD Var	145,6	4,4	73,6	6,4	0,9707	0,9200	0,9530	0,9643	0,9889	0,5979
	VAH-1	147,8	2,2	77,0	3,0	0,9853	0,9625	<b>0,9774</b>	<b>0,9827</b>	0,9980	1,2012
	VAH-2	146,6	3,4	77,4	2,6	0,9773	0,9675	0,9739	0,9799	0,9981	1,2012
	VAH-3	148,2	1,8	76,4	3,6	<b>0,9880</b>	0,9550	0,9765	0,9821	<b>0,9985</b>	1,2012
VAH-4	146,0	4,0	78,0	2,0	0,9733	<b>0,9750</b>	0,9739	0,9799	0,9977	1,2012	
54 Katmanlı 2B ESA	YİD Yok	141,0	9,0	77,2	2,8	0,9400	<b>0,9650</b>	<b>0,9487</b>	<b>0,9599</b>	<b>0,9803</b>	1,2156
	YİD Var	143,6	6,4	60,2	19,8	<b>0,9573</b>	0,7525	0,8861	0,9167	0,9645	1,2086
	VAH-1	146,8	3,2	75,8	4,2	0,9787	0,9475	<b>0,9678</b>	<b>0,9754</b>	<b>0,9923</b>	2,4243
	VAH-2	143,0	7,0	77,4	2,6	0,9533	0,9675	0,9583	0,9675	0,9909	2,4243
	VAH-3	146,8	3,2	74,8	5,2	<b>0,9787</b>	0,9350	0,9635	0,9722	0,9898	2,4243
VAH-4	141,0	9,0	78,2	1,8	0,9400	<b>0,9775</b>	0,9530	0,9631	0,9849	2,4243	

**Çizelge 11.10.** COVID-19 ve COVID-19 değil sınıflandırmasında X-ray görüntülerine KDDD uygulanarak elde edilen LL alt bandının imajiner kısmının kullanılması durumu için sonuçlar (ikinci veri seti)

2B ESA Tipi	Yöntem	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AIKE-AKA	CPU Süresi (saniye)
23 Katmanlı 2B ESA	YİD Yok	145,0	5,0	322,0	4,0	<b>0,9667</b>	<b>0,9877</b>	<b>0,9811</b>	<b>0,9699</b>	<b>0,9970</b>	0,7587
	YİD Var	134,8	15,2	312,0	14,0	0,8987	0,9571	0,9387	0,9022	0,9861	0,7578
	VAH-1	147,2	2,8	322,0	4,0	0,9813	0,9877	<b>0,9857</b>	<b>0,9774</b>	0,9981	1,5164
	VAH-2	146,0	4,0	322,2	3,8	0,9733	0,9883	0,9836	0,9740	0,9982	1,5164
	VAH-3	147,6	2,4	321,0	5,0	<b>0,9840</b>	0,9847	0,9845	0,9755	<b>0,9985</b>	1,5164
VAH-4	144,6	5,4	323,0	3,0	0,9640	<b>0,9908</b>	0,9824	0,9718	0,9969	1,5164	
54 Katmanlı 2B ESA	YİD Yok	146,0	4,0	323,2	2,8	<b>0,9733</b>	<b>0,9914</b>	<b>0,9857</b>	<b>0,9772</b>	<b>0,9981</b>	1,5022
	YİD Var	128,8	21,2	306,0	20,0	0,8587	0,9387	0,9134	0,8615	0,9773	1,6851
	VAH-1	147,4	2,6	322,6	3,4	0,9827	0,9896	<b>0,9874</b>	<b>0,9800</b>	0,9979	3,1874
	VAH-2	146,2	3,8	323,0	3,0	0,9747	0,9908	0,9857	0,9773	<b>0,9984</b>	3,1874
	VAH-3	147,8	2,2	322,0	4,0	<b>0,9853</b>	0,9877	0,9870	0,9794	0,9983	3,1874
VAH-4	145,6	4,4	323,8	2,2	0,9707	<b>0,9933</b>	0,9861	0,9778	0,9982	3,1874	

Uygulamanın dördüncü deney grubunda, X-ray görüntülerine KDDD uygulanarak elde edilen LL, LH ve HL alt görüntülerinin reel kısımları kullanılarak eğitim ve test işlemleri gerçekleştirilmiş ve sonuçlar hesaplanmıştır. Daha sonra X-ray görüntülerine sırasıyla YİD ve KDDD işlemleri uygulanarak elde edilen LL, LH ve HL alt görüntülerinin reel kısımlar kullanılarak eğitim ve test işlemleri gerçekleştirilmiştir. Son olarak, VAH yaklaşımları kullanılarak sonuçlar hesaplanmıştır. Bu deneyler için 2B ESA'ya giriş olarak verilen görüntü boyutları 224×224×3'tür. Deneylerde elde

edilen sonuçlar birinci ve ikinci veri seti için sırasıyla Çizelge 11.11 ve Çizelge 11.12’de verilmiştir.

**Çizelge 11.11.** COVID-19 ve COVID-19 değil sınıflandırmasında X-ray görüntülerine KDDD uygulanarak elde edilen LL, LH, HL alt bantlarının reel kısımlarının kullanılması durumu için sonuçlar (birinci veri seti)

2B ESA Tipi	Yöntem	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AIKE-AKA	CPU Süresi (saniye)
23 Katmanlı 2B ESA	YİD Yok	146,2	3,8	77,8	2,2	0,9747	<b>0,9725</b>	<b>0,9739</b>	<b>0,9799</b>	<b>0,9976</b>	1,0596
	YİD Var	147,4	2,6	71,6	8,4	<b>0,9827</b>	0,8950	0,9522	0,9642	0,9926	1,0598
	VAH-1	148,4	1,6	77,4	2,6	0,9893	0,9675	<b>0,9817</b>	<b>0,9860</b>	<b>0,9984</b>	2,1193
	VAH-2	147,0	3,0	77,8	2,2	0,9800	0,9725	0,9774	0,9826	<b>0,9984</b>	2,1193
	VAH-3	148,4	1,6	77,0	3,0	<b>0,9893</b>	0,9625	0,9800	0,9847	0,9983	2,1193
VAH-4	146,2	3,8	78,2	1,8	0,9747	<b>0,9775</b>	0,9757	0,9812	0,9983	2,1193	
54 Katmanlı 2B ESA	YİD Yok	142,6	7,4	76,8	3,2	<b>0,9507</b>	<b>0,9600</b>	<b>0,9539</b>	<b>0,9642</b>	<b>0,9876</b>	1,6868
	YİD Var	141,2	8,8	64,2	15,8	0,9413	0,8025	0,8930	0,9201	0,9664	1,6890
	VAH-1	146,8	3,2	76,4	3,6	0,9787	0,9550	0,9704	0,9774	<b>0,9948</b>	3,3757
	VAH-2	143,8	6,2	76,8	3,2	0,9587	0,9600	0,9591	0,9684	0,9944	3,3757
	VAH-3	147,4	2,6	75,8	4,2	<b>0,9827</b>	0,9475	<b>0,9704</b>	<b>0,9775</b>	0,9945	3,3757
VAH-4	142,0	8,0	77,4	2,6	0,9467	<b>0,9675</b>	0,9539	0,9640	0,9903	3,3757	

**Çizelge 11.12.** COVID-19 ve COVID-19 değil sınıflandırmasında X-ray görüntülerine KDDD uygulanarak elde edilen LL, LH, HL alt bantlarının reel kısımlarının kullanılması durumu için sonuçlar (ikinci veri seti)

2B ESA Tipi	Yöntem	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AIKE-AKA	CPU Süresi (saniye)
23 Katmanlı 2B ESA	YİD Yok	145,4	4,6	322,8	3,2	<b>0,9693</b>	<b>0,9902</b>	<b>0,9836</b>	<b>0,9739</b>	<b>0,9974</b>	1,3986
	YİD Var	132,0	18,0	309,8	16,2	0,8800	0,9503	0,9282	0,8852	0,9807	1,4043
	VAH-1	146,6	3,4	320,8	5,2	0,9773	0,9840	0,9819	0,9715	0,9979	2,8029
	VAH-2	146,4	3,6	322,6	3,4	0,9760	0,9896	<b>0,9853</b>	<b>0,9766</b>	0,9982	2,8029
	VAH-3	147,8	2,2	320,6	5,4	<b>0,9853</b>	0,9834	0,9840	0,9749	<b>0,9986</b>	2,8029
VAH-4	144,2	5,8	323,0	3,0	0,9613	<b>0,9908</b>	0,9815	0,9704	0,9970	2,8029	
54 Katmanlı 2B ESA	YİD Yok	144,6	5,4	323,4	2,6	<b>0,9640</b>	<b>0,9920</b>	<b>0,9832</b>	<b>0,9730</b>	<b>0,9985</b>	2,1551
	YİD Var	135,0	15,0	308,2	17,8	0,9000	0,9454	0,9311	0,8918	0,9828	2,1720
	VAH-1	146,6	3,4	323,0	3,0	0,9773	0,9908	0,9866	0,9786	0,9987	4,3271
	VAH-2	145,6	4,4	323,0	3,0	0,9707	0,9908	0,9845	0,9752	<b>0,9989</b>	4,3271
	VAH-3	147,2	2,8	322,4	3,6	<b>0,9813</b>	0,9890	<b>0,9866</b>	<b>0,9787</b>	0,9987	4,3271
VAH-4	144,0	6,0	324,0	2,0	0,9600	<b>0,9939</b>	0,9832	0,9729	0,9987	4,3271	

Uygulamanın beşinci deney grubunda, X-ray görüntülerine KDDD uygulanarak elde edilen LL, LH ve HL alt görüntülerinin imajiner kısımları kullanılarak eğitim ve test işlemleri gerçekleştirilmiş ve sonuçlar hesaplanmıştır. Daha sonra X-ray görüntülerine sırasıyla YİD ve KDDD işlemleri uygulanarak elde edilen LL, LH ve HL

alt görüntülerinin imajiner kısımları kullanılarak eğitim ve test işlemleri gerçekleştirilmiştir. Son olarak, VAH yaklaşımları kullanılarak sonuçlar hesaplanmıştır. Bu deneyler için 2B ESA'ya giriş olarak verilen görüntü boyutları 224×224×3'tür. Deneylerde elde edilen sonuçlar Çizelge 11.13 ve Çizelge 11.14'de verilmiştir.

**Çizelge 11.13.** COVID-19 ve COVID-19 değil sınıflandırmasında X-ray görüntülerine KDDD uygulanarak elde edilen LL, LH, HL alt bantlarının imajiner kısımlarının kullanılması durumu için sonuçlar (birinci veri seti)

2B ESA Tipi	Yöntem	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AIKE-AKA	CPU Süresi (saniye)
23 Katmanlı 2B ESA	YİD Yok	145,2	4,8	77,4	2,6	0,9680	<b>0,9675</b>	<b>0,9678</b>	<b>0,9751</b>	<b>0,9967</b>	1,0667
	YİD Var	146,8	3,2	71,8	8,2	<b>0,9787</b>	0,8975	0,9504	0,9628	0,9916	1,0593
	VAH-1	148,4	1,6	77,4	2,6	0,9893	0,9675	<b>0,9817</b>	<b>0,9861</b>	0,9982	2,1261
	VAH-2	145,8	4,2	77,4	2,6	0,9720	0,9675	0,9704	0,9772	0,9980	2,1261
	VAH-3	148,6	1,4	76,8	3,2	<b>0,9907</b>	0,9600	0,9800	0,9848	<b>0,9983</b>	2,1261
54 Katmanlı 2B ESA	VAH-4	145,0	5,0	78,0	2,0	0,9667	<b>0,9750</b>	0,9696	0,9764	0,9970	2,1261
	YİD Yok	143,6	6,4	76,2	3,8	<b>0,9573</b>	<b>0,9525</b>	<b>0,9557</b>	<b>0,9657</b>	<b>0,9876</b>	1,6952
	YİD Var	140,4	9,6	66,8	13,2	0,9360	0,8350	0,9009	0,9252	0,9684	1,6866
	VAH-1	146,4	3,6	76,8	3,2	0,9760	0,9600	<b>0,9704</b>	<b>0,9773</b>	0,9940	3,3818
	VAH-2	144,2	5,8	76,0	4,0	0,9613	0,9500	0,9574	0,9671	<b>0,9943</b>	3,3818
54 Katmanlı 2B ESA	VAH-3	147,6	2,4	75,0	5,0	<b>0,9840</b>	0,9375	0,9678	0,9755	0,9936	3,3818
	VAH-4	142,4	7,6	78,0	2,0	0,9493	<b>0,9750</b>	0,9583	0,9674	0,9907	3,3818

**Çizelge 11.14.** COVID-19 ve COVID-19 değil sınıflandırmasında X-ray görüntülerine KDDD uygulanarak elde edilen LL, LH, HL alt bantlarının imajiner kısımlarının kullanılması durumu için sonuçlar (ikinci veri seti)

2B ESA Tipi	Yöntem	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AIKE-AKA	CPU Süresi (saniye)
23 Katmanlı 2B ESA	YİD Yok	145,8	4,2	322,8	3,2	<b>0,9720</b>	<b>0,9902</b>	<b>0,9845</b>	<b>0,9752</b>	<b>0,9980</b>	1,4026
	YİD Var	134,8	15,2	311,4	14,6	0,8987	0,9552	0,9374	0,9004	0,9839	1,4067
	VAH-1	146,2	3,8	322,0	4,0	0,9747	0,9877	0,9836	0,9740	0,9982	4,2160
	VAH-2	146,0	4,0	322,4	3,6	0,9733	0,9890	0,9840	0,9746	0,9983	7,0253
	VAH-3	147,4	2,6	321,2	4,8	<b>0,9827</b>	0,9853	<b>0,9845</b>	<b>0,9755</b>	<b>0,9988</b>	11,2414
54 Katmanlı 2B ESA	VAH-4	144,6	5,4	323,6	2,4	0,9640	<b>0,9926</b>	0,9836	0,9737	0,9977	18,2667
	YİD Yok	145,2	4,8	323,0	3,0	0,9680	0,9908	0,9836	0,9738	<b>0,9987</b>	2,1541
	YİD Var	130,0	20,0	304,4	21,6	0,8667	0,9337	0,9126	0,8615	0,9733	2,1514
	VAH-1	147,2	2,8	321,8	4,2	0,9813	0,9871	0,9853	0,9768	0,9979	4,3054
	VAH-2	145,4	4,6	322,8	3,2	0,9693	0,9902	0,9836	0,9739	0,9984	4,3054
54 Katmanlı 2B ESA	VAH-3	147,8	2,2	321,6	4,4	<b>0,9853</b>	0,9865	<b>0,9861</b>	<b>0,9782</b>	<b>0,9986</b>	4,3054
	VAH-4	144,6	5,4	323,2	2,8	0,9640	<b>0,9914</b>	0,9828	0,9724	0,9982	4,3054

Uygulamanın altıncı deney grubunda, X-ray görüntülerine KDDD uygulanarak elde edilen LL alt görüntüsünün reel ve imajiner kısımları kullanılarak eğitim ve test işlemleri gerçekleştirilmiş ve sonuçlar hesaplanmıştır. Daha sonra X-ray görüntülerine sırasıyla YİD ve KDDD işlemleri uygulanarak elde edilen LL alt görüntüsünün reel ve imajiner kısımları kullanılarak eğitim ve test işlemleri gerçekleştirilmiştir. Son olarak, VAH yaklaşımları kullanılarak sonuçlar hesaplanmıştır. Bu deneylerde 2B ESA'ya giriş olarak verilen görüntü boyutları 224×224×2'dir. Deneylerde elde edilen sonuçlar Çizelge 11.15 (birinci veri seti) ve Çizelge 11.16'da (ikinci veri seti) verilmiştir.

Uygulamanın yedinci deney grubunda, X-ray görüntülerine KDD uygulanarak elde edilen LL, LH, HL alt görüntülerinin reel ve imajiner kısımları kullanılarak eğitim ve test işlemleri gerçekleştirilmiş ve sonuçlar hesaplanmıştır. Daha sonra X-ray görüntülerine sırasıyla YİD ve KDDD işlemleri uygulanarak elde edilen LL, LH, HL alt görüntülerinin reel ve imajiner kısımları kullanılarak eğitim ve test işlemleri gerçekleştirilmiştir. Son olarak, VAH yaklaşımları kullanılarak sonuçlar hesaplanmıştır. Bu deneyler için ESA'ya giriş olarak verilen görüntü boyutları 224×224×6'dır. Deneylerde elde edilen sonuçlar Çizelge 11.17 (birinci veri seti) ve Çizelge 11.18'de (ikinci veri seti) verilmiştir.

**Çizelge 11.15.** COVID-19 ve COVID-19 değil sınıflandırmasında X-ray görüntülerine KDDD uygulanarak elde edilen LL alt bandının reel ve imajiner kısımlarının kullanılması durumu için sonuçlar (birinci veri seti)

2B ESA Tipi	Yöntem	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AİKE-AKA	CPU Süresi (saniye)
23 Katmanlı 2B ESA	YİD Yok	145,8	4,2	77,6	2,4	<b>0,9720</b>	<b>0,9700</b>	<b>0,9713</b>	<b>0,9779</b>	<b>0,9970</b>	0,8271
	YİD Var	145,8	4,2	68,8	11,2	<b>0,9720</b>	0,8600	0,9330	0,9500	0,9883	0,8273
	VAH-1	148,2	1,8	77,2	2,8	0,9880	0,9650	<b>0,9800</b>	<b>0,9847</b>	0,9982	1,6544
	VAH-2	147,0	3,0	78,0	2,0	0,9800	0,9750	0,9783	0,9833	0,9983	1,6544
	VAH-3	148,4	1,6	76,4	3,6	<b>0,9893</b>	0,9550	0,9774	0,9828	<b>0,9986</b>	1,6544
	VAH-4	145,6	4,4	78,4	1,6	0,9707	<b>0,9800</b>	0,9739	0,9798	0,9970	1,6544
54 Katmanlı 2B ESA	YİD Yok	143,0	7,0	76,4	3,6	<b>0,9533</b>	<b>0,9550</b>	<b>0,9539</b>	<b>0,9643</b>	<b>0,9902</b>	1,4416
	YİD Var	142,6	7,4	67,2	12,8	0,9507	0,8400	0,9122	0,9340	0,9738	1,4399
	VAH-1	148,0	2,0	77,4	2,6	0,9867	0,9675	<b>0,9800</b>	<b>0,9847</b>	<b>0,9969</b>	2,8815
	VAH-2	144,2	5,8	77,4	2,6	0,9613	0,9675	0,9635	0,9717	0,9957	2,8815
	VAH-3	148,0	2,0	75,6	4,4	<b>0,9867</b>	0,9450	0,9722	0,9789	0,9957	2,8815
	VAH-4	143,0	7,0	78,2	1,8	0,9533	<b>0,9775</b>	0,9617	0,9701	0,9922	2,8815

**Çizelge 11.16.** COVID-19 ve COVID-19 değil sınıflandırmasında X-ray görüntülerine KDDD uygulanarak elde edilen LL alt bantının reel ve imajiner kısımlarının kullanılması durumu için sonuçlar (ikinci veri seti)

2B ESA Tipi	Yöntem	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AIKE-AKA	CPU Süresi (saniye)
23 Katmanlı 2B ESA	YİD Yok	143,0	7,0	323,0	3,0	<b>0,9533</b>	<b>0,9908</b>	<b>0,9790</b>	<b>0,9662</b>	<b>0,9980</b>	1,0808
	YİD Var	135,2	14,8	313,6	12,4	0,9013	0,9620	0,9429	0,9086	0,9863	1,0820
	VAH-1	146,8	3,2	321,8	4,2	0,9787	0,9871	<b>0,9845</b>	0,9754	0,9983	2,1627
	VAH-2	145,4	4,6	323,0	3,0	0,9693	0,9908	0,9840	0,9745	0,9983	2,1627
	VAH-3	147,2	2,8	321,4	4,6	<b>0,9813</b>	0,9859	<b>0,9845</b>	<b>0,9755</b>	<b>0,9987</b>	2,1627
VAH-4	142,6	7,4	323,4	2,6	0,9507	<b>0,9920</b>	0,9790	0,9661	0,9977	2,1627	
54 Katmanlı 2B ESA	YİD Yok	145,2	4,8	322,8	3,2	<b>0,9680</b>	<b>0,9902</b>	<b>0,9832</b>	<b>0,9732</b>	<b>0,9982</b>	1,8172
	YİD Var	131,2	18,8	306,0	20,0	0,8747	0,9387	0,9185	0,8711	0,9797	1,8135
	VAH-1	147,4	2,6	323,0	3,0	0,9827	0,9908	<b>0,9882</b>	<b>0,9813</b>	0,9985	3,6307
	VAH-2	145,6	4,4	323,2	2,8	0,9707	0,9914	0,9849	0,9758	0,9986	3,6307
	VAH-3	148,0	2,0	321,8	4,2	<b>0,9867</b>	0,9871	0,9870	0,9795	<b>0,9990</b>	3,6307
VAH-4	144,6	5,4	324,0	2,0	0,9640	<b>0,9939</b>	0,9845	0,9750	0,9980	3,6307	

**Çizelge 11.17.** COVID-19 ve COVID-19 değil sınıflandırmasında X-ray görüntülerine KDDD uygulanarak elde edilen LL, LH, HL alt bantlarının reel ve imajiner kısımlarının kullanılması durumu için sonuçlar (birinci veri seti)

2B ESA Tipi	Yöntem	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AIKE-AKA	CPU Süresi (saniye)
23 Katmanlı 2B ESA	YİD Yok	147,0	3,0	77,6	2,4	<b>0,9800</b>	<b>0,9700</b>	<b>0,9765</b>	<b>0,9819</b>	<b>0,9975</b>	1,7203
	YİD Var	145,4	4,6	74,2	5,8	0,9693	0,9275	0,9548	0,9655	0,9902	1,7311
	VAH-1	148,2	1,8	77,4	2,6	0,9880	0,9675	0,9809	0,9854	0,9984	3,4513
	VAH-2	147,2	2,8	77,8	2,2	0,9813	<b>0,9725</b>	0,9783	0,9833	0,9984	3,4513
	VAH-3	148,8	1,2	77,2	2,8	<b>0,9920</b>	0,9650	<b>0,9826</b>	<b>0,9867</b>	<b>0,9986</b>	3,4513
VAH-4	146,4	3,6	77,8	2,2	0,9760	<b>0,9725</b>	0,9748	0,9806	0,9981	3,4513	
54 Katmanlı 2B ESA	YİD Yok	142,8	7,2	76,8	3,2	<b>0,9520</b>	<b>0,9600</b>	<b>0,9548</b>	<b>0,9648</b>	<b>0,9884</b>	2,4206
	YİD Var	142,0	8,0	70,4	9,6	0,9467	0,8800	0,9235	0,9417	0,9763	2,4210
	VAH-1	146,6	3,4	77,6	2,4	0,9773	0,9700	<b>0,9748</b>	<b>0,9806</b>	<b>0,9956</b>	4,8417
	VAH-2	144,6	5,4	77,4	2,6	0,9640	0,9675	0,9652	0,9731	0,9948	4,8417
	VAH-3	147,8	2,2	76,4	3,6	<b>0,9853</b>	0,9550	0,9748	0,9808	0,9953	4,8417
VAH-4	141,6	8,4	78,0	2,0	0,9440	<b>0,9750</b>	0,9548	0,9646	0,9909	4,8417	

**Çizelge 11.18.** COVID-19 ve COVID-19 değil sınıflandırmasında X-ray görüntülerine KDDD uygulanarak elde edilen LL, LH, HL alt bantlarının reel ve imajiner kısımlarının kullanılması durumu için sonuçlar (ikinci veri seti)

2B ESA Tipi	Yöntem	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AIKE-AKA	CPU Süresi (saniye)
23 Katmanlı 2B ESA	YİD Yok	144,8	5,2	323,0	3,0	<b>0,9653</b>	<b>0,9908</b>	<b>0,9828</b>	<b>0,9724</b>	<b>0,9982</b>	2,3185
	YİD Var	129,2	20,8	308,6	17,4	0,8613	0,9466	0,9197	0,8710	0,9786	2,3401
	VAH-1	147,0	3,0	321,6	4,4	0,9800	0,9865	0,9845	0,9755	0,9974	4,6586
	VAH-2	145,2	4,8	322,8	3,2	0,9680	0,9902	0,9832	0,9732	0,9978	4,6586
	VAH-3	147,6	2,4	321,4	4,6	<b>0,9840</b>	0,9859	<b>0,9853</b>	<b>0,9768</b>	<b>0,9984</b>	4,6586
VAH-4	144,2	5,8	323,2	2,8	0,9613	<b>0,9914</b>	0,9819	0,9710	0,9975	4,6586	
54 Katmanlı 2B ESA	YİD Yok	144,6	5,4	323,4	2,6	<b>0,9640</b>	<b>0,9920</b>	<b>0,9832</b>	<b>0,9731</b>	<b>0,9984</b>	3,1573
	YİD Var	131,4	18,6	304,8	21,2	0,8760	0,9350	0,9164	0,8686	0,9806	3,1369
	VAH-1	147,4	2,6	322,4	3,6	0,9827	0,9890	<b>0,9870</b>	<b>0,9794</b>	0,9982	6,2942
	VAH-2	145,0	5,0	322,6	3,4	0,9667	0,9896	0,9824	0,9719	0,9986	6,2942
	VAH-3	148,2	1,8	321,8	4,2	<b>0,9880</b>	0,9871	0,9874	0,9802	<b>0,9986</b>	6,2942
VAH-4	143,8	6,2	324,0	2,0	0,9587	<b>0,9939</b>	0,9828	0,9723	0,9983	6,2942	

Uygulamada son olarak, önerilen yöntemin ve VAH yaklaşımlarının performansını test etmek için tüm veri setleri birleştirilmiştir. Bu kapsamda 150 tanesi COVID-19 ve 406 tanesi COVID-19 değil olmak üzere toplam 556 adet X-ray görüntüsünü içeren bir birleştirilmiş veri seti oluşturulmuştur. Bu aşamada iki kat çapraz doğrulama yapılarak eğitim ve test işlemlerinin gerçekleştirilmiştir. Yani, veri seti her parça içinde 75 adet COVID-19 ve 203 adet COVID-19 değil X-ray görüntüsü olacak şekilde ikiye bölünmüş ve çaprazlama yapılarak eğitim ve test işlemleri gerçekleştirilmiştir. Daha önce gerçekleştirilen deneylerde en iyi sonuçlar doğrudan orijinal görüntüler ve LL alt bandının reel kısmı kullanılarak elde edildiği için sadece bu giriş görüntüleri için deney sonuçları hesaplanmıştır. Deneylerde elde edilen sonuçlar sırasıyla Çizelge 11.19 ve Çizelge 11.20’de verilmiştir.



**Çizelge 11.19.** COVID-19 ve COVID-19 değil sınıflandırmasında doğrudan X-ray görüntüleri kullanılarak elde edilen sonuçlar (iki kat çapraz doğrulama ve birleştirilmiş veri seti)

2B ESA Tipi	Yöntem	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AIKE-AKA	CPU Süresi (saniye)
23 Katmanlı 2B ESA	YİD Yok	138,8	11,2	401,6	4,4	<b>0,9253</b>	<b>0,9892</b>	<b>0,9719</b>	<b>0,9468</b>	<b>0,9937</b>	0,1460
	YİD Var	133,4	16,6	400,8	5,2	0,8893	0,9872	0,9608	0,9241	0,9932	0,1401
	VAH-1	144,8	5,2	406,0	0,0	0,9653	<b>1,0000</b>	<b>0,9906</b>	<b>0,9823</b>	<b>0,9997</b>	0,2861
	VAH-2	139,8	10,2	402,4	3,6	0,9320	0,9911	0,9752	0,9529	0,9991	0,2861
	VAH-3	146,4	3,6	401,6	4,4	<b>0,9760</b>	0,9892	0,9856	0,9734	0,9984	0,2861
VAH-4	137,2	12,8	406,0	0,0	0,9147	<b>1,0000</b>	0,9770	0,9554	0,9977	0,2861	
54 Katmanlı 2B ESA	YİD Yok	138,6	11,4	403,2	2,8	<b>0,9240</b>	<b>0,9931</b>	<b>0,9745</b>	<b>0,9511</b>	<b>0,9949</b>	0,2853
	YİD Var	120,6	29,4	395,0	11,0	0,8040	0,9729	0,9273	0,8565	0,9786	0,2811
	VAH-1	143,0	7,0	405,4	0,6	0,9533	0,9985	0,9863	0,9740	<b>0,9994</b>	0,5664
	VAH-2	141,0	9,0	404,6	1,4	0,9400	0,9966	0,9813	0,9644	0,9992	0,5664
	VAH-3	145,6	4,4	403,0	3,0	<b>0,9707</b>	0,9926	<b>0,9867</b>	<b>0,9752</b>	0,9991	0,5664
VAH-4	136,0	14,0	405,6	0,4	0,9067	<b>0,9990</b>	0,9741	0,9495	0,9964	0,5664	

**Çizelge 11.20.** COVID-19 ve COVID-19 değil sınıflandırmasında X-ray görüntülerine KDDD uygulanarak elde edilen LL alt bandının reel kısmı kullanılması durumu için sonuçlar (iki kat çapraz doğrulama ve birleştirilmiş veri seti)

2B ESA Tipi	Yöntem	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AIKE-AKA	CPU Süresi (saniye)
23 Katmanlı 2B ESA	YİD Yok	136,2	13,8	401,4	4,6	<b>0,9080</b>	<b>0,9887</b>	<b>0,9669</b>	<b>0,9366</b>	<b>0,9939</b>	0,0496
	YİD Var	121,6	28,4	396,0	10,0	0,8107	0,9754	0,9309	0,8634	0,9798	0,0492
	VAH-1	140,8	9,2	405,4	0,6	0,9387	<b>0,9985</b>	<b>0,9824</b>	<b>0,9663</b>	<b>0,9987</b>	0,0987
	VAH-2	138,8	11,2	403,2	2,8	0,9253	0,9931	0,9748	0,9519	0,9985	0,0987
	VAH-3	142,8	7,2	401,4	4,6	<b>0,9520</b>	0,9887	0,9788	0,9603	0,9981	0,0987
VAH-4	134,2	15,8	405,4	0,6	0,8947	<b>0,9985</b>	0,9705	0,9423	0,9965	0,0987	
54 Katmanlı 2B ESA	YİD Yok	137,8	12,2	403,4	2,6	<b>0,9187</b>	<b>0,9936</b>	<b>0,9734</b>	<b>0,9486</b>	<b>0,9975</b>	0,0932
	YİD Var	99,2	50,8	395,0	11,0	0,6613	0,9729	0,8888	0,7580	0,9553	0,0920
	VAH-1	136,4	13,6	406,0	0,0	0,9093	<b>1,0000</b>	0,9755	0,9523	<b>0,9988</b>	0,1852
	VAH-2	139,2	10,8	404,6	1,4	0,9280	0,9966	0,9781	0,9577	0,9987	0,1852
	VAH-3	141,0	9,0	403,4	2,6	<b>0,9400</b>	0,9936	<b>0,9791</b>	<b>0,9603</b>	0,9983	0,1852
VAH-4	133,2	16,8	406,0	0,0	0,8880	<b>1,0000</b>	0,9698	0,9401	0,9987	0,1852	

## 11.6. X-ray Görüntüler Üzerinden COVID-19 ve COVID-19 Değil Sınıflandırma Sonuçlarının Değerlendirilmesi

Uygulamada elde edilen deney sonuçlarının değerlendirildiği bu bölümde öncelikle VAH yaklaşımı kullanılmadan önce elde edilen sonuçlar karşılaştırılmıştır. Çizelge 11.5 ile Çizelge 11.20 arasında verilen deney sonuçları incelendiğinde genel olarak, aynı giriş görüntüsü için YİD kullanılmadan elde edilen deney sonuçlarının YİD

kullanıldıktan sonra elde edilen deney sonuçlarından daha iyi olduğu görülmektedir. Bu kapsamda sadece, birinci veri seti için 23 katmanlı 2B ESA mimarisi kullanılarak elde edilen duyarlılık parametresi sonuçlarında bazı istisnalar olduğu anlaşılmaktadır. Uygulamada VAH yaklaşımları kullanılmadan önce elde edilen en yüksek duyarlılık, özgüllük, doğruluk, F-1 skoru ve AİKE-AKA parametreleri birinci veri seti ve 23 katmanlı 2B ESA mimarisi için sırasıyla 0,9853; 0,9725; 0,9765; 0,9819; 0,9983; birinci veri seti ve 54 katmanlı 2B ESA mimarisi için sırasıyla 0,9613; 0,9725; 0,9600; 0,9691; 0,9949; ikinci veri seti ve 23 katmanlı 2B ESA mimarisi için sırasıyla 0,9720; 0,9908; 0,9845; 0,9752; 0,9982; ikinci veri seti ve 54 katmanlı 2B ESA mimarisi için sırasıyla 0,9733; 0,9920; 0,9857; 0,9772; 0,9987'dir. Uygulamada 23 katmanlı 2B ESA ve 54 katmanlı 2B ESA mimarilerinin başarılarının genel olarak birbirine yakın olduğu görülmektedir. Ancak; çalışma süresi açısından bir karşılaştırma yapıldığında, 54 katmanlı 2B ESA mimarisinin 23 katmanlı 2B ESA mimarisine göre iki kat daha yavaş olduğu anlaşılmaktadır. Bunun temel nedeni, 54 katmanlı 2B ESA mimarisindeki katman sayısının 23 katmanlı 2B ESA mimarisindeki katman sayısının yaklaşık olarak iki katı olmasıdır. Uygulamada birinci ve ikinci veri seti birleştirilerek ve iki kat çapraz doğrulama kullanılarak yapılan deneylerde de benzer bir durum söz konusudur. Bu deneyler için VAH yaklaşımı kullanılmadan önce elde edilen en yüksek duyarlılık, özgüllük, doğruluk, F-1 skoru ve AİKE-AKA parametreleri 23 katmanlı 2B ESA mimarisi için sırasıyla 0,9253; 0,9892; 0,9719; 0,9468; 0,9939 ve 54 katmanlı 2B ESA mimarisi için sırasıyla 0,9240; 0,9936; 0,9745; 0,9511; 0,9975 olarak gerçekleşmiştir.

Uygulamada görüntü boyutlarının küçültülmesi için KDDD kullanılmıştır. Bu sayede VAH yaklaşımı kullanılması nedeniyle sonuç üretme süresindeki artış tolere edilmiştir. Bu kapsamda orijinal görüntüler kullanılarak elde edilen deney sonuçları ile KDDD kullanılarak elde edilen deney sonuçları karşılaştırıldığında, genel olarak deney sonuçlarında ciddi bir düşüş olmadığı görülmektedir. Uygulamada KDDD kullanılarak görüntü boyutları başarılı bir şekilde küçültülmüş ve sonuç üretme sürelerinde azalma sağlanmıştır.

Uygulamada önerilen VAH yaklaşımları, daha önce detaylandırıldığı gibi YİD kullanılmadan ve YİD kullanıldıktan sonra elde edilen sonuçların birleştirilmesine dayanmaktadır. VAH yaklaşımlarının kullanılmasıyla uygulamada yararlanılan tüm veri setleri ve 2B ESA mimarileri için edilen tüm değerlendirme parametrelerinde iyileştirmeler sağlanmıştır. Bu kapsamda; duyarlılık parametresinde %0,67 ile %3,73 arasında değişen, özgüllük parametresinde %0,06 ile %2,25 arasında değişen, doğruluk

parametresinde %0 ile %2,61 arasında deęişen, F-1 skoru parametresinde %0,03 ile %2,04 arasında deęişen ve AİKE-AKA parametresinde %0 ile %1,20 arasında deęişen miktarlarda iyileşme sağlandığı görülmektedir.

Tüm verilerin birleştirilmesi ve iki kat çaprazlama kullanılarak yapılan deneylerde de benzer bir durumun olduğu görülmektedir. VAH yaklaşımları kullanıldıktan sonra; duyarlılık parametresinde %2,13 ile %5,07 arasında deęişen, özgüllük parametresinde %0,59 ile %1,08 arasında deęişen, doğruluk parametresinde %0,58 ile %1,87 arasında deęişen, F-1 skoru parametresinde %1,18 ile %3,55 arasında deęişen ve AİKE-AKA parametresinde %0,13 ile %0,59 arasında deęişen miktarlarda iyileşme sağlanmıştır.

Uygulamada kullanılan VAH yaklaşımlarının genel olarak sonuçları iyileştirmedeki başarıları karşılaştırıldığında, VAH-1 ve VAH-3 yaklaşımlarının en yüksek duyarlılık değerlerinin elde edilmesini; VAH-4 yaklaşımının en yüksek özgüllük değerlerinin elde edilmesini; VAH-1 ve VAH-3 yaklaşımının en yüksek doğruluk değerlerinin elde edilmesini; VAH-1 ve VAH-3 yaklaşımının en yüksek F-1 skoru değerlerinin elde edilmesini; VAH-1, VAH-2 ve VAH-3 yaklaşımlarının ise en yüksek AİKE-AKA değerlerinin elde edilmesini sağladığı görülmektedir.

Uygulamada VAH kullanılması durumunda en iyi sonuçların elde edilmesi sağlayan giriş verileri incelendiğinde, birinci veri seti için LL alt görüntü bandının reel kısmının ve ikinci veri seti için doğrudan orijinal görüntülerin kullanılmasının en iyi sonuçların elde edilmesini sağladığı görülmektedir. Bu nedenle, tüm veri setleri birleştirerek ve iki kat çapraz doğrulama kullanılarak yapılan deneylerde, uygulamanın uzunluğu da dikkate alınarak, sadece bu giriş görüntüleri için sonuçlar uygulamaya dahil edilmiştir.

Uygulamada VAH yaklaşımları kullanılmadan önce ve VAH yaklaşımı kullanıldıktan sonra elde edilen en iyi deney sonuçlarının literatürde yer alan çalışmalarda elde edilen sonuçlarla karşılaştırılması Çizelge 11.21'de verilmiştir. Uygulamada VAH yaklaşımı kullanılarak elde edilen en yüksek duyarlılık, özgüllük, doğruluk, F-1 skoru ve AİKE-AKA parametreleri; birinci veri seti ve 23 katmanlı 2B ESA mimarisi için sırasıyla 0,9947; 0,9800; 0,9843; 0,9881; 0,9990; birinci veri seti ve 54 katmanlı 2B ESA mimarisi için sırasıyla 0,9867; 0,9800; 0,9809; 0,9853; 0,9977; ikinci veri seti ve 23 katmanlı 2B ESA mimarisi için sırasıyla 0,9853; 0,9926; 0,9857; 0,9774; 0,9988; ikinci eğitim testi ve 54 katmanlı 2B ESA mimarisi için sırasıyla 0,9920; 0,9939; 0,9891; 0,9828; 0,9991 olarak gerçekleşmiştir. Tüm veri setleri

birleştirilerek ve iki kat çapraz doğrulama kullanılarak yapılan deneylerde elde edilen en yüksek duyarlılık, özgüllük, doğruluk, F-1 skoru ve AİKE-AKA parametreleri 23 katmanlı 2B ESA mimarisi için sırasıyla 0,9760; 1,0000; 0,9906; 0,9823; 0,9997; 54 katmanlı 2B ESA mimarisi için sırasıyla 0,9707; 1,0000; 0,9867; 0,9752; 0,9994 olarak hesaplanmıştır.

**Çizelge 11.21.** Tez çalışmasının beşinci uygulamasında X-ray görüntülerden COVID-19 ve COVID-19 değil sınıflandırması için elde edilen sonuçların literatürde yer alan çalışmalarda elde edilen sonuçlar ile karşılaştırması

Çalışma	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AİKE-AKA	
Tuncer ve ark., 2020	0,8149-1,0000	0,9380-1,0000	0,9049-0,9955	X	X	
Panwar ve ark., 2020	0,9762	0,7857	0,881	X	X	
Öztürk ve ark., 2020	0,9513	0,953	0,9808	0,9651	X	
Mohammed ve ark., 2020	0,706-0,974	0,557-1,000	0,620-0,987	0,555-0,987	0,800-0,988	
Khan ve ark., 2020	0,993	0,986	0,990	0,985	X	
Apostolopoulos ve Mpesiana, 2020	0,9866	0,9646	0,9678	X	X	
Waheed ve ark., 2020	0,69-0,90	0,95-0,97	0,85-0,95	X	X	
Mahmud ve ark., 2020	0,978	0,947	0,974	0,971	0,969	
Vaid ve ark., 2020	0,9863	0,9166	0,9633	0,9729	X	
Benbrahim ve ark., 2020	0,9803-0,9811	X	0,9803-0,9901	0,9803-0,9901	X	
Elaziz ve ark., 2020	0,9875-0,9891	X	0,9609-0,9809	X	X	
Martínez ve ark., 2020	0,97	X	0,97	0,97	X	
Loey ve ark., 2020	1,0000	1,0000	1,0000	X	X	
Toraman ve ark., 2020	0,28-0,9742	0,8095-0,98	0,4914-0,9724	0,55-0,9724	X	
Duran-Lopez ve ark., 2020	0,9253	0,9633	0,9443	0,9314	0,988	
Minaee ve ark., 2020	0,98	0,751-0,929	X	X	X	
VAH Kullanılmadan	Birinci Veri Seti	<b>0,9853</b>	0,8950	0,9539	0,9655	0,9939
	Birinci Veri Seti	0,9747	<b>0,9725</b>	0,9739	0,9799	0,9976
	Birinci Veri Seti	0,9800	0,9700	<b>0,9765</b>	<b>0,9819</b>	0,9975
	Birinci Veri Seti	0,9773	0,9675	0,9739	0,9800	<b>0,9983</b>
	İkinci Veri Seti	<b>0,9733</b>	0,9914	<b>0,9857</b>	<b>0,9772</b>	0,9981
	İkinci Veri Seti	0,9640	<b>0,9920</b>	0,9832	0,9730	0,9985
	İkinci Veri Seti	0,9680	0,9902	0,9832	0,9732	<b>0,9982</b>
	Birleştirilmiş Veri Seti	<b>0,9253</b>	0,9892	0,9719	0,9468	0,9937
	Birleştirilmiş Veri Seti	0,9187	<b>0,9936</b>	0,9734	0,9486	<b>0,9975</b>
	Birleştirilmiş Veri Seti	0,9240	0,9931	<b>0,9745</b>	<b>0,9511</b>	0,9949
VAH Kullanılarak	Birinci Veri Seti	<b>0,9947</b>	0,9575	0,9817	0,9862	<b>0,9990</b>
	Birinci Veri Seti	0,9813	<b>0,9800</b>	0,9809	0,9853	0,9977
	Birinci Veri Seti	0,9933	0,9675	<b>0,9843</b>	<b>0,9881</b>	0,9988
	İkinci Veri Seti	<b>0,9920</b>	0,9877	<b>0,9891</b>	<b>0,9828</b>	<b>0,9991</b>
	İkinci Veri Seti	0,9640	<b>0,9939</b>	0,9845	0,9750	0,9980
	Birleştirilmiş Veri Seti	<b>0,9760</b>	0,9892	0,9856	0,9734	0,9984
	Birleştirilmiş Veri Seti	0,9653	<b>1,0000</b>	<b>0,9906</b>	<b>0,9823</b>	<b>0,9997</b>

Uygulamada elde edilen sayısal sonuçlarının daha önce yapılmış çalışmaların sayısal sonuçlarıyla doğrudan karşılaştırılması doğru bir yaklaşım değildir. Çünkü, kullanılan toplam görüntü sayısı, test ve eğitim yaklaşımı, test ve eğitim görüntü sayısındaki farklılıklar sonuçlar üzerinde doğrudan etkili faktörlerdir. Ancak Çizelge 11.21 dikkate alınarak bir karşılaştırma yapmak gerekirse; duyarlılık parametresi için bu

parametrenin hesaplandığı on altı çalışmanın on dört tanesinden, özgüllük parametresi için bu parametrenin hesaplandığı on üç çalışmanın tamamından, doğruluk parametresi için bu parametrenin hesaplandığı on beş çalışmanın on üç tanesinden, F-1 skoru parametresi için bu parametrenin hesaplandığı dokuz çalışmanın sekiz tanesinden ve AİKE-AKA parametresi için bu parametrenin hesaplandığı üç çalışmanın tamamından daha yüksek sonuçlar elde edildiği görülmektedir. Çalışma süreleri açısından bir karşılaştırma yapıldığında Mohammed ve ark. (2020) tarafından gerçekleştirilen çalışmada elde edilen sonuç üretme süresine göre en az üç kat daha hızlı sonuç üretildiği tespit edilmiştir. Ayrıca, Toraman ve ark. (2020) tarafından gerçekleştirilen çalışmaya göre en az on kat daha hızlı sonuç üretilmiştir. Bu iki çalışma, çalışma sürelerinin paylaşıldığı çalışmalardır. Diğer literatür çalışmalarında çalışma süreleri hakkında bilgi verilmemiştir.

Genel olarak, uygulamada elde edilen sonuçlar Tuncer ve arkadaşları (2020), Benbrahim ve arkadaşları (2020) ve Loey ve arkadaşları (2020) tarafından yapılan çalışmalarda elde edilen sonuçların gerisinde kalmıştır. Ancak daha detaylı bir karşılaştırma yapabilmek için bu çalışmalarda kullanılan görüntü sayıları ile bu uygulamada kullanılan görüntü sayılarının karşılaştırılması gerekmektedir. Uygulamada kullanılan görüntü sayısının bu çalışmalarda kullanılan görüntü sayısından fazla olduğu görülmektedir. Uygulamada kullanılan görüntü sayısı Loey ve arkadaşları (2020) tarafından gerçekleştirilen çalışmada kullanılan görüntü sayısının hemen hemen üç katıdır. Bir diğer önemli husus ise çalışmalarda kullanılan eğitim ve test prosedürleridir. Benbrahim ve arkadaşları (2020) ile Loey ve arkadaşları (2020) tarafından gerçekleştirilen çalışmalarda çapraz doğrulama yapılmamıştır. Uygulamada gerçekleştirilen eğitim ve test süreçlerinde çapraz doğrulama yapılması 2B ESA mimarilerinin eğitimi sırasında oluşan aşırı uyum sorununa karşı alınan önlemlerden bir tanesidir. Çapraz doğrulamanın deney sonuçlarını stabilize ettiği ve sonuçlarının güvenilirliğini arttırdığı bilinmektedir. Karşılaştırma yapılırken bu hususların da dikkate alınması gerekmektedir.

## **12. X-RAY GÖRÜNTÜLER ÜZERİNDEN COVID-19 VE SAĞLIKLI, COVID-19 ZATÜRRESİ VE BAKTERİYEL ZATÜRRE, COVID-19 ZATÜRRESİ VE VİRAL ZATÜRRE İLE COVID-19 ZATÜRRESİ VE DİĞER ZATÜRRE SINIFLANDIRMASI**

Tez çalışmasının altıncı uygulamasında X-ray görüntüler üzerinden COVID-19 ve sağlıklı, COVID-19 zatürresi ve bakteriyel zatürre, COVID-19 zatürresi ve viral zatürre ile COVID-19 zatürresi ve diğer zatürre olmak üzere toplam dört başlıkta iki sınıflı sınıflandırma gerçekleştirilmiştir. Söz konusu uygulama sonuçları Yaşar ve Ceylan tarafından (Yaşar ve Ceylan, 2022(b)) yayınlanmıştır.

### **12.1. Uygulamada Kullanılan Veriler**

Uygulamada kullanılan X-ray görüntüleri sekiz farklı açık erişimli veri seti birleştirilerek elde edilmiştir. Bu veri setlerinden alınan X-ray görüntülerinin sayısal bilgileri Çizelge 12.1’de verilmiştir. Uygulamada COVID-19 ve sağlıklı, COVID-19 zatürresi ve bakteriyel zatürre, COVID-19 zatürresi ve viral zatürre ile COVID-19 zatürresi ve diğer zatürre olmak üzere dört başlıkta iki sınıflı sınıflandırma yapılmıştır. Çizelge 12.1’de görüldüğü gibi COVID-19 ve sağlıklı sınıflandırması için 3.405 COVID-19 ve 1.989 sağlıklı olmak üzere toplam 5.394 X-ray görüntüsü kullanılmıştır. COVID-19 zatürresi ve bakteriyel zatürre sınıflandırmasında 3.405 COVID-19 ve 2.780 bakteriyel zatürre olmak üzere toplam 6.185 X-ray görüntüsünden yararlanılmıştır. COVID-19 zatürresi ve viral zatürre sınıflandırması için 3.405 COVID-19 ve 1.493 viral zatürre olmak üzere toplam 4.898 X-ray görüntüsü kullanılmıştır. Son sınıflandırma başlığı olan COVID-19 zatürresi ve diğer zatürre sınıflandırması için 3.405 COVID-19 ve 4.273 diğer zatürre olmak üzere toplam 7.678 X-ray görüntüsünden yararlanılmıştır. Bu sınıflandırma başlığındaki diğer zatürre X-ray görüntüleri bakteriyel zatürre ve viral zatürre X-ray görüntülerinin birleştirilmesiyle elde edilmiştir. Uygulamada kullanılan X-ray görüntülerinin %90’ından fazlası gerçek dünyadan alınmıştır. Uygulamada kullanılan COVID-19 X-ray görüntülerinin sayısı ile literatürde yer alan çalışmalarda kullanılan görüntü sayıları karşılaştırıldığında, uygulamada kullanılan görüntü sayısının literatürde yer alan çalışmalarda kullanılan ortalama görüntü sayısının on katından daha fazla olduğu görülmektedir.

**Çizelge 12.1.** Tez çalışmasının altıncı uygulamasında kullanılan COVID-19, sağlıklı, bakteriyel zatürre ve viral zatürre X-ray görüntülerine ilişkin bilgiler

Kaynak	COVID-19	Diğer Zatürre		Sağlıklı
		Bakteriyel Zatürre	Viral Zatürre	
Cohen ve ark., 2020	462	X	X	X
Wang ve ark., 2020(c)	35	X	X	X
Winther ve ark., 2020	243	X	X	X
Desai ve ark., 2020	253	X	X	X
Vayá ark., 2020	2.412	X	X	X
Kermany ve ark., 2018	X	2.780	1.493	1.583
Jaeger ve ark., 2014 (Montgomery)	X	X	X	80
Jaeger ve ark., 2014 (Shenzhen)	X	X	X	326
	3.405	2.780	1.493	1.989
Toplam	3.405	4.273		1.989
		9.667		

Uygulamada birçok veri setinden görüntüler toplandığı için ön işleme yapılarak görüntülerin kullanıma uygun hale getirilmesi gerekmektedir. Uygulamada kullanılan görüntüler jpeg, jpg, png ve dicom olmak üzere dört farklı formatta kaydedilmiştir. Bu görüntülerin boyutları 154×124 ile 4064×2992 arasında değişmektedir. Ayrıca, görüntülerin bit derinliği 16, 24, 32 ve 48 olmak üzere farklılıklar göstermektedir. Söz konusu görüntüler öncelikle tüm göğüs bölgesini kaplayacak şekilde çerçevelenmiş ve görüntülerden ilgisiz alanlar çıkarılmıştır. Daha sonra, 8 bitlik gri seviye formatına dönüştürülmüştür. Son olarak, görüntü boyutları 224×224 olarak yeniden düzenlenmiştir. Bu ön işlemler tüm X-ray görüntülerine uygulanarak, 224×224×1 boyutlarında ve 8 bit gri seviyeli 9.667 adet görüntü matrisi elde edilmiştir.

## 12.2. Özellik Çıkarma, ESA Modifikasyonları ve Hiperparametreler

Tez çalışmasının altıncı uygulamasında yararlanılan YİD yönteminin işletilmesinde kullanılan yarıçap değeri 1 olarak seçilmiştir. YİD işlemi sonunda görüntü boyutlarında azalma olması sebebiyle, MATLAB *imresize* fonksiyonu kullanılarak görüntü boyutları yeniden düzenlenmiştir. LE görüntülerinin elde edilmesinde MATLAB *entropyfilt* fonksiyonu kullanılmıştır. Fonksiyonun işletilmesi varsayılan parametrelerle yapılmıştır. LE görüntülerinin piksel değerleri MATLAB *rescale* fonksiyonu kullanılarak 0 ile 255 arasına normalize edilerek uygulamada kullanılmıştır.

Uygulamada 2B MobileNetV2 ESA, 2B ResNet-101 ESA ve 2B GoogleNet ESA transfer öğrenme mimarilerinin kullanılabilmesi için üzerlerinde bazı

modifikasyonların yapılması gerekmektedir. Giriş görüntüsündeki satır ve sütun büyüklüğü özgün mimarideki değerler olarak korunmuştur. Ancak giriş verilerinin üçüncü boyutu çalışmanın gereksinimlerine göre 1, 2 ve 3 olarak yeniden düzenlenmiştir. Bu kapsamda modifiye edilmiş 2B MobileNetV2 ESA, 2B ResNet-101 ESA ve 2B GoogleNet ESA mimarisinin yeni giriş görüntü boyutları  $224 \times 224 \times 1$ ,  $224 \times 224 \times 2$  ve  $224 \times 224 \times 3$ 'tür. Uygulamada COVID-19 ve sağlıklı, COVID-19 zatürresi ve bakteriyel zatürre, COVID-19 zatürresi ve viral zatürre ile COVID-19 zatürresi ve diğer zatürre olmak üzere iki sınıflı sınıflandırmalar yapıldığı için her üç transfer öğrenme 2B ESA mimarisinde de tam bağlı katman çıkış boyutu 2 olarak yeniden düzenlenmiştir.

Eğitimler sırasında ilk ağırlık transferi yapılmamıştır. Yani tüm ESA mimarileri baştan rastgele atanan ağırlıklarla eğitilmiştir. Uygulamada yararlanılan yazılım MATLAB 2020(b) kullanılarak oluşturulmuştur. ESA eğitiminde ağ çözücü olarak momentumlu stokastik gradyan inişi seçilmiştir. Maksimum iterasyon sayısı program tarafından varsayılan değer kabul edilen 30 olarak belirlenmiştir. Bu tercihin temel nedeni aşırı uyum probleminden kaçınmaktır. Yani, bu değeri yüksek seçmek yerine varsayılan değer kullanılarak erken durdurma yapılmıştır. Küme boyutu 64 olarak ayarlanmıştır. Aşırı uyum problemine karşı önlem olarak veri karıştırma seçenekleri her iterasyon olarak belirlenmiştir. Uygulamada başlangıç öğrenme oranı varsayılan değer olarak kabul edilen 0,01 olarak seçilmiştir. Momentum, gradyan bozunma faktörü, sıra doldurma gibi diğer tüm parametreler varsayılan değerler olarak ayarlanmıştır. MathWorks sayfasından (MathWorks, 2022(a)) eğitim parametreleri açıklamalarının ve varsayılan değerlerin incelenmesi mümkündür.

### 12.3. Deneyle

Uygulamada COVID-19 ve sağlıklı, COVID-19 zatürresi ve bakteriyel zatürre, COVID-19 zatürresi ve viral zatürre ile COVID-19 zatürresi ve diğer zatürre olmak üzere dört farklı başlıkta iki sınıflı sınıflandırma yapılmıştır. Uygulamada sekiz farklı açık erişimli veri setinin birleştirilmesiyle elde edilen 3.405 COVID-19, 2.780 bakteriyel zatürre, 1.493 viral zatürre ve 1.989 sağlıklı görüntüsü kullanılmıştır. Çizelge 12.1'de görüldüğü gibi COVID-19 ve sağlıklı sınıflandırması için 3.405 COVID-19 ve 1.989 COVID-19 değil olmak üzere toplam 5.394 X-ray görüntüsü kullanılmıştır. COVID-19 zatürresi ve bakteriyel zatürre sınıflandırmasında 3.405 COVID-19 ve 2.780



bakteriyel zatürre olmak üzere toplam 6.185 X-ray görüntüsünden yararlanılmıştır. COVID-19 zatürresi ve viral zatürre sınıflandırması için 3.405 COVID-19 ve 1.493 viral zatürre olmak üzere toplam 4.898 X-ray görüntüsü kullanılmıştır. Son sınıflandırma başlığı olan COVID-19 zatürresi ve diğer zatürre sınıflandırması için 3.405 COVID-19 ve 4.273 diğer zatürre olmak üzere toplam 7.678 X-ray görüntüsünden yararlanılmıştır. Bu sınıflandırma başlığındaki diğer zatürre X-ray görüntüleri bakteriyel zatürre ve viral zatürre X-ray görüntülerinin birleştirilmesiyle elde edilmiştir.

Uygulamada ilk olarak X-ray görüntüleri düzenlenerek standardize edilmiştir. X-ray görüntüleri, akciğer bölgesini içine alacak şekilde çerçevelenmiştir. Bu sayede X-ray görüntülerinde yer alan ilgisiz alanlar görüntülerden çıkarılmıştır. Daha sonra görüntüler, 8 bit derinliğinde gri seviye formatına dönüştürülmüştür. Son olarak, görüntülerin boyutları  $224 \times 224$  olarak yeniden düzenlenmiştir.

Uygulamada ikinci olarak, doku analiz yöntemleri kullanılarak orijinal görüntülerden yeni özellik görüntüleri elde edilmiştir. Bu kapsamda YİD ve LE olmak üzere iki farklı doku analizi yöntemi kullanılmıştır. Bu yöntemler tüm orijinal görüntülere uygulanarak yeni özellik görüntüleri oluşturulmuştur. Bu yeni görüntülerin boyutları ve özellikleri orijinal görüntülerle aynı ( $224 \times 224$ , 8 bit gri seviye) olacak şekilde yeniden düzenlenmiştir.

Uygulamada üçüncü olarak, transfer öğrenme 2B ESA mimarileri kullanılarak sınıflandırma işlemleri yapılmıştır. Transfer öğrenme 2B ESA mimarisi olarak daha önce detayları ve üzerinde yapılan değişiklikler açıklanan 2B MobileNetV2, 2B ResNet-101 ve 2B GoogleNet kullanılmıştır. Transfer öğrenme 2B ESA mimarilerine giriş olarak verilecek görüntüler; Orijinal, YİD ve LE görüntülerinin tek başına veya birlikte kullanılmasıyla oluşturulmuştur. Bu kapsamda altı farklı giriş görüntü kombinasyonu (Orijinal, YİD, LE, Orijinal+YİD, Orijinal+LE, Orijinal+YİD+LE) için sınıflandırma sonuçları hesaplanmıştır.

Uygulamada dördüncü olarak, sınıflandırma işlemleri 24 katmanlı 3B ESA mimarisi kullanılarak gerçekleştirilmiştir. 24 katmanlı 3B ESA mimarisi giriş görüntüleri; Orijinal, YİD ve LE görüntülerinin doğrudan veya birlikte kullanılmasıyla oluşturulmuştur. 3B giriş görüntülerinin üçüncü boyut uzunluğu 24 olarak belirlenmiştir. Uygulamada altı farklı giriş görüntü kombinasyonu (Orijinal $\times$ 24, YİD $\times$ 24, LE $\times$ 24, (Orijinal+YİD) $\times$ 12, (Orijinal+LE) $\times$ 12, (Orijinal+YİD+LE) $\times$ 8) için sınıflandırma sonuçları hesaplanmıştır.

Uygulamanın eğitim ve test işlemleri beş kat çapraz doğrulama prosedürüne göre gerçekleştirilmiştir. Eğitimler sırasında ilk ağırlık transferi yapılmamıştır. Tüm transfer öğrenme 2B ESA mimarileri ve 24 katmanlı 3B ESA mimarisi baştan rastgele atanan ağırlıklarla eğitilmiştir. Uygulamada gerçekleştirilen tüm deneylerde daha önce detayları açıklanan eğitim seçenekleri kullanılmıştır. Uygulama kapsamında bir görüntünün sınıflandırılması için ihtiyaç duyulan süreler (CPU süresi) saniye cinsinden ölçülmüştür. Uygulamanın deneylerinde MATLAB 2020(b) yazılımı ve 64 GB RAM'e sahip Intel (R) Xeon (R) CPU E5-2680 2,7 GHz (32 CPU) bir bilgisayar kullanılmıştır. Uygulamada verilen tüm CPU çalışma süreleri saniye cinsinden zamanı göstermektedir.

## **12.4. Deney Sonuçları**

Uygulamanın deney sonuçları her sınıflandırma başlığı için ayrı ayrı hesaplanmış ve verilmiştir.

### **12.4.1. COVID-19 ve sağlıklı sınıflandırma sonuçları**

Uygulamada ilk olarak COVID-19 ve sağlıklı sınıflandırması için deneyler yapılmıştır. Bu deneylerde 2B MobileNetV2, 2B ResNet-101 ve 2B GoogleNet için giriş görüntü boyutları Orijinal, YİD ve LE için  $224 \times 224 \times 1$ ; Orijinal+YİD ve Orijinal+LE için  $224 \times 224 \times 2$ ; Orijinal+YİD+LE için  $224 \times 224 \times 3$ 'dür. 2B MobileNetV2, 2B ResNet-101 ve 2B GoogleNet kullanılarak elde edilen sınıflandırma sonuçları sırasıyla Çizelge 12.2 ile Çizelge 12.4 arasında verilmiştir. 24 katmanlı 3B ESA'ya giriş olarak verilen görüntülerin boyutları ise  $224 \times 224 \times 24 \times 1$ 'dir. Çizelge 12.5, 24 katmanlı 3B ESA kullanılarak elde edilen sınıflandırma sonuçlarını göstermektedir. Çizelgelerde en yüksek parametre değerleri koyu olarak belirtilmiştir. Bu işaretleme devam eden diğer çizelgeler içinde yapılmıştır.

**Çizelge 12.2.** COVID-19 ve sağlıklı sınıflandırmasında 2B MobileNetV2 ESA kullanılarak elde edilen sonuçlar

Giriş Görüntü Tipi	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AIKE-AKA	CPU Süresi (saniye)
Orijinal	3376	29	1965	24	0,99148	<b>0,98793</b>	<b>0,99017</b>	<b>0,99221</b>	<b>0,99932</b>	1,52888
YİD	3340	65	1914	75	0,98091	0,96229	0,97405	0,97947	0,99640	1,53781
LE	3367	38	1938	51	0,98884	0,97436	0,98350	0,98696	0,99828	1,53571
Orijinal+YİD	3372	33	1939	50	0,99031	0,97486	0,98461	0,98784	0,99884	1,60890
Orijinal+LE	3382	23	1945	44	<b>0,99325</b>	0,97788	0,98758	0,99019	0,99902	1,61216
Orijinal+YİD+LE	3376	29	1936	53	0,99148	0,97335	0,98480	0,98800	0,99871	1,67478

**Çizelge 12.3.** COVID-19 ve sağlıklı sınıflandırmasında 2B ResNet-101 ESA kullanılarak elde edilen sonuçlar

Giriş Görüntü Tipi	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AIKE-AKA	CPU Süresi (saniye)
Orijinal	3378	27	1958	31	0,99207	0,98441	0,98925	0,99149	0,99878	3,29425
YİD	3370	35	1949	40	0,98972	0,97989	0,98610	0,98899	0,99882	3,30719
LE	3376	29	1950	39	0,99148	0,98039	0,98739	0,99003	0,99909	3,29880
Orijinal+YİD	3375	30	1955	34	0,99119	0,98291	0,98813	0,99061	0,99919	3,38626
Orijinal+LE	3369	36	1952	37	0,98943	0,98140	0,98647	0,98928	0,99912	3,37695
Orijinal+YİD+LE	3380	25	1963	26	<b>0,99266</b>	<b>0,98693</b>	<b>0,99055</b>	<b>0,99251</b>	<b>0,99949</b>	3,46030

**Çizelge 12.4.** COVID-19 ve sağlıklı sınıflandırmasında 2B GoogleNet ESA kullanılarak elde edilen sonuçlar

Giriş Görüntü Tipi	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AIKE-AKA	CPU Süresi (saniye)
Orijinal	3374	31	1967	22	<b>0,99090</b>	<b>0,98894</b>	<b>0,99017</b>	<b>0,99221</b>	0,99859	0,76668
YİD	3318	87	1887	102	0,97445	0,94872	0,96496	0,97231	0,99205	0,77280
LE	3371	34	1966	23	0,99001	0,98844	0,98943	0,99162	0,99922	0,77345
Orijinal+YİD	3371	34	1930	59	0,99001	0,97034	0,98276	0,98639	0,99784	0,84699
Orijinal+LE	3374	31	1962	27	<b>0,99090</b>	0,98643	0,98925	0,99148	<b>0,99929</b>	0,84578
Orijinal+YİD+LE	3374	31	1943	46	<b>0,99090</b>	0,97687	0,98572	0,98872	0,99817	0,93245

**Çizelge 12.5.** COVID-19 ve sağlıklı sınıflandırmasında 24 katmanlı 3B ESA kullanılarak elde edilen sonuçlar

Giriş Görüntü Tipi	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AIKE-AKA	CPU Süresi (saniye)
(Orijinal)×24	3385	20	1965	24	<b>0,99413</b>	0,98793	0,99184	0,99354	0,99931	4,30136
(YİD)×24	3377	28	1957	32	0,99178	0,98391	0,98888	0,99119	0,99934	4,33525
(LE)×24	3374	31	1955	34	0,99090	0,98291	0,98795	0,99046	0,99881	4,48620
(Orijinal+YİD)×12	3383	22	1966	23	0,99354	0,98844	0,99166	0,99339	0,99923	4,39649
(Orijinal+LE)×12	3377	28	1967	22	0,99178	0,98894	0,99073	0,99265	0,99946	4,42985
(Orijinal+YİD+LE)×8	3385	20	1969	20	<b>0,99413</b>	<b>0,98994</b>	<b>0,99258</b>	<b>0,99413</b>	<b>0,99958</b>	4,24820

#### 12.4.2. COVID-19 zatürresi ve bakteriyel zatürre sınıflandırma sonuçları

Uygulamada ikinci olarak COVID-19 zatürresi ve bakteriyel zatürre sınıflandırması yapılmıştır. Bu deneylerde 2B MobileNetV2, 2B ResNet-101 ve 2B GoogleNet için giriş görüntü boyutları Orijinal, YİD ve LE için 224×224×1; Orijinal+YİD ve Orijinal+LE için 224×224×2; Orijinal+YİD+LE için 224×224×3'dür. 2B MobileNetV2, 2B ResNet-101 ve 2B GoogleNet kullanılarak elde edilen sınıflandırma sonuçları sırasıyla Çizelge 12.6 ile Çizelge 12.8 arasında verilmiştir. 24 katmanlı 3B ESA'ya giriş olarak verilen görüntülerin boyutları ise 224×224×24×1'dir. Çizelge 12.9, 24 katmanlı 3B ESA kullanılarak elde edilen sınıflandırma sonuçlarını göstermektedir.

**Çizelge 12.6.** COVID-19 zatürresi ve bakteriyel zatürre sınıflandırmasında 2B MobileNetV2 ESA kullanılarak elde edilen sonuçlar

Giriş Görüntü Tipi	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AIKE-AKA	CPU Süresi (saniye)
Orijinal	3388	17	2764	16	0,99501	<b>0,99424</b>	<b>0,99466</b>	<b>0,99515</b>	0,99934	1,52733
YİD	3376	29	2736	44	0,99148	0,98417	0,98820	0,98930	0,99903	1,52932
LE	3386	19	2751	29	0,99442	0,98957	0,99224	0,99296	0,99912	1,52560
Orijinal+YİD	3383	22	2755	25	0,99354	0,99101	0,99240	0,99310	<b>0,99940</b>	1,60832
Orijinal+LE	3392	13	2758	22	<b>0,99618</b>	0,99209	0,99434	0,99487	0,99891	1,60963
Orijinal+YİD+LE	3386	19	2762	18	0,99442	0,99353	0,99402	0,99457	0,99904	1,67383

**Çizelge 12.7.** COVID-19 zatürresi ve bakteriye zatürre sınıflandırmasında 2B ResNet-101 ESA kullanılarak elde edilen sonuçlar

Giriş Görüntü Tipi	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AIKE-AKA	CPU Süresi (saniye)
Orijinal	3372	33	2756	24	0,99031	0,99137	0,99078	0,99162	0,99892	3,28368
YİD	3378	27	2752	28	0,99207	0,98993	0,99111	0,99192	0,99926	3,29297
LE	3382	23	2749	31	0,99325	0,98885	0,99127	0,99208	0,99872	3,29466
Orijinal+YİD	3382	23	2760	20	0,99325	<b>0,99281</b>	0,99305	0,99368	<b>0,99934</b>	3,35726
Orijinal+LE	3374	31	2760	20	0,99090	<b>0,99281</b>	0,99175	0,99250	0,99891	3,36263
Orijinal+YİD+LE	3385	20	2759	21	<b>0,99413</b>	0,99245	<b>0,99337</b>	<b>0,99398</b>	0,99925	3,43009

**Çizelge 12.8.** COVID-19 zatürresi ve bakteriye zatürre sınıflandırmasında 2B GoogleNet ESA kullanılarak elde edilen sonuçlar

Giriş Görüntü Tipi	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AIKE-AKA	CPU Süresi (saniye)
Orijinal	3391	14	2752	28	0,99589	0,98993	0,99321	0,99385	0,99866	0,77360
YİD	3377	28	2743	37	0,99178	0,98669	0,98949	0,99047	0,99892	0,77290
LE	3387	18	2768	12	0,99471	<b>0,99568</b>	<b>0,99515</b>	<b>0,99559</b>	0,99922	0,77270
Orijinal+YİD	3394	11	2742	38	<b>0,99677</b>	0,98633	0,99208	0,99283	<b>0,99929</b>	0,84987
Orijinal+LE	3385	20	2750	30	0,99413	0,98921	0,99192	0,99267	0,99896	0,84982
Orijinal+YİD+LE	3387	18	2753	27	0,99471	0,99029	0,99272	0,99340	0,99916	0,93361

**Çizelge 12.9.** COVID-19 zatürresi ve bakteriye zatürre sınıflandırmasında 24 katmanlı 3B ESA kullanılarak elde edilen sonuçlar

Giriş Görüntü Tipi	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AIKE-AKA	CPU Süresi (saniye)
(Orijinal)×24	3381	24	2765	15	0,99295	0,99460	0,99369	0,99427	0,99909	4,13254
(YİD)×24	3392	13	2767	13	<b>0,99618</b>	0,99532	<b>0,99580</b>	<b>0,99618</b>	<b>0,99971</b>	4,50835
(LE)×24	3386	19	2756	24	0,99442	0,99137	0,99305	0,99369	0,99923	4,52505
(Orijinal+YİD)×12	3380	25	2768	12	0,99266	<b>0,99568</b>	0,99402	0,99456	0,99925	4,32411
(Orijinal+LE)×12	3384	21	2767	13	0,99383	0,99532	0,99450	0,99500	0,99942	4,32021
(Orijinal+YİD+LE)×8	3387	18	2766	14	0,99471	0,99496	0,99483	0,99530	0,99941	4,53055

### 12.4.3. COVID-19 zatürresi ve viral zatürre sınıflandırma sonuçları

Uygulamada üçüncü olarak COVID-19 zatürresi ve viral zatürre sınıflandırması yapılmıştır. Bu deneylerde 2B MobileNetV2, 2B ResNet-101 ve 2B GoogleNet için giriş görüntü boyutları Orijinal, YİD ve LE için 224×224×1; Orijinal+YİD ve Orijinal+LE için 224×224×2; Orijinal+YİD+LE için 224×224×3'dür. 2B MobileNetV2,

2B ResNet-101 ve 2B GoogleNet kullanılarak elde edilen sınıflandırma sonuçları sırasıyla Çizelge 12.10 ile Çizelge 12.12 arasında verilmiştir. 24 katmanlı 3B ESA'ya giriş olarak verilen görüntülerin boyutları ise  $224 \times 224 \times 24 \times 1$ 'dir. Çizelge 12.13, 24 katmanlı 3B ESA kullanılarak elde edilen sınıflandırma sonuçlarını göstermektedir.

**Çizelge 12.10.** COVID-19 zatürresi ve viral zatürre sınıflandırmasında 2B MobileNetV2 ESA kullanılarak elde edilen sonuçlar

Giriş Görüntü Tipi	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AIKE-AKA	CPU Süresi (saniye)
Orijinal	3391	14	1479	14	<b>0,99589</b>	<b>0,99062</b>	<b>0,99428</b>	<b>0,99589</b>	0,99942	1,92029
YİD	3382	23	1446	47	0,99325	0,96852	0,98571	0,98976	0,99807	1,87762
LE	3388	17	1472	21	0,99501	0,98593	0,99224	0,99442	0,99931	1,88044
Orijinal+YİD	3380	25	1473	20	0,99266	0,98660	0,99081	0,99339	0,99873	1,91279
Orijinal+LE	3391	14	1466	27	<b>0,99589</b>	0,98192	0,99163	0,99399	<b>0,99954</b>	1,93166
Orijinal+YİD+LE	3391	14	1477	16	<b>0,99589</b>	0,98928	0,99388	0,99560	0,99945	1,93459

**Çizelge 12.11.** COVID-19 zatürresi ve viral zatürre sınıflandırmasında 2B ResNet-101 ESA kullanılarak elde edilen sonuçlar

Giriş Görüntü Tipi	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AIKE-AKA	CPU Süresi (saniye)
Orijinal	3371	34	1467	26	0,99001	0,98259	0,98775	0,99118	0,99867	3,32059
YİD	3391	14	1460	33	0,99589	0,97790	0,99040	0,99312	0,99852	3,34256
LE	3384	21	1463	30	0,99383	0,97991	0,98959	0,99252	0,99903	3,33412
Orijinal+YİD	3395	10	1472	21	<b>0,99706</b>	0,98593	<b>0,99367</b>	<b>0,99546</b>	<b>0,99949</b>	3,41457
Orijinal+LE	3379	26	1473	20	0,99236	<b>0,98660</b>	0,99061	0,99324	0,99890	3,42491
Orijinal+YİD+LE	3388	17	1472	21	0,99501	0,98593	0,99224	0,99442	0,99940	3,50020

**Çizelge 12.12.** COVID-19 zatürresi ve viral zatürre sınıflandırmasında 2B GoogleNet ESA kullanılarak elde edilen sonuçlar

Giriş Görüntü Tipi	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AIKE-AKA	CPU Süresi (saniye)
Orijinal	3393	12	1470	23	<b>0,99648</b>	0,98459	<b>0,99285</b>	<b>0,99487</b>	<b>0,99937</b>	0,78366
YİD	3343	62	1434	59	0,98179	0,96048	0,97530	0,98222	0,99490	0,78533
LE	3391	14	1407	86	0,99589	0,94240	0,97958	0,98547	0,99861	0,78949
Orijinal+YİD	3388	17	1468	25	0,99501	0,98326	0,99143	0,99384	0,99865	0,86286
Orijinal+LE	3364	41	1478	15	0,98796	<b>0,98995</b>	0,98857	0,99175	0,99835	0,86187
Orijinal+YİD+LE	3386	19	1470	23	0,99442	0,98459	0,99143	0,99384	0,99898	0,93658

**Çizelge 12.13.** COVID-19 zatürresi ve viral zatürre sınıflandırmasında 24 katmanlı 3B ESA kullanılarak elde edilen sonuçlar

Giriş Görüntü Tipi	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AIKE-AKA	CPU Süresi (saniye)
(Orijinal)×24	3386	19	1478	15	0,99442	<b>0,98995</b>	0,99306	0,99500	0,99922	4,06504
(YİD)×24	3388	17	1466	27	0,99501	0,98192	0,99102	0,99355	0,99956	3,97470
(LE)×24	3387	18	1472	21	0,99471	0,98593	0,99204	0,99428	0,99940	3,98068
(Orijinal+YİD)×12	3390	15	1473	20	<b>0,99559</b>	0,98660	0,99285	0,99486	0,99960	4,04915
(Orijinal+LE)×12	3387	18	1477	16	0,99471	0,98928	0,99306	0,99501	0,99962	4,08911
(Orijinal+YİD+LE)×8	3390	15	1476	17	<b>0,99559</b>	0,98861	<b>0,99347</b>	<b>0,99530</b>	<b>0,99963</b>	4,09530

#### 12.4.4. COVID-19 zatürresi ve diğer zatürre sınıflandırma sonuçları

Uygulamada son olarak COVID-19 zatürresi ve diğer zatürre sınıflandırması yapılmıştır. Bu deneylerde 2B MobileNetV2, 2B ResNet-101 ve 2B GoogleNet için giriş görüntü boyutları Orijinal, YİD ve LE için 224×224×1; Orijinal+YİD ve Orijinal+LE için 224×224×2; Orijinal+YİD+LE için 224×224×3'dür. 2B MobileNetV2, 2B ResNet-101 ve 2B GoogleNet kullanılarak elde edilen sınıflandırma sonuçları sırasıyla Çizelge 12.14 ile Çizelge 12.16 arasında verilmiştir. 24 katmanlı 3B ESA'ya giriş olarak verilen görüntülerin boyutları ise 224×224×24×1'dir. Çizelge 12.17, 24 katmanlı 3B ESA kullanılarak elde edilen sınıflandırma sonuçlarını göstermektedir.

**Çizelge 12.14.** COVID-19 zatürresi ve diğer zatürre sınıflandırmasında 2B MobileNetV2 ESA kullanılarak elde edilen sonuçlar

Giriş Görüntü Tipi	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AIKE-AKA	CPU Süresi (saniye)
Orijinal	3379	26	4254	19	0,99236	0,99555	0,99414	0,99339	0,99920	1,53206
YİD	3361	44	4238	35	0,98708	0,99181	0,98971	0,98838	0,99899	1,53449
LE	3383	22	4250	23	0,99354	0,99462	0,99414	0,99339	0,99941	1,54505
Orijinal+YİD	3382	23	4238	35	0,99325	0,99181	0,99245	0,99150	0,99919	1,61698
Orijinal+LE	3390	15	4258	15	<b>0,99559</b>	<b>0,99649</b>	<b>0,99609</b>	<b>0,99559</b>	<b>0,99953</b>	1,61581
Orijinal+YİD+LE	3379	26	4242	31	0,99236	0,99275	0,99258	0,99164	0,99937	1,68222

**Çizelge 12.15.** COVID-19 zatürresi ve diğer zatürre sınıflandırmasında 2B ResNet-101 ESA kullanılarak elde edilen sonuçlar

Giriş Görüntü Tipi	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AIKE-AKA	CPU Süresi (saniye)
Orijinal	3371	34	4248	25	0,99001	0,99415	0,99232	0,99132	0,99895	3,29616
YİD	3385	20	4226	47	0,99413	0,98900	0,99127	0,99020	0,99882	3,29504
LE	3379	26	4241	32	0,99236	0,99251	0,99245	0,99149	0,99924	3,29188
Orijinal+YİD	3386	19	4251	22	<b>0,99442</b>	<b>0,99485</b>	<b>0,99466</b>	<b>0,99398</b>	<b>0,99959</b>	3,37402
Orijinal+LE	3369	36	4229	44	0,98943	0,98970	0,98958	0,98827	0,99886	3,36625
Orijinal+YİD+LE	3377	28	4240	33	0,99178	0,99228	0,99206	0,99105	0,99935	3,43928

**Çizelge 12.16.** COVID-19 zatürresi ve diğer zatürre sınıflandırmasında 2B GoogleNet ESA kullanılarak elde edilen sonuçlar

Giriş Görüntü Tipi	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AIKE-AKA	CPU Süresi (saniye)
Orijinal	3362	43	4262	11	0,98737	<b>0,99743</b>	0,99297	0,99203	0,99922	0,77573
YİD	3013	392	4235	38	0,88488	0,99111	0,94400	0,93340	0,99150	0,77669
LE	3368	37	4233	40	0,98913	0,99064	0,98997	0,98870	0,99843	0,77822
Orijinal+YİD	3374	31	4256	17	0,99090	0,99602	0,99375	0,99294	<b>0,99957</b>	0,85580
Orijinal+LE	3364	41	4240	33	0,98796	0,99228	0,99036	0,98912	0,99911	0,85452
Orijinal+YİD+LE	3386	19	4251	22	<b>0,99442</b>	0,99485	<b>0,99466</b>	<b>0,99398</b>	0,99942	0,92986

**Çizelge 12.17.** COVID-19 zatürresi ve diğer zatürre sınıflandırmasında 24 katmanlı 3B ESA kullanılarak elde edilen sonuçlar

Giriş Görüntü Tipi	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AIKE-AKA	CPU Süresi (saniye)
(Orijinal)×24	3373	32	4255	18	0,99060	0,99579	0,99349	0,99264	0,99938	4,83264
(YİD)×24	3390	15	4259	14	0,99559	<b>0,99672</b>	<b>0,99622</b>	<b>0,99574</b>	0,99976	4,98608
(LE)×24	3376	29	4244	29	0,99148	0,99321	0,99245	0,99148	0,99943	5,15694
(Orijinal+YİD)×12	3387	18	4258	15	0,99471	0,99649	0,99570	0,99515	0,99967	4,66094
(Orijinal+LE)×12	3392	13	4247	26	<b>0,99618</b>	0,99392	0,99492	0,99428	0,99971	4,93204
(Orijinal+YİD+LE)×8	3391	14	4254	19	0,99589	0,99555	0,99570	0,99516	<b>0,99981</b>	5,08685

## 12.5. X-Ray Görüntüler Üzerinden COVID-19 ve Sağlıklı, COVID-19 Zatürresi ve Bakteriyel Zatürre, COVID-19 Zatürresi ve Viral Zatürre ile COVID-19 Zatürresi ve Diğer Zatürre Sınıflandırma Sonuçlarının Değerlendirilmesi

Uygulamada COVID-19 ve sağlıklı, COVID-19 zatürresi ve bakteriyel zatürre, COVID-19 zatürresi ve viral zatürre ile COVID-19 zatürresi ve diğer zatürre



sınıflandırması için deney sonuçları Çizelge 12.2 ile Çizelge 12.17 arasında verilmiştir. Bu bölümde, elde edilen sonuçların genel değerlendirmesi yapılmıştır. COVID-19 ve sağlıklı sınıflandırması için orijinal görüntüler ve özellik görüntülerinin doğrudan veya birlikte kullanılmasıyla elde edilen en iyi sonuçların karşılaştırılması Çizelge 12.18’de özetlenmiştir.

**Çizelge 12.18.** COVID-19 ve COVID-19 değil sınıflandırmasında elde edilen en iyi sonuçların karşılaştırması

ESA Tipi	Giriş Görüntü Tipi	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AIKE-AKA	CPU Süresi (saniye)
2B MobileNetV2	Orijinal+LE	<b>0,99325</b>	0,97788	0,98758	0,99019	0,99902	1,61216
2B MobileNetV2	Orijinal	0,99148	<b>0,98793</b>	<b>0,99017</b>	<b>0,99221</b>	<b>0,99932</b>	1,52888
2B ResNet-101	Orijinal+YİD+LE	<b>0,99266</b>	<b>0,98693</b>	<b>0,99055</b>	<b>0,99251</b>	<b>0,99949</b>	3,46030
2B GoogleNet	Orijinal	<b>0,99090</b>	<b>0,98894</b>	<b>0,99017</b>	<b>0,99221</b>	0,99859	0,76668
2B GoogleNet	Orijinal+YİD+LE	<b>0,99090</b>	0,97687	0,98572	0,98872	0,99817	0,93245
2B GoogleNet	Orijinal+LE	<b>0,99090</b>	0,98643	0,98925	0,99148	<b>0,99929</b>	0,84578
24 Katmanlı 3B ESA	(Orijinal)×24	<b>0,99413</b>	0,98793	0,99184	0,99354	0,99931	4,30136
24 Katmanlı 3B ESA	(Orijinal+YİD+LE)×8	<b>0,99413</b>	<b>0,98994</b>	<b>0,99258</b>	<b>0,99413</b>	<b>0,99958</b>	4,24820

Çizelge 12.18 incelendiğinde en başarılı sonuçların 24 katmanlı 3B ESA mimarisi kullanılarak elde edildiği görülmektedir. Sırasıyla 2B ResNet-101, 2B MobileNetV2 ve 2B GoogleNet mimarileri başarı açısından 24 katmanlı 3B ESA mimarisini takip etmektedir. Bir diğer önemli husus ise en başarılı sonuçların elde edilmesini sağlayan giriş görüntü kombinasyonlarıdır. Orijinal+LE ve Orijinal+YİD+LE kombinasyonlarının kullanılmasının yanı sıra orijinal görüntülerin doğrudan kullanılmasının başarılı sonuçlar elde edilmesini sağladığı görülmektedir. Çalışma süreleri açısından karşılaştırma yapıldığında; en maliyetli çalışma süresinin 24 katmanlı 3B ESA mimarisine, en az maliyetli çalışma süresinin ise 2B GoogleNet ESA mimarisine ait olduğu anlaşılmaktadır.

Çizelge 12.18 ile Çizelge 12.21 arasında yer alan çizelgeler sırasıyla COVID-19 zatürresi ve bakteriyel zatürre, COVID-19 zatürresi ve viral zatürre, COVID-19 zatürresi ve diğer zatürre sınıflandırması için en başarılı sonuçların karşılaştırmasını göstermektedir.

**Çizelge 12.19.** COVID-19 zatürresi ve bakteriyel zatürre sınıflandırmasında elde edilen en iyi sonuçların karşılaştırması

ESA Tipi	Giriş Görüntü Tipi	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AİKE-AKA	CPU Süresi (saniye)
2B MobileNetV2	Orijinal+LE	<b>0,99618</b>	0,99209	0,99434	0,99487	0,99891	1,60963
2B MobileNetV2	Orijinal	0,99501	<b>0,99424</b>	<b>0,99466</b>	<b>0,99515</b>	0,99934	1,52733
2B MobileNetV2	Orijinal+YİD	0,99354	0,99101	0,99240	0,99310	<b>0,99940</b>	1,60832
2B ResNet-101	Orijinal+YİD+LE	<b>0,99413</b>	0,99245	<b>0,99337</b>	<b>0,99398</b>	0,99925	3,43009
2B ResNet-101	Orijinal+LE	0,99090	<b>0,99281</b>	0,99175	0,99250	0,99891	3,36263
2B ResNet-101	Orijinal+YİD	0,99325	<b>0,99281</b>	0,99305	0,99368	<b>0,99934</b>	3,35726
2B GoogleNet	Orijinal+YİD	<b>0,99677</b>	0,98633	0,99208	0,99283	<b>0,99929</b>	0,84987
2B GoogleNet	LE	0,99471	<b>0,99568</b>	<b>0,99515</b>	<b>0,99559</b>	0,99922	0,77270
24 Katmanlı 3B ESA	(YİD)×24	<b>0,99618</b>	0,99532	<b>0,99580</b>	<b>0,99618</b>	<b>0,99971</b>	4,50835
24 Katmanlı 3B ESA	(Orijinal+YİD)×12	0,99266	<b>0,99568</b>	0,99402	0,99456	0,99925	4,32411

**Çizelge 12.20.** COVID-19 zatürresi ve viral zatürre sınıflandırmasında elde edilen en iyi sonuçların karşılaştırması

ESA Tipi	Giriş Görüntü Tipi	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AİKE-AKA	CPU Süresi (saniye)
2B MobileNetV2	Orijinal	<b>0,99589</b>	<b>0,99062</b>	<b>0,99428</b>	<b>0,99589</b>	0,99942	1,92029
2B MobileNetV2	Orijinal+YİD+LE	<b>0,99589</b>	0,98928	0,99388	0,99560	0,99945	1,93459
2B MobileNetV2	Orijinal+LE	<b>0,99589</b>	0,98192	0,99163	0,99399	<b>0,99954</b>	1,93166
2B ResNet-101	Orijinal+YİD	<b>0,99706</b>	0,98593	<b>0,99367</b>	<b>0,99546</b>	<b>0,99949</b>	3,41457
2B ResNet-101	Orijinal+LE	0,99236	<b>0,98660</b>	0,99061	0,99324	0,99890	3,42491
2B GoogleNet	Orijinal	<b>0,99648</b>	0,98459	<b>0,99285</b>	<b>0,99487</b>	<b>0,99937</b>	0,78366
2B GoogleNet	Orijinal+LE	0,98796	<b>0,98995</b>	0,98857	0,99175	0,99835	0,86187
24 Katmanlı 3B ESA	(Orijinal+YİD)×12	<b>0,99559</b>	0,98660	0,99285	0,99486	0,99960	4,04915
24 Katmanlı 3B ESA	(Orijinal+YİD+LE)×8	<b>0,99559</b>	0,98861	<b>0,99347</b>	<b>0,99530</b>	<b>0,99963</b>	4,09530
24 Katmanlı 3B ESA	(Orijinal)×24	0,99442	<b>0,98995</b>	0,99306	0,99500	0,99922	4,06504

**Çizelge 12.21.** COVID-19 zatürresi ve diğer zatürre sınıflandırmasında elde edilen en iyi sonuçların karşılaştırması

ESA Tipi	Giriş Görüntü Tipi	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AİKE-AKA	CPU Süresi (saniye)
2B MobileNetV2	Orijinal+LE	<b>0,99559</b>	<b>0,99649</b>	<b>0,99609</b>	<b>0,99559</b>	<b>0,99953</b>	1,61581
2B ResNet-101	Orijinal+YİD	<b>0,99442</b>	<b>0,99485</b>	<b>0,99466</b>	<b>0,99398</b>	<b>0,99959</b>	3,37402
2B GoogleNet	Orijinal+YİD+LE	<b>0,99442</b>	0,99485	<b>0,99466</b>	<b>0,99398</b>	0,99942	0,92986
2B GoogleNet	Orijinal	0,98737	<b>0,99743</b>	0,99297	0,99203	0,99922	0,77573
2B GoogleNet	Orijinal+YİD	0,99090	0,99602	0,99375	0,99294	<b>0,99957</b>	0,85580
24 Katmanlı 3B ESA	(Orijinal+LE)×12	<b>0,99618</b>	0,99392	0,99492	0,99428	0,99971	4,93204
24 Katmanlı 3B ESA	(YİD)×24	0,99559	<b>0,99672</b>	<b>0,99622</b>	<b>0,99574</b>	0,99976	4,98608
24 Katmanlı 3B ESA	(Orijinal+YİD+LE)×8	0,99589	0,99555	0,99570	0,99516	<b>0,99981</b>	5,08685

Çizelge 12.19 ile Çizelge 12.21 arasında özetlenen sonuçlar incelendiğinde, Çizelge 12.18’de verilen ESA mimari başarı sıralamasının küçük farklılıklar olsa da geçerli olduğu görülmektedir. Ayrıca, en başarılı sonuçların Orijinal+YİD, Orijinal+LE, Orijinal+YİD+LE giriş görüntüsü kombinasyonları kullanılarak ve doğrudan orijinal görüntüler kullanılarak elde edildiği anlaşılmaktadır. ESA mimarilerinin çalışma süreleri karşılaştırıldığında, en maliyetliden en az maliyetliye doğru 24 katmanlı 3B ESA, 2B ResNet-101, 2B MobileNetV2 ve 2B GoogleNet şeklinde olduğu görülmektedir.

Uygulamada COVID-19 ve sağlıklı sınıflandırması için elde edilen sonuçların literatürde yer alan çalışmalarda elde edilen sonuçlarla karşılaştırılması Çizelge 12.22’de verilmiştir. COVID-19 zatürresi ve bakteriyel zatürre, COVID-19 zatürresi ve viral zatürre, COVID-19 zatürresi ve diğer zatürresi için benzer karşılaştırmalar Çizelge 12.23’de yer almaktadır.

**Çizelge 12.22.** Tez çalışmasının altıncı uygulamasında X-ray görüntülerden COVID-19 ve sağlıklı sınıflandırması için elde edilen sonuçların literatürde yer alan çalışmalarda elde edilen sonuçlar ile karşılaştırılması

Çalışma	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AİKE-AKA
Beşinci Uygulama	0,9947	1,0000	0,9906	0,9881	0,9997
Tuncer ve ark., 2020	0,8149-1,0000	0,9380-1,0000	0,9049-0,9955	X	X
Panwar ve ark., 2020	0,9762	0,7857	0,881	X	X
Öztürk ve ark., 2020	0,9513	0,953	0,9808	0,9651	X
Mohammed ve ark., 2020	0,706-0,974	0,557-1,000	0,620-0,987	0,555-0,987	0,800-0,988
Toraman ve ark., 2020	0,28-0,9742	0,8095-0,98	0,4914-0,9724	0,55-0,9724	X
Khan ve ark., 2020	0,993	0,986	0,990	0,985	X
Waheed ve ark., 2020	0,69-0,90	0,95-0,97	0,85-0,95	X	X
Duran-Lopez ve ark., 2020	0,9253	0,9633	0,9443	0,9314	0,988
Vaid ve ark., 2020	0,9863	0,9166	0,9633	0,9729	X
Benbrahim ve ark., 2020	0,9803-0,9811	X	0,9803-0,9901	0,9803-0,9901	X
Loey ve ark., 2020	1,0000	1,0000	1,0000	X	X
Minaee ve ark., 2020	0,98	0,751-0,929	X	X	X
Elaziz ve ark., 2020	0,9875-0,9891	X	0,9609-0,9809	X	X
Martínez ve ark., 2020	0,97	X	0,97	0,97	X
Mahmud ve ark., 2020	0,978	0,947	0,974	0,971	0,969
24 Katmanlı 3B ESA (Orijinal)×24	<b>0,99413</b>	0,98793	0,99184	0,99354	0,99931
24 Katmanlı 3B ESA (Orijinal+YİD+LE)×8	<b>0,99413</b>	<b>0,98994</b>	<b>0,99258</b>	<b>0,99413</b>	<b>0,99958</b>

**Çizelge 12.23.** Tez çalışmasının altıncı uygulamasında X-ray görüntülerden COVID-19 zatürresi ve bakteriyel zatürre, COVID-19 zatürresi ve viral zatürre, COVID-19 zatürresi ve diğer zatürresi sınıflandırması için elde edilen sonuçların literatürde yer alan çalışmalarda elde edilen sonuçlar ile karşılaştırılması

Çalışma	Sınıflar	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AIKE-AKA
Mahmud ve ark., 2020	COVID-19	0,944	0,933	0,947	0,939	0,951
2B GoogleNet/Orijinal+YİD	Zatürresi	<b>0,99677</b>	0,98633	0,99208	0,99283	0,99929
2B GoogleNet/LE	ve	0,99471	<b>0,99568</b>	0,99515	0,99559	0,99922
24 Katmanlı 3B ESA/(Orijinal+YİD)×12	Bakteriyel	0,99266	<b>0,99568</b>	0,99402	0,99456	0,99925
24 Katmanlı 3B ESA/(YİD)×24	Zatürre	0,99618	0,99532	<b>0,99580</b>	<b>0,99618</b>	<b>0,99971</b>
Mahmud ve ark., 2020	COVID-19	0,874	0,855	0,873	0,878	0,921
2B GoogleNet/Orijinal	Zatürresi	<b>0,99648</b>	0,98459	0,99285	0,99487	0,99937
2B GoogleNet/ Orijinal+LE	ve	0,98796	<b>0,98995</b>	0,98857	0,99175	0,99835
24 Katmanlı 3B ESA/(Orijinal)×24	Viral	0,99442	<b>0,98995</b>	0,99306	0,99500	0,99922
24 Katmanlı 3B ESA/(Orijinal+YİD+LE)×8	Zatürre	0,99559	0,98861	<b>0,99347</b>	<b>0,99530</b>	<b>0,99963</b>
Horry ve ark., 2020	COVID-19	0,86-0,89	X	X	0,86-0,89	X
24 Katmanlı 3B ESA/((Orijinal+LE)×12	Zatürresi	<b>0,99618</b>	0,99392	0,99492	0,99428	0,99971
2B GoogleNet/Orijinal	ve	0,98737	<b>0,99743</b>	0,99297	0,99203	0,99922
24 Katmanlı 3B ESA/((YİD)×24	Diğer	0,99559	0,99672	<b>0,99622</b>	<b>0,99574</b>	0,99976
24 Katmanlı 3B ESA/((Orijinal+YİD+LE)×8	Zatürre	0,99589	0,99555	0,99570	0,99516	<b>0,99981</b>

Uygulamada elde edilen sayısal sonuçlarının daha önce yapılmış çalışmaların sayısal sonuçlarıyla doğrudan karşılaştırılması doğru bir yaklaşım değildir. Çünkü, kullanılan toplam görüntü sayısı, test ve eğitim yaklaşımı, test ve eğitim görüntü sayısındaki farklılıklar sonuçlar üzerinde doğrudan etkili faktörlerdir. Ancak COVID-19 ve sağlıklı sınıflandırması için uygulamada elde edilen sonuçlarının literatürde yer alan çalışmalarda elde edilen sonuçlarla karşılaştırılması gerekirse, önemli sonuçların sağlandığı görülmektedir. Çizelge 12.22 incelendiğinde; uygulamada elde edilen duyarlılık parametresinin, bu parametrenin hesaplandığı on altı çalışmanın on dört tanesinden daha yüksek olduğu görülmektedir. Ayrıca, özgüllük parametresi bu parametrenin hesaplandığı on üç çalışmanın dokuz tanesinden daha iyidir. Doğruluk parametreleri arasında bir karşılaştırma yapıldığında, uygulamada elde edilen sonucun bu parametrenin hesaplandığı on beş çalışmanın on üç tanesinden daha yüksek olduğu görülmektedir. Ayrıca, F-1 skoru parametresi bu parametrenin hesaplandığı on çalışmanın tamamından ve AIKE-AKA parametresi bu parametrenin hesaplandığı dört çalışmanın tamamından daha yüksektir.

Uygulamada COVID-19 ve sağlıklı sınıflandırması için elde edilen sonuçlar Tuncer ve arkadaşları (2020), Loey ve arkadaşları (2020) ile Mohammed ve arkadaşları (2020) tarafından gerçekleştirilen çalışmalarda elde edilen sonuçların gerisinde

kalmıştır. Ancak daha detaylı bir karşılaştırmanın yapılabilmesi için çalışmalarda kullanılan görüntü sayısı, eğitim ve test süreçlerinde kullanılan yöntemlerin de dikkate alınması gerekmektedir. Uygulamada kullanılan COVID-19 X-ray görüntü sayısı, Tuncer ve arkadaşları (2020) tarafından gerçekleştirilen çalışmada kullanılan görüntü sayısının kırk katı, Loey ve arkadaşları (2020) tarafından gerçekleştirilen çalışmada kullanılan görüntü sayısının elli katı, Mohammed ve arkadaşları (2020) tarafından gerçekleştirilen çalışmada kullanılan görüntü sayısının ise yüz otuz beş katıdır. Uygulamada kullanılan COVID-19 X-ray görüntülerinin sayısının diğer çalışmalara göre oldukça fazla olması, elde edilen sonuçların daha stabil olduğunu göstermektedir. Ayrıca, Loey ve arkadaşları (2020) tarafından gerçekleştirilen çalışmada uygulamamızda yararlanılan sınıflandırıcılar kullanılmıştır. Bir diğer önemli husus ise uygulamada k kat çapraz doğrulama yapılmış olmasıdır. Ancak, Loey ve arkadaşları (2020) tarafından gerçekleştirilen çalışmada kullanılan eğitim ve test prosedürü k kat çapraz doğrulama prosedüründen farklıdır.

Çizelge 12.23'de COVID-19 zatürresi ve bakteriyel zatürre, COVID-19 zatürresi ve viral zatürre, COVID-19 zatürresi ve diğer zatürresi sınıflandırması için elde edilen sonuçlar ile önceki çalışmalarda elde edilen sonuçlar karşılaştırılmaktadır. Uygulamada elde edilen duyarlılık, özgüllük, doğruluk, F-1 skoru ve AİKE-AKA sonuçlarının önceki çalışmalarda elde edilen sonuçlardan daha yüksek olduğu görülmektedir. Bu sınıflandırma başlıkları için uygulamada kullanılan COVID-19 X-ray görüntü sayısının diğer çalışmalara göre oldukça yüksek olduğu dikkate alınması gereken bir diğer önemli husustur.

### **13. X-RAY GÖRÜNTÜLER ÜZERİNDEN COVID-19 ZATÜRRESİ, SAĞLIKLI VE DİĞER ZATÜRRE İLE COVID-19 ZATÜRRESİ, SAĞLIKLI, BAKTERİYEL ZATÜRRE VE VİRAL ZATÜRRE SINIFLANDIRMASI**

Tez çalışmasının yedinci uygulamasında X-ray görüntüler üzerinden COVID-19 zatürresi, sağlıklı ve diğer zatürre ile COVID-19 zatürresi, sağlıklı, bakteriyel zatürre ve viral zatürre olmak üzere iki başlıkta sırasıyla üç sınıflı ve dört sınıflı otomatik sınıflandırma gerçekleştirilmiştir.

#### **13.1. Uygulamada Kullanılan Veriler**

Uygulamada kullanılan COVID-19 X-ray görüntüleri beş farklı veri seti birleştirilerek toplanmıştır. İlk olarak Cohen ve arkadaşları (Cohen ve ark., 2020) tarafından oluşturulan veri setinden 462 adet COVID-19 X-ray görüntüsü uygulamaya dahil edilmiştir. İkinci olarak Wang ve arkadaşları (Wang ve ark., 2020(c)) tarafından oluşturulan veri setinden 35 adet COVID-19 X-ray görüntüsü alınmıştır. Winther ve arkadaşları (Winther ve ark., 2020) tarafından oluşturulan veri setinden 243 adet COVID-19 X-ray görüntüsü uygulamada kullanılmıştır. Son olarak Desai ve arkadaşları (Desai ve ark., 2020) tarafından oluşturulan veri setinden 253 adet COVID-19 X-ray görüntüsü ve Vayá ve arkadaşları (Vayá ve ark., 2020) tarafından oluşturulan veri setinden 2.412 adet COVID-19 X-ray görüntüsü uygulamaya dahil edilmiştir. Sonuç olarak, beş farklı veri setinden toplam 3.405 COVID-19 X-ray görüntüsü içeren karma bir veri seti elde edilmiştir. Söz konusu görüntüler jpeg, jpg, png ve dicom gibi farklı formatlarda kaydedilmiş dosyalardır. Ayrıca, 16 bit ile 48 bit arasında değişen bit derinliklerine sahiptirler. Görüntü boyutları ise 154×124 ile 4064×2992 arasında değişmektedir. COVID-19 X-ray görüntülerinin önemli bir kısmı (%90'dan fazlası) gerçek dünyadan alınmıştır.

Uygulamada kullanılan bakteriyel zatürre ve viral zatürre X-ray görüntüleri Kermany ve arkadaşları (Kermany ve ark., 2018) tarafından oluşturulan veri setinden alınmıştır. Veri setinde yer alan 2.780 bakteriyel zatürre ve 1.493 viral zatürre X-ray görüntüsü uygulamaya dahil edilmiştir. Söz konusu görüntüler 24 bit derinliğinde ve jpeg formatındadır. Görüntü boyutları ise 333×127 ile 2292×1552 arasında değişmektedir.

Uygulamada kullanılan sağlıklı X-ray görüntüleri üç farklı veri setinden alınmıştır. İlk olarak, Kermany ve arkadaşları (Kermany ve ark., 2018) tarafından oluşturulan veri setinden 1.583 adet sağlıklı X-ray görüntüsü uygulamaya dahil edilmiştir. Ayrıca, Montgomery veri setinden (Jaeger ve ark., 2014) 80 adet sağlıklı X-ray görüntüsü ve Shenzhen veri setinden (Jaeger ve ark., 2014) 326 adet sağlıklı X-ray görüntüsü kullanılmıştır. Sonuç olarak 1.989 sağlıklı X-ray görüntüsü içeren karma bir veri seti elde edilmiştir. Görüntüler jpeg (24 bit) ve png (8 bit) formatında olup boyutları 736×536 ile 4892×4020 arasında değişmektedir.

Uygulamada COVID-19 zatürresi, bakteriyel zatürre, viral zatürre ve sağlıklı olmak üzere dört sınıflı sınıflandırma için 3.405 COVID-19, 2.780 bakteriyel zatürre, 1.493 viral zatürre ve 1.989 sağlıklı olmak üzere toplam 9.667 X-ray görüntüsü kullanılmıştır. Aynı görüntüler COVID-19 zatürresi, diğer zatürre ve sağlıklı olmak üzere üç sınıflı sınıflandırma için de kullanılmıştır. Bu aşamada diğer zatürre görüntüleri, bakteriyel zatürre ve viral zatürre görüntülerinin birleştirilmesiyle elde edilmiştir. Uygulamada kullanılan COVID-19 X-ray görüntü sayısı, literatürde yer alan üç sınıflı ve dört sınıflı sınıflandırma çalışmalarında kullanılan ortalama görüntü sayısından sırasıyla on iki ve on beş kat daha fazladır. Uygulamada kullanılan X-ray görüntülerinin özet bilgileri Çizelge 13.1’de yer almaktadır.

**Çizelge 13.1.** Tez çalışmasının yedinci uygulamasında kullanılan COVID-19, sağlıklı, bakteriyel zatürre ve viral zatürre X-ray görüntülerine ilişkin bilgiler

Kaynak	COVID-19	Diğer Zatürre		Sağlıklı
		Bakteriyel Zatürre	Viral Zatürre	
Cohen, 2020	462	X	X	X
Wang ve ark., 2020(c)	35	X	X	X
Winther ve ark., 2020	243	X	X	X
Desai ve ark., 2020	253	X	X	X
Vayá ark., 2020	2.412	X	X	X
Kermany ve ark., 2018	X	2.780	1.493	1.583
Jaeger ve ark., 2014 (Montgomery)	X	X	X	80
Jaeger ve ark., 2014 (Shenzhen)	X	X	X	326
	3.405	2.780	1.493	1.989
Toplam	3.405	4.273		1.989
		9.667		

Uygulamada sınıflandırıcı olarak transfer öğrenme 2B ESA mimarileri kullanılmıştır. Transfer öğrenme 2B ESA mimarisinin çalışma yapısı nedeniyle giriş görüntülerinin standart bir formda olması gerekmektedir. Bu nedenle, söz konusu görüntüler öncelikle tüm göğüs bölgesini kaplayacak şekilde çerçevelenmiş ve

görüntülerden ilgisiz alanlar çıkarılmıştır. Daha sonra, 8 bitlik gri seviye formatına dönüştürülmüştür. Son olarak, görüntü boyutları  $224 \times 224$  olarak yeniden düzenlenmiştir. Bu aşamadan sonra kullanılacak transfer öğrenme 2B ESA mimarisine uygun olarak görüntü boyutları tekrar düzenlenmiştir.

### 13.2. Özellik Çıkarma, ESA Modifikasyonları ve Hiperparametreler

Tez çalışmasının yedinci uygulamasında yararlanılan YİD yönteminin işletilmesinde kullanılan yarıçap değeri 1 olarak seçilmiştir. YİD işlemi sonunda görüntü boyutlarında azalma olması sebebiyle, MATLAB *imresize* fonksiyonu kullanılarak görüntü boyutları yeniden düzenlenmiştir. LE görüntülerinin elde edilmesinde MATLAB *entropyfilt* fonksiyonu kullanılmıştır. Fonksiyonun işletilmesi varsayılan parametrelerle yapılmıştır. LE görüntülerinin piksel değerleri MATLAB *rescale* fonksiyonu kullanılarak 0 ile 255 arasına normalize edilerek uygulamada kullanılmıştır.

Uygulamada toplam yedi adet transfer öğrenme 2B ESA mimarisinden yararlanılmıştır. Bu mimariler; 2B MobileNetV2, 2B ResNet-101, 2B GoogleNet, 2B Xception, 2B DenseNet-201, 2B EfficientNetB0 ve 2B InceptionV3'dir. Söz konusu transfer öğrenme 2B ESA mimarilerinin uygulamada kullanılabilmesi için üzerlerinde bazı modifikasyonların yapılması gerekmektedir. Bu bağlamda giriş görüntüsündeki satır ve sütun büyüklüğü özgün mimarideki değerler olarak korunmuştur. Ancak giriş verilerinin üçüncü boyutu çalışmanın gereksinimlerine göre 1 olarak yeniden düzenlenmiştir. Bu kapsamda giriş görüntü boyutları 2B MobileNetV2, 2B ResNet-101, 2B GoogleNet, 2B DenseNet-201 ve 2B EfficientNetB0 mimarileri için  $224 \times 224 \times 1$ ; 2B Xception ve 2B InceptionV3 mimarileri için  $299 \times 299 \times 1$ 'dir. Ayrıca bu mimarilerin özgün versiyonlarında tam bağlı katman çıkış boyutları 1000'dir. Uygulamada üç sınıflı ve dört sınıflı sınıflandırma yapıldığı için tam bağlı katman çıkışı 3 ve 4 olacak şekilde yeniden düzenlenmiştir.

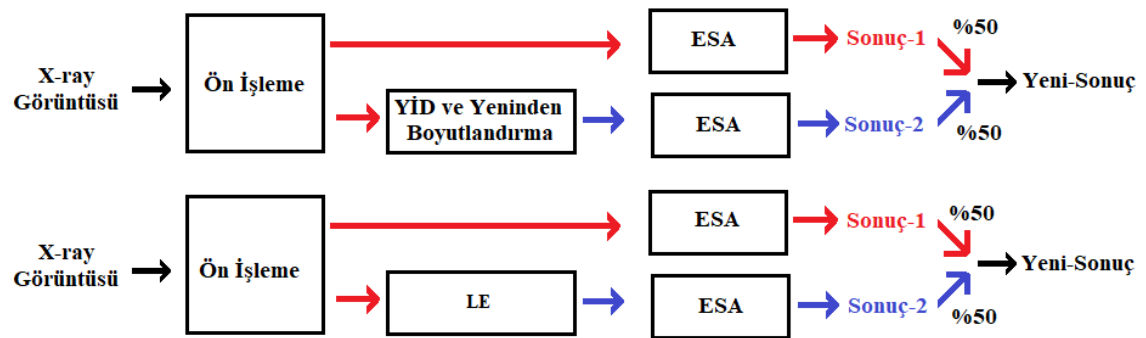
Eğitimler sırasında ilk ağırlık transferi yapılmamıştır. Yani tüm ESA mimarileri baştan rastgele atanan ağırlıklarla eğitilmiştir. Uygulamada yararlanılan yazılım MATLAB 2020(b) kullanılarak oluşturulmuştur. ESA eğitiminde ağ çözücü olarak momentumlu stokastik gradyan inişi seçilmiştir. Maksimum iterasyon sayısı program tarafından varsayılan değer kabul edilen 30 olarak belirlenmiştir. Bu tercihin temel nedeni aşırı uyum probleminden kaçınmaktır. Yani, bu değeri yüksek seçmek yerine



varsayılan değer kullanılarak erken durdurma yapılmıştır. Küme boyutu 16 olarak ayarlanmıştır. Aşırı uyum problemine karşı önlem olarak veri karıştırma seçenekleri her iterasyon olarak belirlenmiştir. Uygulamada başlangıç öğrenme oranı varsayılan değer olarak kabul edilen 0,01 olarak seçilmiştir. Momentum, gradyan bozunma faktörü, sıra doldurma gibi diğer tüm parametreler varsayılan değerler olarak ayarlanmıştır. MathWorks sayfasından (MathWorks, 2022(a)) eğitim parametreleri açıklamalarının ve varsayılan değerlerin incelenmesi mümkündür.

### 13.3. Uygulamada Kullanılan VAH Yaklaşımları

Uygulamada orijinal görüntüler, YİD özellik görüntüleri ve LE özellik görüntüleri kullanılarak ayrı ayrı elde edilen deney sonuçları, bir VAH yaklaşımı kullanılarak birleştirilmiştir. Bu kapsamda orijinal görüntüler kullanılarak elde edilen sonuçlar YİD özellik görüntüleri kullanılarak elde edilen sonuçlarla %50-%50 birleştirme oranı kullanılarak birleştirilmiş ve yeni sonuçlar oluşturulmuştur. Yani her sınıf için ilgili transfer öğrenme 2B ESA mimarisi tarafından orijinal ve YİD özellik görüntüsü kullanılarak elde edilen yüzdesel sonuçlar 0,5 ile çarpılmış ve ardından toplanmıştır. Benzer bir işlem, orijinal görüntüler ile LE özellik görüntüleri kullanılarak elde edilen sonuçların %50-%50 oranında birleştirilmesiyle gerçekleştirilmiştir. Uygulamada kullanılan VAH yaklaşımının genel çalışma yapısı Şekil 13.1'de görülmektedir. VAH yaklaşımının çalışması için gereken süre saniyenin binde birinden daha azdır. Bu nedenle; VAH yaklaşımı kullanarak bir görüntü için sonuç üretme süresi, orijinal görüntünün ve YİD (veya LE) özellik görüntüsünün tek başlarına sonuç üretme sürelerinin toplamına eşittir.



Şekil 13.1. Tez çalışmasının yedinci uygulamasında kullanılan VAH yaklaşımı

### 13.4. Deneyler

Uygulamada X-ray görüntüleri üzerinden COVID-19 zatürresi, sağlıklı ve diğer zatürre ile COVID-19 zatürresi, sağlıklı, bakteriyel zatürre ve viral zatürre olmak üzere iki başlıkta sırasıyla üç sınıflı ve dört sınıflı otomatik sınıflandırma gerçekleştirilmiştir. Uygulamada sekiz farklı açık erişimli veri setinin birleştirilmesiyle elde edilen 3.405 COVID-19, 2.780 bakteriyel zatürre, 1.493 viral zatürre ve 1.989 sağlıklı görüntüsü kullanılmıştır. Çizelge 12.1’de görüldüğü gibi COVID-19 zatürresi, bakteriyel zatürre, viral zatürre ve sağlıklı olmak üzere dört sınıflı sınıflandırma için toplam 9.667 X-ray görüntüsü kullanılmıştır. Aynı görüntüler COVID-19 zatürresi, diğer zatürre ve sağlıklı olmak üzere üç sınıflı sınıflandırma için de kullanılmıştır. Bu aşamada diğer zatürre görüntüleri, bakteriyel zatürre ve viral zatürre görüntüleri birleştirilerek elde edilmiştir.

Uygulamada ilk olarak X-ray görüntüleri düzenlenerek standardize edilmiştir. X-ray görüntüleri, akciğer bölgesini içine alacak şekilde çerçevelenmiştir. Bu sayede X-ray görüntülerinde yer alan ilgisiz alanlar görüntülerden çıkarılmıştır. Daha sonra görüntüler, 8 bit derinliğinde gri seviye formatına dönüştürülmüştür. Son olarak, görüntülerin boyutları 224×224 olarak düzenlenmiştir. Bu aşamadan sonra kullanılacak transfer öğrenme 2B ESA mimarisine uygun olarak görüntü boyutları tekrar düzenlenmiştir.

Uygulamada ikinci olarak, doku analiz yöntemleri kullanılarak orijinal görüntülerden yeni özellik görüntüleri elde edilmiştir. Bu kapsamda YİD ve LE olmak üzere iki farklı doku analizi yöntemi kullanılmıştır. Bu yöntemler tüm orijinal görüntülere uygulanarak yeni özellik görüntüleri oluşturulmuştur. Bu yeni görüntülerin boyutları ve özellikleri orijinal görüntülerle aynı (224×224, 8 bit gri seviye) olacak şekilde düzenlenmiştir. Bu aşamadan sonra kullanılacak transfer öğrenme 2B ESA mimarisine uygun olarak görüntü boyutları tekrar düzenlenmiştir.

Uygulamada üçüncü olarak, transfer öğrenme 2B ESA mimarileri kullanılarak sınıflandırma işlemleri yapılmıştır. Transfer öğrenme 2B ESA sınıflandırıcı olarak daha önce detayları ve üzerinde yapılan değişiklikler açıklanan 2B MobileNetV2, 2B ResNet-101, 2B GoogleNet, 2B Xception, 2B DenseNet-201, 2B EfficientNetB0 ve 2B InceptionV3 mimarileri kullanılmıştır. Eğitim ve test işlemleri her transfer öğrenme 2B ESA mimarisi için orijinal görüntüler, YİD özellik görüntüleri ve LE özellik görüntüleri için ayrı ayrı gerçekleştirilmiş ve sınıflandırma sonuçları elde edilmiştir. Daha sonra VAH yaklaşımı kullanılarak yeni sınıflandırma sonuçları hesaplanmıştır.

Uygulamanın eğitim ve test işlemleri dört kat çapraz doğrulama prosedürüne göre gerçekleştirilmiştir. Eğitimler sırasında ilk ağırlık transferi yapılmamıştır. Tüm transfer öğrenme 2B ESA mimarileri baştan rastgele atanan ağırlıklarla eğitilmiştir. Uygulamada gerçekleştirilen tüm deneylerde daha önce detayları açıklanan eğitim seçenekleri kullanılmıştır. Uygulama kapsamında bir görüntünün sınıflandırılması için ihtiyaç duyulan süreler (CPU süresi) saniye cinsinden ölçülmüştür. Uygulamanın deneylerinde MATLAB 2020(b) yazılımı ve 64 GB RAM'e sahip Intel (R) Xeon (R) CPU E5-2680 2,7 GHz (32 CPU) bilgisayar kullanılmıştır. Uygulamada verilen tüm CPU çalışma süreleri saniye cinsinden zamanı göstermektedir.

### **13.5. Deney Sonuçları**

Uygulamanın deney sonuçları her sınıflandırma başlığı için ayrı ayrı hesaplanmış ve verilmiştir.

#### **13.5.1. COVID-19 zatürresi, sağlıklı ve diğer zatürre sınıflandırma sonuçları**

Uygulamada ilk olarak COVID-19 zatürresi, sağlıklı ve diğer zatürre sınıflandırması gerçekleştirilmiştir. Deneylerde giriş görüntü boyutları 2B MobileNetV2, 2B ResNet-101, 2B GoogleNet, 2B DenseNet-201 ve 2B EfficientNetB0 mimarileri için  $224 \times 224 \times 1$ ; 2B Xception ve 2B InceptionV3 mimarileri için  $299 \times 299 \times 1$ 'dir. 2B MobileNetV2, 2B ResNet-101, 2B GoogleNet, 2B Xception, 2B DenseNet-201, 2B EfficientNetB0 ve 2B InceptionV3 ESA mimarileri ile orijinal, YİD, LE giriş görüntüleri ve VAH yaklaşımı kullanılarak elde edilen sınıflandırma sonuçları sırasıyla Çizelge 13.2 ile Çizelge 13.8 arasında yer almaktadır.

**Çizelge 13.2.** COVID-19 zatürresi, sağlıklı ve diğer zatürre sınıflandırmasında 2B MobileNetV2 ESA kullanılarak elde edilen sonuçlar

Giriş	Sınıf	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AİKE-AKA	Genel Doğruluk
Orijinal	COVID-19	3360	45	6229	33	0,9868	0,9947	0,9919	0,9885	0,9991	
	Diğer Zat.	4045	228	5274	120	0,9466	0,9778	0,9640	0,9588	0,9914	0,9602
	Sağlıklı	1877	112	7446	232	0,9437	0,9698	0,9644	0,9161	0,9908	
	Genel (ağırlıklı)					0,9602	0,9821	0,9739	0,9605	0,9940	
YİD	COVID-19	3364	41	6197	65	0,9880	0,9896	0,9890	0,9845	0,9993	
	Diğer Zat.	4016	257	5140	254	0,9399	0,9529	0,9471	0,9402	0,9873	0,9413
	Sağlıklı	1720	269	7430	248	0,8648	0,9677	0,9465	0,8693	0,9793	
	Genel (ağırlıklı)					0,9413	0,9689	0,9618	0,9412	0,9899	
LE	COVID-19	3368	37	6194	68	0,9891	0,9891	0,9891	0,9847	0,9990	
	Diğer Zat.	4044	229	5161	233	0,9464	0,9568	0,9522	0,9460	0,9881	0,9461
	Sağlıklı	1734	255	7458	220	0,8718	0,9713	0,9509	0,8795	0,9834	
	Genel (ağırlıklı)					0,9461	0,9712	0,9649	0,9459	0,9910	
VAH (Orijinal-YİD)	COVID-19	3390	15	6232	30	0,9956	0,9952	0,9953	0,9934	0,9997	
	Diğer Zat.	4095	178	5270	124	0,9583	0,9770	0,9688	0,9644	0,9929	0,9663
	Sağlıklı	1856	133	7506	172	0,9331	0,9776	0,9684	0,9241	0,9902	
	Genel (ağırlıklı)					0,9663	0,9835	0,9781	0,9663	0,9948	
VAH (Orijinal-LE)	COVID-19	3391	14	6231	31	0,9959	0,9950	0,9953	0,9934	0,9995	
	Diğer Zat.	4096	177	5271	123	0,9586	0,9772	0,9690	0,9647	0,9930	0,9669
	Sağlıklı	1860	129	7512	166	0,9351	0,9784	0,9695	0,9265	0,9913	
	Genel (ağırlıklı)					0,9669	0,9837	0,9784	0,9669	0,9949	

**Çizelge 13.3.** COVID-19 zatürresi, sağlıklı ve diğer zatürre sınıflandırmasında 2B ResNet-101 ESA kullanılarak elde edilen sonuçlar

Giriş	Sınıf	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AİKE-AKA	Genel Doğruluk
Orijinal	COVID-19	3353	52	6229	33	0,9847	0,9947	0,9912	0,9875	0,9979	
	Diğer Zat.	4098	175	5230	164	0,9590	0,9696	0,9649	0,9603	0,9942	0,9607
	Sağlıklı	1836	153	7495	183	0,9231	0,9762	0,9652	0,9162	0,9920	
	Genel (ağırlıklı)					0,9607	0,9798	0,9743	0,9608	0,9950	
YİD	COVID-19	3370	35	6196	66	0,9897	0,9895	0,9896	0,9852	0,9989	
	Diğer Zat.	4008	265	5103	291	0,9380	0,9461	0,9425	0,9351	0,9813	0,9366
	Sağlıklı	1676	313	7422	256	0,8426	0,9667	0,9411	0,8549	0,9737	
	Genel (ağırlıklı)					0,9366	0,9656	0,9588	0,9363	0,9859	
LE	COVID-19	3353	52	6185	77	0,9847	0,9877	0,9867	0,9811	0,9983	
	Diğer Zat.	4002	271	5203	191	0,9366	0,9646	0,9522	0,9454	0,9874	0,9467
	Sağlıklı	1797	192	7431	247	0,9035	0,9678	0,9546	0,8911	0,9833	
	Genel (ağırlıklı)					0,9467	0,9734	0,9648	0,9468	0,9904	
VAH (Orijinal-YİD)	COVID-19	3389	16	6231	31	0,9953	0,9950	0,9951	0,9931	0,9995	
	Diğer Zat.	4118	155	5228	166	0,9637	0,9692	0,9668	0,9625	0,9940	0,9644
	Sağlıklı	1816	173	7531	147	0,9130	0,9809	0,9669	0,9190	0,9917	
	Genel (ağırlıklı)					0,9644	0,9807	0,9768	0,9643	0,9954	
VAH (Orijinal-LE)	COVID-19	3378	27	6240	22	0,9921	0,9965	0,9949	0,9928	0,9994	
	Diğer Zat.	4117	156	5256	138	0,9635	0,9744	0,9696	0,9655	0,9941	0,9674
	Sağlıklı	1857	132	7523	155	0,9336	0,9798	0,9703	0,9283	0,9925	
	Genel (ağırlıklı)					0,9674	0,9833	0,9787	0,9675	0,9957	

**Çizelge 13.4.** COVID-19 zatürresi, sağlıklı ve diğer zatürre sınıflandırmasında 2B GoogleNet ESA kullanılarak elde edilen sonuçlar

Giriş	Sınıf	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AİKE-AKA	Genel Doğruluk
Orijinal	COVID-19	3347	58	6222	40	0,9830	0,9936	0,9899	0,9856	0,9989	0,9559
	Diğer Zat.	4154	119	5135	259	0,9722	0,9520	0,9609	0,9565	0,9934	
	Sağlıklı	1740	249	7551	127	0,8748	0,9835	0,9611	0,9025	0,9894	
	Genel (ağırlıklı)					0,9559	0,9731	0,9711	0,9556	0,9945	
YİD	COVID-19	3270	135	6206	56	0,9604	0,9911	0,9802	0,9716	0,9977	0,9288
	Diğer Zat.	4041	232	5049	345	0,9457	0,9360	0,9403	0,9334	0,9861	
	Sağlıklı	1668	321	7391	287	0,8386	0,9626	0,9371	0,8458	0,9748	
	Genel (ağırlıklı)					0,9288	0,9609	0,9537	0,9288	0,9879	
LE	COVID-19	3330	75	6194	68	0,9780	0,9891	0,9852	0,9790	0,9980	0,9459
	Diğer Zat.	4036	237	5177	217	0,9445	0,9598	0,9530	0,9468	0,9905	
	Sağlıklı	1778	211	7440	238	0,8939	0,9690	0,9536	0,8879	0,9855	
	Genel (ağırlıklı)					0,9459	0,9720	0,9645	0,9460	0,9921	
VAH (Orijinal-YİD)	COVID-19	3380	25	6238	24	0,9927	0,9962	0,9949	0,9928	0,9995	0,9614
	Diğer Zat.	4155	118	5163	231	0,9724	0,9572	0,9639	0,9597	0,9938	
	Sağlıklı	1759	230	7560	118	0,8844	0,9846	0,9640	0,9100	0,9896	
	Genel (ağırlıklı)					0,9614	0,9766	0,9748	0,9611	0,9950	
VAH (Orijinal-LE)	COVID-19	3373	32	6230	32	0,9906	0,9949	0,9934	0,9906	0,9993	0,9647
	Diğer Zat.	4156	117	5206	188	0,9726	0,9651	0,9684	0,9646	0,9948	
	Sağlıklı	1797	192	7557	121	0,9035	0,9842	0,9676	0,9199	0,9921	
	Genel (ağırlıklı)					0,9647	0,9796	0,9771	0,9646	0,9958	

**Çizelge 13.5.** COVID-19 zatürresi, sağlıklı ve diğer zatürre sınıflandırmasında 2B Xception ESA kullanılarak elde edilen sonuçlar

Giriş	Sınıf	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AİKE-AKA	Genel Doğruluk
Orijinal	COVID-19	3378	27	6239	23	0,9921	0,9963	0,9948	0,9927	0,9993	0,9667
	Diğer Zat.	4086	187	5283	111	0,9562	0,9794	0,9692	0,9648	0,9946	
	Sağlıklı	1881	108	7490	188	0,9457	0,9755	0,9694	0,9271	0,9940	
	Genel (ağırlıklı)					0,9667	0,9846	0,9783	0,9669	0,9961	
YİD	COVID-19	3387	18	6217	45	0,9947	0,9928	0,9935	0,9908	0,9995	0,9515
	Diğer Zat.	4046	227	5190	204	0,9469	0,9622	0,9554	0,9494	0,9905	
	Sağlıklı	1765	224	7458	220	0,8874	0,9713	0,9541	0,8883	0,9848	
	Genel (ağırlıklı)					0,9515	0,9749	0,9685	0,9514	0,9925	
LE	COVID-19	3368	37	6225	37	0,9891	0,9941	0,9923	0,9891	0,9991	0,9588
	Diğer Zat.	4089	184	5220	174	0,9569	0,9677	0,9630	0,9581	0,9918	
	Sağlıklı	1812	177	7491	187	0,9110	0,9756	0,9623	0,9087	0,9892	
	Genel (ağırlıklı)					0,9588	0,9786	0,9732	0,9589	0,9939	
VAH (Orijinal-YİD)	COVID-19	3393	12	6241	21	0,9965	0,9966	0,9966	0,9952	0,9996	0,9698
	Diğer Zat.	4113	160	5277	117	0,9626	0,9783	0,9713	0,9674	0,9950	
	Sağlıklı	1869	120	7524	154	0,9397	0,9799	0,9717	0,9317	0,9933	
	Genel (ağırlıklı)					0,9698	0,9851	0,9803	0,9698	0,9962	
VAH (Orijinal-LE)	COVID-19	3396	9	6247	15	0,9974	0,9976	0,9975	0,9965	0,9995	0,9728
	Diğer Zat.	4129	144	5285	109	0,9663	0,9798	0,9738	0,9703	0,9954	
	Sağlıklı	1879	110	7539	139	0,9447	0,9819	0,9742	0,9379	0,9940	
	Genel (ağırlıklı)					0,9728	0,9865	0,9823	0,9728	0,9965	

**Çizelge 13.6.** COVID-19 zatürresi, sağlıklı ve diğer zatürre sınıflandırmasında 2B DenseNet-201 ESA kullanılarak elde edilen sonuçlar

Giriş	Sınıf	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AİKE-AKA	Genel Doğruluk
Orijinal	COVID-19	3373	32	6227	35	0,9906	0,9944	0,9931	0,9902	0,9995	0,9701
	Diğer Zat.	4121	152	5280	114	0,9644	0,9789	0,9725	0,9687	0,9954	
	Sağlıklı	1884	105	7538	140	0,9472	0,9818	0,9747	0,9389	0,9954	
	Genel (ağırlıklı)					0,9701	0,9849	0,9802	0,9702	0,9968	
YİD	COVID-19	3392	13	6223	39	0,9962	0,9938	0,9946	0,9924	0,9994	0,9589
	Diğer Zat.	4063	210	5236	158	0,9509	0,9707	0,9619	0,9567	0,9919	
	Sağlıklı	1815	174	7478	200	0,9125	0,9740	0,9613	0,9066	0,9887	
	Genel (ağırlıklı)					0,9589	0,9795	0,9733	0,9590	0,9939	
LE	COVID-19	3385	20	6227	35	0,9941	0,9944	0,9943	0,9919	0,9994	0,9643
	Diğer Zat.	4117	156	5236	158	0,9635	0,9707	0,9675	0,9633	0,9937	
	Sağlıklı	1820	169	7526	152	0,9150	0,9802	0,9668	0,9190	0,9918	
	Genel (ağırlıklı)					0,9643	0,9810	0,9768	0,9643	0,9953	
VAH (Orijinal-YİD)	COVID-19	3395	10	6241	21	0,9971	0,9966	0,9968	0,9955	0,9996	0,9727
	Diğer Zat.	4124	149	5289	105	0,9651	0,9805	0,9737	0,9701	0,9961	
	Sağlıklı	1884	105	7540	138	0,9472	0,9820	0,9749	0,9394	0,9955	
	Genel (ağırlıklı)					0,9727	0,9865	0,9821	0,9727	0,9972	
VAH (Orijinal-LE)	COVID-19	3393	12	6239	23	0,9965	0,9963	0,9964	0,9949	0,9996	0,9753
	Diğer Zat.	4157	116	5283	111	0,9729	0,9794	0,9765	0,9734	0,9964	
	Sağlıklı	1878	111	7573	105	0,9442	0,9863	0,9777	0,9456	0,9958	
	Genel (ağırlıklı)					0,9753	0,9868	0,9837	0,9753	0,9974	

**Çizelge 13.7.** COVID-19 zatürresi, sağlıklı ve diğer zatürre sınıflandırmasında 2B EfficientNetB0 ESA kullanılarak elde edilen sonuçlar

Giriş	Sınıf	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AİKE-AKA	Genel Doğruluk
Orijinal	COVID-19	3371	34	6223	39	0,9900	0,9938	0,9924	0,9893	0,9995	0,9607
	Diğer Zat.	4083	190	5239	155	0,9555	0,9713	0,9643	0,9595	0,9924	
	Sağlıklı	1833	156	7492	186	0,9216	0,9758	0,9646	0,9147	0,9894	
	Genel (ağırlıklı)					0,9607	0,9801	0,9743	0,9608	0,9943	
YİD	COVID-19	3374	31	6172	90	0,9909	0,9856	0,9875	0,9824	0,9986	0,9402
	Diğer Zat.	3969	304	5175	219	0,9289	0,9594	0,9459	0,9382	0,9861	
	Sağlıklı	1746	243	7409	269	0,8778	0,9650	0,9470	0,8721	0,9777	
	Genel (ağırlıklı)					0,9402	0,9698	0,9608	0,9402	0,9888	
LE	COVID-19	3371	34	6208	54	0,9900	0,9914	0,9909	0,9871	0,9993	0,9522
	Diğer Zat.	4060	213	5193	201	0,9502	0,9627	0,9572	0,9515	0,9890	
	Sağlıklı	1774	215	7471	207	0,8919	0,9730	0,9563	0,8937	0,9850	
	Genel (ağırlıklı)					0,9522	0,9749	0,9689	0,9521	0,9918	
VAH (Orijinal-YİD)	COVID-19	3389	16	6229	33	0,9953	0,9947	0,9949	0,9928	0,9996	0,9654
	Diğer Zat.	4113	160	5246	148	0,9626	0,9726	0,9681	0,9639	0,9923	
	Sağlıklı	1831	158	7525	153	0,9206	0,9801	0,9678	0,9217	0,9888	
	Genel (ağırlıklı)					0,9654	0,9819	0,9775	0,9654	0,9942	
VAH (Orijinal-LE)	COVID-19	3386	19	6232	30	0,9944	0,9952	0,9949	0,9928	0,9997	0,9658
	Diğer Zat.	4115	158	5242	152	0,9630	0,9718	0,9679	0,9637	0,9933	
	Sağlıklı	1835	154	7529	149	0,9226	0,9806	0,9687	0,9237	0,9910	
	Genel (ağırlıklı)					0,9658	0,9819	0,9776	0,9657	0,9951	

**Çizelge 13.8.** COVID-19 zatürresi, sağlıklı ve diğer zatürre sınıflandırmasında 2B InceptionV3 ESA kullanılarak elde edilen sonuçları

Giriş	Sınıf	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AİKE-AKA	Genel Doğruluk
Orişinal	COVID-19	3350	55	6224	38	0,9838	0,9939	0,9904	0,9863	0,9992	0,9638
	Diğer Zat.	4115	158	5243	151	0,9630	0,9720	0,9680	0,9638	0,9952	
	Sağlıklı	1852	137	7517	161	0,9311	0,9790	0,9692	0,9255	0,9933	
	Genel (ağırlıklı)					0,9638	0,9812	0,9761	0,9639	0,9962	
YİD	COVID-19	3375	30	6222	40	0,9912	0,9936	0,9928	0,9897	0,9994	0,9558
	Diğer Zat.	4028	245	5248	146	0,9427	0,9729	0,9596	0,9537	0,9923	
	Sağlıklı	1837	152	7437	241	0,9236	0,9686	0,9593	0,9034	0,9888	
	Genel (ağırlıklı)					0,9558	0,9793	0,9712	0,9560	0,9941	
LE	COVID-19	3362	43	6228	34	0,9874	0,9946	0,9920	0,9887	0,9992	0,9536
	Diğer Zat.	4043	230	5210	184	0,9462	0,9659	0,9572	0,9513	0,9918	
	Sağlıklı	1813	176	7447	231	0,9115	0,9699	0,9579	0,8991	0,9889	
	Genel (ağırlıklı)					0,9536	0,9768	0,9696	0,9537	0,9938	
VAH (Orişinal-YİD)	COVID-19	3389	16	6237	25	0,9953	0,9960	0,9958	0,9940	0,9996	0,9732
	Diğer Zat.	4139	134	5288	106	0,9686	0,9803	0,9752	0,9718	0,9961	
	Sağlıklı	1880	109	7550	128	0,9452	0,9833	0,9755	0,9407	0,9945	
	Genel (ağırlıklı)					0,9732	0,9865	0,9825	0,9732	0,9970	
VAH (Orişinal-LE)	COVID-19	3387	18	6244	18	0,9947	0,9971	0,9963	0,9947	0,9996	0,9728
	Diğer Zat.	4137	136	5280	114	0,9682	0,9789	0,9741	0,9707	0,9960	
	Sağlıklı	1880	109	7547	131	0,9452	0,9829	0,9752	0,9400	0,9946	
	Genel (ağırlıklı)					0,9728	0,9861	0,9821	0,9728	0,9970	

COVID-19 zatürresi, sağlıklı ve diğer zatürre sınıflandırmasında uygulamada kullanılan transfer öğrenme 2B ESA mimarileri için görüntü başına çalışma süreleri Çizelge 13.9’da verilmiştir.

**Çizelge 13.9.** COVID-19 zatürresi, sağlıklı ve diğer zatürre sınıflandırması için gereken CPU çalışma sürelerinin (saniye) karşılaştırması

Transfer Öğrenme 2B ESA Mimarisi	Orişinal	YİD	LE	VAH (Orişinal-YİD)	VAH (Orişinal-LE)
MobileNetV2	1,7175	1,7149	1,7112	3,4324	3,4286
ResNet-101	4,6348	4,6434	4,6470	9,2782	9,2818
GoogleNet	0,8115	0,8454	0,8344	1,6570	1,6460
Xception	3,4998	3,4652	3,4572	6,9651	6,9570
DenseNet-201	11,3934	11,4319	11,3858	22,8253	22,7792
EfficientNetB0	5,1678	5,1760	5,1980	10,3438	10,3658
InceptionV3	4,5589	4,5833	4,4531	9,1422	9,0120

### 13.5.2. COVID-19 zatürresi, sağlıklı, bakteriyel zatürre ve viral zatürre sınıflandırma sonuçları

Uygulamada ikinci olarak COVID-19 zatürresi, sağlıklı, bakteriyel zatürre ve viral zatürre sınıflandırması gerçekleştirilmiştir. Deneylerde giriş görüntü boyutları 2B

MobileNetV2, 2B ResNet-101, 2B GoogleNet, 2B DenseNet-201 ve 2B EfficientNetB0 mimarileri için  $224 \times 224 \times 1$ ; 2B Xception ve 2B InceptionV3 mimarileri için  $299 \times 299 \times 1$ 'dir. 2B MobileNetV2, 2B ResNet-101, 2B GoogleNet, 2B Xception, 2B DenseNet-201, 2B EfficientNetB0 ve 2B InceptionV3 ESA mimarileri ile orijinal, YİD, LE giriş görüntüleri ve VAH yaklaşımı kullanılarak elde edilen sınıflandırma sonuçları sırasıyla Çizelge 13.10 ile Çizelge 13.16 arasında yer almaktadır.

**Çizelge 13.10.** COVID-19 zatürresi, sağlıklı, bakteriyel zatürre ve viral zatürre sınıflandırmasında 2B MobileNetV2 ESA kullanılarak elde edilen sonuçlar

Giriş	Sınıf	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AİKE-AKA	Genel Doğruluk
Orijinal	COVID-19 Z.	3372	33	6207	55	0,9903	0,9912	0,9909	0,9871	0,9992	0,8581
	Bakteriyel Z.	2337	443	6247	640	0,8406	0,9071	0,8880	0,8119	0,9488	
	Viral Z.	774	719	7702	472	0,5184	0,9423	0,8768	0,5652	0,8851	
	Sağlıklı	1812	177	7473	205	0,9110	0,9733	0,9605	0,9046	0,9897	
	Genel (ağırlıklı)					0,8581	0,9558	0,9374	0,8546	0,9651	
YİD	COVID-19 Z.	3352	53	6170	92	0,9844	0,9853	0,9850	0,9788	0,9985	0,8292
	Bakteriyel Z.	2166	614	6325	562	0,7791	0,9184	0,8783	0,7865	0,9428	
	Viral Z.	726	767	7582	592	0,4863	0,9276	0,8594	0,5165	0,8688	
	Sağlıklı	1772	217	7273	405	0,8909	0,9473	0,9357	0,8507	0,9769	
	Genel (ağırlıklı)					0,8292	0,9493	0,9248	0,8258	0,9580	
LE	COVID-19 Z.	3361	44	6193	69	0,9871	0,9890	0,9883	0,9835	0,9989	0,8419
	Bakteriyel Z.	2159	621	6293	594	0,7766	0,9138	0,8743	0,7804	0,9392	
	Viral Z.	844	649	7570	604	0,5653	0,9261	0,8704	0,5740	0,8861	
	Sağlıklı	1775	214	7417	261	0,8924	0,9660	0,9509	0,8820	0,9831	
	Genel (ağırlıklı)					0,8419	0,9529	0,9296	0,8409	0,9611	
VAH (Orijinal-YİD)	COVID-19 Z.	3396	9	6214	48	0,9974	0,9923	0,9941	0,9917	0,9994	0,8701
	Bakteriyel Z.	2372	408	6318	569	0,8532	0,9174	0,8989	0,8292	0,9566	
	Viral Z.	784	709	7791	383	0,5251	0,9531	0,8870	0,5895	0,8995	
	Sağlıklı	1859	130	7422	256	0,9346	0,9667	0,9601	0,9059	0,9897	
	Genel (ağırlıklı)					0,8701	0,9594	0,9432	0,8652	0,9697	
VAH (Orijinal-LE)	COVID-19 Z.	3389	16	6220	42	0,9953	0,9933	0,9940	0,9915	0,9994	0,8738
	Bakteriyel Z.	2369	411	6303	584	0,8522	0,9152	0,8971	0,8264	0,9550	
	Viral Z.	831	662	7762	412	0,5566	0,9496	0,8889	0,6075	0,9059	
	Sağlıklı	1858	131	7496	182	0,9341	0,9763	0,9676	0,9223	0,9913	
	Genel (ağırlıklı)					0,8738	0,9606	0,9445	0,8705	0,9705	



**Çizelge 13.11.** COVID-19 zatürresi, sağlıklı, bakteriyel zatürre ve viral zatürre sınıflandırmasında 2B ResNet-101 ESA kullanılarak elde edilen sonuçlar

Giriş	Sınıf	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AİKE-AKA	Genel Doğruluk
Orijinal	COVID-19 Z.	3359	46	6217	45	0,9865	0,9928	0,9906	0,9866	0,9984	0,8573
	Bakteriyel Z.	2184	596	6380	507	0,7856	0,9264	0,8859	0,7984	0,9505	
	Viral Z.	883	610	7567	607	0,5914	0,9257	0,8741	0,5920	0,9028	
	Sağlıklı	1862	127	7458	220	0,9361	0,9713	0,9641	0,9148	0,9907	
	Genel (ağırlıklı)					0,8573	0,9589	0,9370	0,8568	0,9683	
YİD	COVID-19 Z.	3369	36	6181	81	0,9894	0,9871	0,9879	0,9829	0,9987	0,8358
	Bakteriyel Z.	2284	496	6174	713	0,8216	0,8965	0,8749	0,7907	0,9417	
	Viral Z.	683	810	7651	523	0,4575	0,9360	0,8621	0,5061	0,8649	
	Sağlıklı	1744	245	7408	270	0,8768	0,9648	0,9467	0,8713	0,9778	
	Genel (ağırlıklı)					0,8358	0,9486	0,9275	0,8311	0,9573	
LE	COVID-19 Z.	3364	41	6164	98	0,9880	0,9844	0,9856	0,9798	0,9985	0,8484
	Bakteriyel Z.	2163	617	6359	528	0,7781	0,9233	0,8816	0,7907	0,9419	
	Viral Z.	871	622	7574	600	0,5834	0,9266	0,8736	0,5877	0,8852	
	Sağlıklı	1803	186	7438	240	0,9065	0,9687	0,9559	0,8943	0,9834	
	Genel (ağırlıklı)					0,8484	0,9547	0,9323	0,8473	0,9616	
VAH (Orijinal-YİD)	COVID-19 Z.	3390	15	6215	47	0,9956	0,9925	0,9936	0,9909	0,9995	0,8700
	Bakteriyel Z.	2384	396	6285	602	0,8576	0,9126	0,8968	0,8269	0,9566	
	Viral Z.	778	715	7777	397	0,5211	0,9514	0,8850	0,5832	0,9073	
	Sağlıklı	1858	131	7467	211	0,9341	0,9725	0,9646	0,9157	0,9915	
	Genel (ağırlıklı)					0,8700	0,9591	0,9430	0,8653	0,9713	
VAH (Orijinal-LE)	COVID-19 Z.	3389	16	6202	60	0,9953	0,9904	0,9921	0,9889	0,9993	0,8708
	Bakteriyel Z.	2267	513	6401	486	0,8155	0,9294	0,8967	0,8194	0,9568	
	Viral Z.	895	598	7672	502	0,5995	0,9386	0,8862	0,6194	0,9117	
	Sağlıklı	1867	122	7477	201	0,9387	0,9738	0,9666	0,9204	0,9926	
	Genel (ağırlıklı)					0,8708	0,9615	0,9431	0,8690	0,9722	

**Çizelge 13.12.** COVID-19 zatürresi, sağlıklı, bakteriyel zatürre ve viral zatürre sınıflandırmasında 2B GoogleNet ESA kullanılarak elde edilen sonuçlar

Giriş	Sınıf	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AIKE-AKA	Genel Doğruluk
Orijinal	COVID-19 Z.	3384	21	6182	80	0,9938	0,9872	0,9896	0,9853	0,9987	0,8657
	Bakteriyel Z.	2257	523	6432	455	0,8119	0,9339	0,8988	0,8219	0,9594	
	Viral Z.	933	560	7623	551	0,6249	0,9326	0,8851	0,6268	0,9142	
	Sağlıklı	1795	194	7466	212	0,9025	0,9724	0,9580	0,8984	0,9890	
	Genel (ağırlıklı)					0,8657	0,9604	0,9408	0,8651	0,9724	
YİD	COVID-19 Z.	3315	90	6189	73	0,9736	0,9883	0,9831	0,9760	0,9972	0,8128
	Bakteriyel Z.	1950	830	6448	439	0,7014	0,9363	0,8687	0,7545	0,9419	
	Viral Z.	920	573	7230	944	0,6162	0,8845	0,8431	0,5481	0,8723	
	Sağlıklı	1672	317	7324	354	0,8406	0,9539	0,9306	0,8329	0,9721	
	Genel (ağırlıklı)					0,8128	0,9502	0,9178	0,8168	0,9568	
LE	COVID-19 Z.	3354	51	6173	89	0,9850	0,9858	0,9855	0,9796	0,9983	0,8465
	Bakteriyel Z.	2294	486	6235	652	0,8252	0,9053	0,8823	0,8013	0,9470	
	Viral Z.	809	684	7635	539	0,5419	0,9341	0,8735	0,5695	0,8957	
	Sağlıklı	1726	263	7474	204	0,8678	0,9734	0,9517	0,8808	0,9824	
	Genel (ağırlıklı)					0,8465	0,9521	0,9316	0,8446	0,9645	
VAH (Orijinal-YİD)	COVID-19 Z.	3385	20	6207	55	0,9941	0,9912	0,9922	0,9890	0,9993	0,8697
	Bakteriyel Z.	2218	562	6486	401	0,7978	0,9418	0,9004	0,8216	0,9610	
	Viral Z.	960	533	7609	565	0,6430	0,9309	0,8864	0,6362	0,9146	
	Sağlıklı	1844	145	7439	239	0,9271	0,9689	0,9603	0,9057	0,9898	
	Genel (ağırlıklı)					0,8697	0,9631	0,9429	0,8693	0,9732	
VAH (Orijinal-LE)	COVID-19 Z.	3392	13	6199	63	0,9962	0,9899	0,9921	0,9889	0,9993	0,8799
	Bakteriyel Z.	2367	413	6385	502	0,8514	0,9271	0,9053	0,8380	0,9628	
	Viral Z.	892	601	7772	402	0,5975	0,9508	0,8962	0,6401	0,9238	
	Sağlıklı	1855	134	7484	194	0,9326	0,9747	0,9661	0,9188	0,9922	
	Genel (ağırlıklı)					0,8799	0,9627	0,9470	0,8772	0,9757	

**Çizelge 13.13.** COVID-19 zatürresi, sağlıklı, bakteriyel zatürre ve viral zatürre sınıflandırmasında 2B Xception ESA kullanılarak elde edilen sonuçlar

Giriş	Sınıf	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AIKE-AKA	Genel Doğruluk
Orijinal	COVID-19 Z.	3385	20	6234	28	0,9941	0,9955	0,9950	0,9930	0,9996	0,8766
	Bakteriyel Z.	2415	365	6257	630	0,8687	0,9085	0,8971	0,8292	0,9604	
	Viral Z.	809	684	7781	393	0,5419	0,9519	0,8886	0,6004	0,9112	
	Sağlıklı	1865	124	7536	142	0,9377	0,9815	0,9725	0,9334	0,9939	
	Genel (ağırlıklı)					0,8766	0,9609	0,9458	0,8730	0,9735	
YİD	COVID-19 Z.	3382	23	6208	54	0,9932	0,9914	0,9920	0,9887	0,9995	0,8448
	Bakteriyel Z.	2274	506	6277	610	0,8180	0,9114	0,8846	0,8030	0,9488	
	Viral Z.	699	794	7711	463	0,4682	0,9434	0,8700	0,5266	0,8784	
	Sağlıklı	1812	177	7305	373	0,9110	0,9514	0,9431	0,8682	0,9813	
	Genel (ağırlıklı)					0,8448	0,9527	0,9322	0,8391	0,9625	
LE	COVID-19 Z.	3384	21	6205	57	0,9938	0,9909	0,9919	0,9886	0,9992	0,8610
	Bakteriyel Z.	2289	491	6331	556	0,8234	0,9193	0,8917	0,8139	0,9537	
	Viral Z.	795	698	7726	448	0,5325	0,9452	0,8815	0,5811	0,8959	
	Sağlıklı	1855	134	7395	283	0,9326	0,9631	0,9569	0,8990	0,9874	
	Genel (ağırlıklı)					0,8610	0,9575	0,9388	0,8570	0,9678	
VAH (Orijinal-YİD)	COVID-19 Z.	3397	8	6236	26	0,9977	0,9958	0,9965	0,9950	0,9998	0,8818
	Bakteriyel Z.	2457	323	6289	598	0,8838	0,9132	0,9047	0,8422	0,9627	
	Viral Z.	777	716	7864	310	0,5204	0,9621	0,8939	0,6023	0,9150	
	Sağlıklı	1893	96	7469	209	0,9517	0,9728	0,9684	0,9254	0,9926	
	Genel (ağırlıklı)					0,8818	0,9621	0,9485	0,8761	0,9745	
VAH (Orijinal-LE)	COVID-19 Z.	3395	10	6237	25	0,9971	0,9960	0,9964	0,9949	0,9997	0,8834
	Bakteriyel Z.	2433	347	6323	564	0,8752	0,9181	0,9058	0,8423	0,9635	
	Viral Z.	828	665	7823	351	0,5546	0,9571	0,8949	0,6198	0,9196	
	Sağlıklı	1884	105	7491	187	0,9472	0,9756	0,9698	0,9281	0,9939	
	Genel (ağırlıklı)					0,8834	0,9634	0,9492	0,8793	0,9757	

**Çizelge 13.14.** COVID-19 zatürresi, sağlıklı, bakteriyel zatürre ve viral zatürre sınıflandırmasında 2B DenseNet-201 ESA kullanılarak elde edilen sonuçlar

Giriş	Sınıf	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AİKE-AKA	Genel Doğruluk
Orijinal	COVID-19 Z.	3377	28	6234	28	0,9918	0,9955	0,9942	0,9918	0,9994	
	Bakteriyel Z.	2336	444	6386	501	0,8403	0,9273	0,9022	0,8318	0,9591	
	Viral Z.	947	546	7720	454	0,6343	0,9445	0,8966	0,6545	0,9205	0,8824
	Sağlıklı	1870	119	7524	154	0,9402	0,9799	0,9718	0,9320	0,9940	
	Genel (ağırlıklı)					0,8824	0,9648	0,9481	0,8814	0,9745	
YİD	COVID-19 Z.	3393	12	6226	36	0,9965	0,9943	0,9950	0,9930	0,9997	
	Bakteriyel Z.	2263	517	6436	451	0,8140	0,9345	0,8999	0,8238	0,9585	
	Viral Z.	894	599	7651	523	0,5988	0,9360	0,8839	0,6144	0,9080	0,8687
	Sağlıklı	1848	141	7419	259	0,9291	0,9663	0,9586	0,9023	0,9892	
	Genel (ağırlıklı)					0,8687	0,9623	0,9430	0,8672	0,9715	
LE	COVID-19 Z.	3383	22	6211	51	0,9935	0,9919	0,9924	0,9893	0,9993	
	Bakteriyel Z.	2331	449	6359	528	0,8385	0,9233	0,8989	0,8267	0,9572	
	Viral Z.	892	601	7750	424	0,5975	0,9481	0,8940	0,6351	0,9086	0,8751
	Sağlıklı	1854	135	7474	204	0,9321	0,9734	0,9649	0,9162	0,9916	
	Genel (ağırlıklı)					0,8751	0,9616	0,9447	0,8728	0,9716	
VAH (Orijinal-YİD)	COVID-19 Z.	3398	7	6237	25	0,9979	0,9960	0,9967	0,9953	0,9999	
	Bakteriyel Z.	2408	372	6454	433	0,8662	0,9371	0,9167	0,8568	0,9672	
	Viral Z.	952	541	7799	375	0,6376	0,9541	0,9052	0,6752	0,9306	0,8954
	Sağlıklı	1898	91	7500	178	0,9542	0,9768	0,9722	0,9338	0,9946	
	Genel (ağırlıklı)					0,8954	0,9687	0,9545	0,8934	0,9787	
VAH (Orijinal-LE)	COVID-19 Z.	3396	9	6236	26	0,9974	0,9958	0,9964	0,9949	0,9998	
	Bakteriyel Z.	2415	365	6404	483	0,8687	0,9299	0,9123	0,8507	0,9653	
	Viral Z.	931	562	7808	366	0,6236	0,9552	0,9040	0,6674	0,9297	0,8938
	Sağlıklı	1898	91	7526	152	0,9542	0,9802	0,9749	0,9398	0,9949	
	Genel (ağırlıklı)					0,8938	0,9674	0,9535	0,8915	0,9780	

**Çizelge 13.15.** COVID-19 zatürresi, sağlıklı, bakteriyel zatürre ve viral zatürre sınıflandırmasında 2B EfficientNetB0 ESA kullanılarak elde edilen sonuçlar

Giriş	Sınıf	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AİKE-AKA	Genel Doğruluk
Orijinal	COVID-19 Z.	3375	30	6213	49	0,9912	0,9922	0,9918	0,9884	0,9992	
	Bakteriyel Z.	2336	444	6265	622	0,8403	0,9097	0,8897	0,8142	0,9511	
	Viral Z.	796	697	7720	454	0,5332	0,9445	0,8809	0,5804	0,8873	0,8631
	Sağlıklı	1837	152	7480	198	0,9236	0,9742	0,9638	0,9130	0,9901	
	Genel (ağırlıklı)					0,8631	0,9574	0,9396	0,8598	0,9662	
YİD	COVID-19 Z.	3370	35	6138	124	0,9897	0,9802	0,9836	0,9770	0,9986	
	Bakteriyel Z.	2296	484	6168	719	0,8259	0,8956	0,8756	0,7924	0,9397	
	Viral Z.	646	847	7719	455	0,4327	0,9443	0,8653	0,4981	0,8518	0,8313
	Sağlıklı	1724	265	7345	333	0,8668	0,9566	0,9381	0,8522	0,9761	
	Genel (ağırlıklı)					0,8313	0,9455	0,9249	0,8243	0,9544	
LE	COVID-19 Z.	3370	35	6191	71	0,9897	0,9887	0,9890	0,9845	0,9990	
	Bakteriyel Z.	2308	472	6252	635	0,8302	0,9078	0,8855	0,8066	0,9484	
	Viral Z.	776	717	7690	484	0,5198	0,9408	0,8758	0,5637	0,8831	0,8517
	Sağlıklı	1779	210	7434	244	0,8944	0,9682	0,9530	0,8868	0,9845	
	Genel (ağırlıklı)					0,8517	0,9538	0,9344	0,8483	0,9636	
VAH (Orijinal-YİD)	COVID-19 Z.	3387	18	6216	46	0,9947	0,9927	0,9934	0,9906	0,9996	
	Bakteriyel Z.	2435	345	6220	667	0,8759	0,9032	0,8953	0,8279	0,9546	
	Viral Z.	716	777	7834	340	0,4796	0,9584	0,8845	0,5618	0,8944	0,8661
	Sağlıklı	1835	154	7437	241	0,9226	0,9686	0,9591	0,9028	0,9892	
	Genel (ağırlıklı)					0,8661	0,9567	0,9413	0,8596	0,9683	
VAH (Orijinal-LE)	COVID-19 Z.	3389	16	6223	39	0,9953	0,9938	0,9943	0,9920	0,9996	
	Bakteriyel Z.	2422	358	6270	617	0,8712	0,9104	0,8991	0,8324	0,9574	
	Viral Z.	796	697	7810	364	0,5332	0,9555	0,8902	0,6001	0,9046	0,8750
	Sağlıklı	1852	137	7490	188	0,9311	0,9755	0,9664	0,9193	0,9906	
	Genel (ağırlıklı)					0,8750	0,9601	0,9451	0,8706	0,9709	

**Çizelge 13.16.** COVID-19 zatürresi, sağlıklı, bakteriyel zatürre ve viral zatürre sınıflandırmasında 2B InceptionV3 ESA kullanılarak elde edilen sonuçlar

Giriş	Sınıf	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AİKE-AKA	Genel Doğruluk
Orijinal	COVID-19 Z.	3341	64	6228	34	0,9812	0,9946	0,9899	0,9855	0,9993	0,8752
	Bakteriyel Z.	2317	463	6377	510	0,8335	0,9259	0,8993	0,8265	0,9578	
	Viral Z.	929	564	7698	476	0,6222	0,9418	0,8924	0,6411	0,9148	
	Sağlıklı	1874	115	7492	186	0,9422	0,9758	0,9689	0,9257	0,9929	
	Genel (ağırlıklı)					0,8752	0,9628	0,9445	0,8743	0,9730	
YİD	COVID-19 Z.	3377	28	6208	54	0,9918	0,9914	0,9915	0,9880	0,9993	0,8621
	Bakteriyel Z.	2216	564	6424	463	0,7971	0,9328	0,8938	0,8119	0,9557	
	Viral Z.	961	532	7547	627	0,6437	0,9233	0,8801	0,6238	0,9121	
	Sağlıklı	1780	209	7489	189	0,8949	0,9754	0,9588	0,8994	0,9890	
	Genel (ağırlıklı)					0,8621	0,9607	0,9395	0,8629	0,9712	
LE	COVID-19 Z.	3362	43	6193	69	0,9874	0,9890	0,9884	0,9836	0,9986	0,8566
	Bakteriyel Z.	2282	498	6294	593	0,8209	0,9139	0,8871	0,8071	0,9497	
	Viral Z.	793	700	7728	446	0,5311	0,9454	0,8815	0,5805	0,8978	
	Sağlıklı	1844	145	7400	278	0,9271	0,9638	0,9562	0,8971	0,9897	
	Genel (ağırlıklı)					0,8566	0,9555	0,9362	0,8528	0,9672	
VAH (Orijinal-YİD)	COVID-19 Z.	3391	14	6229	33	0,9959	0,9947	0,9951	0,9931	0,9997	0,8885
	Bakteriyel Z.	2344	436	6444	443	0,8432	0,9357	0,9091	0,8421	0,9663	
	Viral Z.	978	515	7725	449	0,6551	0,9451	0,9003	0,6699	0,9317	
	Sağlıklı	1876	113	7525	153	0,9432	0,9801	0,9725	0,9338	0,9945	
	Genel (ağırlıklı)					0,8885	0,9671	0,9511	0,8876	0,9785	
VAH (Orijinal-LE)	COVID-19 Z.	3384	21	6229	33	0,9938	0,9947	0,9944	0,9921	0,9997	0,8835
	Bakteriyel Z.	2380	400	6360	527	0,8561	0,9235	0,9041	0,8370	0,9622	
	Viral Z.	870	623	7810	364	0,5827	0,9555	0,8979	0,6381	0,9241	
	Sağlıklı	1907	82	7476	202	0,9588	0,9737	0,9706	0,9307	0,9946	
	Genel (ağırlıklı)					0,8835	0,9638	0,9486	0,8802	0,9762	

COVID-19 zatürresi, sağlıklı, bakteriyel zatürre ve viral zatürre sınıflandırmasında uygulamada kullanılan transfer öğrenme 2B ESA mimarileri için görüntü başına çalışma süreleri Çizelge 13.17’de verilmiştir.

**Çizelge 13.17.** COVID-19 zatürresi, sağlıklı, bakteriyel zatürre ve viral zatürre sınıflandırması için gereken CPU çalışma sürelerinin (saniye) karşılaştırması

Transfer Öğrenme 2B ESA Mimarisi	Orijinal	YİD	LE	VAH (Orijinal-YİD)	VAH (Orijinal-LE)
MobileNetV2	1,3685	1,3698	1,3709	2,7382	2,7394
ResNet-101	4,6275	4,6449	4,6448	9,2724	9,2723
GoogleNet	0,7231	0,7265	0,7239	1,4495	1,4469
Xception	2,9742	2,9788	2,9805	5,9531	5,9547
DenseNet-201	11,2532	11,3975	11,3028	22,6506	22,5560
EfficientNetB0	4,1183	4,1328	4,1424	8,2510	8,2606
InceptionV3	3,5685	3,5727	3,5508	7,1412	7,1193

### 13.6. X-Ray Görüntüler Üzerinden COVID-19 Zatürresi, Sağlıklı ve Diğer Zatürre ile COVID-19 Zatürresi, Sağlıklı, Bakteriyel Zatürre ve Viral Zatürre Sınıflandırma Sonuçlarının Değerlendirilmesi

Tez çalışmasının yedinci uygulamasında COVID-19 zatürresi, sağlıklı ve diğer zatürre sınıflandırma sonuçları Çizelge 13.2 ile Çizelge 13.8 arasında, COVID-19 zatürresi, sağlıklı, bakteriyel zatürre ve viral zatürre sınıflandırma sonuçları ise Çizelge 13.10 ile Çizelge 13.16 arasında verilmiştir. Bu bölümde söz konusu sonuçların değerlendirilmesi yapılmıştır.

Çizelge 13.18 COVID-19 zatürresi, sağlıklı ve diğer zatürre sınıflandırması için VAH yaklaşımı kullanılmadan önce ve kullanıldıktan sonra elde edilen en yüksek ağırlıklı parametreleri, genel doğruluk parametrelerini ve çalışma sürelerini göstermektedir.

**Çizelge 13.18.** COVID-19 zatürresi, sağlıklı ve diğer zatürre sınıflandırmasında VAH yaklaşımı kullanılmadan önce ve kullanıldıktan sonra elde edilen en iyi sınıflandırma sonuçlarının karşılaştırması

Yöntem	Genel (ağırlıklı)					Genel Doğruluk	CPU Süresi (saniye)
	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AIKE-AKA		
VAH'dan Önce (MobileNetV2/Orijinal)	0,9602	0,9821	0,9739	0,9605	0,9940	0,9602	1,7175
VAH'dan Sonra (MobileNetV2/Orijinal-LE)	0,9669	0,9837	0,9784	0,9669	0,9949	0,9669	3,4286
VAH'dan Önce (ResNet-101/Orijinal)	0,9607	0,9798	0,9743	0,9608	0,9950	0,9607	4,6348
VAH'dan Sonra (ResNet-101/Orijinal-LE)	0,9674	0,9833	0,9787	0,9675	0,9957	0,9674	9,2818
VAH'dan Önce (GoogleNet/Orijinal)	0,9559	0,9731	0,9711	0,9556	0,9945	0,9559	0,8115
VAH'dan Sonra (GoogleNet/Orijinal-LE)	0,9647	0,9796	0,9771	0,9646	0,9958	0,9647	1,6460
VAH'dan Önce (Xception/Orijinal)	0,9667	0,9846	0,9783	0,9669	0,9961	0,9667	3,4998
VAH'dan Sonra (Xception/Orijinal-LE)	0,9728	0,9865	0,9823	0,9728	0,9965	0,9728	6,9570
VAH'dan Önce (DenseNet-201/Orijinal)	0,9701	0,9849	0,9802	0,9702	0,9968	0,9701	11,3934
VAH'dan Sonra (DenseNet-201/Orijinal-LE)	0,9753	0,9868	0,9837	0,9753	0,9974	0,9753	22,7792
VAH'dan Önce (EfficientNetB0/Orijinal)	0,9607	0,9801	0,9743	0,9608	0,9943	0,9607	5,1678
VAH'dan Sonra (EfficientNetB0/Orijinal-LE)	0,9658	0,9819	0,9776	0,9657	0,9951	0,9658	10,3658
VAH'dan Önce (InceptionV3/Orijinal)	0,9638	0,9812	0,9761	0,9639	0,9962	0,9638	4,5589
VAH'dan Sonra (InceptionV3/Orijinal-YİD)	0,9732	0,9865	0,9825	0,9732	0,9970	0,9732	9,1422

Çizelge 13.18'den en yüksek sonuçların VAH yaklaşımı kullanılmadan önce giriş görüntüsü olarak orijinal görüntülerin kullanılmasıyla elde edildiği görülmektedir. Çizelge 3.2 ile Çizelge 13.8 arasında verilen detaylı sonuçlar incelendiğinde bazı istisnalar (2B InceptionV3) olmakla birlikte LE giriş görüntüleri kullanılarak elde edilen

sonuçların YİD giriş görüntüleri kullanılarak elde edilen sonuçlardan daha yüksek olduğu anlaşılmaktadır.

Çizelge 13.18 incelendiğinde en başarılı ilk beş transfer öğrenme 2B ESA mimarisinin sırasıyla 2B DenseNet-201, 2B Xception, 2B InceptionV3, 2B ResNet-101 ve 2B EfficientNetB0 olduğu anlaşılmaktadır. Eğitim ve test işlemleri dahil olmak üzere görüntü başına en yavaş çalışma süresine sahip ilk beş transfer öğrenme 2B ESA mimarisi ise sırasıyla 2B DenseNet-201, 2B EfficientNetB0, 2B ResNet-101, 2B InceptionV3 ve 2B Xception'dur. VAH yaklaşımı kullanılması durumunda bu sıralamaların genellikle korunduğu görülmektedir.

Çizelge 13.18 incelendiğinde, VAH yaklaşımları kullanılması durumunda tüm transfer öğrenme 2B ESA mimarileri için sonuçların iyileştiği görülmektedir. Bu kapsamda, ağırlıklı duyarlılık parametresinde %0,51 ile %0,94 arasında bir iyileşme sağlanmıştır. Benzer şekilde ağırlıklı özgüllük parametresinde %0,16 ile %0,64 arasında, ağırlıklı doğruluk parametresinde ise %0,33 ile %0,63 arasında artış olmuştur. Ağırlıklı F-1 skoru parametresinde %0,50 ile %0,94 arasında ve ağırlıklı AİKE-AKA parametresinde %0,04 ile %0,13 arasında bir iyileşme görülmektedir. Ayrıca, Genel doğruluk parametresinde %0,51 ile %0,94 arasında bir artış sağlanmıştır. VAH yaklaşımlarında genellikle orijinal görüntü ile LE özellik görüntü eşleşmesinin orijinal görüntü ile YİD özellik görüntü eşleşmesinden daha iyi sonuçlar verdiği görülmektedir.

Uygulamada üç sınıflı sınıflandırma için VAH yaklaşımında doku özellik görüntüleri kullanılmasının avantajlarını ortaya çıkarmak için bir deney daha gerçekleştirilmiştir. Orijinal görüntüler kullanılarak en yüksek sonuçları sağlayan 2B Xception ve 2B DenseNet-201 mimarilerinin sonuçları aynı VAH yaklaşımı kullanılarak birleştirilmiştir. Bu deneyde elde edilen sınıflandırma sonuçları Çizelge 13.19'da görülmektedir. Ayrıca karşılaştırmanın daha kolay anlaşılabilmesi için, 2B DenseNet-201 mimarisi için orijinal görüntüler, LE özellik görüntüleri ve VAH yaklaşımı kullanılarak elde edilen sonuçlar çizelgeye eklenmiştir. 2B DenseNet-201 ve 2B Xception mimarileri için genel doğrulukları 0,9701 ve 0,9667 olan iki sonuç kümesi birleştirilerek genel doğruluk parametresi 0,9732 seviyesine yükseltilmiştir. 2B DenseNet-201 mimarisinin orijinal görüntü ve LE özellik görüntü sonuçları VAH yaklaşımı ile birleştirilerek genel doğruluk 0,9753 seviyesine yükseltilir. Bu birleştirme işleminde genel doğruluğu daha düşük (0,9643) bir sonuç kümesi kullanılmasına rağmen birleştirme sonucunun daha yüksek olduğu görülmektedir.



**Çizelge 13.19.** VAH yaklaşımında doku özellik görüntüleri kullanılmasının COVID-19 zatürresi, sağlıklı ve diğer zatürre sınıflandırma sonuçlarına etkisi

Giriş	Sınıf	DP	YN	DN	YP	Duyarluluk	Özgüllük	Doğruluk	F-1 Skoru	AIKE-AKA	Genel Doğruluk
2B DenseNet-201 (Orijinal)	COVID-19	3373	32	6227	35	0,9906	0,9944	0,9931	0,9902	0,9995	0,9701
	Diğer Zat.	4121	152	5280	114	0,9644	0,9789	0,9725	0,9687	0,9954	
	Sağlıklı	1884	105	7538	140	0,9472	0,9818	0,9747	0,9389	0,9954	
	Genel (ağırlıklı)					0,9701	0,9849	0,9802	0,9702	0,9968	
2B Xception (Orijinal)	COVID-19	3378	27	6239	23	0,9921	0,9963	0,9948	0,9927	0,9993	0,9667
	Diğer Zat.	4086	187	5283	111	0,9562	0,9794	0,9692	0,9648	0,9946	
	Sağlıklı	1881	108	7490	188	0,9457	0,9755	0,9694	0,9271	0,9940	
	Genel (ağırlıklı)					0,9667	0,9846	0,9783	0,9669	0,9961	
VAH (2B Densenet201 (Orijinal)-2B Xception (Orijinal))	COVID-19	3384	21	6238	24	0,9938	0,9962	0,9953	0,9934	0,9996	0,9732
	Diğer Zat.	4122	151	5304	90	0,9647	0,9833	0,9751	0,9716	0,9964	
	Sağlıklı	1902	87	7533	145	0,9563	0,9811	0,9760	0,9425	0,9962	
	Genel (ağırlıklı)					0,9732	0,9874	0,9824	0,9733	0,9975	
2B DenseNet-201 (Orijinal)	COVID-19	3373	32	6227	35	0,9906	0,9944	0,9931	0,9902	0,9995	0,9701
	Diğer Zat.	4121	152	5280	114	0,9644	0,9789	0,9725	0,9687	0,9954	
	Sağlıklı	1884	105	7538	140	0,9472	0,9818	0,9747	0,9389	0,9954	
	Genel (ağırlıklı)					0,9701	0,9849	0,9802	0,9702	0,9968	
2B DenseNet-201 (LE)	COVID-19	3385	20	6227	35	0,9941	0,9944	0,9943	0,9919	0,9994	0,9643
	Diğer Zat.	4117	156	5236	158	0,9635	0,9707	0,9675	0,9633	0,9937	
	Sağlıklı	1820	169	7526	152	0,9150	0,9802	0,9668	0,9190	0,9918	
	Genel (ağırlıklı)					0,9643	0,9810	0,9768	0,9643	0,9953	
VAH (2B DenseNet-201 (Orijinal)-LE)	COVID-19	3393	12	6239	23	0,9965	0,9963	0,9964	0,9949	0,9996	0,9753
	Diğer Zat.	4157	116	5283	111	0,9729	0,9794	0,9765	0,9734	0,9964	
	Sağlıklı	1878	111	7573	105	0,9442	0,9863	0,9777	0,9456	0,9958	
	Genel (ağırlıklı)					0,9753	0,9868	0,9837	0,9753	0,9974	

Çizelge 13.20 COVID-19 zatürresi, sağlıklı, bakteriyel zatürre ve viral zatürre olmak üzere dört sınıflı sınıflandırma için VAH yaklaşımı kullanılmadan önce ve kullanıldıktan sonra elde edilen en yüksek ağırlıklı parametreleri, genel doğruluk parametresini ve çalışma sürelerini göstermektedir. Çizelge 13.20 incelendiğinde en yüksek sonuçların VAH yaklaşımı kullanılmadan önce giriş görüntüsü olarak orijinal görüntülerin kullanılmasıyla elde edildiği görülmektedir. Çizelge 13.10 ile Çizelge 13.16 arasında verilen detaylı sonuçlar incelendiğinde bazı istisnalar (2B DenseNet-201 ve 2B InceptionV3) olmakla birlikte LE giriş görüntüleri kullanılarak elde edilen sonuçların YİD giriş görüntüleri kullanılarak elde edilen sonuçlardan daha yüksek olduğu anlaşılmaktadır.

Çizelge 13.20 incelendiğinde, VAH yaklaşımları kullanılması durumunda tüm transfer öğrenme 2B ESA mimarileri için sonuçların iyileştiği görülmektedir. Bu kapsamda ağırlıklı özgüllük parametresinde %0,68 ile %1,57 arasında bir iyileşme sağlanmıştır. Benzer şekilde ağırlıklı özgüllük parametresinde %0,23 ile %0,48

arasında, ağırlıklı doğruluk parametresinde ise %0,34 ile %0,70 arasında artış olmuştur. Ağırlıklı F-1 skoru parametresinde %0,63 ile %1,59 arasında ve ağırlıklı AİKE-AKA parametresinde %0,22 ile %0,55 arasında bir iyileşme elde edilmiştir. Genel doğruluk parametresinde %0,68 ile %1,57 arasında bir artış sağlanmıştır. VAH yaklaşımlarında genellikle orijinal görüntü ile LE özellik görüntü eşleşmesinin orijinal görüntü ile YİD özellik görüntü eşleşmesinden daha iyi sonuçlar verdiği görülmektedir.

**Çizelge 13.20.** COVID-19 zatürresi, sağlıklı, bakteriyel zatürre ve viral zatürre sınıflandırmasında VAH yaklaşımı kullanılmadan önce ve kullanıldıktan sonra elde edilen en iyi sınıflandırma sonuçlarının karşılaştırması

Yöntem	Genel (ağırlıklı)					Genel Doğruluk	CPU Süresi (saniye)
	Duyarluluk	Özgüllük	Doğruluk	F-1 Skoru	AİKE-AKA		
VAH'dan Önce (MobileNetV2/Orijinal)	0,8581	0,9558	0,9374	0,8546	0,9651	0,8581	1,3685
VAH'dan Sonra (MobileNetV2/Orijinal-LE)	0,8738	0,9606	0,9445	0,8705	0,9705	0,8738	2,7394
VAH'dan Önce (ResNet-101/Orijinal)	0,8573	0,9589	0,9370	0,8568	0,9683	0,8573	4,6275
VAH'dan Sonra (ResNet-101/Orijinal-LE)	0,8708	0,9615	0,9431	0,8690	0,9722	0,8708	9,2723
VAH'dan Önce (GoogleNet/Orijinal)	0,8657	0,9604	0,9408	0,8651	0,9724	0,8657	0,7231
VAH'dan Sonra (GoogleNet/Orijinal-LE)	0,8799	0,9627	0,9470	0,8772	0,9757	0,8799	1,4469
VAH'dan Önce (Xception/Orijinal)	0,8766	0,9609	0,9458	0,8730	0,9735	0,8766	2,9742
VAH'dan Sonra (Xception/Orijinal-LE)	0,8834	0,9634	0,9492	0,8793	0,9757	0,8834	5,9547
VAH'dan Önce (DenseNet-201/Orijinal)	0,8824	0,9648	0,9481	0,8814	0,9745	0,8824	11,2532
VAH'dan Sonra (DenseNet-201/Orijinal-YİD)	0,8954	0,9687	0,9545	0,8934	0,9787	0,8954	22,6506
VAH'dan Önce (EfficientNetB0/Orijinal)	0,8631	0,9574	0,9396	0,8598	0,9662	0,8631	4,1183
VAH'dan Sonra (EfficientNetB0/Orijinal-LE)	0,8750	0,9601	0,9451	0,8706	0,9709	0,8750	8,2606
VAH'dan Önce (InceptionV3/Orijinal)	0,8752	0,9628	0,9445	0,8743	0,9730	0,8752	3,5685
VAH'dan Sonra (InceptionV3/Orijinal-YİD)	0,8885	0,9671	0,9511	0,8876	0,9785	0,8885	7,1412

Uygulamada dört sınıflı sınıflandırma için VAH yaklaşımında doku özellik görüntüleri kullanılmasının avantajlarını ortaya çıkarmak için bir deney daha gerçekleştirilmiştir. Orijinal görüntüler kullanılarak en yüksek sonuçları sağlayan 2B Xception ve 2B DenseNet-201 mimarilerinin sonuçları aynı VAH yaklaşımı kullanılarak birleştirilmiştir. Bu deneyde elde edilen sınıflandırma sonuçları Çizelge 13.21'de görülmektedir. Ayrıca karşılaştırmanın daha kolay anlaşılabilmesi için, 2B DenseNet-201 mimarisi için orijinal görüntüler, YİD özellik görüntüleri ve VAH yaklaşımı kullanılarak elde edilen sonuçlar çizelgeye eklenmiştir. 2B DenseNet-201 ve 2B Xception mimarileri için genel doğrulukları 0,8824 ve 0,8766 olan iki sonuç kümesi birleştirilerek genel doğruluk parametresi 0,8906 seviyesine yükseltilmiştir. 2B DenseNet-201 mimarisinin orijinal görüntü ve YİD özellik görüntü sonuçları VAH yaklaşımı ile birleştirilerek genel doğruluk 0,8954 seviyesine yükseltilir. Bu birleştirme

işleminde genel doğruluğu daha düşük (0,8687) bir sonuç kümesi kullanılmasına rağmen birleştirme sonucunun daha yüksek olduğu görülmektedir.

**Çizelge 13.21.** VAH yaklaşımında doku özellik görüntüleri kullanılmasının COVID-19 zatürresi, sağlıklı, bakteriyel zatürre ve viral zatürre sınıflandırma sonuçlarına etkisi

Giriş	Sınıf	DP	YN	DN	YP	Duyarlılık	Özgüllük	Doğruluk	F-1 Skoru	AIKE-AKA	Genel Doğruluk
2B DenseNet-201 (Orijinal)	COVID-19	3377	28	6234	28	0,9918	0,9955	0,9942	0,9918	0,9994	0,8824
	Bakteriyel	2336	444	6386	501	0,8403	0,9273	0,9022	0,8318	0,9591	
	Viral Z.	947	546	7720	454	0,6343	0,9445	0,8966	0,6545	0,9205	
	Sağlıklı	1870	119	7524	154	0,9402	0,9799	0,9718	0,9320	0,9940	
	Genel (ağırlıklı)					0,8824	0,9648	0,9481	0,8814	0,9745	
2B Xception (Orijinal)	COVID-19	3385	20	6234	28	0,9941	0,9955	0,9950	0,9930	0,9996	0,8766
	Bakteriyel	2415	365	6257	630	0,8687	0,9085	0,8971	0,8292	0,9604	
	Viral Z.	809	684	7781	393	0,5419	0,9519	0,8886	0,6004	0,9112	
	Sağlıklı	1865	124	7536	142	0,9377	0,9815	0,9725	0,9334	0,9939	
	Genel (ağırlıklı)					0,8766	0,9609	0,9458	0,8730	0,9735	
VAH (2B Densenet201 (Orijinal)-2B Xception (Orijinal))	COVID-19	3388	17	6235	27	0,9950	0,9957	0,9954	0,9935	0,9996	0,8906
	Bakteriyel	2445	335	6339	548	0,8795	0,9204	0,9087	0,8470	0,9648	
	Viral Z.	891	602	7822	352	0,5968	0,9569	0,9013	0,6513	0,9261	
	Sağlıklı	1885	104	7547	131	0,9477	0,9829	0,9757	0,9413	0,9955	
	Genel (ağırlıklı)					0,8906	0,9654	0,9519	0,8878	0,9774	
2B DenseNet-201 (Orijinal)	COVID-19	3377	28	6234	28	0,9918	0,9955	0,9942	0,9918	0,9994	0,8824
	Bakteriyel	2336	444	6386	501	0,8403	0,9273	0,9022	0,8318	0,9591	
	Viral Z.	947	546	7720	454	0,6343	0,9445	0,8966	0,6545	0,9205	
	Sağlıklı	1870	119	7524	154	0,9402	0,9799	0,9718	0,9320	0,9940	
	Genel (ağırlıklı)					0,8824	0,9648	0,9481	0,8814	0,9745	
2B DenseNet-201 (YİD)	COVID-19	3393	12	6226	36	0,9965	0,9943	0,9950	0,9930	0,9997	0,8687
	Bakteriyel	2263	517	6436	451	0,8140	0,9345	0,8999	0,8238	0,9585	
	Viral Z.	894	599	7651	523	0,5988	0,9360	0,8839	0,6144	0,9080	
	Sağlıklı	1848	141	7419	259	0,9291	0,9663	0,9586	0,9023	0,9892	
	Genel (ağırlıklı)					0,8687	0,9623	0,9430	0,8672	0,9715	
VAH (2B DenseNet-201 (Orijinal)-YİD)	COVID-19	3398	7	6237	25	0,9979	0,9960	0,9967	0,9953	0,9999	0,8954
	Bakteriyel	2408	372	6454	433	0,8662	0,9371	0,9167	0,8568	0,9672	
	Viral Z.	952	541	7799	375	0,6376	0,9541	0,9052	0,6752	0,9306	
	Sağlıklı	1898	91	7500	178	0,9542	0,9768	0,9722	0,9338	0,9946	
	Genel (ağırlıklı)					0,8954	0,9687	0,9545	0,8934	0,9787	

Çizelge 13.22 ve Çizelge 13.23’de literatürde yer alan üç sınıflı ve dört sınıflı sınıflandırma çalışmalarında elde edilen sonuçlar ile uygulamada VAH yaklaşımları kullanılmadan önce ve kullanıldıktan sonra elde edilen en iyi ilk beş sonucu karşılaştırması yer almaktadır.

**Çizelge 13.22.** Tez çalışmasının yedinci uygulamasında X-ray görüntülerden COVID-19 zatürresi, sağlıklı ve diğer zatürre sınıflandırması için elde edilen sonuçların literatürde yer alan çalışmalarda elde edilen sonuçlar ile karşılaştırılması

Çalışma	Duyarlılık	Özgüllük	Ağırlıklı Doğruluk/ Genel Doğruluk	F-1 Skoru	AIKE-AKA
Islam ve ark., 2020	X	X	0,9940	X	X
Yıldırım ve Çınar, 2020	X	X	0,8889-0,9630	X	X
Rahimzadeh ve Attar, 2020	X	X	0,8979-0,9140	X	X
Nour ve ark., 2020	0,8753-0,9461	0,9554-0,9975	0,9209-0,9897	0,8769-0,9672	X
Das ve ark., 2020	0,970921	0,972973	0,974068	0,969697	X
Öztürk ve ark., 2020	0,8535	0,9218	0,8702	0,8737	X
Toraman ve ark., 2020	0,8422	0,9179	0,8919/0,8422	0,8421	X
Khan ve ark., 2020	0,969	0,975	0,950	0,956	X
Toğaçar ve ark., 2020	X	X	0,9781-0,9927	X	X
Uçar ve Korkmaz, 2020	0,6921-0,9826	0,7993-0,9913	0,7637-0,9826	0,6689-0,9825	X
Civit-Masot ve ark., 2020	0,85-0,86	0,92-0,93	0,85-0,86	0,85-0,86	0,949
Singh ve ark., 2020	0,956	X	0,958	0,9588	X
Shorfuzzaman ve Masud, 2020	0,9565-1,000	0,9767-0,9889	0,9411-0,9926	0,9573-0,9889	0,9547-0,9944
Pandit ve Bandy, 2020	0,867	0,951	0,9253	X	X
Loey ve ark., 2020	0,8148-0,8519	X	0,8148-0,8519	0,8146-0,8519	X
VAH'dan Önce (EfficientNetB0/Orijinal)	0,9607	0,9801	0,9743/0,9607	0,9608	0,9943
VAH'dan Sonra (EfficientNetB0/Orijinal-LE)	0,9658	0,9819	0,9776/0,9658	0,9657	0,9951
VAH'dan Önce (ResNet-101/Orijinal)	0,9607	0,9798	0,9743/0,9607	0,9608	0,9950
VAH'dan Sonra (ResNet-101/Orijinal-LE)	0,9674	0,9833	0,9787/0,9674	0,9675	0,9957
VAH'dan Önce (InceptionV3/Orijinal)	0,9638	0,9812	0,9761/0,9638	0,9639	0,9962
VAH'dan Sonra (InceptionV3/Orijinal-YİD)	0,9732	0,9865	0,9825/0,9732	0,9732	0,9970
VAH'dan Önce (Xception/Orijinal)	0,9667	0,9846	0,9783/0,9667	0,9669	0,9961
VAH'dan Sonra (Xception/Orijinal-LE)	0,9728	0,9865	0,9823/0,9728	0,9728	0,9965
VAH'dan Önce (DenseNet-201/Orijinal)	0,9701	0,9849	0,9802/0,9701	0,9702	0,9968
VAH'dan Sonra (DenseNet-201/Orijinal-LE)	0,9753	0,9868	0,9837/0,9753	0,9753	0,9974

**Çizelge 13.23.** Tez çalışmasının yedinci uygulamasında X-ray görüntülerden COVID-19 zatürresi, sağlıklı, bakteriyel zatürre ve viral zatürre sınıflandırması için elde edilen sonuçların literatürde yer alan çalışmalarda elde edilen sonuçlar ile karşılaştırılması

Çalışma	Duyarlılık	Özgüllük	Ağırlıklı Doğruluk/ Genel Doğruluk	F-1 Skoru	AIKE-AKA
Khan ve ark., 2020	0,8992	0,964	0,896	0,898	X
Mahmud ve ark., 2020	0,899	0,891	0,902	0,904	0,911
Loey ve ark., 2020	0,6667-0,8056	X	0,6667-0,8056	0,6566-0,8232	X
VAH'dan Önce (EfficientNetB0)	0,8631	0,9574	0,9396/0,8631	0,8598	0,9662
VAH'dan Sonra (EfficientNetB0)	0,8750	0,9601	0,9451/0,8750	0,8706	0,9709
VAH'dan Önce (GoogleNet)	0,8657	0,9604	0,9408/0,8657	0,8651	0,9724
VAH'dan Sonra (GoogleNet)	0,8799	0,9627	0,9470/0,8799	0,8772	0,9757
VAH'dan Önce (InceptionV3)	0,8752	0,9628	0,9445/0,8752	0,8743	0,9730
VAH'dan Sonra (InceptionV3)	0,8885	0,9671	0,9511/0,8885	0,8876	0,9785
VAH'dan Önce (Xception)	0,8766	0,9609	0,9458/0,8766	0,8730	0,9735
VAH'dan Sonra (Xception)	0,8834	0,9634	0,9492/0,8834	0,8793	0,9757
VAH'dan Önce (DenseNet-201)	0,8824	0,9648	0,9481/0,8824	0,8814	0,9745
VAH'dan Sonra (DenseNet-201)	0,8954	0,9687	0,9545/0,8954	0,8934	0,9787

Uygulamada elde edilen sayısal sonuçlarının daha önce yapılmış çalışmaların sayısal sonuçlarıyla doğrudan karşılaştırılması doğru bir yaklaşım değildir. Çünkü, kullanılan toplam görüntü sayısı, test ve eğitim yaklaşımı, test ve eğitim görüntü sayısındaki farklılıklar sonuçlar üzerinde doğrudan etkili faktörlerdir. Ancak, daha önce gerçekleştirilen çalışmalarda kullanılan hemen hemen tüm transfer öğrenme 2B ESA mimarileri uygulamaya dahil edilmiştir. Bu sebeple, VAH yaklaşımı sayesinde literatürde daha önce gerçekleştirilen çalışmalara göre daha başarılı sonuçların elde edildiği kesin olarak söylenebilir.



## 14. SONUÇ VE ÖNERİLER

Tez çalışmasında derin öğrenme yöntemleri kullanılarak BT görüntüleri ve X-ray görüntüleri üzerinden COVID-19 hastalığının teşhisi ile diğer bakteriyel veya viral zatürrelerden ayırt edilmesi üzerine uygulamalar gerçekleştirilmiştir. Ayrıca, BT görüntüleri üzerinden COVID-19 hastalığına bağlı olarak gelişen zatürrenin seviyesinin belirlenmesi üzerinde durulmuştur. Bu bölümde, uygulamalarda elde edilen sonuçlar bir bütün halinde ele alınmış ve gelecek çalışmalar hakkında önerilerde bulunulmuştur.

### 14.1. Sonuç

Tez çalışmasında elde edilen uygulama sonuçları dikkate alınarak derin öğrenme sınıflandırıcılar ile makine öğrenmesi sınıflandırıcılar arasında bir karşılaştırma yapılırsa, derin öğrenme sınıflandırıcıların makine öğrenmesi sınıflandırıcılara göre daha başarılı olduğu görülmektedir. Ayrıca, derin öğrenme sınıflandırıcıların makine öğrenmesi sınıflandırıcılara göre daha hızlı sonuç ürettiği anlaşılmaktadır.

Tez çalışmasında YİD, LE, GSEM gibi doku analiz yöntemleriyle elde edilen özellik görüntülerinin orijinal görüntülerle birlikte kullanılması durumunda sınıflandırma sonuçlarında önemli iyileşmeler sağlanabileceği gösterilmiştir. Ayrıca, bu iyileşmenin sadece 2B ESA mimarileri için değil 3B ESA mimarileri için de geçerli olduğu sonucuna varılmıştır. Bu kapsamda, 3B ESA mimarileri kullanılarak 2B ESA mimarilerine göre daha iyi sonuçlar elde edilebileceği ancak bu durumda çalışma sürelerinde artışlar yaşanacağı görülmektedir.

Tez çalışmasında VAH yaklaşımları yardımıyla, YİD veya LE özellik görüntüleri kullanılarak elde edilen sınıflandırma sonuçları ile orijinal görüntüler kullanılarak elde edilen sınıflandırma sonuçlarının birleştirilmesinin sonuçlara olumlu yansıdığı gösterilmiştir. Bir diğer önemli sonuç ise KDDD kullanılarak, VAH yaklaşımına bağlı olarak ortaya çıkan çalışma süresindeki artışın tolere edilebileceğidir. Uygulama sonuçları, KDDD'nin ara işlem olarak kullanılmasıyla hem sınıflandırma sonuçlarının iyileştirilebileceğini hem de çalışma sürelerinin normale göre azaltılabileceğini göstermektedir. Bu işlemlerde KDDD ve YİD için ölçek değerinin 1 olarak belirlenmesinin en iyi tercih olacağı görülmektedir.

Tez çalışmasında VAH yaklaşımları BT ve X-ray görüntüleri üzerinden gerçekleştirilen birçok sınıflandırma başlığında kullanılmıştır. Ayrıca, tez çalışmasında

oluşturulan ve diğer çalışmalardan transfer edilen birçok ESA mimarisi için test edilmiştir. Bütün uygulamalar en iyi sonuçların VAH yaklaşımı kullanılması durumunda elde edildiğini göstermektedir. Bu durum, önerilen VAH yaklaşımlarının kısmi değil genel çözümler olduğuna işaret etmektedir. Sonuç olarak, VAH yaklaşımlarının literatürde yer alan çalışmalarda kullanılan yöntemlere eklenmesinin bu çalışmaların da başarısını artacağı değerlendirilmektedir.

VAH yaklaşımları, farklı ESA mimarileri için orijinal görüntüler kullanılarak elde edilen sonuçları birleştirmek için de kullanılabilir. Ancak, bu durumda özellik görüntüleri kullanılmasına göre daha düşük bir performans göstermektedir. Bu durumun temel nedeni, orijinal görüntüler giriş olarak kullanıldığında farklı ESA mimarileri ile sınıflandırılmış olsalar bile inatçı sayılabilecek yanlış sınıflandırılmış görüntüler kümesinin çok fazla değişmemesidir. Ancak, giriş görüntü tipi değiştirildiğinde ESA mimarisi değişirse bile yanlış sınıflandırılan görüntü kümesi değişmektedir. Bu durum VAH yaklaşımının daha iyi sonuçlar üretmesini sağlamaktadır.

Tez çalışmasında elde edilen sonuçlar, ESA ve YİD yöntemlerinin birlikte kullanılmasının veya tek başına YİD kullanılmasının çalışma başarısını arttırdığını ortaya koyan bazı çalışmaları (Hardalaç ve ark., 2020; Zhang ve ark., 2017; Ke ve ark., 2018; Yang ve ark., 2017; Touahri ve ark., 2019; Juefei-Xu ve ark., 2017) desteklemektedir. Ancak, bu çalışmalarda YİD kullanımı sonuçları doğrudan iyileştiren bir faktör olarak görülmektedir. Tez çalışmasında gerçekleştirilen uygulamalarda ise, tek başına YİD kullanımı sonuçları doğrudan artırmamış aksine sıklıkla azaltmıştır. Bununla birlikte, YİD işlemi önerilen VAH yaklaşımları ile birlikte kullanıldığında sonuçlar önemli ölçüde iyileşmiştir.

## 14.2. Öneriler

Tez çalışmasından sonra konu hakkında yapılacak çalışmalarda sınıflandırma başarılarının artırılması için aşağıda yer alan hususların dikkate alınması önerilmektedir.

- Sınıflandırma işlemlerinde reel değerli 2B ESA mimarileri yerine kompleks değerli 2B ESA mimarileri kullanılmasının sonuçların iyileştirilmesine katkı sağlayabileceği değerlendirilmektedir. Bu aşamada, KDDD ile elde edilen kompleks değerli özellik matrislerinin doğrudan 2B ESA girişi olarak kullanılabilmesi öngörülmektedir.

- Tez çalışmasında yararlanılan YİD, LE ve GSEM dışındaki doku analiz yöntemleri ile elde edilen özellik görüntülerinin doğrudan, orijinal görüntülerle kombine edilerek veya VAH yaklaşımlarında kullanılmasının sonuçların iyileştirilmesine katkı sağlayabileceği değerlendirilmektedir.
- Ultrason görüntüleri ve akciğer grafipleri üzerinden COVID-19 hastalığının teşhisi ile diğer bakteriyel veya viral zatürrelerden ayırt edilmesi üzerine uygulamalar yapılmasının yararlı olacağı değerlendirilmektedir.
- Tez çalışmasında yararlanılan KDDD dışındaki çoklu çözünürlük analizi yöntemlerinin ara işlem olarak kullanılmasının sonuçların iyileştirilmesine ve çalışma sürelerinin azaltılmasına katkı sağlayabileceği öngörülmektedir.
- VAH yaklaşımlarında kullanılan birleştirme oranlarının optimize edilmesinin sınıflandırma sonuçlarına olumlu yansımaları olacağı değerlendirilmektedir. Ayrıca, farklı konfigürasyonlara sahip VAH yaklaşımları oluşturulması ve başarılarının test edilmesi önerilmektedir.
- Sınıflandırma için yeni 3B ESA mimarileri oluşturulmasının sınıflandırma sonuçlarını iyileştirebileceği öngörülmektedir. Bu kapsamda, kompleks değerli 3B ESA mimarileri geliştirilmesinin literatüre önemli bir katkı sağlayacağı değerlendirilmektedir.



## KAYNAKLAR

- Albarello, F., Pianura, E., Stefanoa, F. D., Cristofaro, M., Petrone, A., Marchioni, L., Palazzolo, C., Schininà, V., Nicastrì, E., Petrosillo, N., Campioni, P., Eskild, P., Zumla, A. and Ippolito, G., 2020, 2019-novel coronavirus severe adult respiratory distress syndrome in two cases in Italy: an uncommon radiological presentation, *International Journal of Infectious Diseases*, 93, 192-197.
- Alshazly, H., Linse, C., Barth, E. and Martinetz, T., 2021, Explainable COVID-19 detection using chest CT scans and deep learning, *Sensors*, 21 (2), 455.
- Altman, N. S., 1992, An introduction to kernel and nearest-neighbor nonparametric regression, *The American Statistician*, 46 (3), 175-185.
- Amari, S. I., 1993, Backpropagation and stochastic gradient descent method, *Neurocomputing*, 5 (4-5), 185-196.
- Amyar, A., Modzelewski, R., Li, H. and Ruan, S., 2020, Multi-task deep learning based CT imaging analysis for COVID-19 pneumonia: Classification and segmentation, *Computers in Biology and Medicine*, 126, 104037.
- Angelov, P. and Almeida Soares, E., 2020, SARS-CoV-2 CT-scan dataset: A large dataset of real patients CT scans for SARS-CoV-2 identification, *MedRxiv*, Veri Seti Erişimi: <https://www.kaggle.com/plameneduardo/a-covid-multiclass-dataset-of-ct-scans> (Erişim Tarihi: 1 Haziran 2022).
- Apostolopoulos, I. D. and Mpesiana, T. A., 2020, Covid-19: automatic detection from X-ray images utilizing transfer learning with convolutional neural networks, *Physical and Engineering Sciences in Medicine*, 43 (2), 635-640.
- Ardakani, A. A., Kanafi, A. R., Acharya, U. R., Khadem, N. and Mohammadi, A., 2020, Application of deep learning technique to manage COVID-19 in routine clinical practice using CT images: Results of 10 convolutional neural networks, *Computers in Biology and Medicine*, 121, 103795.
- Armato, S. G., McLennan, G., Bidaut, L., McNitt-Gray, M. F., Meyer, C. R., Reeves, A. P., Zhao, B., Aberle, D. R., Henschke, C. I., Hoffman, E. A., Kazerooni, E. A., MacMahon, H., Van Beeke, E. J., Yankelevitz, D., Biancardi, A. M., Bland, P. H., Brown, M. S., Engelmann, R. M., Laderach, G. E., Max, D., Pais, R. C., Qing, D. P., Roberts, R. Y., Smith, A. R., Starkey, A., Batrah, P., Caligiuri, P., Farooqi, A., Gladish, G. W., Jude, C. M., Munden, R. F., Petkovska, I., Quint, L. E., Schwartz, L. H., Sundaram, B., Dodd, L. E., Fenimore, C., Gur, D., Petrick, N., Freymann, J., Kirby, J., Hughes, B., Castele, A. V., Gupte, S., Sallamm, M., Heath, M. D., Kuhn, M. H., Dharaiya, E., Burns, R., Fryd, D. S., Salganicoff, M., Anand, V., Shreter, U., Vastagh, S. and Croft, B. Y., 2011, The Lung Image Database Consortium (LIDC) and Image Database Resource Initiative (IDRI): A completed reference database of lung nodules on CT scans, *Medical Physics*, 38, 915-931.
- Armato, S. G., McLennan, G., Bidaut, L., McNitt-Gray, M. F., Meyer, C. R., Reeves, A. P., Zhao, B., Aberle, D. R., Henschke, C. I., Hoffman, E. A., Kazerooni, E. A.,

- MacMahon, H., Van Beek, E. J. R., Yankelevitz, D., Biancardi, A. M., Bland, P. H., Brown, M. S., Engelmann, R. M., Laderach, G. E., Max, D., Pais, R. C., Qing, D. P. Y., Roberts, R. Y., Smith, A. R., Starkey, A., Batra, P., Caligiuri, P., Farooqi, A., Gladish, G. W., Jude, C. M., Munden, R. F., Petkovska, I., Quint, L. E., Schwartz, L. H., Sundaram, B., Dodd, L. E., Fenimore, C., Gur, D., Petrick, N., Freymann, J., Kirby, J., Hughes, B., Castele, A. V., Gupte, S., Sallam, M., Heath, M. D., Kuhn, M. H., Dharaiya, E., Burns, R., Fryd, D. S., Salganicoff, M., Anand, V., Shreter, U., Vastagh, S., Croft, B. Y. and Clarke, L. P., 2015, Data From LIDC-IDRI [Data set], *The Cancer Imaging Archive*, 9 (7).
- Atlas, L., Homma, T. and Marks, R., 1987, An artificial neural network for spatio-temporal bipolar patterns: Application to phoneme classification, *Neural Information Processing Systems*, NIPS 1987, Denver.
- Benbrahim, H., Hachimi, H. and Amine, A., 2020, Deep transfer learning with apache spark to detect covid-19 in chest X-ray images, *Romanian Journal of Information Science and Technology*, 23 (S, SI), S117-S129.
- Bloice, M. D., Stocker, C. and Holzinger, A., 2017, Augmentor: an image augmentation library for machine learning, *arXiv preprint*, arXiv:1708.04680.
- Bloice, M. D., Roth, P. M. and Holzinger, A., 2019(a), Biomedical image augmentation using Augmentor, *Bioinformatics*, 35 (21), 4522-4524.
- Bloice, M. D., Roth, P. M. and Holzinger, A., 2019(b), Patch augmentation: Towards efficient decision boundaries for neural networks, *arXiv preprint*, arXiv:1911.07922.
- Calina, D., Docea, A. O., Petrakis, D., Egorov, A. M., Ishmukhametov, A. A., Gabibov, A. G., Shtilman, M. I., Kostoff, R., Carvalho, F., Vinceti, M., Spandidos, D. A. and Tsatsakis, A., 2020, Towards effective COVID-19 vaccines: Updates, perspectives and challenges, *International Journal of Molecular Medicine*, 46 (1), 3-16.
- Carvalho, A. R. S., Guimarães, A., Werberich, G. M., de Castro, S. N., Pinto, J. S. F., Schmitt, W. R., França, M., Bozza, F. A., Guimarães, B. L. D. S., Zin, W. A. and Rodrigues, R. S., 2020, COVID-19 chest computed tomography to stratify severity and disease extension by artificial neural network computer-aided diagnosis, *Frontiers in Medicine*, 7.
- Ceylan, M., 2009, Bilgisayar tomografili akciğer görüntülerinin değerlendirilmesinde kompleks değerli yeni bir akıllı sistem tasarımı, Doktora tezi, *Selçuk Üniversitesi Fen Bilimleri Enstitüsü*, Konya, 21-50.
- Chaudhary, P. K. and Pachori, R. B., 2021, FBSED based automatic diagnosis of COVID-19 using X-ray and CT images, *Computers in Biology and Medicine*, 134, 104454.
- Chen, N., Zhou, M., Dong, X., Qu, J., Gong, F., Han, Y., Qiu, Y., Wang, J., Liu, Y., Wei, Y., Xia, J., Yu, T., Zhang, X. and Zhang, L., 2020, Epidemiological and

- clinical characteristics of 99 cases of 2019 novel coronavirus pneumonia in Wuhan, China: a descriptive study, *The Lancet*, 395 (10223), 507-513.
- Cheng, S. C., Chang, Y. C., Chiang, Y. L. F., Chien, Y. C., Cheng, M., Yang, C. H., Huang, C. H. and Hsu, Y. N., 2020, First case of coronavirus disease 2019 (COVID-19) pneumonia in Taiwan, *Journal of the Formosan Medical Association*, 119 (3), 747-751.
- Chollet, F., 2017, Xception: Deep learning with depthwise separable convolutions, *IEEE Conference on Computer Vision and Pattern Recognition, CVPR-2017*, Honolulu, 1251-1258.
- Civit-Masot, J., Luna-Perejón, F., Domínguez Morales, M. and Civit, A., 2020, Deep learning system for COVID-19 diagnosis aid using X-ray pulmonary images, *Applied Sciences*, 10 (13), 4640.
- Clark, K., Vendt, B., Smith, K., Freymann, J., Kirby, J., Koppel, P., Moore, S., Phillips, S., Maffitt, D., Pringle, M., Tarbox, L. and Prior, F., 2013, The Cancer Imaging Archive (TCIA): Maintaining and operating a public information repository, *Journal of Digital Imaging*, 26 (6), 1045-1057.
- Cohen, J. P., Morrison, P. and Dao, L., 2020, COVID-19 image data collection, *arXiv preprint*, arXiv:2003.11597. Veri Seti Erişimi: <https://github.com/ieee8023/covid-chestxray-dataset> (Erişim Tarihi: 1 Haziran 2022).
- Cortes, C. and Vapnik, V., 1995, Support-vector networks, *Machine Learning*, 20 (3), 273-297.
- Cuong, L. V., Giang, H. T. N., Linh, L. K., Shah, J., Van Sy, L., Hung, T. H., Reda, A., Truong, L. N., Tien, D. X. and Huy, N. T., 2020, The first Vietnamese case of COVID-19 acquired from China, *The Lancet Infectious Diseases*, 20 (4), 408-409.
- Dadario, A. M., 2020, COVID-19 X rays, *Kaggle*, Veri Seti Erişimi: <https://doi.org/10.34740/KAGGLE/DSV/1019469> (Erişim Tarihi: 1 Haziran 2022).
- Das, N. N., Kumar, N., Kaur, M., Kumar, V. and Singh, D., 2020, Automated deep transfer learning-based approach for detection of COVID-19 infection in chest X-rays, *IRBM*.
- Daubechies, I., 1990, The Wavelet transform, time-frequency localization and signal analysis, *IEEE Transactions on Information Theory*, 36, 961-1005.
- Desai, S., Baghal, A., Wongsurawat, T., Al-Shukri, S., Gates, K., Farmer, P., Rutherford, M., Blake, G. D., Nolan, T., Powell, T., Sexton, K., Bennett, W. and Prior, F., 2020, Data from chest imaging with clinical and genomic correlates representing a rural COVID-19 positive population, *The Cancer Imaging Archive*.
- DSÖ, 2020(a), WHO Director-General's opening remarks at the media briefing on COVID-19-11 March 2020, <https://www.who.int/director->

general/speeches/detail/who-director-general-s-opening-remarks-at-the-media-briefing-on-covid-19---11-march-2020 (Erişim Tarihi: 1 Haziran 2022).

DSÖ, 2020(b), <https://www.who.int/director-general/speeches/detail/who-director-general-s-remarks-at-the-media-briefing-on-2019-ncov-on-11-february-2020> (Erişim Tarihi: 1 Haziran 2022).

DSÖ, 2020(c), Emergency use ICD codes for COVID-19 disease outbreak, <https://www.who.int/classifications/icd/covid19/en/> (Erişim Tarihi: 1 Haziran 2022).

DSÖ, 2021, [https://extranet.who.int/pqweb/sites/default/files/documents/Status\\_COVID\\_VAX\\_20Oct2021.pdf](https://extranet.who.int/pqweb/sites/default/files/documents/Status_COVID_VAX_20Oct2021.pdf) (Erişim Tarihi: 1 Haziran 2022).

DSÖ, 2022, <https://covid19.who.int/> (Erişim Tarihi: 1 Haziran 2022).

Duran-Lopez, L., Dominguez-Morales, J. P., Corral-Jaime, J., Vicente-Diaz, S. and Linares-Barranco, A., 2020, COVID-XNet: A custom deep learning system to diagnose and locate COVID-19 in chest X-ray images, *Applied Sciences*, 10 (16), 5683.

Elaziz, M. A., Hosny, K. M., Salah, A., Darwish, M. M., Lu, S. and Sahlol, A. T., 2020, New machine learning method for image-based diagnosis of COVID-19, *Plos One*, 15 (6), e0235187.

Endachev, D. V., Vasin, P. A. and Shadrin, S. S., 2019, Applicability of computer vision architectures and their influence on traffic safety of autonomous vehicles, *International Journal of Engineering and Advanced Technology*, 8 (6), 5295-5301.

Fang, Y., Zhang, H., Xie, J., Lin, M., Ying, L., Pang, P. and Ji, W., 2020, Sensitivity of chest CT for COVID-19: comparison to RT-PCR, *Radiology*, 296 (2), E115-E117.

Fix, E. and Hodges, J. L., 1951, Discriminatory analysis, Nonparametric discrimination: Consistency properties, Report, *USAF School of Aviation Medicine*, Randolph Field, Texas.

Gabor, D., 1946, Theory of communication, *Journal of the IEEE*, 93 (26), 429-441.

Giordano, F. M., Ippolito, E., Quattrocchi, C. C., Greco, C., Mallio, C. A., Santo, B., D'Alessio, P., Crucitti, P., Fiore, M., Zobel, B. B., D'Angelillo, R. M. and Ramella, S., 2021, Radiation-induced pneumonitis in the Era of the COVID-19 Pandemic: Artificial intelligence for differential diagnosis, *Cancers*, 13 (8), 1960.

Goel, T., Murugan, R., Mirjalili, S. and Chakrabartty, D. K., 2021, Automatic screening of covid-19 using an optimized generative adversarial network, *Cognitive Computation*, 1-16.

- Grandini, M., Bagli, E. and Visani, G., 2020, Metrics for multi-class classification: an overview, *arXiv preprint*, 2008.05756.
- Guo, H., 1995, Theory and applications of shift-invariant, time-varying and undecimated wavelet transform, MSc Thesis, *Rice University*, Houston.
- Han, X., Zhong, Y., Cao, L. and Zhang, L., 2017, Pre-trained alexnet architecture with pyramid pooling and supervision for high spatial resolution remote sensing image scene classification, *Remote Sensing*, 9 (8), 848.
- Han, Z., Wei, B., Hong, Y., Li, T., Cong, J., Zhu, X., Wei, H. and Zhang, W., 2020, Accurate screening of COVID-19 using attention based deep 3D multiple instance learning, *IEEE Transactions on Medical Imaging*, 39 (8), 2584-2594.
- Hardalaç, F., Yaşar, H., Akyel, A. and Kutbay, U., 2020, A novel comparative study using multi-resolution transforms and convolutional neural network (CNN) for contactless palm print verification and identification, *Multimedia Tools and Applications*, 79 (31), 22929-22963.
- Harmon, S. A., Sanford, T. H., Xu, S., Turkbey, E. B., Roth, H., Xu, Z., Yang, D., Myronenko, A., Anderson, V., Amalou, A., Blain, M., Kassin, M., Long, D., Varble, N., Walker, S. M., Bagci, U., Ierardi, A. M., Stellato, E., Plensich, G. G., Franceschelli, G., Girlando, C., Irmici, G., Labella, D., Hammoud, D., Malayeri, A., Jones, E., Summers, R. M., Choyke, P. L., Xu, D., Flores, M., Tamura, K., Obinata, H., Mori, H., Patella, F., Cariati, M., Carrafiello, G., An, P., Wood, B. J. and Turkbey, B., 2020, Artificial intelligence for the detection of COVID-19 pneumonia on chest CT using multinational datasets, *Nature Communications*, 11 (4080), 1-7.
- Hasan, A. M., Al-Jawad, M. M., Jalab, H. A., Shaiba, H., Ibrahim, R. W. and AL-Shamasneh, A. A. R., 2020, Classification of covid-19 coronavirus, pneumonia and healthy lungs in CT scans using q-deformed entropy and deep learning features, *Entropy*, 22 (5), 517.
- He, K., Zhang, X., Ren, S. and Sun, J., 2016, Deep residual learning for image recognition, *IEEE Conference on Computer Vision and Pattern Recognition*, CVPR-2016, Las Vegas, 770-778.
- Ho, T. T., Park, J., Kim, T., Park, B., Lee, J., Kim, J. Y., Kim, K. B., Choi, S., Kim, Y. H., Lim, J. K. and Choi, S., 2021, Deep learning models for predicting severe progression in COVID-19-infected patients: retrospective study, *JMIR Medical Informatics*, 9 (1), e24973.
- Holshue, M. L., DeBolt, C., Lindquist, S., Lofy, K. H., Wiesman, J., Bruce, H., Spitters, C., Ericson, K., Wilkerson, S., Tural, A., Diaz, G., Cohn, A., Fox, L., Patel, A., Gerber, S. I., Kim, L., Tong, S., Lu, X., Lindstrom, S., Pallansch, M. A., Weldon, W. C., Biggs, H. M., Uyeki, T. M. and Pillai, S. K., 2020, First case of 2019 novel coronavirus in the United States, *The New England Journal of Medicine*, 382 (10), 929-936.

- Horry, M. J., Chakraborty, S., Paul, M., Ulhaq, A., Pradhan, B., Saha, M. and Shukla, N., 2020, COVID-19 detection through transfer learning using multimodal imaging data, *IEEE Access*, 8, 149808-149824.
- Hsieh, W. H., Cheng, M. Y., Ho, M. W., Chou, C. H., Lin, P. C., Chi, C. Y., Liao, W. C., Chen, C. Y., Leong, L. Y., Tien, N., Lai, H. C., Lai, Y. C. and Lu M. C., 2020, Featuring COVID-19 cases via screening symptomatic patients with epidemiologic link during flu season in a medical center of Central Taiwan, *Journal of Microbiology, Immunology and Infection*, 53 (3), 459-466.
- Hu, S., Gao, Y., Niu, Z., Jiang, Y., Li, L., Xiao, X., Wang, M., Fang, E. F., Menpes-Smith, W., Xia, J., Ye, H. and Yang G., 2020, Weakly supervised deep learning for COVID-19 infection detection and classification from CT images, *IEEE Access*, 8, 118869-118883.
- Huang, G., Liu, Z., Van Der Maaten, L. and Weinberger, K. Q., 2017, Densely connected convolutional networks, *IEEE Conference on Computer Vision and Pattern Recognition, CVPR-2017, Honolulu*, 4700-4708.
- Huang, C., Wang, Y., Li, X., Ren, L., Zhao, J., Hu, Y., Zhang, L., Fan, G., Xu, J., Gu, X., Cheng, Z., Yu, T., Xia, J., Wei, Y., Wu, W., Xie, X., Yin, W., Li, H., Liu, M., Xiao, Y., Gao, H., Guo, L., Xie, J., Wang, G., Jiang, R., Gao, Z., Jin, Q., Wang, J. and Cao, B., 2020, Clinical features of patients infected with 2019 novel coronavirus in Wuhan, China, *The Lancet*, 395 (10223), 497-506.
- Huang, Z., Liu, X., Wang, R., Zhang, M., Zeng, X., Liu, J., Yang, Y., Liu, X., Zheng, H. and Hu, Z., 2021, FaNet: fast assessment network for the novel coronavirus (COVID-19) pneumonia based on 3D CT imaging and clinical symptoms, *Applied Intelligence*, 51 (5), 2838-2849.
- Islam, M. Z., Islam, M. M. and Asraf, A., 2020, A combined deep CNN-LSTM network for the detection of novel coronavirus (COVID-19) using X-ray images, *Informatics in Medicine Unlocked*, 20, 100412.
- Jaeger, S., Candemir, S., Antani, S., Wang, Y. X. J., Lu, P. X. and Thoma, G., 2014, Two public chest X-ray datasets for computer-aided screening of pulmonary diseases, *Quantitative Imaging in Medicine and Surgery*, 4 (6), 475.
- Jaiswal, A., Gianchandani, N., Singh, D., Kumar, V. and Kaur, M., 2021, Classification of the COVID-19 infected patients using DenseNet201 based deep transfer learning, *Journal of Biomolecular Structure and Dynamics*, 39 (15), 5682-5689.
- Jin, C., Chen, W., Cao, Y., Xu, Z., Tan, Z., Zhang, X., Deng, L., Zheng, C., Zhou, J., Shi, H. and Feng, J., 2020, Development and evaluation of an artificial intelligence system for COVID-19 diagnosis, *Nature Communications*, 11 (1), 5088.
- Juefei-Xu, F., Naresh Boddeti, V. and Savvides, M., 2017, Local binary convolutional neural networks, *IEEE Conference on Computer Vision and Pattern Recognition, CVPR-2017, Honolulu*, 19-28.

- Kang, M., Hong, K. S., Chikontwe, P., Luna, M., Jang, J. G., Park, J., Shin, K. C., Park, S. H. and Ahn, J. H., 2021, Quantitative assessment of chest CT patterns in COVID-19 and bacterial pneumonia patients: A deep learning perspective, *Journal of Korean Medical Science*, 36 (5), e46.
- Kaur, T., Gandhi, T. K. and Panigrahi, B. K., 2021, Automated diagnosis of COVID-19 using deep features and parameter free BAT optimization, *IEEE Journal of Translational Engineering in Health and Medicine*, 9, 1800209.
- Ke, P., Cai, M., Wang, H. and Chen, J., 2018, A novel face recognition algorithm based on the combination of LBP and CNN, *IEEE International Conference on Signal Processing*, ICSP-2018, Beijing, 539-543.
- Kermany, D. S., Goldbaum, M., Cai, W., Valentim, C. C. S., Liang, H., Baxter, S. L., McKeown, A., Yang, G., Wu, X., Yan, F., Dong, J., Prasadha, M. K., Pei, J., Ting, M. Y. L., Zhu, J., Li, C., Hewett, S., Dong, J., Ziyar, I., Shi, A., Zhang, R., Zheng, L., Hou, R., Shi, W., Fu, X., Duan, Y., Huu, V. A. N., Wen, C., Zhang, E. D., Zhang, C. L., Li, O., Wang, X., Singer, M. A., Sun, X., Xu, J., Tafreshi, A., Lewis, M. A., Xia, H. and Zhang, K., 2018, Identifying medical diagnoses and treatable diseases by image-based deep learning, *Cell*, 172 (5):1122-1131, Veri Seti Erişimi: <https://www.kaggle.com/paultimothymooney/chest-xray-pneumonia> (Erişim Tarihi: 1 Haziran 2022).
- Khan, A. I., Shah, J. L. and Bhat, M. M., 2020, CoroNet: A deep neural network for detection and diagnosis of COVID-19 from chest X-ray images, *Computer Methods and Programs in Biomedicine*, 196, 105581.
- Kingsbury, N., 2001, Complex wavelets for shift invariant analysis and filtering of signals, *Applied and Computational Harmonic Analysis*, 10 (3), 234-253.
- Ko, H., Chung, H., Kang, W. S., Kim, K. W., Shin, Y., Kang, S. J., Lee, J. H., Kim, Y. J., Kim, N. Y., Jung, H. and Lee, J., 2020, COVID-19 pneumonia diagnosis using a simple 2D deep learning framework with a single chest CT image: model development and validation, *Journal of Medical Internet Research*, 22 (6), e19569.
- Konar, D., Panigrahi, B. K., Bhattacharyya, S., Dey, N. and Jiang, R., 2021, Auto-diagnosis of covid-19 using lung CT images with semi-supervised shallow learning network, *IEEE Access*, 9, 28716-28728.
- Kong, W. and Agarwal, P. P., 2020, Chest imaging appearance of COVID-19 infection, *Radiology: Cardiothoracic Imaging*, 2 (1), e200028.
- Kovács, A., Palásti, P., Veréb, D., Bozsik, B., Palkó, A. and Kincses, Z. T., 2021, The sensitivity and specificity of chest CT in the diagnosis of COVID-19, *European Radiology*, 31 (5), 2819-2824.

- Kriegova, E., Fillerova, R. and Kvapil, P., 2020, Direct-RT-qPCR detection of SARS-CoV-2 without RNA extraction as part of a COVID-19 testing strategy: From sample to result in one hour, *Diagnostics*, 10 (8), 605.
- Krizhevsky, A., Sutskever, I. and Hinton, G. E., 2012, Imagenet classification with deep convolutional neural networks, *Advances in Neural Information Processing Systems*, 25.
- Lacerda, P., Barros, B., Albuquerque, C. and Conci, A., 2021, Hyperparameter optimization for COVID-19 pneumonia diagnosis based on chest CT, *Sensors*, 21 (6), 2174.
- Lawton, W., 1993, Applications of complex valued wavelet transforms to subband decomposition, *IEEE Transactions on Signal Processing*, 41 (12), 3566-3568.
- Lee, N. Y., Li, C. W., Tsai, H. P., Chen, P. L., Syue, L. S., Li, M. C., Tsai, C. S., Lo, C. L., Hsueh, P. R. and Ko, W. C., 2020, A case of COVID-19 and pneumonia returning from Macau in Taiwan: clinical course and antiSARS-CoV-2 IgG dynamic, *Journal of Microbiology, Immunology and Infection*, 53 (3), 485-487.
- Li, L., Qin, L., Xu, Z., Yin, Y., Wang, X., Kong, B., Bai, J., Lu, Y., Fang, Z., Song, Q., Cao, K., Liu, D., Wang, G., Xu, Q., Fang, X., Zhang, S., Xia, J. and Xia, J., 2020(a), Using artificial intelligence to detect COVID-19 and community-acquired pneumonia based on pulmonary CT: evaluation of the diagnostic accuracy, *Radiology*, 296 (2), E65-E71.
- Li, C., Dong, D., Li, L., Gong, W., Li, X., Bai, Y., Wang, M., Hu, Z., Zha, Y. and Tian, J., 2020(b), Classification of severe and critical Covid-19 using deep learning and radiomics, *IEEE Journal of Biomedical and Health Informatics*, 24 (12), 3585-3594.
- Li, Z., Zhong, Z., Li, Y., Zhang, T., Gao, L., Jin, D., Sun, Y., Ye, X., Yu, L., Hu, Z., Xiao, J., Huang, L. and Tang, Y., 2020(c) From community-acquired pneumonia to COVID-19: a deep learning-based method for quantitative analysis of COVID-19 on thick-section CT scans, *European Radiology*, 30 (12), 6828-6837.
- Liang, X., Zhang, Y., Wang, J., Ye, Q., Liu, Y. and Tong, J., 2021, Diagnosis of COVID-19 pneumonia based on graph convolutional network, *Frontiers in Medicine*, 7, 612962.
- Lim, J., Jeon, S., Shin, H. Y., Kim, M. J., Seong, Y. M., Lee, W. J., Choe, K. W., Kang, Y. M., Lee, B. and Park, S. J., 2020, Case of the index patient who caused tertiary transmission of COVID-19 infection in Korea: the application of lopinavir/ritonavir for the treatment of COVID-19 infected pneumonia monitored by quantitative RT-PCR, *Journal of Korean Medical Science*, 35 (6), e79.
- Lin, L., Fu, G., Chen, S., Tao, J., Qian, A., Yang, Y. and Wang, M., 2021, CT manifestations of coronavirus disease (COVID-19) pneumonia and influenza virus pneumonia: A comparative study, *American Journal of Roentgenology*, 216 (1), 71-79.



- Lina, J. M., 1997, Image processing with complex Daubechies wavelets, *Journal of Mathematical Imaging and Vision*, 7 (3), 211-223.
- Liu, Y. C., Liao, C. H., Chang, C. F., Chou, C. C. and Lin, Y. R., 2020, A locally transmitted case of SARS-CoV-2 infection in Taiwan, *New England Journal of Medicine*, 382 (11), 1070-1072.
- Loey, M., Smarandache, F. and M Khalifa, N. E., 2020, Within the lack of chest COVID-19 X-ray dataset: a novel detection model based on GAN and deep transfer learning, *Symmetry*, 12 (4), 651.
- Long, J. B. and Ehrenfeld, J. M., 2020, The role of augmented intelligence (AI) in detecting and preventing the spread of novel coronavirus, *Journal of Medical Systems*, 44 (3), 1-2.
- Mahdianpari, M., Salehi, B., Rezaee, M., Mohammadimanesh, F. and Zhang, Y., 2018, Very deep convolutional neural networks for complex land cover mapping using multispectral remote sensing imagery, *Remote Sensing*, 10 (7), 1119.
- Mahmud, T., Rahman, M. A. and Fattah, S. A., 2020, CovXNet: A multi-dilation convolutional neural network for automatic COVID-19 and other pneumonia detection from chest X-ray images with transferable multi-receptive feature optimization, *Computers in Biology and Medicine*, 122, 103869.
- Mallat, S., 1989, A theory for multiresolution signal decomposition: the wavelet representation, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 11 (7), 674-693.
- Martínez, F., Martínez, F. and Jacinto, E., 2020, Performance evaluation of the NASNet convolutional network in the automatic identification of COVID-19, *International Journal on Advanced Science, Engineering and Information Technology*, 10 (2), 662.
- MathWorks, 2022(a), Options for training deep learning neural network, <https://www.mathworks.com/help/deeplearning/ref/trainingoptions.html;jsessionid=f9ba0fd351bf94f59f3f6325b4ff> (Erişim Tarihi: 1 Haziran 2022).
- MathWorks, 2022(b), AlexNet convolutional neural network, <https://www.mathworks.com/help/deeplearning/ref/alexnet.html> (Erişim Tarihi: 1 Haziran 2022).
- MathWorks, 2022(c), MobileNet-v2 convolutional neural network, <https://www.mathworks.com/help/deeplearning/ref/mobilenetv2.html> (Erişim Tarihi: 1 Haziran 2022).
- MathWorks, 2022(d), ResNet-101 convolutional neural network, <https://www.mathworks.com/help/deeplearning/ref/resnet101.html> (Erişim Tarihi: 1 Haziran 2022).

- MathWorks, 2022(e), GoogLeNet convolutional neural network, <https://www.mathworks.com/help/deeplearning/ref/googlenet.html> (Erişim Tarihi: 1 Haziran 2022).
- MathWorks, 2022(f), Inception-v3 convolutional neural network, <https://www.mathworks.com/help/deeplearning/ref/inceptionv3.html> (Erişim Tarihi: 1 Haziran 2022).
- MathWorks, 2022(g), Xception convolutional neural network, <https://www.mathworks.com/help/deeplearning/ref/xception.html> (Erişim Tarihi: 1 Haziran 2022).
- MathWorks, 2022(h), DenseNet-201 convolutional neural network, <https://www.mathworks.com/help/deeplearning/ref/densenet201.html> (Erişim Tarihi: 1 Haziran 2022).
- MathWorks, 2022(i), EfficientNet-b0 convolutional neural network, <https://www.mathworks.com/help/deeplearning/ref/efficientnetb0.html> (Erişim Tarihi: 1 Haziran 2022).
- MathWorks, 2022(j), DarkNet-53 convolutional neural network, <https://www.mathworks.com/help/deeplearning/ref/darknet53.html> (Erişim Tarihi: 1 Haziran 2022).
- McCall, B., 2020, COVID-19 and artificial intelligence: protecting health-care workers and curbing the spread, *The Lancet Digital Health*, 2 (4), e166-e167.
- Meng, L., Dong, D., Li, L., Niu, M., Bai, Y., Wang, M., Qiu, X., Zha, Y. and Tian, J., 2020, A Deep learning prognosis model help alert for COVID-19 patients at high-risk of death: a multi-center study, *IEEE Journal of Biomedical and Health Informatics*, 24 (12), 3576-3584.
- Minaee, S., Kafieh, R., Sonka, M., Yazdani, S. and Soufi, G. J., 2020, Deep-COVID: Predicting COVID-19 from chest X-ray images using deep transfer learning, *Medical Image Analysis*, 65, 101794.
- Mishra, N. K., Singh, P. and Joshi, S. D., 2021, Automated detection of COVID-19 from CT scan using convolutional neural network, *Biocybernetics and Biomedical Engineering*, 41 (2), 572-588.
- Misiti, M., Misiti, Y., Oppenheim, G. and Poggi, J. M., 2004, Wavelet toolbox users guide, *MathWorks*, Natick-Massachusetts.
- Mohammed, M. A., Abdulkareem, K. H., Al-Waisy, A. S., Mostafa, S. A., Al-Fahdawi, S., Dinar, A. M., Alhakami, W., Baz, A., Al-Mhiqani, M. N., Alhakami, H., Arbaiy, N., Maashi, M. S., Mutlag, A. A., García-Zapirain, B. and Díez I. T., 2020, Benchmarking methodology for selection of optimal COVID-19 diagnostic model based on entropy and TOPSIS methods, *IEEE Access*, 8, 99115-99131.

- Ng, M. Y., Lee, E. Y., Yang, J., Yang, F., Li, X., Wang, H., Lui, M. M., Lo, C. S. Y., Leung, B., Khong, P. L., Hui, C. K. M., Yuen, K. Y. and Kuo, M. D., 2020, Imaging profile of the COVID-19 infection: radiologic findings and literature review, *Radiology: Cardiothoracic Imaging*, 2 (1), e200034.
- Ni, Q., Sun, Z. Y., Qi, L., Chen, W., Yang, Y., Wang, L., Zhang, X., Yang, L., Fang, Y., Xing, Z., Zhou, Z., Yu, Y., Lu, G. M. and Zhang, L. J., 2020, A deep learning approach to characterize 2019 coronavirus disease (COVID-19) pneumonia in chest CT images, *European Radiology*, 30 (12), 6517-6527.
- Nour, M., Cömert, Z. and Polat, K., 2020, A novel medical diagnosis model for COVID-19 infection detection based on deep features and Bayesian optimization, *Applied Soft Computing*, 97, 106580.
- Ojala, T., Pietikäinen, M. and Harwood, D., 1996, A comparative study of texture measures with classification based on featured distributions, *Pattern Recognition*, 29 (1), 51-59.
- Ouyang, X., Huo, J., Xia, L., Shan, F., Liu, J., Mo, Z., Yan, F., Ding, Z., Yang, Q., Song, B., Shi, F., Yuan, H., Wei, Y., Cao, X., Gao, Y., Wu, D., Wang, Q. and Shen, D., 2020, Dual-sampling attention network for diagnosis of COVID-19 from community acquired pneumonia, *IEEE Transactions on Medical Imaging*, 39 (8), 2595-2605.
- Öztürk, T., Talo, M., Yildirim, E. A., Baloglu, U. B., Yildirim, O. and Acharya, U. R., 2020, Automated detection of COVID-19 cases using deep neural networks with X-ray images, *Computers in Biology and Medicine*, 121, 103792.
- Örnek, A. H., Ceylan, M. and Ervural, S., 2019, Health status detection of neonates using infrared thermography and deep convolutional neural networks, *Infrared Physics and Technology*, 103, 103044.
- Örnek, A. H. and Ceylan, M., 2019, Comparison of traditional transformations for data augmentation in deep learning of medical thermography, *International Conference on Telecommunications and Signal Processing*, TSP-2019, Budapest, 191-194.
- Pandit, M. K. and Banday, S. A., 2020, SARS n-CoV2-19 detection from chest X-ray images using deep neural networks, *International Journal of Pervasive Computing and Communications*, 16 (5), 419-427.
- Panwar, H., Gupta, P. K., Siddiqui, M. K., Morales-Menendez, R. and Singh, V., 2020, Application of deep learning for fast detection of COVID-19 in X-Rays using nCOVnet, *Chaos, Solitons and Fractals*, 138, 109944.
- Pathak, Y., Shukla, P. K., Tiwari, A., Stalin, S., Singh, S. and Shukla, P. K., 2020, Deep transfer learning based classification model for COVID-19 disease, *IRBM*.
- Peng, Y., Tang, Y., Lee, S., Zhu, Y., Summers, R. M. and Lu, Z., 2021, COVID-19-CT-CXR: a freely accessible and weakly labeled chest X-ray and CT image collection

- on COVID-19 from biomedical literature, *IEEE Transactions on Big Data*, 7 (1), 3-12.
- Phan, L. T., Nguyen, T. V., Luong, Q. C., Nguyen, T. V., Nguyen, H. T., Le, H. Q., Nguyen, T. T., Cao, T. M. and Pham, Q. D., 2020, Importation and human-to-human transmission of a novel coronavirus in Vietnam, *New England Journal of Medicine*, 382 (9), 872-874.
- Pianura, E., Di Stefano, F., Cristofaro, M., Petrone, A., Fusco, N., Albarello, F., Lapa, D., Cicalini, S., Campioni, P. and Schininà, V., 2020, Coronavirus-HKU1 pneumonia and differential diagnosis with COVID 19, *Radiology: Cardiothoracic Imaging*, 2 (2), e200162.
- Pontone, G., Scafuri, S., Mancini, M. E., Agalbato, C., Guglielmo, M., Baggiano, A., Muscogiuri, G., Fusini, L., Andreini, D., Mushtaq, S., Conte, E., Annoni, A., Formenti, A., Gennari, A. G., Guaricci, A. I., Rabbat, M. R., Pompilio, G., Pepi, M. and Rossi, A., 2021, Role of computed tomography in COVID-19, *Journal of Cardiovascular Computed Tomography*, 15 (1), 27-36.
- Ragab, D. A. and Attallah, O., 2020, FUSI-CAD: Coronavirus (COVID-19) diagnosis based on the fusion of CNNs and handcrafted features, *PeerJ Computer Science*, 6, e306.
- Rahimzadeh, M. and Attar, A., 2020, A modified deep convolutional neural network for detecting COVID-19 and pneumonia from chest X-ray images based on the concatenation of Xception and ResNet50V2, *Informatics in Medicine Unlocked*, 19, 100360.
- Redmon, J., 2013, Darknet: Open source neural networks in C, <https://pjreddie.com/darknet> (Erişim Tarihi: 1 Haziran 2022).
- Saad, W., Shalaby, W. A., Shokair, M., Abd El-Samie, F., Dessouky, M. and Abdellatef, E., 2021, COVID-19 classification using deep feature concatenation technique, *Journal of Ambient Intelligence and Humanized Computing*, 1-19.
- Saba, L., Agarwal, M., Patrick, A., Puvvula, A., Gupta, S. K., Carriero, A., Laird, J. R., Kitas, G. D., Johri, A. M., Balestrieri, A., Falaschi, Z., Paschè, A., Viswanathan, V., El-Baz, A., Alam, I., Jain, A., Naidu, S., Oberleitner, R., Khanna, N. N., Bit, A., Fatemi, M., Alizad, A. and Suri, J. S., 2021, Six artificial intelligence paradigms for tissue characterisation and classification of non-COVID-19 pneumonia against COVID-19 pneumonia in computed tomography lungs, *International Journal of Computer Assisted Radiology and Surgery*, 16 (3), 423-434.
- Sakagianni, A., Feretzakis, G., Kalles, D., Koufopoulou, C. and Kaldis, V., 2020, Setting up an Easy-to-Use Machine Learning Pipeline for Medical Decision Support: Case Study for COVID-19 Diagnosis Based on Deep Learning with CT Scans, *Studies in Health Technology and Informatics*, 272, 13-16.

- Sandler, M., Howard, A., Zhu, M., Zhmoginov, A. and Chen, L. C., 2018, Mobilenetv2: Inverted residuals and linear bottlenecks, *IEEE Conference on Computer Vision and Pattern Recognition, CVPR-2018*, Salt Lake City, 4510-4520.
- Sen, S., Saha, S., Chatterjee, S., Mirjalili, S. and Sarkar, R., 2021, A bi-stage feature selection approach for COVID-19 prediction using chest CT images, *Applied Intelligence*, 51 (12), 8985-9000.
- Sharma, S., 2020, Drawing insights from COVID-19-infected patients using CT scan images and machine learning techniques: a study on 200 patients, *Environmental Science and Pollution Research*, 27 (29), 37155-37163.
- Shi, H., Han, X. and Zheng, C., 2020, Evolution of CT manifestations in a patient recovered from 2019 novel coronavirus (2019-nCoV) pneumonia in Wuhan, China, *Radiology*, 295 (1), 20-20.
- Shi, W., Tong, L., Zhu, Y. and Wang, M. D., 2021, COVID-19 Automatic diagnosis with radiographic imaging: explainable attentiontransfer deep neural networks, *IEEE Journal of Biomedical and Health Informatics*, 25 (7), 2376-2387.
- Shorfuzzaman, M. and Masud, M., 2020, On the detection of covid-19 from chest X-ray images using cnn-based transfer learning, *CMC-Computers Materials and Continua*, 64 (3), 1359-1381.
- Silverstein, W. K., Stroud, L., Cleghorn, G. E. and Leis, J. A., 2020, First imported case of 2019 novel coronavirus in Canada, presenting as mild pneumonia, *The Lancet*, 395 (10225), 734.
- Simonyan, K. and Zisserman, A., 2014, Very deep convolutional networks for large-scale image recognition, *arXiv preprint*, arXiv:1409, 1556.
- Singh, K. K., Siddhartha, M. and Singh, A., 2020, Diagnosis of coronavirus disease (COVID-19) from chest X-ray images using modified XceptionNet, *Romanian Journal of Information Science and Technology*, 23 (657), 91-115.
- Singh, M., Bansal, S., Ahuja, S., Dubey, R. K., Panigrahi, B. K. and Dey, N., 2021, Transfer learning-based ensemble support vector machine model for automated COVID-19 detection using lung computerized tomography scan data, *Medical and Biological Engineering and Computing*, 59 (4), 825-839.
- Song, F., Shi, N., Shan, F., Zhang, Z., Shen, J., Lu, H., Ling, Y., Jiang, Y. and Shi, Y., 2020, Emerging 2019 novel coronavirus (2019-nCoV) pneumonia, *Radiology*, 295 (1), 210-217.
- Song, Y., Zheng, S., Li, L., Zhang, X., Zhang, X., Huang, Z., Chen, J., Wang, R., Zhao, H., Chong, Y., Shen, J., Zha, Y. and Yang, Y., 2021, Deep learning enables accurate diagnosis of novel coronavirus (COVID-19) with CT images, *IEEE/ACM Transactions on Computational Biology and Bioinformatics*, 18 (6), 2775-2780.

- Strang, G. and Nguyen, T., 1996, Wavelets and filter banks, *Wellesley-Cambridge Press*.
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V. and Rabinovich, A., 2015, Going deeper with convolutions, *IEEE Conference on Computer Vision and Pattern Recognition, CVPR-2015*, Boston, 1-9.
- Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J. and Wojna, Z., 2016, Rethinking the inception architecture for computer vision, *IEEE Conference on Computer Vision and Pattern Recognition, CVPR-2016*, Las Vegas, 2818-2826.
- Tan, M. and Le, Q., 2019, Efficientnet: Rethinking model scaling for convolutional neural networks, *International Conference on Machine Learning*, 6105-6114.
- Thanh Noi, P. and Kappas, M., 2018, Comparison of random forest, k-nearest neighbor, and support vector machine classifiers for land cover classification using Sentinel-2 imagery, *Sensors*, 18 (1), 18.
- Thevarajan, I., Nguyen, T. H., Koutsakos, M., Druce, J., Caly, L., van de Sandt, C. E., Jia, X., Nicholson, S., Catton, M., Cowie, B., Tong, S. Y. C., Lewin, S. R. and Kedzierska, K., 2020, Breadth of concomitant immune responses prior to patient recovery: a case report of non-severe COVID-19, *Nature Medicine*, 26 (4), 450-455.
- Toğaçar, M., Ergen, B. and Cömert, Z., 2020, COVID-19 detection using deep learning models to exploit Social Mimic Optimization and structured chest X-ray images using fuzzy color and stacking approaches, *Computers in Biology and Medicine*, 121, 103805.
- Toraman, S., Alakus, T. B. and Turkoglu, I., 2020, Convolutional capsnet: A novel artificial neural network approach to detect COVID-19 disease from X-ray images using capsule networks, *Chaos, Solitons and Fractals*, 140, 110122.
- Touahri, R., AzizI, N., Hammami, N. E., Aldwairi, M. and Benaida, F., 2019, Automated breast tumor diagnosis using local binary patterns (LBP) based on deep learning classification, *International Conference on Computer and Information Sciences, ICCIS-2019*, Al-Jawf, 1-5.
- Tuncer, T., Dogan, S. and Ozyurt, F., 2020, An automated Residual Exemplar Local Binary Pattern and iterative ReliefF based corona detection method using lung X-ray image, *Chemometrics and Intelligent Laboratory Systems*, 203, 104054.
- Turing, A. M., 1950, Can a machine think, *Mind*, 59 (236), 433-460.
- Uçar, F. and Korkmaz, D., 2020, COVIDiagnosis-Net: Deep Bayes-SqueezeNet based diagnosis of the coronavirus disease 2019 (COVID-19) from X-ray images, *Medical Hypotheses*, 140, 109761.

- Vaid, S., Kalantar, R. and Bhandari, M., 2020, Deep learning COVID-19 detection bias: accuracy through artificial intelligence, *International Orthopaedics*, 44 (8), 1539-1542.
- Vayá, M. D. L. I., Saborit, J. M., Montell, J. A., Pertusa, A., Bustos, A., Cazorla M, Galant, J., Barber, X., Orozco-Beltrán, D., García-García, F., Caparrós, M., González, G. and Salinas, J. S., 2020, BIMCV COVID-19+: a large annotated dataset of RX and CT images from COVID-19 patients, *arXiv preprint*, arXiv:2006.01174, Veri Seti Erişimi: <https://bimcv.cipf.es/bimcv-projects/bimcv-covid19/> (Erişim Tarihi: 1 Haziran 2022).
- Waheed, A., Goyal, M., Gupta, D., Khanna, A., Al-Turjman, F. and Pinheiro, P. R., 2020, Covidgan: Data augmentation using auxiliary classifier gan for improved covid-19 detection, *IEEE Access*, 8, 91916-91923.
- Wang, X., Deng, X., Fu, Q., Zhou, Q., Feng, J., Ma, H., Liu, W. and Zheng, C., 2020(a), A Weakly-supervised Framework for COVID-19 Classification and Lesion Localization from Chest CT, *IEEE Transactions on Medical Imaging*, 39 (8), 2615-2625.
- Wang, J., Bao, Y., Wen, Y., Lu, H., Luo, H., Xiang, Y., Li, X., Liu, C. and Qian, D., 2020(b), Prior-attention residual learning for more discriminative COVID-19 screening in CT images, *IEEE Transactions on Medical Imaging*, 39 (8), 2572-2583.
- Wang, L., Lin, Z. Q. and Wong, A., 2020(c), Covid-net: A tailored deep convolutional neural network design for detection of covid-19 cases from chest X-ray images, *Scientific Reports*, 10 (1), 1-12, Veri Seti Erişimi: <https://github.com/agchung/figure1-covid-chestxray-dataset> (Erişim Tarihi: 1 Haziran 2022).
- Winther, H. B., Laser, H., Gerbel, S., Maschke, S. K., Hinrichs, J. B., Vogel-Claussen, J., Wacker, F. K., Höper, M. M. and Meyer, B. C., 2020, COVID-19 Image Repository, Veri Seti Erişimi: <https://github.com/ml-workgroup/covid-19-image-repository> (Erişim Tarihi: 1 Haziran 2022).
- Wong, M. D., Thai, T., Li, Y. and Liu, H., 2020, The role of chest computed tomography in the management of COVID-19: A review of results and recommendations, *Experimental Biology and Medicine*, 245 (13), 1096-1103.
- Wu, Y. and He, K., 2018, Group normalization, *European Conference on Computer Vision*, ECCV-2018, Munich, 3-19.
- Wu, J., Liu, J., Zhao, X., Liu, C., Wang, W., Wang, D., Xu, W., Zhang, C., Yu, J., Jiang, B., Cao, H. and Li, L., 2020(a), Clinical characteristics of imported cases of coronavirus disease 2019 (COVID-19) in Jiangsu Province: a multicenter descriptive study, *Clinical Infectious Diseases*, 71 (15), 706-712.
- Wu, X., Hui, H., Niu, M., Li, L., Wang, L., He, B., Yang, X., Li, L., Li, H., Tian, J. and Zha, Y., 2020(b), Deep learning-based multi-view fusion model for screening

- 2019 novel coronavirus pneumonia: a multicentre study, *European Journal of Radiology*, 128, 109041.
- Xiao, L. S., Li, P., Sun, F., Zhang, Y., Xu, C., Zhu H, Cai, F., He, Y., Zhang, W., Ma, S., Hu, C., Gong, M., Liu, L., Shi, W. and Zhu, H., 2020, Development and validation of a deep learning-based model using computed tomography imaging for predicting disease severity of Coronavirus disease 2019, *Frontiers in Bioengineering and Biotechnology*, 8, 898.
- Xiao, B., Yang, Z., Qiu, X., Xiao, J., Wang, G., Zeng, W., Li, W., Nian, Y. and Chen, W., 2021, PAM-DenseNet: A Deep Convolutional Neural Network for Computer-Aided COVID-19 Diagnosis, *IEEE Transactions on Cybernetics*, 1-12.
- Xing, Z. and Jia, H., 2020, An improved thermal exchange optimization based GLCM for multi-level image segmentation, *Multimedia Tools and Applications*, 79 (17), 12007-12040.
- Xu, X., Jiang, X., Ma, C., Du, P., Li, X., Lv, S., Yu, L., Ni, Q., Chen, Y., Su, J., Lang, G., Li, Y., Zhao, H., Liu, J., Xu, K., Ruan, L., Sheng, J., Qiu, Y., Wu, W., Liang, T. and Li, L., 2020, A deep learning system to screen novel coronavirus disease 2019 pneumonia, *Engineering*, 6 (10), 1122-1129.
- Yan, T., Wong, P. K., Ren, H., Wang, H., Wang, J. and Li, Y., 2020, Automatic distinction between covid-19 and common pneumonia using multi-scale convolutional neural network on chest CT scans, *Chaos, Solitons and Fractals*, 140, 110153.
- Yang, X., Li, M. and Zhao, S., 2017, Facial expression recognition algorithm based on CNN and LBP feature fusion, *International Conference on Robotics and Artificial Intelligence*, 33-38.
- Yang, W., Cai, L. and Wu, F., 2020, Image segmentation based on gray level and local relative entropy two dimensional histogram, *Plos One*, 15 (3), e0229651.
- Yaşar, H. and Ceylan, M., 2021(a), A novel comparative study for detection of Covid-19 on CT lung images using texture analysis, machine learning, and deep learning methods, *Multimedia Tools and Applications*, 80 (4), 5423-5447.
- Yaşar, H. and Ceylan, M., 2021(b), A new deep learning pipeline to detect Covid-19 on chest X-ray images using local binary pattern, dual tree complex wavelet transform and convolutional neural networks, *Applied Intelligence*, 51 (5), 2740-2763.
- Yaşar, H. and Ceylan, M., 2022(a), Deep Learning–Based Approaches to Improve Classification Parameters for Diagnosing COVID-19 from CT Images, *Cognitive Computation*, 1-28.
- Yaşar, H. and Ceylan, M., 2022(b), A novel study for automatic two-class COVID-19 diagnosis (between COVID-19 and Healthy, Pneumonia) on X-ray images using



- texture analysis and 2-D/3-D convolutional neural networks, *Multimedia Systems*, 1-19.
- Yaşar, H., Ceylan, M., Cebeci, H., Kılıçer, A., Kanat, F. and Koplay, M., (2022), A novel study to increase the classification parameters on automatic three-class COVID-19 classification from CT images, including cases from Turkey, *Journal of Experimental & Theoretical Artificial Intelligence*, 1-21.
- Yıldırım, M. and Çınar, A., 2020, A deep learning based hybrid approach for COVID-19 disease detections, *Traitement du Signal*, 37 (3), 461-468.
- Yoon, S. H., Lee, K. H., Kim, J. Y., Lee, Y. K., Ko, H., Kim, K. H., Park, C. M. and Kim, Y. H., 2020, Chest radiographic and CT findings of the 2019 novel coronavirus disease (Covid-19): analysis of nine patients treated in Korea, *Korean Journal of Radiology*, 21 (4), 494-500.
- Yousefzadeh, M., Esfahanian, P., Movahed, S. M. S., Gorgin, S., Rahmati, D., Abedini, A., Nadji, S. A., Haseli, S., Bakhshayesh Karam, M., Kiani, A., Hoseinyazdi, M., Roshandel, J. and Lashgari R., 2021, ai-corona: Radiologist-assistant deep learning framework for COVID-19 diagnosis in chest CT scans, *PLoS One*, 16 (5), e0250952.
- Yu, Z., Li, X., Sun, H., Wang, J., Zhao, T., Chen, H., Ma, Y., Zhu, S. and Xie, Z., 2020, Rapid identification of COVID-19 severity in CT scans through classification of deep features, *BioMedical Engineering OnLine*, 19 (1), 1-13.
- Zhang, X. P., Desai, M. D. and Peng, Y. N., 1999, Orthogonal complex filter banks and wavelets: some properties and design, *IEEE Transactions on Signal Processing*, 47 (4), 1039-1048.
- Zhang, H., Qu, Z., Yuan, L. and Li, G., 2017, A face recognition method based on LBP feature for CNN, *IEEE Advanced Information Technology, Electronic and Automation Control Conference*, IAEAC-2017, Chongqing, 544-547.
- Zhang, J. J., Dong, X., Cao, Y. Y., Yuan, Y. D., Yang, Y. B., Yan, Y. Q., Akdis, C. A. and Gao, Y. D., 2020, Clinical characteristics of 140 patients infected with SARS-CoV-2 in Wuhan, China, *Allergy*, 75 (7), 1730-1741.
- Zhang, X., Wang, D., Shao, J., Tian, S., Tan, W., Ma, Y., Xu, Q., Ma, X., Li, D., Chai, J., Wang, D., Liu, W., Lin, L., Wu, J., Xia, C. and Zhang, Z., 2021, A deep learning integrated radiomics model for identification of coronavirus disease 2019 using computed tomography, *Scientific Reports*, 11 (1), 3938.
- Zhao, D., Yao, F., Wang, L., Zheng, L., Gao, Y., Ye, J., Guo, F., Zhao, H. and Gao, R., 2020(a), A comparative study on the clinical features of COVID-19 pneumonia to other pneumonias, *Clinical Infectious Diseases*, 71 (15), 756-761.
- Zhao, J., Zhang, Y., He, X. and Xie, P., 2020(b), Covid-CT-dataset: a CT scan dataset about covid-19, *arXiv preprint*, arXiv:2003.13865. Veri Seti Erişimi: <https://github.com/UCSD-AI4H/COVID-CT> (Erişim Tarihi: 1 Haziran 2022).

- Zhu, N., Zhang, D., Wang, W., Li, X., Yang, B., Song, J., Zhao X., Huang B., Shi W., Lu R., Niu P., Zhan F., Ma X., Wang D., Xu W., Wu G., Gao G. F. and Tan W., 2020, A novel coronavirus from patients with pneumonia in China, 2019, *New England Journal of Medicine*, 382 (8), 727-733.
- Zhu, Z., Xingming, Z., Tao, G., Dan, T., Li, J., Chen, X., Li, Y., Zhou, Z., Zhang, X., Zhou, J., Chen, D., Wen, H. and Cai, H., 2021(a), Classification of COVID-19 by compressed chest CT image through deep learning on a large patients cohort, *Interdisciplinary Sciences: Computational Life Sciences*, 13 (1), 73-82.
- Zhu, X., Song, B., Shi, F., Chen, Y., Hu, R., Gan, J., Zhang, W., Li, M., Wang, L., Gao, Y., Shan, F. and Shen, D., 2021(b), Joint prediction and time estimation of COVID-19 developing severe symptoms using chest CT scan, *Medical Image Analysis*, 67, 101824.
- Zu, Z. Y., Jiang, M. D., Xu, P. P., Chen, W., Ni, Q. Q., Lu, G. M. and Zhang, L. J., 2020, Coronavirus disease 2019 (COVID-19): a perspective from China, *Radiology*, 296 (2), E15-E25.