



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



**U-NET DERİN ÖĞRENME MİMARİSİ**  
**KULLANILARAK YANMIŞ ALANLARIN**  
**UYDU GÖRÜNTÜLERİNDEN TESPİTİ**

**Damlanur ALKAN**

**YÜKSEK LİSANS TEZİ**

**Harita Mühendisliği Anabilim Dalı**

**Temmuz-2023**  
**KONYA**  
**Her Hakkı Saklıdır**

## TEZ KABUL VE ONAYI

Damlanur ALKAN tarafından hazırlanan ‘‘U-Net Derin Öğrenme Mimarisi Kullanılarak Yanmış Alanların Uydu Görüntülerinden Tespiti’’ adlı tez çalışması 07/07/2023 tarihinde aşağıdaki jüri tarafından oy birliği ile Konya Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü Harita Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

### Jüri Üyeleri

#### Başkan

Prof. Dr. Hakan KARABÖRK

#### Danışman

Dr. Öğr. Üyesi Lütfiye KARASAKA

#### Üye

Prof. Dr. Hakan KARABÖRK

#### Üye

Dr. Öğr. Üyesi A. Merve ACILAR

### İmza

.....

.....

.....

.....

Yukarıdaki sonucu onaylarım.

Prof. Dr. Mevlüt UYAN  
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.

Damlanur ALKAN

Tarih: 07/07/2023

## ÖZET

### YÜKSEK LİSANS TEZİ

## U-NET DERİN ÖĞRENME MİMARİSİ KULLANILARAK YANMIŞ ALANLARIN UYDU GÖRÜNTÜLERİNDEN TESPİTİ

**Damlanur ALKAN**

**Konya Teknik Üniversitesi  
Lisansüstü Eğitim Enstitüsü  
Harita Mühendisliği Anabilim Dalı**

**Danışman: Dr. Öğr. Üyesi Lutfiye KARASAKA**

**2023, 102 Sayfa, 13 Sayfa Ek**

**Jüri**

**Dr. Öğr. Üyesi Lutfiye KARASAKA**

**Prof. Dr. Hakan KARABÖRK**

**Dr. Öğr. Üyesi A. Merve ACILAR**

Doğal afetlerden biri olan yangınlar canlı-cansız bütün varlıklara zarar vermektedir. Bu zararın tespit edilebilmesi gelecek planlamaları açısından önem arz eder. Çeşitli amaçlar için kullanım alanı sağlayan uzaktan algılama teknolojileri yanmış alanların tespiti için de kullanılabilir. Bu tez çalışmasında yanmış alanların uzaktan algılama teknolojileri ile tespit edilmesinde bant kombinasyonlarının, veri artırımının ve eşik değer seçiminin etkilerinin incelenmesi amaçlanmıştır. Bu amaç doğrultusunda Landsat-8 uydu görüntüleri ve U-Net derin öğrenme mimarisi kullanılmıştır. İşlemler Python programlama dili kullanılarak gerçekleştirilmiştir. Çalışma kapsamında yanmış alanların uydu görüntüleri üzerinden tespiti için farklı kombinasyonlar kullanılarak eğitim ve test işlemleri gerçekleştirilmiş, elde edilen sonuçlar incelenmiştir. Test sonuçları için farklı eşik değerler (0.1, 0.5 ve 0.9) kullanılmıştır. Çalışma sonucunda eşik değer 0.1 ve 0.5 olduğu durumlarda daha iyi sonuçlara ulaşılmıştır. Yapılan kombinasyonlar karşılaştırıldığında 7,5,4 bant kombinasyonunun ve AdaMax algoritması kullanımının diğer kombinasyonlardan daha iyi sonuçlar verdiği görülmüştür. Bu kombinasyondaki eğitim veri setine 90°, 180° ve 270° döndürme uygulanarak veri artırımı yapılmıştır. Veri artırımı gerçekleştirilen veri seti nihai modele girdi olarak verilmiştir. Nihai modele dair sonuçlar, veri artırımı yapılmadan elde edilen sonuçlarla karşılaştırıldığında veri artırımının olumlu etki yaptığı görülmüştür. Sonuç olarak nihai modelde elde edilen test doğruluğu değeri eşik değerin 0.5 olduğu durumda en yüksek olup %97.76'dır. Aynı eşik değeri için elde edilen F1-skoru değeri ise %79.38'dir.

**Anahtar Kelimeler:** Derin Öğrenme, Landsat-8, Segmentasyon, U-Net, Uydu Görüntüsü, Uzaktan Algılama, Yanmış Alan.

## **ABSTRACT**

### **MS THESIS**

# **DETECTION OF BURNED AREAS FROM SATELLITE IMAGES USING U-NET DEEP LEARNING ARCHITECTURE**

**Damlanur ALKAN**

**Konya Technical University  
Institute of Graduate Studies  
Department of Geomatics Engineering**

**Advisor: Asst. Prof. Dr. Lütfiye KARASAKA**

**2023, 102 Pages, 13 Pages Appendix**

#### **Jury**

**Asst. Prof. Dr. Lütfiye KARASAKA**

**Prof. Dr. Hakan KARABÖRK**

**Asst. Prof. Dr. A. Merve ACILAR**

Fires, one of the natural disasters, damage all living and non-living things. The detection of this damage is important for future planning. Remote sensing technologies, which provide a field of use for various purposes, can also be used for the detection of burned areas. In this thesis, it was aimed to examine the effects of band combinations, data augmentation and threshold value selection on detection of burned areas with remote sensing technologies. For this purpose, Landsat-8 satellite images and U-Net deep learning architecture were used. The operations were carried out using the Python programming language. Within the scope of the study, train and test processes were performed by using different combinations to determine the burned areas on satellite images, and the outcomes were examined. For the test results, different threshold values (0.1, 0.5 and 0.9) were used. As a consequence of the study, better results were obtained for the threshold values 0.1 and 0.5. When the combinations were compared, it was seen that the 7,5,4 band combination and the use of the AdaMax algorithm gave better results than the other combinations. Data augmentation was performed by applying 90°, 180° and 270° rotation to the training data set in this combination. The augmented data set was given as input to the final model. When the results of the final model was compared with the ones obtained without data augmentation, it was seen that data augmentation has a positive effect. In conclusion, the test accuracy value of the final model is the highest when the threshold value is 0.5 and it is 97.76%. The F1-score value obtained for the same threshold value is 79.38%.

**Keywords:** Burned Area, Deep Learning, Landsat-8, Remote Sensing, Satellite Image, Segmentation, U-Net.

## ÖNSÖZ

Tez çalışmamda ve akademik hayatımda bana yol gösterici olan, bilgi, birikim ve tecrübelerini her daim benimle paylaşan tez danışman hocam Dr. Öğr. Üyesi Lütfiye KARASAKA'ya, bana vakit ayırarak görüş ve önerileriyle tezime önemli katkılarda bulunan tez jüri üyesi Dr. Öğr. Üyesi Ayşe Merve ACILAR'a, zaman zaman fikirlerini aldığım Öğr. Gör. İlyas YALÇIN, Recep CAN ve Arş. Gör. Mücahit CİHAN'a, anabilim dalı üyelerimize ve arkadaşlarıma teşekkür ederim.

Hayatımın her anında yanımda olan, bana inanan, güvenen, maddi-manevi her anlamda desteklerini sunan canım annem Aynur ALKAN'a ve canım babam S. Birol ALKAN'a, her daim yanımda hissettiğim beni motive eden akrabalarımın gönülden teşekkürler.

Damlanur ALKAN  
KONYA-2023

## İÇİNDEKİLER

<b>ÖZET</b> .....	<b>iv</b>
<b>ABSTRACT</b> .....	<b>v</b>
<b>ÖNSÖZ</b> .....	<b>vi</b>
<b>İÇİNDEKİLER</b> .....	<b>vii</b>
<b>KISALTMALAR</b> .....	<b>ix</b>
<b>1. GİRİŞ</b> .....	<b>1</b>
<b>2. KAYNAK ARAŞTIRMASI</b> .....	<b>4</b>
<b>3. MATERYAL VE YÖNTEM</b> .....	<b>17</b>
3.1. Uydu Görüntüleri .....	17
3.2. Görüntü Segmentasyonu (Görüntü Bölütlemesi, Image Segmentation).....	18
3.3. Veri Artırımı (Data Augmentation) .....	19
3.3.1. Geometrik dönüşümler .....	19
3.3.2. Renk uzayı dönüşümleri .....	22
3.4. Yapay Sinir Ağları (Artificial Neural Networks-ANN).....	23
3.4.1. Katmanlar.....	25
3.4.2. Eğitim, doğrulama ve test veri setleri .....	26
3.4.3. Hiper parametreler .....	27
3.5. Derin Öğrenme (Deep Learning) .....	32
3.5.1. Avantajları ve dezavantajları .....	33
3.5.2. Kütüphaneler.....	33
3.5.3. Veri Setleri.....	35
3.6. Evrimsel Sinir Ağları (Convolutional Neural Networks – CNN) .....	35
3.6.1. Katmanlar.....	37
3.7. U-Net.....	42
3.7.1. Daralma yolu.....	44
3.7.2. Genişleme yolu .....	44
3.7.3. Avantajları ve kullanım alanları .....	44
3.8. Doğruluk Metrikleri (Evaluation Metrics).....	45
3.8.1. Hata matrisi (Confusion matrix).....	45
3.8.2. Genel doğruluk (Overall accuracy – OA).....	47
3.8.3. Duyarlılık (Recall) .....	49
3.8.4. Kesinlik (Precision) .....	49
3.8.5. F1-skoru (F1-score) .....	50
3.8.6. Jaccard skoru (Kesişim bölü birleşim, Intersection over union - IoU).....	50

3.9. Uygulama .....	51
3.9.1. Kullanılan platform.....	51
3.9.2. Kullanılan Derin Öğrenme Yapısı ve Veri Seti .....	52
3.9.3. Veri setinin ve hiper parametrelerin ayarlanması .....	55
<b>4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA.....</b>	<b>57</b>
4.1. Bant Kombinasyonlarının Karşılaştırılması.....	57
4.1.1. Bant kombinasyonu 7,5,4 için test görüntülerini değerlendirme.....	59
4.1.2. Bant kombinasyonu 5,3,7 için test görüntülerini değerlendirme.....	62
4.1.3. Bant kombinasyonu 5,4,3 için test görüntülerini değerlendirme.....	64
4.1.4. Bant kombinasyonu 4,3,2 için test görüntülerini değerlendirme.....	65
4.1.5. Bant kombinasyonu 4,3,2,5 için test görüntülerini değerlendirme.....	67
4.1.6. Bant kombinasyonu 2,3,4,5,6,7 için test görüntülerini değerlendirme.....	69
4.1.7. Bant kombinasyonları için istatistiksel değerlendirme .....	70
4.2. Optimizasyon Algoritmalarının Karşılaştırılması .....	75
4.2.1. Bant kombinasyonu 7,5,4 ve AdaGrad algoritması için test görüntülerini değerlendirme .....	76
4.2.2. Bant kombinasyonu 7,5,4 ve AdaMax algoritması test görüntülerini değerlendirme .....	78
4.2.3. Bant kombinasyonu 4,3,2 ve AdaGrad algoritması için test görüntülerini değerlendirme .....	79
4.2.4. Bant kombinasyonu 4,3,2 ve AdaMax algoritması için test görüntülerini değerlendirme .....	81
4.2.5. Optimizasyon algoritmaları için istatistiksel değerlendirme .....	83
4.3. Nihai Modelin Oluşturulması.....	87
4.3.1. Nihai model için test görüntülerini değerlendirme .....	89
4.3.2. Nihai model için istatistiksel değerlendirme .....	90
<b>5. SONUÇLAR.....</b>	<b>93</b>
<b>KAYNAKLAR .....</b>	<b>95</b>
<b>EKLER .....</b>	<b>103</b>



## KISALTMALAR

BA-Net	: Burned Areas Neural Network
CAL FIRE	: California Department of Forestry & Fire Protection
CNN	: Convolutional Neural Networks
CPU	: Central Process Unit
EMS	: Emergency Management System
DLR	: German Aerospace Center
DN	: Doğru Negatif
dNBR	: Difference Normalized Burned Ratio
dNDVI	: Difference Normalized Difference Vegetation Index
DP	: Doğru Pozitif
ESA	: European Space Agency
FESM	: Fire Extent and Severity Mapping
FIRMS	: The Fire Information for Resource Management System
FRAP	: Fire and Resource Assessment Program
GEEBAM	: Google Earth Engine Burnt Area Map
GPU	: Grafical Processing Unit
ICNF	: Portuguese Institute for Nature Conservation and Forests
ILSVRC	: ImageNet Large Scale Visual Recognition
MGRS	: Military Grid Reference System
MTBS	: Monitoring Trends in Burn Severity
NBR	: Normalized Burned Ratio
NDVI	: Normalized Difference Vegetation Index
NDWI	: Normalized Difference Water Index
OGM	: Orman Genel Müdürlüğü
OLI	: Operational Land Imager
ReLU	: Rectified Linear Unit
SGD	: Stochastic Gradient Descent
TERN	: Australia's Terrestrial Ecosystem Research Network
TIRS	: Thermal Infrared Sensor
VIIRS	: Visible Infrared Imaging Radiometer Suite
WGS 1984	: World Geodetic System 1984
Uint	: Unsigned Integer
USGS	: United States Geological Survey
YN	: Yanlış Negatif
YP	: Yanlış Pozitif

## 1. GİRİŞ

Afetler normal hayatın ve yapılan aktivitelerin durmasına veya kesintiye uğramasına sebep olan, çeşitli kayıplarla (ekonomik, sosyal, fiziksel) sonuçlanan olaylardır (Erkal ve Değerliyurt, 2009). Geçmişten günümüze kadar çevrede meydana gelen afetler çeşitli canlıları etkilenmiştir ve etkilemeye devam edecektir (Sarp ve ark., 2018). Deprem, sel, heyelan, çığ ve yangınlar afetlere örnek olarak verilebilir.

Yangınlar, çeşitli unsurların bir araya gelerek kimyasal bir reaksiyon gerçekleştirmesi sonucunda oluşmaktadır (Ergün, 2023). Ormanlarda meydana gelen yangınlar heyelan, erozyon, çölleşme gibi farklı problemlere sebep olabilmektedir (Saylan ve Çömert, 2019). Öncelikle orman; geniş bir alan boyunca çeşitli ağaçlardan ve bitkilerden oluşan topluluk olarak ifade edilebilir. İçerisinde çeşitli mikroorganizmaların ve hayvanların da dahil olduğu birçok canlıyı barındırır. Canlı varlıklar orman içerisinde hava, su, ışık, toprak gibi faktörler eşliğinde birbirleri ile ilişki içerisinde ve etkileşim halinde bulunur. İnsanların beslenme, barınma gibi birçok ihtiyacını karşılayan ormanlar hammadde kaynağıdır. Ekonomik ve sosyal hayata önemli katkılarda bulunur. Ormanların sunduğu maddi ve manevi imkanlardan faydalanmaya devam edebilmek için ormanların korunması önem taşımaktadır.

Orman yangınları; doğal sebeplerden ya da insan kaynaklı sebeplerden ortaya çıkan (Sunar ve Özkan, 2001), yayılmaya eğilimli olan, içinde bulunan canlı cansız yanabilen bütün varlıkları kısmen ya da tamamen yakan bir afet türüdür (URL-1). Canlılara, evlere, doğal ve kültürel kaynaklara zarar vermekte (Huot ve ark., 2020); çevreyi, insan sağlığını ve mülkiyeti tehdit altında bırakmaktadır (Sunar ve Özkan, 2001). OGM (Orman Genel Müdürlüğü) tarafından sunulan resmi istatistiklere göre 2021 yılında Türkiye’de meydana gelen orman yangını sayısı 2793’tür. Bunlardan 110 adedinin kasıt sonucu, 1001 adedinin ihmal-kaza sonucu, 353 adedinin doğal sebepler sonucu ve 1329 adedinin bilinmeyen sebepler sonucu meydana geldiği belirtilmiştir. Yine 2021 yılı için toplam yanan alan ise 139503.16 hektardır. Bu alandan 72511.65 hektarına doğal gençleştirme hazırlığı yapıldığı, 28426.29 hektarının suni gençleştirme programına alındığı, 7761.44 hektarının rehabilite edildiği, 4602.63 hektarının ağaçlandırma programına alındığı ve 21499 hektarının yapılacak teknik bir işlem olmadığı için korumaya alındığı belirtilmiştir (URL-2). Görüldüğü üzere yangınlar sonrası oluşan zararın tespit edilmesi ve değerlendirilmesi önemlidir. Çünkü bu alanların gençleştirilmesi, rehabilitasyonu, yeniden ağaçlandırılması, korumaya alınması gibi

planlama ve uygulamaların yapılabilmesi açısından yanmış alanların tespit edilebilmesi gereklidir.

Yangınlar sonucunda meydana gelen yanmış alanların tespit edilmesinde yersel yöntemlerin yanı sıra uzaktan algılama teknolojilerinin de tercih edildiği görülmektedir. Yersel yöntemlerle araziden veri toplamanın çok fazla zaman alacağı ve çok maliyetli olacağı göz önünde bulundurulduğunda hatta yangın sonrası yanan bölgeye ulaşmanın mümkün bile olmayabileceği dikkate alındığında, uzaktan algılama cazip bir hale gelmekte ve kullanılmaktadır (Sabuncu ve Özener, 2019). Uzaktan algılama, herhangi bir fiziksel temas olmadan nesnelere üzerinden yansıyan ve yayılan enerjinin ilgili platformlara kaydedilmesi suretiyle yeryüzündeki büyük alanlar üzerinde meydana gelen değişimlerin kısa sürede incelenebilmesine imkan sağlar. Uzaktan algılama teknolojilerinde meydana gelen gelişmeler sayesinde daha fazla veriye kolay ve hızlı bir şekilde ulaşılabilen, yeryüzünde zaman içerisinde meydana gelen değişimler ve bu değişimlerin sebepleri ortaya koyulabilmektedir (Deniz, 2012). Uzaktan algılamada uydular geçmişten günümüze kadar çeşitli amaçları karşılamak için çok sayıda veri toplamaktadır. Ancak, elde edilen bu büyük verinin analiz edilmesinde klasik yöntemler yetersiz kalmaktadır. Bu sebeple son zamanlarda büyük verinin analizinde daha iyi sonuçlar verdiği belirtilen derin öğrenme tekniklerinin kullanımı popüler hale gelmiştir.

Derin öğrenme beynin işleyişini temel alan bir yöntemdir (Bayramoğlu, 2021). Verilerin temsilleri üzerinden öğrenilmesi (Şeker ve ark., 2017), çok sayıda gizli katmandan oluşması (Sarıyıldız, 2021) ve doğrusal olmayan (non-linear) problemlerin üstesinden gelebilmesi (Deng ve Yu, 2014) gibi çeşitli avantajlar sağlamaktadır. Derin öğrenme bir makine öğrenmesi yöntemidir. Ancak makine öğrenmesi karmaşık kural setlerini içermesi ve ham veriden özellik çıkarımını gerektirmesi gibi dezavantajlara sahiptir (Brand ve Manandhar, 2021). Bununla birlikte derin öğrenme özellik çıkarımını otomatik olarak gerçekleştirir. Bu işlemi kullanıcı tarafından sunulan ekstra bir girdiye ihtiyaç duymadan sadece belirli birkaç hiper parametre ile yapar (Hu ve ark., 2021). Sağladığı avantajlardan dolayı derin öğrenme birçok görüntü işleme probleminde kullanıldığı gibi uzaktan algılama alanında ve yanmış alanların tespitinde de (Knopp ve ark., 2020; Brand ve Manandhar, 2021; Prabowo ve ark., 2022b) tercih edilen bir yöntem olmuştur.

Bu tez çalışması kapsamında derin öğrenme mimarisi ile yanmış alanlarının uydu görüntülerinden tespiti gerçekleştirilmiştir. Derin öğrenme yöntemi olarak U-Net mimarisi tercih edilmiştir. Kullanılan uydu görüntüleri ise Landsat-8 uydusuna aittir.

Çalışmanın amacı uygulamada kullanılan bant kombinasyonu tercihlerinin, eşik değer seçiminin ve veri artırımı yapılmasının yanmış alanların tespitinde etkisinin olup olmadığının incelenmesidir. Bu amaçların gerçekleştirilmesi için 7,5,4; 5,3,7; 5,4,3; 4,3,2; 4,3,2,5 ve 2,3,4,5,6,7 bantları kullanılarak 6 farklı bant kombinasyonu oluşturulmuştur. Optimizasyon algoritması olarak Adam algoritması kullanılmıştır. Bant kombinasyonlarının her biri için ayrı ayrı eğitim ve test işlemleri gerçekleştirilmiştir. Test sonuçları için 0.1, 0.5 ve 0.9 eşik değerleri kullanılmıştır. Yapılan kombinasyonlardan en iyi ve en kötü sonucu veren kombinasyonlar seçilerek AdaGrad ve AdaMax optimizasyon algoritmaları ile yeniden eğitim ve test işlemlerine tabi tutulmuştur. Bütün kombinasyonlar arasında en iyi sonucu veren kombinasyon nihai modelin belirlenmesinde kullanılmıştır. Ardından eğitim veri setine 90°, 180° ve 270° döndürme uygulanarak veri artırımı gerçekleştirilmiştir. Veri artırımı ile oluşturulan veri seti nihai modele girdi olarak verilmiştir. Elde edilen sonuçların değerlendirilmesinde doğruluk metriklerinden genel doğruluk, duyarlılık, kesinlik, F1-skoru ve Jaccard skoru kullanılmıştır.

## 2. KAYNAK ARAŞTIRMASI

Tez çalışması kapsamında yapılan kaynak araştırmasında yangınların/yanmış alanların tespitinde derin öğrenme yöntemlerini kullanan çalışmalar incelenmiştir. Bahsi geçen çalışmalar tezin bu bölümünde yıllara göre sıralanarak özetlenmiştir. İlgili çalışmalarda hangi uydu görüntülerinin ve veri setlerinin kullanıldığı, hangi hiper parametre ayarlarının yapıldığı ve modellerin performanslarının değerlendirilmesinde hangi metriklerin kullanıldığı gibi tercihler incelenmiştir.

Park ve Lee (2019), U-Net yapısını kullanarak semantik segmentasyon işlemi gerçekleştirmişlerdir. Landsat-5 ve Landsat-8 uydu görüntülerini ve bu görüntülerle birlikte NDVI, NDWI ve FWI spektral indekslerini girdi verisi olarak kullanmışlardır. Kore Orman Servisi (Korea Forest Service) tarafından sunulan orman yangını zarar kitabına göre, 2003-2018 yılları arasında olup zarar gören alanın 10 hektar ve üzeri olduğu görüntüleri seçmişler, mümkün oldukça zarar tarihinden itibaren 3 ay içerisindeki veriyi kullanmışlardır. Girdi verisi için kırmızı, yakın kızılötesi, yeşil bantları ile NDVI, NDWI ve FWI spektral indekslerini; referans verisi için ise QGIS platformunda kırmızı, yeşil, mavi ve kırmızı, yakın kızılötesi, yeşil bant kombinasyonundaki görüntüleri tercih etmişlerdir. Uygulamada girdi görüntülerine veri artırımı (data augmentation) uygulamışlar ve toplam 800 adet girdi görüntüsü oluşturmuşlardır. Çapraz doğrulama (cross-validation) yöntemini kullanarak veri setini 10 parçaya (fold) bölmüşlerdir. Her birinde 80 adet doğrulama verisi ve 80 adet test verisi kullanmışlardır. Girdi görüntü boyutlarını 96x96 olarak ayarlamışlardır. Kayıp fonksiyonu olarak ikili çapraz entropi (binary cross entropy) ve optimizasyon için Adam algoritması kullanmışlardır. Öğrenme hızını 0.0001, küme boyutlarını (batch size) 30 ve 50, epok sayılarını 300 ve 500 olarak seçmişlerdir. Doğruluk metriklerinden doğruluk (accuracy), kesinlik (precision), duyarlılık (recall) ve F1-skor (F1-score) değerlerini hesaplamışlardır. Modelde epok sayısı 300 ve küme boyutu 30 olarak seçildiği durumda daha yüksek doğruluk değerleri elde edildiğine değinmişlerdir. Bununla birlikte yangından zarar gören alanların yakınında yol, nehir ya da kentsel alan gibi yapılar olmasının doğruluk değerini azalttığını ifade etmişlerdir. Çıktı ürünün 0-1 aralığında değişen olasılık değerlerinden oluştuğunu ve bu değerlere 0.5 değerine göre yuvarlama (round) işlemi yapıldığında 0 ve 1 değerlerinden oluşan sonuç ürünün elde edildiğini belirtmişlerdir.

Park (2020), yüksek lisans tez çalışmasında USGS'nin sağladığı Landsat-5 ve Landsat-8 uydu görüntülerini kullanmıştır. Bu görüntüler için NDVI, NDWI ve FWI

spektral indekslerini hesaplamış ve bunları derin öğrenme modelinde girdi verisi olarak tercih etmiştir. Kore Orman Servisi tarafından sunulan orman yangını zarar kitabına göre, 2003-2018 yılları arasında olup zarar gören alanın 10 hektar ve üzeri olduğu görüntüleri seçtiğini belirtmiştir. Zarar gören alanın çok küçük olmasının modelin öğrenme sürecine olumsuz etki yapabileceğini ifade etmiştir. Bahsi geçen şartları sağlayan 48 adet görüntü tespit etmiştir. Referans verisi için kırmızı, yeşil, mavi ve kırmızı, yakın kızılötesi, yeşil bant kombinasyonundaki görüntüleri QGIS platformunda kullanmıştır. Uygulamada girdi görüntülerine veri artırımı uygulayarak 960 tane görüntü elde etmiştir. Bunlardan 80 tanesini doğrulama verisi ve diğer 80 tanesini test verisi olarak kullanmıştır. Görüntüleri standartlaştırma işlemine tabi tutmuştur. Çapraz doğrulama yöntemini kullanarak veri setini 12 parçaya bölmüştür. Girdi görüntü boyutlarını 96x96 olarak ayarlamıştır. Kayıp fonksiyonu olarak ikili çapraz entropi, aktivasyon fonksiyonu olarak ReLU (Rectified Linear Unit) ve optimizasyon için Adam algoritması kullanmıştır. Öğrenme hızını 0.001, küme boyutlarını 10 ve epok sayısını 300 olarak belirlemiştir. DNN ile karşılaştırıldığında U-Net modelinin daha iyi sonuçlar verdiğini belirtmiştir.

Pinto ve ark. (2020), günlük olarak elde edilen görüntü dizilerinden yanmış alanların haritalanması ve tarihlendirilmesini gerçekleştirmişlerdir. Bu amaçla BA-Net (Burned Areas Neural Network) olarak adlandırdıkları bir model geliştirmişlerdir. Bu modeli U-Net yapısı üzerinde birtakım değişiklikler uygulayarak oluşturduklarını belirtmişlerdir. Modelde U-Net yapısına dayanan CNN ve LSTM mimarilerini kullanmışlardır. Çalışma bölgesi olarak Kaliforniya, Portekiz, Brezilya, Mozambik ve Avustralya'yı tercih etmişlerdir. Her bölge için yangınların en aktif olduğu zaman dilimlerine ait verileri kullanmışlardır. Girdi olarak VIIRS verisinden (kırmızı, yakın kızılötesi ve orta kızılötesi bantları); referans verisi olarak Kaliforniya için MTBS (Monitoring Trends in Burn Severity), Portekiz için ICNF (Portuguese Institute for Nature Conservation and Forests), Brezilya için Landsat-8, Mozambik için FireCCISFD11 ve Avustralya için TERN (Australia's Terrestrial Ecosystem Research Network) AusCover verilerinden yararlanmışlardır. Doğrulama verisi olarak VIIRS (Visible Infrared Imaging Radiometer Suite) aktif yangın verisini kullanmışlardır. Verileri 28 piksellik bindirmelerle 128x128 boyutlarında parçalara bölmüşlerdir. Veri artırımı işlemi uygulamışlardır. Kayıp fonksiyonu olarak ikili çapraz entropi ve optimizasyon için Adam algoritması kullanmışlardır. Maksimum öğrenme hızını 0.01, epok sayısını 8 olarak belirlemişlerdir. Çapraz doğrulama işlemi gerçekleştirmişlerdir. Sonuçta 0 ile 1 aralığında değişen değerlere sahip yanma olasılığını gösteren veriler elde

etmişlerdir. Daha sonra ikili (binary) çıktısının elde edilmesi için eşik (threshold) değerinden yararlanmışlardır. Bu değeri 0.5 olarak seçmişlerdir. Doğruluk metriklerinden genel doğruluk (overall accuracy) ve zar katsayısı (dice coefficient) değerlerini hesaplamışlardır.

Khryashchev ve Larionov (2020), ResNet34 ve U-Net yapıları ile U-ResNet34 yapısını geliştirmişlerdir. Planet veri seti ve Resurs-P uydusunun Resource veri setini kullanmışlardır. Görüntüleri aynı boyutlarda olacak şekilde ayarlamışlar ve normalize etmişlerdir. Görüntü ve maskesini bindirmeli olarak 256x256 boyutlarında parçalara bölmüşlerdir. Bu parçalar arasında nesne içeren görüntü parçalarının sayısının, herhangi bir nesne içermeyen görüntü parçalarının sayısına göre daha az olduğundan bahsetmişlerdir. Bunun ağ öğrenimini etkilemesinin önüne geçilebilmesi amacıyla görüntü kümelerinin seçimine müdahale edilerek 8 tane yangın içeren ve 8 tane yangın içermeyen görüntü parçalarının rastgele seçilmesi sağlamışlardır. En iyi sonuçları bu şekilde elde ettiklerini ifade etmişlerdir. Veri artırımı uygulamışlardır. Çalışmada kayıp fonksiyonu olarak ikili çapraz entropi ve zar kaybı değerlerinin toplamını, optimizasyon için Adam algoritması kullanmışlardır. Epok sayısını 100 olarak seçmişlerdir. Doğruluk metriklerinden kesinlik, duyarlılık, f1-skor, zar katsayısı ve IoU katsayısı değerlerini hesaplamışlardır. Resurs veri setindeki test sonuçlarının, Planet veri setindekinden daha iyi olduğunu, bununla birlikte bahsedilen yöntemin iki veri seti için de tatmin edici olduğunu belirtmişlerdir.

Knopp ve ark. (2020), CNN'ye dayalı bir derin öğrenme modeli uygulamışlardır. U-Net yapısı ve Sentinel-2 görüntülerinden yararlanmışlar, görüntüleri Sentinel-2 ESA (European Space Agency) Kopernik Açık Erişim sitesi (Copernicus Open Access Hub) üzerinden elde etmişlerdir. Uygulamada referans için kullandıkları veri setlerini CAL FIRE (California Department of Forestry & Fire Protection), ICNF ve DLR (German Aerospace Center) üzerinden almışlardır. Görüntüleri %10'luk bindirmeler ile 256x256 boyutlarında parçalara bölmüşlerdir. Verileri ön işleme tabi tutmuşlardır. Verilere veri artırımı uygulamışlardır. Kayıp fonksiyonu olarak ikili çapraz entropi ve optimizasyon için Adam algoritması kullanmışlardır. İlk öğrenme hızını 0.001 ve küme boyutunu 16 olarak seçmişlerdir. En düşük doğrulama kaybı (validation loss) değerine sahip olan modeli kaydetmişlerdir. Uygulama için Python'da TensorFlow arka ucuna sahip Keras kullanmışlardır. Sonuçta 0 ile 1 aralığında değişen değerlere sahip yanma olasılığını gösteren görüntü parçaları elde etmişlerdir. İkili çıktısının elde edilmesi için eşik değerinden yararlanmışlar, bu değeri 0.5 olarak seçmişlerdir. Sonuç görüntü parçalarını

orijinal görüntü boyutlarına getirmişlerdir. Uygulamada modelin değerlendirilmesi için doğruluk metriklerinden genel doğruluk, Cohen'in kappa katsayısı kesinlik, duyarlılık ve F1-skor değerlerini hesaplamışlardır. İyi sonuçlara ulaşıldığı ancak koyu su kütlesi kıyıların, tarımsal alanların ve volkanik kökenli kayaların mevcudiyetinde sınıflandırmalarda hatalar olabildiği ve ek olarak küçük yangın alanlarının belirlenmesinde de sorunlar olabildiğini belirtmişlerdir. Bu tarz sorun teşkil edebilecek bölgelerin tespiti için daha büyük bölgeler üzerinde testler yapılabileceğini tavsiye etmişlerdir. Ek modüller eklenerek sonuçların geliştirilebileceğini ve su kütleleri gibi yanmamış bölgeler barındıran kısımların maskelenerek yanlış sınıflandırma örneklerinin azaltılabileceğini ifade etmişlerdir. Ayrıca nihai yanmış alan maskesinin (burned area mask) belirlenmesinde bölge büyütme işleminin uygulanabileceğine değinmişlerdir. Bunlara ek olarak uygulamada kullanılan bölgede aktif bir yangının ve bulutların mevcut olmadığı ancak uzun süreli yangınlar için alınan görüntülerin dumanlar içerebilmesi sebebiyle yanmış alanların tespitinde zorluklar yaşanabileceğini belirtmişlerdir. Bu tarz durumlarda Landsat gibi farklı optik veri setlerinden ve/veya radar veri setleri ile yapılacak olan entegrasyonlardan yararlanılmasını tavsiye etmişlerdir. Bunların yanında ağda farklı bant kombinasyonları denendiğinde mavi, yeşil, kırmızı bant kombinasyonunun kullanıldığı durumda elde edilen sonuçların diğer kombinasyonlara göre daha kötü olduğuna değinmişlerdir. Bunun tespiti için önce veri artırımı yapılmamış (non-augmented) olan veri seti ile farklı bant kombinasyonlarında eğitim işlemlerini gerçekleştirmişlerdir. Kombinasyonlardaki performans değerlendirmeleri baz alınarak uygulamada asıl eğitim işlemi için mavi, yeşil, kırmızı, yakın kızılötesi ve kısa dalga kızılötesi bant kombinasyonunu kullanmışlar ve veri artırımı işlemi uygulamışlardır. Ek olarak sonuçları Rastgele Orman (Random Forest) algoritmasıyla karşılaştırmışlar, U-Net yapısının daha iyi metrikler sunduğunu ve daha hızlı olduğunu belirtmişlerdir. Ayrıca yangın öncesi ve yangın sonrası görüntülerin kullanılması yerine sadece yangın sonrasına dair görüntülerin kullanılmasının, verilerin ön işleme tabi tutulmamasının ve manuel olarak indirilmesine gerek olmamasının işlem süresini kısalttığına değinmişlerdir. Bununla birlikte Landsat ya da MODIS verisinin kullanılması yerine Sentinel-2 verisinin kullanılmasının çözünürlük anlamında olumlu bir etki yaptığını işaret etmişlerdir.

Farasin ve ark. (2020), yanmış alanların çıkarılmasında derin öğrenme ağlarından CNN'yi tercih etmişlerdir. U-Net ve CuMedVision adındaki iki yapıyı kullanmışlardır. Kopernik EMS (Emergency Management System) ve ESA'nın sağladığı Sentinel-2 verilerinden yararlanmışlardır. Sentinel-2 verileri kullanılarak BAI, NBR, NBR2 ve



BAIS2 indekslerini hesaplamışlardır. Referans verisinin çıkarımı için Kopernik EMS tarafından sağlanan haritalar kullanılarak ikili görüntüler oluşturmuşlardır. Bunun için Otsu eşikleme yöntemini (Otsu thresholding method, Otsu method) kullanmışlardır. Uygulama öncesinde verilere ön işleme uygulamışlardır. Bunun için normalizasyon ve veri artırımı gibi işlemler gerçekleştirmişlerdir. Kayıp fonksiyonu olarak ikili çapraz entropi ve optimizasyon için Adam algoritması kullanmışlardır. Küme boyutunu 8 olarak seçmişlerdir. Sonuçta oluşan olasılık haritasını 0.5 değeri ile eşikleme yaparak ikili maske (binary mask) haline getirdiklerini ifade etmişlerdir. Çapraz-değerlendirme yaklaşımı uygulamışlardır. Bu amaçla k-parça (k-fold) tekniğini tercih ederek veri setini  $k=7$  parçaya ayırmışlardır. Bunlardan ilk 6 tanesini eğitim için ve 7.sini değerlendirme için kullanmışlardır. Değerlendirmede doğruluk metriklerinden kesinlik, duyarlılık ve F1-skor değerlerini hesaplamışlardır. U-Net ve CuMedVision yöntemlerini karşılaştırmışlar ve U-Net'in daha iyi sonuçlar verdiğini belirtmişlerdir. Çalışmada hem görünür bölgeye ait bantların kullanılmasını hem de Sentinel-2'nin sunduğu bütün bantların kullanılmasını incelemişlerdir. Bantların tamamının kullanılmasının daha iyi sonuçlar verdiğini, modelin küçük yanmış alan bölgelerini belirlemede eksikliklerinin olduğunu, dağlık ve ekili alanlarda gölgelerin de var olması sebebiyle sınıflandırmada hatalar olabildiğini ifade etmişlerdir. Ek olarak Sentinel-2 Level-1C verisinde atmosferik etkiler olmasından dolayı sonuçların etkilenebileceğini, bu sebeple veriden gürültünün kaldırılması için işlem den geçirilmesinin ya da Sentinel-2 Level-2A verisinin kullanılmasının daha iyi sonuçlar verebileceğini belirtmişlerdir.

Lee ve ark. (2020), U-Net kullanarak yangından etkilenen alanların tespitini gerçekleştirmişlerdir. Çalışma bölgesi için açık kaynaklı olan AGDC sisteminden yararlanmışlardır. Avustralya'nın bazı bölgeleri ve bu bölgelerdeki 20 km'den daha fazla alana yayılan yangın alanlarını tercih etmişlerdir. Çalışma bölgesini görsel olarak FESM (Fire Extent and Severity Mapping) ve GEEBAM (Google Earth Engine Burnt Area Map) ile karşılaştırarak göstermişlerdir. Uygulama için Sentinel-1 ve Sentinel-2 verilerinden yararlanmışlardır. Etiketli görüntüler için Sentinel-2 verileriyle oluşturdukları NDWI, NBR, dNBR (Difference Normalized Burned Ratio) ve RBR spektral indekslerini kullanmışlardır. Atmosferik düzeltme yapmışlardır. Sentinel-1 aracılığıyla elde edilen ikili polarize edilmiş (VH/VV) C bant SAR (Sentetik Açıklıklı Radar) verileri ile haritalar oluşturmuşlar ve farklarını almışlardır. Bu haritaların oluşturulması için ESA'nın sağladığı SNAP Sentinel-1/-2 Toolbox yazılımını kullanmışlardır. Bu şekilde çeşitli işlemlerden geçen Sentinel-1 ve Sentinel-2 verilerini aynı konumsal çözünürlükte olacak

şekilde yeniden örneklemişler ve füzyon etmişlerdir. Girdi olarak Sentinel-1 aracılığıyla elde edilen tutarlılık fark haritalarını ve Sentinel-2 aracılığıyla elde edilen RBR indeksli görüntüleri kullanmışlardır. Uygulamada ilk başta önceden-eğitilmiş (pre-trained) bir ağ kullanmışlar, sonra hiper parametre seçimi (hyper parameter tuning) ve veri artırımı işlemi yapmışlardır. Uygulamada Python Tensorflow kütüphanesini kullanmışlardır. Girdi görüntü boyutlarını 256x256 olarak ve 3 bant şeklinde belirlemişlerdir. Toplamda oluşan 2058 tane görüntüden 1234 tanesini eğitim için, 412 tanesini doğrulama için ve kalan 412 tanesini de test için kullanmışlardır. Çıktı ürüne morfolojik kapatma işlemi uygulamışlardır. Optimizasyon için Adam algoritması kullanmışlar, epok sayısını 40 olarak belirlemişlerdir. Doğruluk metriklerinden F1-skoru değerini hesaplanmışlardır. Sonuçların tatmin edici olduğu ve optik veri mevcut olmadığında SAR verisinin yangından etkilenen alanları doğru bir şekilde gösterebildiğini belirtmişlerdir.

Mohla ve ark. (2020), Amazon Yağmur Ormanlarında yanık izlerinin belirlenmesine dair bir çalışma gerçekleştirmişlerdir. Bunun için AmazonNET adında evrişim tabanlı olan ve U-Net mimarisine dayanan bir ağ kullanmışlar ve Landsat-8 uydusunun mavi, kırmızı, yeşil ve yakın kızılötesi bantlarından yararlanmışlardır. Referans verisi olarak gürültü içeren, kısmen etiketlenmiş hatta bazı bölgelerde yanlış etiketlenmiş olan verileri tercih etmişlerdir. Böyle bir veri seti kullanılarak doğru yanmış alanları içeren bölgelerin seçilme durumu ve yanlış etiketlenmiş bölgelerin reddedilme durumunu incelemişlerdir. Uygulamada optimizasyon için Adam algoritması kullanmışlardır. Öğrenme hızını 0.0001 ve epok sayısını 50 olarak belirlemişlerdir. Küme boyutunu eğitim veri setleri için 8, doğrulama veri setleri için 4 olarak seçmişlerdir. Sonuç olarak referans verisinde etiketli olmayan yanık izlerinin ağ tarafından doğru etiketlediğini, yanlış etiketlenmiş bölgelerin ise ağ tarafından seçilmediğini belirtmişlerdir. Ancak verinin bulut, nehir, dolambaçlı yol gibi yerleri barındırması durumunda yanık izlerinin tespitinde hatalar olabildiğini ifade etmişlerdir.

Rashkovetsky (2020), yüksek lisans tez çalışmasında U-Net yapısını kullanmış, girdi verisi olarak Sentinel-1, Sentinel-2, Sentinel-3, Terra ve Aqua uydularından, referans verisi için FRAP (Fire and Resource Assessment Program) tarafından sağlanan CAL FIRE verisinden yararlanılmıştır. Sonuçların doğrulanmasında ise NASA tarafından sunulan FIRMS (The Fire Information for Resource Management System) verisi kullanılmıştır. Kayıp fonksiyonu olarak ikili çapraz entropi ile zar kaybı fonksiyonlarının bir tür kombinasyonunu ve optimizasyon için Adam algoritmasını tercih etmiştir. Öğrenme hızını 0.001 ve küme boyutlarını 8 olarak belirlemiştir. Doğruluk

metriklerinden IoU metriği, genel doğruluk, F1-skoru, Cohen'in kapa katsayısı, kesinlik ve duyarlılık hesaplamıştır. Uygulamada Python'da TensorFlow arka ucuna sahip Keras kullanmıştır. Sonuçta kullandığı kayıp fonksiyonunu ikili çapraz entropi fonksiyonu ile karşılaştırdığında, kullandığının daha yüksek duyarlılık ve F1-skoru değerine ulaştığını ancak daha düşük kesinlik değeri verdiğini belirtmiştir. Multispektral görüntü için farklı bant kombinasyonlarını denemiş, kırmızı, yeşil, mavi bant kombinasyonunun daha kötü sonuçlar verdiğini belirtmiştir. En yüksek F1-skoruna ulaşan modeli nihai model olarak seçmiştir.

Brand ve Manandhar (2021), Endonezya ve Orta Afrika için Sentinel-2 görüntüleri ile FIRMS üzerinden sağlanan ve yangın içeren bölgelerin işaretli olduğu bir MODIS verisi kullanmışlardır. Sentinel-2 verisine atmosferik düzeltme gibi bir takım ön işleme adımları uygulamışlardır. Bu ürünlerin alanında uzman kişiler tarafından manuel olarak sınıflandırıldığını ve bu şekilde maskeler oluşturulduğunu belirtmişlerdir. Orijinal görüntüleri ve maskeleri 256x256 boyutlarında parçalara bölmüşler ve bu parçalardan yanmış alan içermeyenleri kullanmamışlardır. Toplam 6656 veri elde etmişlerdir. Verileri eğitim, doğrulama ve test verileri olarak sırayla %60, %30 ve %10'luk oranlarda ayırmışlardır. U-Net'e dayanan CNN yapısı tercih etmişlerdir. Kayıp fonksiyonu olarak ikili çapraz entropi, aktivasyon fonksiyonu olarak ReLU ve optimizasyon için Adam algoritması kullanmışlardır. Öğrenme hızını 0.001, küme boyutunu 30 ve maksimum epok sayısını 100 olarak belirlemişlerdir. Doğruluk metriklerinden kesinlik, duyarlılık ve F1-skor değerlerini hesaplamışlardır. Uygulamada TensorFlow arka ucuna sahip Keras kullanmışlar ve uygulamayı Google Colab üzerinden gerçekleştirmişlerdir. Arazi örtüsü türlerindeki farklılığın performansı olumsuz etkileyebildiğini, özellikle ilgili bölgede kentsel alanlar ya da çıplak toprak örtüsü gibi yapılar olduğunda yanmış alanlara dair sınıflandırmalarda hatalar gözlemlendiğini belirtmişlerdir.

Hu ve ark. (2021), multispektral görüntüler kullanarak yanmış alanların derin öğrenme ile haritalanmasını gerçekleştirmişlerdir. Sentinel-2 ve Landsat-8 görüntülerini kullanmışlardır. Referans verisi için Kopernik EMS'den yararlanmışlardır. Görüntüleri 256x256 boyutlarında parçalara bölmüşlerdir. Görüntülere veri artırımı uygulamışlardır. Optimizasyon için Adam algoritması kullanmışlardır. İlk öğrenme hızını 0.000005 ve küme boyutunu 8 olarak belirlenmişlerdir. Farklı derin öğrenme metotlarını, makine öğrenmesi algoritmalarını ve eşikleme yöntemlerini karşılaştırmışlar; derin öğrenme modellerinin kabul edilebilir sonuçlara ulaşılabilirliğini belirtmişlerdir.

Pinto ve ark. (2021), 1500 hektarlık bir yangın için 10 m çözünürlükte yangın haritasının 5 dk içerisinde oluşturulabileceğini göstermişlerdir. Yanmış alanlara dair ürünler elde edilirken Pinko ve ark. (2020) tarafından oluşturulan BA-Net derin öğrenme modelini kullanmışlardır. Yangın öncesi ve sonrasına ait olan Sentinel-2 görüntülerini (kırmızı, yakın KÖ, kısa dalga KÖ bantları) tercih etmişleridir. Görüntü boyutlarını 512x512 olarak ayarlamışlardır. Uygulamada çeşitli ülkelerden altı farklı bölgeye ait verileri kullanmışlardır. Referans haritalarını CEMS üzerinden üretmişlerdir. Çalışmada, NBR indeksinden de yararlanmışlardır. U-Net gibi modellere kıyasla daha az parametreye sahip olan, daha hızlı çalışan ve daha az hafızaya ihtiyaç duyan model geliştirilerek gerçeğe yakın zamanlı yangın haritası oluşturduklarını belirtmişlerdir.

Rashkovetsky ve ark. (2021), farklı uydu görüntüleri ve füzyonları kullanarak hem bulutlu hem de bulutsuz verilerde yangın tespitinin gerçekleştirilmesini incelemişlerdir. Bunun için görünür, kızılötesi ve mikrodalga bölgelerine ait uydu görüntülerini ve U-Net yapısını kullanmışlardır. Veri seti için Sentinel-1, Sentinel 2, Sentinel-3, Terra ve Aqua uydularından, referans verisi için CAL FIRE verisinden yararlanmışlardır. Doğruluk metriklerinden Cohen'in kappa katsayısı, kesinlik, duyarlılık ve genel doğruluk hesaplamışlardır. Kullanılan verilerle yangın tespiti için derin öğrenmenin iyi bir potansiyelinin olduğunu, Sentinel-2 ile iyi sonuçlara varıldığını, Sentinel-2 ve Sentinel-3 verilerinin füzyonuyla daha da iyi sonuçlara ulaşıldığını belirtmişlerdir. Bulutsuz görüntülerde en iyi sonuçlara Sentinel-2 ve Sentinel-3 verileri ile ulaşıldığını, bulutlu verilerde ise Sentinel-1 ve Sentinel-2 verilerinin füzyonuyla daha iyi sonuçlar elde edildiğini ifade etmişlerdir.

Belenguer-Plomer ve ark. (2021), derin öğrenme ile yangın alanlarının haritalanmasında radar ve optik veri setlerinden yararlanmışlardır. Çalışma alanı olarak MGRS (Military Grid Reference System)'deki 10 adet veriyi kullanmışlardır. Bunlardan 5 tanesini eğitim verisi olarak, kalan 5 tanesini ise test verisi olarak tercih etmişlerdir. Radar verileri için Sentinel-1 A uydusundan, optik veriler için ise Sentinel-2 uydusundan ve yangın çevresi için referans verisi olarak Landsat-8 uydusundan yararlanmışlardır. Sentinel-1 ve Sentinel-2 verileri Kopernik açık erişim sistemi üzerinden, Landsat-8 verisini USGS (United States Geological Survey) üzerinden indirmişlerdir. Sentinel-1 ve Sentinel-2 verilerine ön işleme yapmışlardır. Yangın öncesi ve sonrasına dair veriler için NBR, NDWI, NDVI ve MIRBI spektral indekslerini hesaplamışlardır. YKÖ ve KDKÖ bantlarını, yangın öncesine ait NBR ve yangın öncesiyle sonrasının NBR farklarından oluşan dNBR verileri ile rastgele orman sınıflandırıcısını kullanmışlardır. Arazi örtüsü

için ESA'nın sunduğu orman, çalılık gibi çeşitli sınıfları barındıran 2015 yılına ait Land\_Cover\_cci verisini kullanmışlardır. NASA'nın sağladığı FIRMS üzerinden VIIRS ve MODIS verilerini indirmişlerdir. 2 tane gizli katmana sahip olan bir CNN modeli kullanmışlardır. Bu modelin kullanımının hesaplama süresinin kısalması açısından avantaj sağladığını belirtmişlerdir. Ayrıca bu modelin, daha derin modellere kıyasla haritalama doğruluğunu korumada neredeyse hiç kayıp vermediğinden bahsetmişlerdir.

Zhang ve ark. (2021), Sentinel-1 ve Sentinel-2 verilerini kullanarak derin öğrenme tabanlı yanmış alan haritalamasını gerçekleştirmişlerdir. SSA (Siamese Self-Attention) sınıflandırmasından yararlanmışlardır. Yangın öncesine ve sonrasına dair görüntüleri kullanmışlardır. Yanmış ve yanmamış alanların işaretlenmesinde PlanetScope verisine görüntüye uygulanan dNDVI (Normalize Edilmiş Bitki Örtüsü İndeksi Farkı - Difference Normalized Difference Vegetation Index) indekslerinin farkından yararlanmışlardır.

Huppertz ve ark. (2021), transfer öğrenme kullanarak mülteci yerleşimlerinin yerel yangın dinamikleri üzerindeki etkisinin nasıl olduğunun incelenmesini amaçlamışlardır. Bu amaçla çalışma alanı olarak Kuzey Uganda'nın Batı Nil bölgesini tercih etmişlerdir. Bölgeye ait neredeyse hiç referans verisinin olmaması sebebiyle eğitim işlemini Portekiz'in referans verisi kullanarak gerçekleştirmişler ve bu modeli daha sonrasında Batı Nil bölgesine uygulamışlardır. Uygulamada Sentinel-2 verisini kullanmışlardır. Yakın kızılötesi, yeşil ve kısa dalga kızılötesi bantlarını tercih ederek yalancı renkte (false color) görüntüler oluşturmuşlardır. Bu görüntüleri 128x128 boyutlarında parçalara bölmüşlerdir. Eğitim için küme boyutunu 16 olarak seçmişlerdir. Veri setinin %70'ini eğitim ve doğrulama için, %30'unu ise test için ayırmışlardır. Doğruluk metriklerinden IoU metriğini ve zar katsayısını hesaplamışlardır.

Knopp (2021), Sentinel-2 görüntüsü kullanılarak yanmış alan haritalamasını gerçekleştirmiştir. Bunun için U-Net yapısına dayanan CNN mimarisini kullanmıştır. Bütün bantlara çözünürlükleri 10 m olacak şekilde yeniden örnekleme işlemi uygulamış ve görüntüleri 256x256 boyutlarında parçalara bölmüştür. TensorFlow arka ucuna sahip Keras kullanmıştır. Kayıp fonksiyonu olarak ikili çapraz entropi; optimizasyon için Adam, AdaGrad ve RMSProp yöntemlerini tercih etmiştir. AdaGrad algoritmasının en iyi sonucu verdiğiinden bahsetmiştir. Ayrıca ağda farklı bant kombinasyonlarını denediğinde mavi, yeşil, kırmızı, yakın kızılötesi ve kısa dalga kızılötesi bant kombinasyonunun en iyi sonucu verdiğini belirtmiştir. Veri artırımı işleminin ağ performansını geliştirmeye yönelik katkı sağlamadığı ancak farklı atmosferik ve

geometrik koşullara karşı dayanıklılığı (robustness) artırdığını ifade etmiştir. Doğruluk metriklerinden genel doğruluk ve Cohen'in kappa katsayısı değerlerini hesaplamıştır. Sonuçların başarılı olduğunu ancak ağın; yanmamış olan yollar ve su yolları gibi dar alanları yanmış olarak belirttiğini, kayalık bölgelerin ve hasadı gerçekleşmiş olan tarlaların benzer spektral imzaya sahip olmaları kaynaklı karışıklıklar olduğunu ifade etmiştir.

Maskouni ve Seydi (2021), yangın öncesi ve sonrasına dair Sentinel-2 görüntülerinden yararlanarak İran'ın kuzeyindeki Golestan Ormanının yanmış alan haritasını çıkarmışlardır. Bunun için Snap yazılımındaki Sen2cor modülü kullanılarak Sentinel-2 verilerine ön işleme uygulamışlardır. Yangın öncesi ve sonrasına dair verileri CNN kullanılarak eğitim işlemine tabi tutmuşlardır. Kayıp fonksiyonu olarak ikili çapraz entropi ve optimizasyon için SGD (Stochastic Gradient Descent) algoritması kullanmışlardır. İlk öğrenme hızını 0.001 ve epok sayısını 500 olarak seçmişlerdir. Doğruluk metriklerinden genel doğruluk, kappa ve F1-skor değerlerini hesaplamışlardır. Yöntemlerinin sadece üç bant kullanımı ile çok iyi bir performans gösterdiğinden, diğer yöntemlere göre daha az konvolüsyon katmanı içerdiğinden, daha hızlı olduğundan ve makine öğrenmesi yöntemlerinin aksine derin özellikleri otomatik olarak çıkarabildiğinden bahsetmişlerdir.

Prabowo ve ark. (2022b), derin öğrenme ile yanmış alanların tespitinde kullanılması amacıyla yeni bir veri seti oluşturmuşlardır. Bu veri setinin Endonezya'ya ait yanmış alanları içerdiğini; U-Net gibi modellerde eğitim, test ve doğrulama için kullanımının uygun olduğunu ve yanmış alanların haritalanmasıyla ilgili olan çalışmalarda kullanılabileceğini belirtmişlerdir. Veri setinin oluşturulmasında 2019 ve 2021 yılları arasındaki 227 adet Landsat-8 uydu görüntülerinden yararlanmışlardır. Her bir görüntüyü 512x512 boyutlarında GeoTIFF formatında ve 8 bantlı olarak kaydetmişlerdir. Bu bantlardan ilk 7 tanesinin Landsat-8 bantları ile aynı olduğunu ancak 8. bandın Landsat-8'deki 9. banda karşılık geldiğini belirtmişlerdir. Yanmış alan maskelerinin CBS uzmanları tarafından Quantum CBS yazılımı kullanılarak oluşturulduğuna değinmişlerdir. Verilerin ön işlenmesi sürecini Python üzerinde GDAL kütüphanesi kullanarak gerçekleştirmişlerdir. Veri setini kırmızı, yakın kızılötesi, kısa dalga kızılötesi-2 bant kombinasyonunda kullanmışlardır. Veri setini U-Net kullanarak derin öğrenme uygulamasına tabi tutmuşlardır. Uygulamada girdi görüntülerine veri artırımı uygulamışlar ve girdi görüntü boyutlarını 512x512 olarak kullanmışlardır. Optimizasyon için Adam algoritması kullanmışlardır. Öğrenme hızını 0.0001 ve epok

sayısını 200 olarak seçmişlerdir. Doğruluk metriklerinden Jaccard indeksini hesaplamışlardır.

Tez çalışması kapsamında yapılan kaynak araştırmasına bakıldığında yangınların/yanmış alanların derin öğrenme yöntemleri ile tespitinin, özellikle son beş yılda sıklıkla tercih edilen güncel bir konu olduğu görülmektedir. Tezin devamında kaynak araştırması sonucunda yukarıdaki bilgileri özetleyen bazı çizelgeler oluşturulmuştur. Çizelge 2.1’de literatürde genellikle kullanılan uydu verileri ve kullanıldıkları kaynaklar özetlenmiştir. Çizelge 2.1 incelendiğinde Sentinel ve Landsat uydu verilerinin sıklıkla tercih edildiği görülmektedir.

**Çizelge 2.1.** Literatürde Kullanılan Uydu Verileri ve Kullanıldığı Kaynaklar

Uydu verisi	Kullanıldığı Kaynaklar
Sentinel	Rashkovetsky, 2020; Knopp ve ark., 2020; Farasin ve ark., 2020; Lee ve ark., 2020; Brand ve Manandhar, 2021; Hu ve ark., 2021; Pinto ve ark., 2021; Rashkovetsky ve ark., 2021; Belenguer-Plomer ve ark., 2021; Huppertz ve ark., 2021; Knopp, 2021; Maskouni ve Seydi, 2021; Zhang ve ark., 2021
Landsat	Park ve Lee, 2019; Pinto ve ark., 2020; Park, 2020; Hu ve ark., 2021; Prabowo ve ark., 2022; Mohla ve ark., 2020; Belenguer-Plomer ve ark., 2021, Prabowo ve ark., 2022b
Planet ve Resurs-P	Khryashchev ve Larionov, 2020
PlanetScope	Zhang ve ark., 2021
MODIS	Rashkovetsky, 2020; Rashkovetsky ve ark., 2021; Brand ve Manandhar, 2021; Belenguer-Plomer ve ark., 2021; Huppertz ve ark., 2021
VIIRS	Pinto ve ark., 2020; Pinto ve ark., 2021; Belenguer-Plomer ve ark., 2021

Çizelge 2.2’de literatürde genellikle kullanılan veriler ve kullanıldıkları kaynaklar özetlenmiştir. Çizelge 2.2 incelendiğinde CAL FIRE ve FIRMS verilerinin diğerlerinden daha fazla tercih edildiği görülmektedir.

**Çizelge 2.2.** Literatürde Kullanılan Veriler ve Kullanıldığı Kaynaklar

Veri	Kullanıldığı Kaynaklar
CAL FIRE	Rashkovetsky, 2020; Knopp ve ark., 2020; Rashkovetsky ve ark., 2021
FIRMS	Rashkovetsky, 2020; Brand ve Manandhar, 2021; Belenguer-Plomer ve ark., 2021
MTBS	Pinto ve ark., 2020
ICNF	Pinto ve ark., 2020; Knopp ve ark., 2020

**Çizelge 2.2.** Literatürde Kullanılan Veriler ve Kullanıldığı Kaynaklar (devamı)

DLR	Knopp ve ark., 2020
Kopernik EMS	Farasın ve ark., 2020
FireCCISFD11, TERN AusCover	Pinto ve ark., 2020
FESM	Lee ve ark., 2020
GEEBAM	Lee ve ark., 2020
Amazon Yağmur Ormanı	Mohla ve ark., 2020
Mendeley	Prabowo ve ark., 2022b

Çizelge 2.3'te literatürde genellikle kullanılan veri artırımı teknikleri ve kullanıldıkları kaynaklar özetlenmiştir. Çizelge 2.3 incelendiğinde döndürme tekniğinin diğerlerinden daha fazla tercih edildiği görülmektedir. Döndürme tekniğinden sonra daha fazla tercih edilen teknik parlaklık ve kontrast değişimleri olarak gözükmektedir.

**Çizelge 2.3.** Literatürde Kullanılan Veri Artırımı Teknikleri ve Kullanıldığı Kaynaklar

<b>Veri Artırımı Teknikleri</b>	<b>Kullanıldığı Kaynaklar</b>
Parlaklık (Brightness)	Pinto ve ark., 2020; Knopp ve ark., 2020; Hu ve ark., 2021
Kontrast (Contrast)	Pinto ve ark., 2020; Knopp ve ark., 2020; Hu ve ark., 2021
Renksel doygunluk (Saturation)	Hu ve ark., 2021
Silme (Erasing)	Pinto ve ark., 2020
Döndürme (Rotation)	Khryashchev ve Larionov, 2020; Knopp ve ark., 2020; Farasın ve ark., 2020; Hu ve ark., 2021; Prabowo ve ark., 2022b
Kaydırma (Shifting)	Khryashchev ve Larionov, 2020; Knopp ve ark., 2020
HSV renk distorsiyonu (Chromatic distortion in HSV)	Khryashchev ve Larionov, 2020
Ölçeklendirme (Scaling)	Knopp ve ark., 2020; Hu ve ark., 2021
Kırpma (Cropping)	Hu ve ark., 2021
Aynalama (Mirroring)	Khryashchev ve Larionov, 2020
Çevirme (Flipping)	Farasın ve ark., 2020; Hu ve ark., 2021

Çizelge 2.4'te literatürde genellikle kullanılan hiper parametre ayarları ve kullanıldıkları kaynaklar özetlenmiştir.



**Çizelge 2.4.** Literatürde Kullanılan Hiper Parametre Ayarları ve Kullanıldığı Kaynaklar

Mimari	Optimizasyon	Görüntü Boyutu	Öğrenme Hızı	Epok Sayısı	Kayıp (Yitim) Fonksiyonu	Kullanıldığı Kaynaklar
U-Net	Adam	96x96	0.0001	300 ve 500	İkili çapraz entropi	Park ve Lee, 2019
BA-Net	Adam	128x128	0.01	8	İkili çapraz entropi	Pinto ve ark., 2020
U-ResNet34	Adam	256x256	x*	100	İkili çapraz entropi ve zar kaybı	Khryashchev ve Larionov, 2020
U-Net	Adam	256x256	0.001	x*	İkili çapraz entropi	Knopp ve ark., 2020
U-Net ve CuMed Vision	x*	x*	x*	x*	İkili çapraz entropi	Farasin ve ark., 2020
x*	x*	256x256	x*	40	x*	Lee ve ark., 2020
x*	x*	x*	0.0001	50	x*	Mohla ve ark., 2020
x*	x*	x*	0.001	x*	İkili çapraz entropi ve zar kaybı	Rashkovetsky ve ark., 2020
U-Net	Adam	256x256	0.001	100	İkili çapraz entropi	Brand ve Manandhar, 2021
x*	x*	256x256	0.000005	x*	x*	Hu ve ark., 2021
x*	x*	512x512	x*	x*	x*	Pinto ve ark., 2021
Transfer Öğrenme	x*	128x128	x*	x*	x*	Huppertz ve ark., 2021
U-Net	Adam, AdaGrad ve RMSProp	256x256	x*	x*	İkili çapraz entropi	Knopp, 2021
CNN	SGD	x*	0.001	500	İkili çapraz entropi	Maskouni ve Seydi, 2021
U-Net	Adam	512x512	0.0001	200	x*	Prabowo ve ark., 2022b

\* İlgili kaynakta karşılığı anlaşılmayan sütunlar x ile gösterilerek boş bırakılmıştır.

### 3. MATERYAL VE YÖNTEM

#### 3.1. Uydu Görüntüleri

Uzaktan algılama yeryüzü ve yeryüzündeki kaynaklarla ilgili yapılacak olan incelemelerin onlarla herhangi bir fiziksel temas gerçekleştirilmeden incelenmesini ve kaydedilmesini sağlayan tekniğin adıdır. Uzaktan algılamada algılayıcı sistemler pasif ve aktif olarak ikiye ayrılır. Aktif algılayıcılar kendilerinde mevcut olan yapay enerji kaynaklarından ürettikleri sinyallerin hedefe gönderilmesi ve hedeften geri gelen enerjinin algılanması suretiyle çalışır. Pasif algılayıcılar ise yeryüzündeki cisimlerden yansıyan ya da yayılan enerjinin genellikle elektromanyetik spektrumunda ilgili kısımlara karşılık gelen çeşitli bantlara kaydedilmesi suretiyle çalışır (Seyrek, 2021). Görüntüde mevcut olan bantların sayısına göre görüntüler pankromatik, multispektral ve hiperspektral görüntüler olarak üç kısma ayrılabilir. Pankromatik görüntüler tek bir bant içeren görüntülerdir. Multispektral görüntüler genellikle üç ya da daha fazla banda sahip olan görüntülerdir. Hiperspektral görüntüler ise multispektral görüntülere göre çok daha fazla sayıda bant içeren görüntülerdir.

Pasif bir algılayıcı sistemi olan Landsat uydusunun 1972 yılında ilk kez uzaya fırlatılmasının ardından günümüze kadar çeşitli Landsat uyduları uzaya gönderilmeye devam etmiştir. Bunlardan sekizincisi olan Landsat-8 uydusu 2013 yılında uzaya gönderilmiştir. Landsat-8 uydusu üzerinde OLI (Operational Land Imager) ve TIRS (Thermal Infrared Sensor) adında iki sensör taşımaktadır. Bunlardan OLI sensörü 30 m konumsal çözünürlüğünde kıyı/aerosol, mavi, yeşil, kırmızı, yakın kızılötesi, kısa dalga kızılötesi-1, kısa dalga kızılötesi-2 ve sirrus bantlarına ve 15 m konumsal çözünürlüğünde pankromatik banda sahiptir. TIRS ise 100 m konumsal çözünürlüğünde uzun dalga kızılötesi-1 ve uzun dalga kızılötesi-2 bantlarını sunar. OLI-TIRS sensörleri ve elde ettikleri verilere dair bilgiler Çizelge 3.1'de gösterilmiştir (URL-3). Bu tez çalışması kapsamında kullanılan veri seti Landsat-8 uydusuna ait olan multispektral görüntülerden oluşmakta olup kıyı/aerosol, mavi, yeşil, kırmızı, yakın kızılötesi, kısa dalga kızılötesi-1, kısa dalga kızılötesi-2 ve sirrus bantlarını içermektedir. Pankromatik, uzun dalga kızılötesi-1 ve uzun dalga kızılötesi-2 bantları veri setinin içerisinde mevcut değildir.


**Çizelge 3.1.** Landsat-8 uydusuna ait bilgiler (URL-3)

Sensör	Bant İsimleri	Dalgaboyu ( $\mu\text{m}$ )	Çözünürlük (m)
OLI	Bant 1-Kıyı/ Aerosol	0.43 - 0.45	30
	Bant 2-Mavi	0.45 - 0.51	30
	Bant 3-Yeşil	0.53 - 0.59	30
	Bant 4-Kırmızı	0.64 - 0.67	30
	Bant 5-Yakın Kızılötesi	0.85 - 0.88	30
	Bant 6-Kısa Dalga Kızılötesi-1	1.57 - 1.65	30
	Bant 7-Kısa Dalga Kızılötesi-2	2.11 - 2.29	30
	Bant 8-Pankromatik	0.50 - 0.68	15
	Bant 9-Sirrus	1.36 - 1.38	30
TIRS	Bant 10-Uzun Dalga Kızılötesi-1	10.6 - 11.19	100
	Bant 11-Uzun Dalga Kızılötesi-2	11.50 - 12.51	100

### 3.2. Görüntü Segmentasyonu (Görüntü Bölütlemesi, Image Segmentation)

Segmentasyon bir görüntü içerisinde benzer spektral özelliklere sahip olan piksellerin gruplandırılması (Yiğit ve Uysal, 2019) ve farklı spektral özelliklere sahip bölgelerin birbirinden ayrıştırılması işlemidir (Doğan, 2008). Bir segmentasyon işleminden beklenen, belirli bir konuda ilgilenilen nesnelere mevcut görüntü üzerinden otomatik olarak tespit edilebilmesidir (Batz ve Schäpe, 2000). Segmentasyon sonucunda görüntü daha anlamlı bir hale gelmiş olur, görüntü analizinde kolaylık sağlanır ve varsa segmentasyondan sonra gerçekleştirilecek olan aşamaların daha hızlı olması mümkün hale gelir (Gurusamy ve ark., 2013; Sağlam ve Baykan, 2017). Sonuç ürün olarak maskeli görüntüler elde edilir.

Segmentasyon kısaca görüntünün anlamlı parçalara ayrılmasıdır (Çölkesen ve ark., 2015). Genel olarak iki tür segmentasyon tekniği vardır. Bunlardan biri semantik (semantic) segmentasyon, diğeri ise örnek (instance) segmentasyon olarak adlandırılır. Semantik segmentasyon görüntünün aynı nesne sınıfına ait olan parçalarının gruplandırılmasıdır (Thoma, 2016). Bu segmentasyonda her piksel ilgili nesne sınıfına göre etiketlenir. Örnek segmentasyon ise görüntünün aynı nesne sınıfına ait farklı nesnelere farklı olarak etiketlendirilmesidir (Hafiz ve Bhat, 2020). Şekil 3.1'de semantik segmentasyon ve örnek segmentasyonun farkı görsel olarak ifade edilmiştir.



**Şekil 3.1.** (a) Girdi görüntü, (b) semantik segmentasyon ve (c) örnek segmentasyon (Casado-García ve ark., 2019)

### 3.3. Veri Artırımı (Data Augmentation)

Veri artırımı ya da veri artırma, eğitim veri sayısının artmasını sağlayan tekniklere verilen genel isimdir. Bunun için veri setinde yer alan görüntülere çeşitli dönüşümler uygulanarak yeni görüntüler elde edilir. Dolayısıyla mevcut verinin çoğaltılması sağlanır. Genellikle eğitim verisinin çok az sayıda olduğu durumlarda tercih edilir.

Mevcut verilere veri artırımının uygulanması birtakım avantajları beraberinde getirir. Verilerin elde edilmesi ve etiketlenmesi için gereken maliyet ve zaman kaybının azaltılması, modele daha fazla eğitim verisinin eklenmesi veri artırımının sağladığı avantajlardır. Derin öğrenme uygulamalarında çok sayıda eğitim verisinin modele girdi olarak verilmesi gerektiği için, eldeki eğitim verisi sayısı çok az olduğunda veri artırımı yapılmasına ihtiyaç duyulur.

#### 3.3.1. Geometrik dönüşümler

Geometrik dönüşümler ile veri artırımı tekniklerinde veri artırımı uygulanan görüntülere dair piksel konumlarında değişiklikler meydana gelir (Kaur ve ark., 2021).

##### 3.3.1.1. Çevirme (Flipping)


Çevirme tekniği görüntünün dikey (vertical) veya yatay (horizontal) olarak çevrilmesidir (Khosla ve Saini, 2020). Yatay yöndeki çevirmelerin dikey yöndeki çevirmelere göre daha yaygın olduğu belirtilse de (Shorten ve Khoshgoftaar, 2019), çevirmenin yönü yapılan uygulamaya göre değişiklik gösterir. Görüntülere çevirme tekniğinin uygulanması sonucunda bir tür aynalama (mirroring) işlemi gerçekleştirilir (Kaur ve ark., 2021).



Şekil 3.2. (a) Orijinal görüntü ve (b) çevirme uygulanmış görüntü (Gu ve ark., 2019)

### 3.3.1.2. Döndürme (Rotation)

Döndürme tekniği görüntünün bir eksen üzerinde sağ veya sol yönde  $1^\circ$  ile  $359^\circ$  arasında döndürülmesi suretiyle yapılır (Shorten ve Khoshgoftaar, 2019).



Şekil 3.3. (a) Orijinal görüntü ve (b) döndürme uygulanmış görüntü (Gu ve ark., 2019)

### 3.3.1.3. Kırpma (Cropping)

Kırpma yöntemi görüntünün bir kısmının seçilmesi ve kalan kısmının çıkarılması suretiyle gerçekleştirilir. Kırpma sonucunda görüntüde ilgilenilen nesnelerin kaybedilmemiş olmasına dikkat edilmelidir (Kaur ve ark., 2021).



(a)



(b)

Şekil 3.4. (a) Orijinal görüntü ve (b) kırpma uygulanmış görüntü (Shijie ve ark., 2017)

### 3.3.1.4. Kaydırma (Shifting, translation)

Kaydırma tekniği görüntünün sağa, sola, yukarı ya da aşağı yönde kaydırılmasıdır (Shorten ve Khoshgoftaar, 2019)



(a)



(b)

Şekil 3.5. (a) Orijinal görüntü ve (b) kaydırma uygulanmış görüntü (Shijie ve ark., 2017)

### 3.3.1.5. Ölçeklendirme (Scaling)

Görüntünün boyutlarının belirli bir miktarda değiştirilmesidir. Görüntünün hem genişliği hem de yüksekliği değiştirilebilir (Kaur ve ark., 2021).



(a)

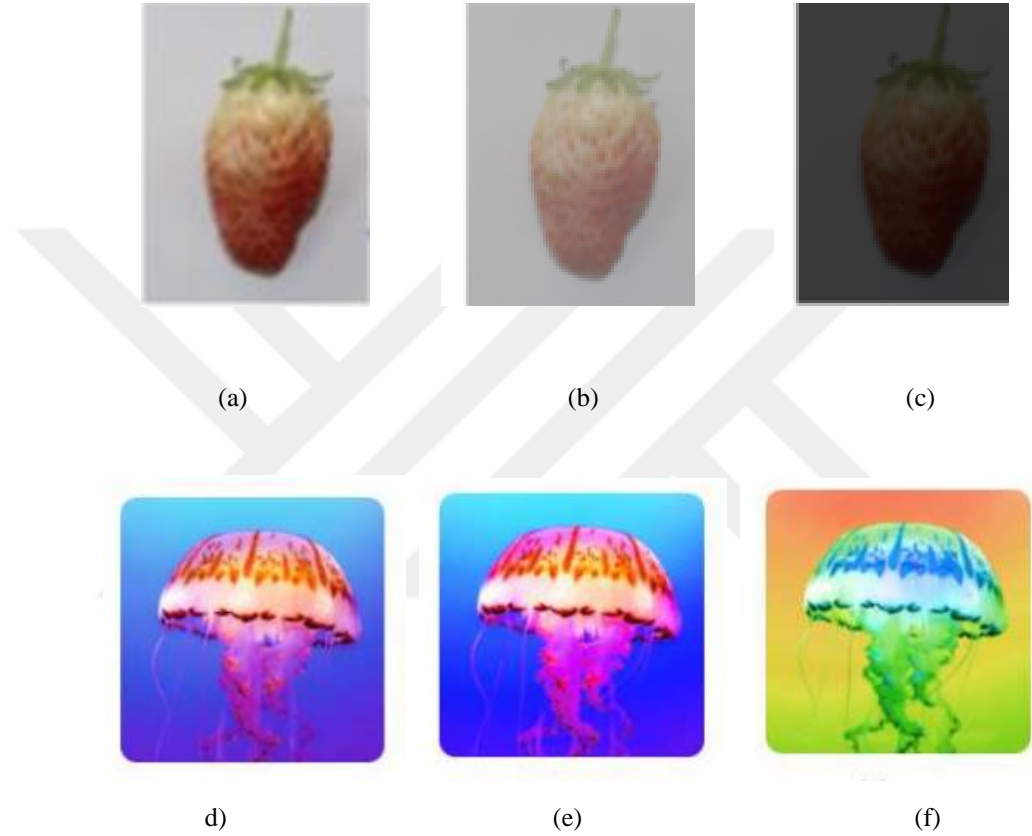


(b)

Şekil 3.6. (a) Orijinal görüntü ve (b) ölçeklendirme uygulanmış görüntü (Gu ve ark., 2019)

### 3.3.2. Renk uzayı dönüşümleri

Renk uzayı dönüşümleri ile veri artırımı tekniklerinde veri artırımı uygulanan görüntülere dair piksel değerleri değiştirilerek görüntülerin renk özelliklerinin değiştirilmesi sağlanır. Parlaklık, kontrast, RGB renk uzayının HSV gibi farklı bir renk uzayına değiştirilmesi teknikleri bu gruptadır.



**Şekil 3.7.** (a) Orijinal görüntü 1 ve bu görüntüde (b) parlaklık ve (c) kontrast ile oynanmış görüntüler (Ni ve ark., 2021) (d) orijinal görüntü 2 ve bu görüntüde (e) renksel doygunluk ve (f) ton ile oynanmış görüntüler (Kaur ve ark., 2021)

#### 3.3.2.1. Parlaklık (Brightness)

Parlaklık tekniği görüntüdeki piksel değerlerinin artırılarak daha aydınlık, daha parlak bir görüntüye ulaşılması veya görüntüdeki piksel değerlerinin azaltılarak daha koyu, daha sönük bir görüntüye ulaşılması suretiyle yapılır.

### 3.3.2.2. Kontrast (Contrast)

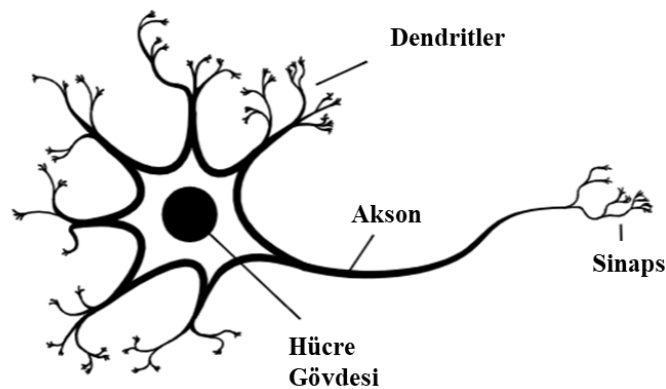
Kontrast tekniđi kontrastın artması veya azaltılması suretiyle gerekleřtirilir. Kontrast grntdeki aydınlık ve karanlık kısımların farkına karřılık gelir. Kontrastın artması grntnn parlak kısımlarının daha parlak, koyu kısımlarının ise daha koyu bir hale gelmesi demektir.

### 3.3.2.3. Renksel doygunluk ve ton (Saturation and hue)

Renksel doygunluk grntnn renklere ayrılmasıyla, ton ise grntdeki renklerin glgesiyle ilgilidir (Wagle ve ark., 2021).

## 3.4. Yapay Sinir Ađları (Artificial Neural Networks-ANN)

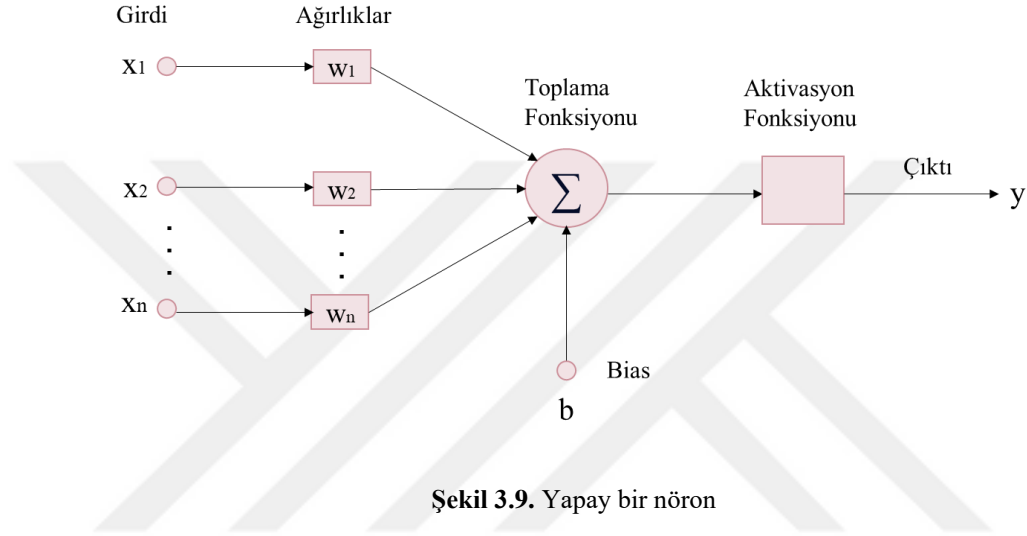
Yapay sinir ađları beyin iřleyiřinden esinlenerek geliřtirilmiřtir. Biyolojik sinir sisteminden yararlanılarak, beyindeki ve sinir sistemindeki elektriksel aktivitelerin taklit edilmesiyle oluřturulmuřtur (Walczak, 2019). Biyolojik sinir ađlarının temel zelliklerini ieren en basit nron modeli 1943 yılında McCulloch ve Pitts (1943) tarafından ortaya koyulmuřtur (Da Silva ve ark., 2017). Yapay sinir ađlarında nron, yapay sinir ađlarının bilgi iřleme elemanlarıdır. Yapay nron veya dđm olarak da adlandırılan nronlar yapay sinir ađlarının temel elemanlarına karřılık gelmektedir (Abraham, 2005).



řekil 3.8. Biyolojik bir nron (Kholkin ve ark. (2023)'den uyarlanmıřtır.)



Biyolojik bir nöron; Şekil 3.8’de gösterildiği üzere dendrit, hücre gövdesi (soma) ve aksondan oluşmakta olup dendritler aracılığıyla nörona girişi sağlanan verinin hücre gövdesinde işlendikten sonra akson aracılığıyla başka bir nörona iletimi gerçekleştirilmektedir (Krenker ve ark., 2011). Yapay nöronlar da tıpkı beyindeki sinaptik bağlantılar gibi diğer nöronlarla bağlantılıdır (Walczak, 2019). Yapay bir nöron Şekil 3.9’da gösterildiği gibi girdiler, ağırlıklar (weights), bias, aktivasyon fonksiyonu ve çıktılardan oluşur.



Yapay sinir ağları çarpma, toplama ve aktivasyon aşamalarını içerir. Yapay nöronun giriş kısmında, nörona gelen girdi verileri ilgili ağırlık ile çarpılır. Bu işlem ağırlıklandırma olarak ifade edilir. Yapay nöronun çekirdeğinde, bias değerinin ve giriş kısmında ağırlıklandırılmış olan verilerin toplaması gerçekleştirilir. Denklem 3.1’de gösterildiği gibi bu işlem için toplama fonksiyonu kullanılır.

$$Z = \sum_{i=1}^n x_i w_i + b = x_1 w_1 + x_2 w_2 + \dots + x_n w_n + b \quad (3.1)$$

Denklem 3.1 sonucunda elde edilen Z değerinin aktivasyon fonksiyonundan geçmesi sonucunda yapay nöronun çıkışı olan y değeri elde edilir.

### **3.4.1. Katmanlar**

Yapay sinir ağlarında üç temel katman türü bulunmaktadır. Bunlar:

- 1- Girdi katmanı
- 2- Gizli (Ara) katman(lar)
- 3- Çıktı katmanı

#### **3.4.1.1. Girdi katmanı**

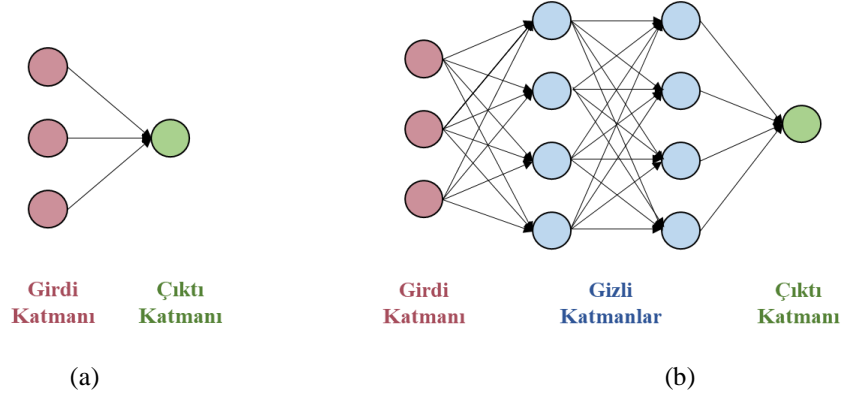
Veriler giriş parametresi olarak girdi katmanına sunulur (Önün, 2019). Ağa dışarıdan gelen veriler girdi katmanında bulundurulur. Bu katmandaki düğümlerin her biri veri setindeki ilgili özelliklere karşılık gelir. Girdi katmanındaki veriler, ağırlıklı kenarlar ile gizli katmanda bulunan düğümlere bağlanır.

#### **3.4.1.2. Gizli (Ara) katmanı(lar)**

Veriler girdi katmanından sonra gizli katman(lar)a gelir (Erhandı, 2020). Bu katman hesaplama zamanı, karmaşıklığı gibi faktörleri etkileyebilecek olan katmandır. Ara katmanın kaç adet olacağı uygulamada kullanılan modele göre değişiklik gösterebilir (Önün, 2019). Ara katmanda ağırlıklar kullanılarak işlenen veriler çıktı katmanına aktarılır.

#### **3.4.1.3. Çıktı katmanı**

Çıktı katmanı çıktı değer(ler)inin bulunduğu kısımdır. Ara katmandan gelen bilgilerin çıktı değer(ler)i bu katmanda oluşturulur. Bu katmandaki hata fonksiyonları, beklenen değerler ile hesap edilen değerler arasındaki farkın bulunmasını sağlar. Optimizasyon fonksiyonları ise hesaplanan hata değerinin dikkate alınarak her bir ağırlığın güncellenmesini sağlar. Böylece öğrenme gerçekleştirilmiş olunur (Erhandı, 2020).



Şekil 3.10. (a) Tek katmanlı sinir ağı ve (b) çok katmanlı sinir ağı örnekleri

Şekil 3.10’da tek katmanlı ve çok katmanlı ağlar gösterilmiştir. Bir yapay sinir ağı sadece girdi katmanı ve çıktı katmanından oluşuyorsa bu ağ tek katmanlı sinir ağı olarak adlandırılır. Eğer yapay sinir ağı bir adet girdi katmanı, bir veya birden fazla sayıda gizli katman ve bir adet çıktı katmanından oluşuyorsa bu ağ çok katmanlı sinir ağı olarak adlandırılır (Erhandı, 2020).

### 3.4.2. Eğitim, doğrulama ve test veri setleri

Bu tez çalışmasında, uygulamada kullanılan veri seti eğitim, doğrulama ve test aşamalarında kullanılmak üzere üç parçaya ayrılmıştır:

#### 3.4.2.1. Eğitim (train, training) veri seti

Eğitim veri seti öğrenme işlemi için gerekli olan yapıları barındırır (Mahesh, 2020). Eğitim veri seti kullanılarak girdiler ve çıktılar arasındaki ilişkiler belirlenmeye çalışılır (Sadeghi ve Askarinejad, 2012).

#### 3.4.2.2. Doğrulama (validation) veri seti

Doğrulama veri seti modelin genelleme performansının belirlenmesini (Gagné ve ark., 2006) ve model doğruluğunun değerlendirilmesini sağlar (Xu ve Goodacre, 2018). Eğitim işlemi yapılan modelin doğrulama veri seti ile doğrulaması gerçekleştirilir, böylelikle en uygun ve en doğru modelin belirlenmesi amaçlanır (Sadeghi ve Askarinejad, 2012).

### 3.4.2.3. Test veri seti

Test veri seti eğitim ve doğrulama veri setinin dışında kalan kısımdır. Eğitim işleminin ardından test işlemine tabi tutulan model, daha önceden görmediği test veri seti üzerinden tahmin işlemini gerçekleştirir. Böylelikle modelin performansının değerlendirilmesini sağlar (Murat, 2021).

### 3.4.3. Hiper parametreler

Sinir ağı uygulamalarında modelin tasarımı yapılırken hiper parametre seçimi yapılmalıdır. Hiper parametreler eğitim başlamadan önce kullanıcı tarafından değerleri belirlenen algoritmaya ait parametrelerdir. Farklı hiper parametre seçimlerine göre, farklı makine öğrenmesi modelleri oluşur. Bu yüzden uygun hiper parametre değerlerinin belirlenmesi önemlidir. Küme boyutu, öğrenme hızı, epok sayısı, aktivasyon fonksiyonu, kayıp fonksiyonu, düzenleme ve optimizasyon algoritması hiper parametrelere örnek olarak verilebilir.

#### 3.4.3.1. Küme boyutu (Batch size)

Küme boyutu her bir iterasyon için aynı anda kaç tane verinin işleneceğini belirten bir değerdir. Derin öğrenme uygulamalarında çok miktarda verinin bulunduğu veri setleri kullanılır. Bu veriler işlenirken verinin tamamının aynı anda işlenmesi yerine veri seti parçalara bölünür ve öğrenme işlemi bu küçük parçalar üzerinden gerçekleştirilir. Küme boyutu her bir parçada bulunacak olan veri miktarını tanımlayan değerdir. Seçilen bu değerinin eğitim kümesinde bulunan eleman sayısını geçmemesine ve GPU (Graphical Processing Unit - Grafik İşlemci Ünitesi) belleğine sığmasına dikkat edilmelidir (Uyar, 2022). Bu değer genellikle 2'nin kuvvetleri olacak şekilde seçilmelidir. Böylece GPU'nun mümkün oldukça fazla çekirdeğinin kullanılması sağlanır. Böylece daha başarılı sonuçlar elde edilebilir. Ancak küme boyutu ne kadar büyük seçilirse ihtiyaç duyulan hafıza alanı da o kadar fazla olur (Sivri, 2019). Derin öğrenme modelinde verinin parçalara bölünerek kullanılması tamamının kullanıldığı duruma göre donanım ve maliyet açısından avantajlıdır (Bayramoğlu, 2021).

### 3.4.3.2. Öğrenme hızı (Learning rate)

Öğrenme hızı veya diğer bir deyişle öğrenme oranı, ağıdaki parametrelerin güncellenme hızı olarak ifade edilir (Bayramoğlu, 2021). Öğrenme hızının ne olacağı kullanıcı tarafından deneme-yanılma yoluyla belirlenir (Yılmaz, 2020). Bu değer genellikle 0.1 ile 0.000001 arasında bir değer olarak seçilir (Saralioğlu, 2020). Sabit bir değer olarak seçilebileceği gibi artan ya da azalan değerler şeklinde de seçilebilir (Karademir, 2019). Öğrenme hızının küçük bir değer olarak seçilmesi durumunda eğitim süresi uzayabilir. Ayrıca çok küçük bir öğrenme hızı ağı aşırı öğrenmesi ile sonuçlanabilir. Bununla birlikte öğrenme hızının büyük bir değer olarak seçilmesi durumunda ise eğitim süresi kısalmış ancak ağı öğrenmesi gerçekleşmeyebilir (Yılmaz, 2020).


### 3.4.3.3. Epok (Epoch) sayısı

Epok sayısı derin öğrenme uygulamalarında kullanılan algoritmanın veri setinin tamamı üzerinde kaç kez çalışacağını belirten hiper parametredir. Epok sayısının kaç olarak belirleneceği uygulamaya göre farklılık gösterir. Epok sayısının düşük bir değer olarak seçilmesi durumunda öğrenememe söz konusu olabilmektedir. Büyük bir değer olarak seçilmesi durumunda ise doğruluk değerinin bir zaman sonra değişmemesi ya da değişimlerin çok küçük miktarlarda gerçekleşmesi durumuyla karşılaşılabilir. Bu tarz durumlarda Tensorflow kütüphanesi aracılığıyla erken durdurma (early stopping) işleminin gerçekleştirilmesi mümkündür. Bu sayede doğruluk değeri istenilen seviyeye geldiğinde eğitim işlemi otomatik olarak durdurulur (Saralioğlu, 2020; Bayramoğlu, 2021).

### 3.4.3.4. Aktivasyon fonksiyonu

Transfer fonksiyonları olarak da adlandırılan (Krenker ve ark., 2011) aktivasyon fonksiyonları, bir katmandaki nöronların çıktısı değerinin sonraki katmanlara iletilmesinde kullanılır (Gazel ve Bati, 2019). Bu fonksiyonlar bir önceki adımdan gelen bilginin bir sonraki adıma iletilip iletilmeyeceğinin kararını verir. Böylelikle ağı daha hızlı öğrenmesini sağlar (İnik ve Ülker, 2017; Bayramoğlu, 2021). Sigmoid ve ReLU fonksiyonları aktivasyon fonksiyonlarına örnektir.


**Sigmoid aktivasyon fonksiyonu:** “S” harfine benzemekte olan sigmoid aktivasyon fonksiyonunun çıktı değerleri  $[0, 1]$  aralığındadır (Namin ve ark., 2009). Bu fonksiyon sınıflandırıcı olarak kullanılabilir (Ağgöl, 2021). Şekil 3.11’de sigmoid aktivasyon fonksiyonu gösterilmiştir. Şekil 3.11 incelendiğinde x eksenindeki küçük bir değişimin y ekseninde büyük bir değişime karşılık geldiği görülmektedir (Ağgöl, 2021). Bu fonksiyonun matematiksel karşılığı denklem 3.2’de verilmiştir.



Şekil 3.11. Sigmoid aktivasyon fonksiyonu (Jin ve Niu, 2021)

$$g(x) = \frac{1}{1 + e^{(-x)}} \quad (3.2)$$

**ReLU aktivasyon fonksiyonu:** ReLU ifadesi İngilizce Rectified Linear Unit (Doğrultulmuş Doğrusal Birim) ifadesinin ilk harflerinden oluşmaktadır. ReLU fonksiyonunun girdi verisindeki negatif değerleri sıfıra dönüştürmek gibi bir etkisi vardır. Bu durum ReLU’nun sigmoid fonksiyonuna göre daha hızlı çalışmasını sağlar (Demirtaş, 2018). Şekil 3.12’de ReLU aktivasyon fonksiyonu gösterilmiştir. Şekil 3.12 incelendiğinde girdilerin negatif olması durumunda sıfır değerini aldığı ve pozitif x değeri olması durumunda x değerini aldığı görülmektedir. ReLU’nun çıktı değerleri  $[0, +\infty]$  aralığındadır (Ağgöl, 2021). ReLU aktivasyon fonksiyonunun matematiksel karşılığı denklem 3.3’te verilmiştir.



Şekil 3.12. ReLU aktivasyon fonksiyonu (Jin ve Niu, 2021)

$$g(x) = \max(0, x) = \begin{cases} x & \text{if } x \geq 0 \\ 0 & \text{if } x < 0 \end{cases} \quad (3.3)$$

#### 3.4.3.5. Kayıp fonksiyonu (Loss function)

Hata (error) fonksiyonları ya da maliyet (cost) fonksiyonları olarak da adlandırılan (Seyyarer ve ark., 2020) kayıp fonksiyonları sinir ağı uygulamalarında ağın son katmanlarında yer alır (Demirezen ve ark., 2021). Tahmin edilen değer gerçek değere göre değerlendirilmesini ve bunun sonucunda model hatasının gösterilmesini sağlar. Tahmin işlemi gerçekleştirildikten sonra bu tahminin doğruluğu kayıp fonksiyonları aracılığıyla tespit edilir. Kayıp fonksiyonları, tahmin edilen değer gerçek değere olan uzaklığını hesaplar. Böylece modelin hatasını görmesi sağlanır ve optimizasyon yapılarak daha iyi sonuçlar elde edilmeye çalışılır. Amaç model hatasının gösterilmesi ve kayıp değerinin sifıra yakın olmasıdır (Mete, 2019). Kayıp değerinin 0'a eşit olması ise ideal durumdur. İdeal durumda tahmin edilen değer ile gerçek değer arasında herhangi bir sapma yoktur (Yavuz, 2021).

**İkili çapraz entropi (Binary cross entropy):** İkili çapraz entropi kayıp fonksiyonu, ikili sınıflandırma problemlerinde kullanılır. Yani sınıflandırma işleminin iki adet sınıf arasında gerçekleştirileceği durumlarda tercih edilir. Bu durumda çıktı ürün sadece 0 ve 1 değerlerinden oluşur (Göksu, 2022).

$$K = -\frac{1}{N} \sum_{i=0}^N y_i * \log(p_i) + (1 - y_i) * \log(1 - p_i) \quad (3.4)$$

Denklem 3.4'te ikili çapraz entropinin matematiksel karşılığı gösterilmiştir. Burada  $K$  kayıp fonksiyonu değerine,  $N$  veri setindeki toplam veri sayısına,  $y_i$  veri setindeki  $i$ . verinin etiket değerine,  $p_i$  ise veri setindeki  $i$ . veriye dair elde edilen sonuç değerine karşılık gelmektedir (Demirezen ve ark., 2021). Diğer bir deyişle  $p_i$   $i$ . verinin bir sınıfa ait olma olasılığını,  $(1-p_i)$  ise bir diğer sınıfa ait olma olasılığını ifade eder. İlgili veri hangi sınıfa ait ise denklemde o sınıfın karşılığı olan kısım aktif halde olur ve denklemin diğer sınıfa karşılık gelen kısmı sıfırlanır. Böylelikle ikili çapraz entropi hesabı yapılmış olunur (Göksu, 2022).

#### 3.4.3.6. Düzenleştirme (Regularization)

Düzenleştirme sinir ağı modelinin aşırı öğrenme yapmasının önüne geçmek için kullanılan tekniktir (Patterson ve Gibson, 2017). Düzenleştirme yöntemleri ağdaki düğümlerin bazılarının kaldırılması esasına dayanırlar (Sarıyıldız, 2021). Bu sayede aşırı öğrenmenin önüne geçilmesi amaçlanır. Örnek olarak seyreltme (dropout) yöntemi bu amacı karşılayan yöntemlerdendir.

**Seyreltme Yöntemi:** Seyreltme yöntemi her bir nöronun seçilip seçilmeyeceğine karar verir. Bu sayede nöronların bazıları sürece dahi edilirken bazıları dahil edilmez. Böylelikle ağın aşırı öğrenmesinin önüne geçilmesi amaçlanır (Srivastava ve ark., 2014).

#### 3.4.3.7. Optimizasyon (En iyileme)

Optimizasyon, belirli amaçları (maliyetin azaltılması vb.) gerçekleştirebilmek için mevcut kaynakların (zaman, ekipman vb.) en verimli şekilde kullanılmasıdır (Saralioğlu, 2020). Derin öğrenme aslında bir optimizasyon işlemidir (Lee ve You, 2019). Öğrenmenin iyi bir şekilde gerçekleştirilebilmesi için kayıp fonksiyonunun mutlak minimum değerinin elde edilmesine ihtiyaç duyulur. Mutlak minimumun elde edilmesi ise optimizasyon algoritmaları ile sağlanır. Optimizasyon algoritmaları, ağdaki hata değerinin (üretilen çıktı değeri ile gerçek değer arasındaki fark) en küçük yapılması amacıyla kullanılan yöntemlerdir (Gazel ve Bati, 2019).

AdaGrad (Adaptive Gradient), Adam (Adaptive Moment Estimation) ve AdaMax (Maximum Adaptive Moment Estimation) derin öğrenme uygulamalarında tercih edilen optimizasyon algoritmalarındandır. Öğrenme hızının ayarlanması eğitim sürecinde



önemli bir rol oynadığından ve bunun her algoritma ile tam olarak ayarlanması mümkün olmadığından optimizasyonda çeşitli algoritmalarına ihtiyaç duyulmuştur (Gazel ve Bati, 2019). Hangi optimizasyon algoritmasının kullanılacağı uygulamalara göre değişmekle birlikte yangınlar/yanmış alanların tespiti ile ilgili yapılan çalışmalarda genellikle Adam algoritmasının tercih edildiği görülmüştür (Park ve Lee, 2019; Pinto ve ark., 2020; Khryashchev ve Larionov, 2020; Knopp ve ark., 2020; Farasin ve ark., 2020; Brand ve Manandhar, 2021; Prabowo ve ark., 2022).

**AdaGrad (Adaptive gradient - Uyarlanabilir gradyan):** AdaGrad optimizasyon algoritması 2011 yılında Duchi ve ark. (2011) tarafından ortaya koyulmuştur. Her bir parametre için her bir adımda farklı öğrenme oranları kullanılır, dolayısıyla her parametrenin kendi öğrenme hızı vardır. Böylece her bir parametre için farklı güncellemeler yapılır. Bu durum öğrenme hızının manuel bir şekilde ayarlanmasına duyulan ihtiyacı ortadan kaldırır (Gazel ve Bati, 2019).

**Adam (Adaptive moment estimation - Uyarlanabilir momentum tahmini):** Adam optimizasyon algoritması 2014 yılında Kingma ve Ba (2014) tarafından ortaya koyulmuştur. Öğrenme hızının her iterasyonda güncellenmesini sağlar (Ünlü, 2019). Uygulamaşının basit olması, hesaplama açısından verimli olması ve fazla bellek gerektirmemesi (Yaşub ve ark., 2020) gibi avantajları vardır.

**AdaMax (Maximum adaptive moment estimation – Maksimum uyarlanabilir momentum tahmini):** AdaMax algoritması 2014 yılında Kingma ve Ba (2014) tarafından ortaya koyulmuştur. Adam optimizasyon algoritmasının genişletilmiş halidir (Soydaner, 2020).

### 3.5. Derin Öğrenme (Deep Learning)

Derin öğrenme verilerin temsilleri üzerinden öğrenilmesine dayanır. Örnek olarak görüntü verisinin temsili, piksele karşılık gelen yoğunluk değerlerinden oluşan bir vektör olarak ele alınabilir (Şeker ve ark., 2017).

Kökeni yapay sinir ağlarına dayanan (Cengil ve Çınar, 2016) derin öğrenme, yapay sinir ağlarının ikiden daha fazla sayıda katmana sahip olması fikriyle şekillenmiştir (Akca, 2020). “Derin öğrenme” ifadesi ilk kez 1986 yılında Rina Dechter tarafından

ortaya atılmıştır (Dechter, 1986). Burada kullanılan “derin” ifadesi, ağda mevcut olan katmanların sayısına karşılık gelmektedir. Katman sayısının çokluğu ağın derinliğiyle doğru orantılıdır (Metlek ve Çetiner, 2021). Derin öğrenme ve yapay sinir ağı kavramları genel olarak benzerlik göstermekle birlikte, derin öğrenme yapay sinir ağlarının daha karmaşık bir halidir. Derin öğrenme çok sayıda gizli katmana sahip olması (Sarıyıldız, 2021) ve çok sayıda veri kullanılması (Erhandı, 2020) gibi nedenlerden dolayı yapay sinir ağlarından farklılık gösterir.

Mevcut donanımların kısıtlı olması sebebiyle 80’li yıllarda kullanım imkanı bulamayan derin öğrenme yaklaşımı (Cengil ve Çınar, 2016) 2006 yılında Hinton ve ark. tarafından ele alınmıştır (Hinton ve ark., 2006). Teknoloji, donanım ve yazılım alanlarındaki gelişmelerle birlikte derin öğrenme algoritmaları özellikle 2000’li yıllardan itibaren halen kullanılmaktadır (Şeker ve ark., 2017). Bilgisayarla görme, sınıflandırma, nesne tespiti, ses verilerinin işlenmesi, endüstriyel ve medikal alanlar derin öğrenmenin geçmişten günümüze kadar kullanılmakta olduğu alanlardan bazılarıdır (Doğan ve Türkoğlu, 2019).

### **3.5.1. Avantajları ve dezavantajları**

Derin öğrenmenin kullanımı çeşitli avantajlar ve dezavantajları beraberinde getirmektedir. Büyük ve karmaşık veri setlerini ele alabilmesi, veriler üzerinden özellik (features) öğrenimini otomatik olarak gerçekleştirebilmesi, doğrusal olmayan problemlerin üstesinden gelebilmesi, geleceğe yönelik tahminler yapabilmesi, genelleme yapabilmesi ve GPU kullanımları ile büyük hesaplamaları yapabilmesi derin öğrenmenin sağladığı avantajlardandır.

Aşırı öğrenmenin meydana gelmesi, veri kalitesinin (gürültülü vb.) sonuçları etkilemesi, çok miktarda veriye ihtiyaç duyması ancak bunun her zaman mümkün olmaması, mevcut problemi analiz edebilecek uzmanların az sayıda olması, parametre seçimlerinde belirli bir standardının olmaması ve pahalı GPU’lar ile pahalı makinelere ihtiyaç duyması (Goodfellow ve ark., 2016) derin öğrenmenin dezavantajlarından.

### **3.5.2. Kütüphaneler**

Derin öğrenme için oluşturulmuş olan çeşitli kütüphaneler mevcuttur. Bu kütüphanelerden ihtiyaca uygun olanlar seçilerek kullanılır. Kütüphaneler sayesinde hazır


fonksiyonların kullanılması sağlanarak programlamayı yapan kişinin iş yükü azaltılır (Kutlu, 2019). Böylece eğitim süresinin kısaltılması, uygulamanın geliştirilmesine daha fazla zaman ayrılması gibi avantajlar sağlanır (Yiğit, 2017). Tensorflow, Keras, Digits ve Caffe derin öğrenmede kullanılan kütüphanelerden bazılarıdır.

### 3.5.2.1. Tensorflow

Tensorflow Google firması tarafından ortaya koyulan bir derin öğrenme kütüphanesidir. İlk başlarda Google bünyesinde kullanılmış olsa da ilerleyen zamanlarda diğer alanlarda da kullanım imkanı sağlanmıştır (Erhandı, 2020). Açık kaynak kodludur. CPU (Central Process Unit - Merkezî İşlem Birimi) ve GPU ile kullanıma imkan sağlamakla birlikte GPU kullanımını için NVIDIA markalı bir grafik kartına ihtiyaç duyar (Karademir, 2019). Tensorflow verilerin tensor adı verilen nesnelere tutulmasını sağlar. Tensor yapısı çok boyutlu verileri tutabilmektedir (Erhandı, 2020).

### 3.5.2.2. Keras

Keras, François Chollet tarafından ortaya koyulan bir derin öğrenme kütüphanesidir. CPU ve GPU üzerinden çalışma imkanı sağlar. TensorFlow ya da Theano gibi kütüphanelerin üzerinde çalışması mümkündür. Şekil 3.13'te Keras'a ait işlev yapı verilmiştir (Yiğit, 2017).



Şekil 3.13. Keras'ın işlev yapısı (Yiğit, 2017)

Keras kütüphanesi modelin eğitimi ve çalıştırılması sırasında ihtiyaç duyulan komutların gerçekleştirilmesini sağlar. Evrişimli ağ yapılarında, tekrarlayan ağ yapılarında ya da bu iki ağ yapısının birleşimiyle oluşturulan ağ yapılarında kullanımında, kolay ve hızlı kullanım arayışında, CPU ve GPU üzerinde çalışma imkanı istğinde Keras kütüphanesinin kullanımı tavsiye edilmektedir (Erhandı, 2020).

### 3.5.2.3. Digits

Digits, NVIDIA firması tarafından ortaya koyulan bir derin öğrenme kütüphanesidir ve Derin Öğrenme GPU Eğitim Sistemi (Deep Learning GPU Training System) anlamına gelir. Çoklu GPU sistemlerini kullanabilme imkanı sağlar (Erhandı, 2020).

### 3.5.2.4. Caffe

Caffe, Berkley üniversitesi tarafından ortaya koyulan bir derin öğrenme kütüphanesidir. Özellik Çıkarımı için Evrişimsel Mimari (Convolution Architecture for Feature Extraction) anlamına gelir. Açık kaynak kodludur ve GPU kullanımına imkan sağlar (Doğan ve Türkoğlu, 2019).

### 3.5.3. Veri Setleri

Derin öğrenme uygulamalarında çeşitli veri setleri kullanılmaktadır. Bu veri setleri kullanıcılar tarafından sıfırdan oluşturulabileceği gibi, kullanıcılar daha önceden başka kullanıcıların oluşturup paylaştığı hazır veri setlerini de kullanmayı tercih edebilirler.

Segmentasyon işlemi veya nesne/alan tespiti amacıyla oluşturulan veri setlerinin içerisinde görüntülerle birlikte görüntülere ait maskelerin de bulundurulması gerekir. Maske görüntülerin oluşturulması sürecinde karmaşık bilgilere ihtiyaç duyulmasından ve sürecin zahmetli olmasından dolayı maske görüntüler için ehli olan kişiler tarafından oluşturulmalıdır (Saralıoğlu, 2022). ImageNet (Deng ve ark., 2009), Open Images (Kuznetsova ve ark., 2020) ve Microsoft COCO (Lin ve ark., 2014) derin öğrenme uygulamalarında tercih edilen veri setlerinden bazılarıdır.

## 3.6. Evrişimsel Sinir Ağları (Convolutional Neural Networks – CNN)

Çok katmanlı bir yapay sinir ağı türü olan evrişimsel sinir ağları, derin öğrenme mimarilerinden biridir. Görme mantığı ele alınarak tasarlanan bu mimari evrişimli sinir ağları ya da konvolüsyonel sinir ağları olarak da adlandırılır.

**LeNet:** LeCun ve ark. (1998) tarafından ortaya koyulan LeNet, evrişimsel sinir ağlarının ilki olarak bilinir. Bu model el yazısı ile yazılmış 0-9 arasındaki sayıların sınıflandırılmasını sağlamıştır. Banka çeklerinin, posta kodlarının, dijital verisinin vb. okunmasında kullanılır.

**AlexNet:** Krizhevsky ve ark. (2012) tarafından ortaya koyulan AlexNet, 2012 yılında düzenlenen ImageNet Büyük Ölçekli Görsel Tanıma Yarışması (ImageNet Large Scale Visual Recognition Challenge - ILSVRC) sonucunda birinci olmuştur. Eğitim, GPU grafik işlemcileri kullanılarak gerçekleştirilmiştir.

**VGGNet:** Simonyan ve Zisserman (2014) tarafından ortaya koyulan VGGNet, 2014 yılında düzenlenen ILSVRC sonucunda ikinci olmuştur. Hata oranı %11,7'dir. 6 farklı modeli mevcuttur. VGG-16 ve VGG-19 bu modellerden bazılarıdır. VGGNet modeli AlexNet ile karşılaştırıldığında daha fazla evrişim katmanına sahiptir.

**GoogleNet:** Szegedy ve ark. (2015) tarafından ortaya koyulan GoogleNet, 2014 yılında düzenlenen ILSVRC sonucunda birinci olmuştur. Hata oranı %6,7'dir. Inception olarak da adlandırılır.

**ResNet:** ResNet 2015 yılında düzenlenen ILSVRC sonucunda birinci olmuştur. Hata oranı %3,7'dir. Artık (residual) olarak adlandırılan bir yapının kullanılmasıyla daha derin modellerin oluşturulması sağlanmıştır. ResNet modellerinden olan ResNet18, ResNet50 ve ResNet101 modelleri sırasıyla 18, 50 ve 101 katman derinliğindedir (Doğan, 2021).

Evrişimsel sinir ağı ve dolayısıyla klasik bir derin öğrenme mimarisi; giriş katmanı, evrişim (konvolüsyon) katmanı, aktivasyon katmanı, havuzlama katmanı, seyreltme katmanı, tam bağlantı katmanı ve sınıflandırma katmanından oluşur. Bu katmanların her birinin ayrı bir işlevi vardır (Metlek ve Çetiner, 2021). Ayrıca evrişimsel sinir ağlarının ilk katmanında düşük seviyedeki özellikler öğrenilir. Bununla birlikte ilerleyen katmanlara gidildikçe daha yüksek seviyedeki özelliklerin öğrenilmesi gerçekleştirilir (Karademir, 2019). Evrişimsel sinir ağlarının diğer sinir ağlarından farkı,

evrişimsel sinir ağlarındaki katmanların her biriminde en az bir adet evrişimsel filtrenin bulunmasıdır (Yılmaz, 2020).

Şekil 3.14’te klasik bir derin öğrenme mimarisi gösterilmektedir. Burada girdi olarak verilen görüntünün bir köpeğe mi yoksa bir kediye mi ait olduğunun belirlenmesine dair bir örnek gösterilmektedir. Ağa girdi katmanından gönderilen girdi görüntüsü sınıflandırma katmanı sonucunda köpek olarak ifade edilmektedir.



Şekil 3.14. Klasik derin öğrenme mimarisi (Metlek ve Çetiner (2021)’den uyarlanmıştır)

### 3.6.1. Katmanlar

#### 3.6.1.1. Giriş katmanı

Giriş katmanı, evrişimsel sinir ağının ilk katmanıdır. Girdi verisi ağ bu katmandan yüklenir. Verilerin boyutlandırılması daha önceden yapılmamışsa ve ağın girişi için boyuta dair uyulması gereken bir kural varsa boyutlandırma işlemi bu katmanda yapılır (Metlek ve Çetiner, 2021). Giriş katmanındaki görüntü boyutunun yüksek seçilmesi halinde eğitim süresinin uzaması, ihtiyaç duyulan bellek miktarının artması gibi durumlarla karşılaşılabilir. Görüntü boyutunun düşük seçilmesi ise eğitim süresi ve ihtiyaç duyulan bellek miktarını azaltmakla birlikte elde edilen sonuçlardaki başarıyı düşürebilir. Bu sebeplerden dolayı uygulamaya uygun bir görüntü boyutu seçilmelidir.

#### 3.6.1.2. Evrişim (Konvolüsyon) katmanı (Convolutional layer)

Evrişim katmanı, önceki katmandan gelen verinin özelliklerinin çıkarıldığı katmandır. Özellik çıkarımını gerçekleştirmek için gelen veriye filtreleme işlemi uygulanır. Kullanılan filtre ve filtrenin boyutu, uygulamada elde edilmesi istenen özelliğe göre değişiklik gösterebilir. Örneğin kenar çıkarımının istendiği bir uygulama için


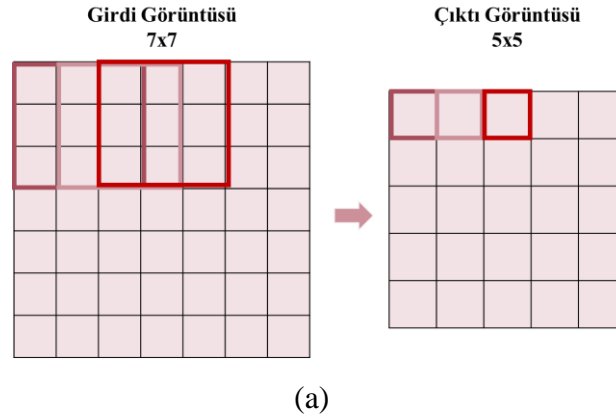
evrişim katmanında kullanılacak olan filtre kenar algılayan bir filtre olur. Kullanılacak olan filtre, veri boyutundan küçük olacak şekilde 3x3, 5x5 gibi çeşitli boyutlarda tercih edilebilir. Ancak büyük boyutlu bir filtrenin seçimi verideki birtakım özelliklerin kaybolmasına sebep olabilir. Filtreleme işlemi, verinin sol üst köşesinden başlayarak uygulanır. Filtre veri üzerinde ilk konumundan itibaren yatay ve dikey hareketler eşliğinde dolaştırılır ve tüm veri taranana kadar kaydırma işlemi devam eder. Filtrenin her bir konumunda evrişim işlemi gerçekleştirilir. Bunun için filtredeki değerler ile filtrenin bulunduğu konumdaki veriye ait değerler birbiri ile çarpılır. Çarpım sonuçları toplanarak çıktı değeri elde edilir (Daşkin ve ark., 2018; Metlek ve Çetiner, 2021; Sarıyıldız, 2021). Tüm işlemler bittiğinde oluşan çıktı; özellik haritası, aktivasyon haritası ya da öznitelik haritası gibi adlandırmalara sahiptir. Bu haritaların boyutu girdi katmanının boyutundan küçüktür (Daşkin ve ark., 2018). Şekil 3.15'te evrişim işlemine bir örnek gösterilmiştir.



Şekil 3.15. Evrişim işlemi

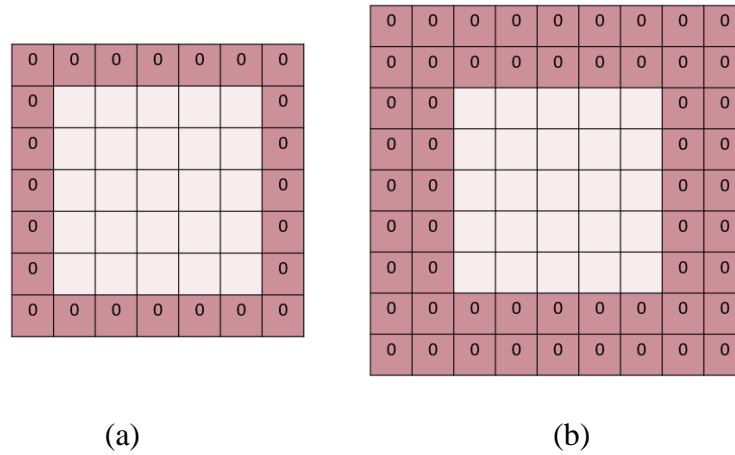
Filtreleme işlemleri sırasında kullanılan iki kavram vardır. Bunlar adım sayısı (stride) ve sıfır dolgu (zero padding) kavramlarıdır.

**Adım sayısı:** Adım sayısı, filtrenin görüntü üzerinde ne kadar kaydırılması gerektiğini ifade eden değerdir. Şekil 3.16'da adım sayısının 1 ve 2 olduğu durumlara örnekler gösterilmiştir. Şekilde görüldüğü üzere 7x7 boyutlarındaki bir girdi görüntüsüne 3x3 boyutlarında bir filtre adım sayısı 1 olarak uygulandığında çıktı görüntünün boyutları 5x5 olur. Adım sayısı 2 olarak uygulandığında ise çıktı boyutları 3x3 olur.



**Şekil 3.16.** a) Adım sayısı=1 ve b) adım sayısı=2 örnekleri

**Sıfır dolgu:** Bir filtre ya da pencere işlemi uygulandığında çıktı görüntünün boyutları orijinal görüntüden daha küçük olur. Bu küçülmenin önüne geçebilmek için sıfır dolgu işlemi yapılır. Sıfır dolgu işleminde görüntünün her bir kenarına çerçeve eklenecekmişçesine sıfırlar eklenir. Görüntünün kenarına eklenen bu kenarın sayısı tercihe göre değişiklik gösterebilir. Şekil 3.17’de sıfır dolguya örnek gösterilmiştir.



**Şekil 3.17.** a) 1 kenar ve b) 2 kenar eklenen dolgulama işlemi örneği




### 3.6.1.3. Aktivasyon katmanı (Activation layer)

Aktivasyon katmanı, evrişim katmanından hemen sonra kullanılan bir katmandır (Bayramoğlu, 2021). Bu katmanda, evrişim katmanında oluşturulan özellik haritasının bütün bileşenlerine aktivasyon fonksiyonu uygulanır. Böylece bileşenlerin her biri, doğrusal olmayan bir hale dönüştürülmüş olur (Erdem, 2018). Özellik haritasının aktivasyon fonksiyonları aracılığıyla doğrusal olmayan bir hale getirilmesinden dolayı bu katman aktivasyon katmanı, doğrusal olmayan katman ya da ReLU katmanı gibi farklı şekillerde isimlendirilir (Sarıyıldız, 2021). ReLU, bu katmanda kullanılan aktivasyon fonksiyonlarından birinin adıdır (Güzel, 2021).

### 3.6.1.4. Havuzlama (Ortaklama) katmanı (Pooling layer)

Havuzlama katmanı girdi verisinin boyutunun (Genişlik x Yükseklik) azaltıldığı katmandır. Bu işlem sırasında derinlik boyutu etkilenmez. Ancak bu katmanda meydana gelen boyut azalması veri kaybının meydana gelmesine sebep olur (İnik, 2019). Veri kaybı ağın başarısını düşürse de, hesaplamadaki karmaşıklıkların (Sarıyıldız, 2021), kullanılan bellek miktarının (Bayramoğlu, 2021) ve hesaplama maliyetinin azaltılması ağın daha verimli bir hale gelmesini sağlar (Erdem, 2018). Havuzlama katmanda öğrenilen parametre yoktur (Sarıyıldız, 2021). Amaç, önemi olmayan bilgilerin kullanılmasının önüne geçmek (Erdem, 2018) ve önemli olan özelliklerin korunmasını sağlamaktır (Güzel, 2021).


Havuzlama işlemini gerçekleştirmek için çeşitli yöntemler mevcuttur. Bu yöntemlerde, önceki katmandan gelen veri üzerinde bir pencere kaydırılır ve bu pencerenin içine karşılık gelen değerler dikkate alınır. Pencere içindeki değerlerden en büyük olan değer seçiliyorsa bu işlem maksimum havuzlama (maximum pooling), pencere içindeki değerlerin ortalaması alınıyorsa bu işlem ortalama havuzlama (average pooling) olarak adlandırılır. Şekil 3.18'de filtre boyutu 2x2 ve adım sayısı 2 için maksimum havuzlama örneği gösterilmiştir.



Şekil 3.18. Maksimum havuzlama işlemi

### 3.6.1.5. Seyreltme katmanı (Dropout layer)

Seyreltme katmanının kullanımı genellikle havuzlama katmanı ve tam bağlantı katmanı arasında gerçekleştirilir. Bu katman ağıın ezberleme yapması halinde bunun unutturulması için kullanılır (Metlek ve Çetiner, 2021). Seyreltme katmanında düzenleme yöntemleri kullanılarak ağıın aşırı öğrenmesinin önüne geçilmesinin amaçlanır. Şekil 3.19'da seyreltme katmanının kullanılmadığı ve kullanıldığı durumlar gösterilmiştir.




Şekil 3.19. (a) Standart ağ modeli ve (b) seyreltme yapılmış ağ modeli

### 3.6.1.6. Tam bağlantı katmanı (Tam bağı katman, fully connected layer)

Tam bağlantı katmanı; havuzlama katmanından sonra, seyreltme katmanından sonra, sınıflandırma katmanından önce kullanılabilir (Metlek ve Çetiner, 2021). Bu katmanda önceki katmandan gelen verilere düzleştirme (flattening) işlemi uygulanır ve önceki katmandan gelen bütün girişler bu katmandaki bütün nöronlara bağlanır (Güzel, 2021; Seyrek, 2021). Bu sebeple konumsal bilginin kaybolması durumu ortaya çıkar. Bu durum semantik segmentasyon uygulamaları için istenmeyen bir durum olarak ifade edilir

çünkü bu tarz uygulamalarda konum bilgisi önem arz eder (Muruganandham, 2016). Şekil 3.20’de tam bağlantı katmanına örnek gösterilmiştir.



Şekil 3.20. Tam bağlantı katmanı

### 3.6.1.7. Sınıflandırma katmanı

Sınıflandırma katmanı ağıın en son katmanıdır. Bu katmanda, uygulamada belirlenen amaca göre gelen veriler değerlendirilir ve bu şekilde çıkış değeri elde edilir. Sınıflandırma işlemini gerçekleştirmek için bunu sağlayan çeşitli aktivasyon fonksiyonları vardır (Sarıyıldız, 2021). Sigmoid aktivasyon fonksiyonu buna örnektir.


## 3.7. U-Net

U-Net yapısı ilk olarak 2015 yılında Uluslararası Biyomedikal Görüntüleme Sempozyumu’nda (International Symposium on Biomedical Imaging - ISBI) Ronneberger ve ark. (2015) tarafından ortaya koyulmuştur. Ronneberger ve ark. (2015) geliştirdikleri U-Net yapısı ile bu sempozyumdaki Hücre İzleme Yarışması’nın (Cell Tracking Challenge) kazananı olmuşlardır.

Ronneberger ve ark. (2015) “U-Net: Convolutional Networks for Biomedical Image Segmentation” adlı yayınlarında, sınıflandırma için kullanılan tipik bir evrişimsel ağda eğitim için binlerce görüntüye ihtiyaç duyulduğundan ve eğitim sonucunda oluşan çıktı ürünün her bir görüntüye dair tek bir sınıf etiketinden ibaret olduğundan bahsetmişlerdir. Bununla birlikte biyomedikal uygulamalar için bu kadar fazla görüntüye ulaşmanın mümkün olmadığını ve çıktı ürünün lokalizasyon içermesi (örneğin sınıf etiketlerinin piksellere atanması) gerektiğini belirtmişlerdir. Lokalizasyona yönelik

olarak yapılan çeşitli çalışmaların (Ciresan ve ark., 2012; Seyedhosseini ve ark., 2013; Hariharan ve ark., 2015) ardından ortaya koyulan U-Net yapısı, eğitim için gerekli olan görüntü sayısının çok az olması ve eğitim süresinin makul olması gibi sebeplerden dolayı avantaj sağlamaktadır (Ronneberger ve ark., 2015).

U-Net yapısı adını U harfine benzemesinden almaktadır. Toplam 23 adet evrişim katmanı içeren bu mimariye ait genel yapı Şekil 3.21’de gösterilmektedir. Şekilde her bir özellik haritası (feature map) mavi renkli kutucuklar halinde ifade edilmiştir. Kutucukların üzerinde yazan sayılar özellik haritalarının bant sayılarına karşılık gelir. Kutucukların sol alt tarafında yazan sayılar ise özellik haritalarının x-y ile ifade edilen boyutlarıdır. Beyaz renk ile gösterilen kutucuklar kopyalanan özellik haritalarıdır. Kutucuklar arasında farklı renklerle gösterilen ok işaretleri ise farklı işlemleri temsil eder (Ronneberger ve ark., 2015). Şekilde de görüldüğü üzere U-Net yapısı iki kısımdan oluşur. Bunlar U şeklindeki ağ yapısının sol tarafında bulunan aşağı yöndeki parçası ve sağ tarafında bulunan yukarı yöndeki parçasıdır. Bu iki parça sırasıyla daralma yolu (contracting path) ve genişleme yolu (expansive path) olarak ifade edilir (Dös, 2020). Literatürde bu iki terim için büzülme yolu ve açılma yolu ifadelerinin de kullanıldığı (Atlan ve Peñçe, 2021), ayrıca kodlayıcı (encoder) ve kod çözücü (decoder) olarak da bahsedildiği (Güzel, 2021; Karagöl ve ark., 2021; Kaya ve Önal, 2021) görülmektedir.



Şekil 3.21. U-Net mimarisi (Ronneberger ve ark. (2015)’den uyarlanmıştır.)

### 3.7.1. Daralma yolu

Daralma yolunda tipik bir evrişimsel ağ mimarisi mevcuttur (Farasin ve ark., 2020). Daralma yolunda boyutları 3x3 olan evrişim katmanları bulunur. Ayrıca daralma yolu her iki evrişim işleminin ardından gelen ReLU aktivasyon fonksiyonunu ve boyutları 2x2 olan maksimum havuzlama operasyonunu içerir. Kullanılan adım sayısı 2'dir. Daralma yolu bahsi geçen işlemlerin art arda tekrarlanmasıyla oluşur. Bu süreçte alt örnekleme işlemi gerçekleştirilmiş olunur. Yapılan her bir alt örnekleme işleminde özellik kanallarının (feature channels) sayısı ikiye katlanır (Ronneberger ve ark., 2015).

### 3.7.2. Genişleme yolu

U-Net yapısının genişleme yolunda üst örnekleme (upsampling) işlemi gerçekleştirilir. Bu kısım boyutları 2x2 olan evrişim katmanını, daralma yolunda karşılık gelen kırılmış özellik haritası ile birleşimi, boyutları 3x3 olan iki tane evrişim katmanını ve her bir evrişim işleminin ardından gelen ReLU aktivasyon fonksiyonunu içerir. Her bir evrişim işleminde kırma işlemi de gerçekleştirilir. Ayrıca her bir 2x2'lik evrişim işlemi özellik kanallarının sayısını yarıya düşürür. En son katman boyutları 1x1 olan evrişim katmanından oluşur (Ronneberger ve ark., 2015).

### 3.7.3. Avantajları ve kullanım alanları

Bir tür evrişimsel sinir ağı mimarisi olan U-Net mimarisi, tam evrişimsel ağ (fully convolutional network) mimarisine dayanmaktadır ve tam bağlantı katmanlarını içermez. Bilgi çıkarımı için sadece evrişim katmanlarını kullanır. Tam bağlantı katmanlarının olmaması ve küçük bir yapıdan oluşması U-Net'e avantaj sağlar. Ayrıca eğitim için kullanılacak veri sayısının az olması ve bu haliyle iyi sonuçlar vermeyi hedeflemesi U-Net'in sahip olduğu diğer avantajlardandır. U-Net ile yapılan segmentasyon sonucu oluşan özellik haritaları konum bilgisini de içerir. Çünkü U-Net her bir üst örnekleme işleminin öncesinde simetrik katmandan aldığı aynı boyutlu özellik haritasını kullanır, bunu mevcut özellik haritası ile birleştirir. Böylelikle özellik haritasına konum bilgisinin aktarılması sağlanır (Sivri, 2019).

İlk oluşturulduğunda biyomedikal görüntü segmentasyonu (Ronneberger ve ark., 2015) uygulamaları için kullanılan bu ağ yapısı, zamanla su segmentasyonu

(Wieland ve Martinis, 2019), bulut segmentasyonu (Wieland ve ark., 2019), gemi segmentasyonu (Karki ve Kulkarni, 2021), bina segmentasyonu (Erdem ve Avdan, 2020) ve yol segmentasyonu (Abderrahim ve ark., 2020) gibi farklı uygulamalarda da kullanım alanı bulmuştur.

### **3.8. Doğruluk Metrikleri (Evaluation Metrics)**

Görüntülerin sınıflandırılması, segmentasyonu gibi süreçlerde kullanılan model tercihinin ne olduğu, eğer varsa kullanıcının model için belirlediği hiper parametre değerleri ve maskelerin oluşturulması, elde edilen sonuçların doğrulukları üzerinde etkilidir (Seyrek, 2021). Bu gibi uygulamalarda kullanılan modelin doğruluğunun değerlendirilmesi için doğruluk değerlendirme metriklerine ihtiyaç vardır. Bu metrikler ile modelin performansının ne olduğu yani modelin ne kadar başarılı olduğu tespit edilir. Bunun tespitinde nitel ve nicel yöntemler kullanılır. Nitel yöntemler görsel olarak elde edilen sonuçların gerçek olan görsel verilerle karşılaştırılması suretiyle yapılır. Nicel yöntemler ise duyarlılık (recall), kesinlik (precision), F1-skoru (F1-score) ve Jaccard Skoru (Jaccard Score) ölçütleridir (Clarisse, 2021). Genel doğruluk (overall accuracy), duyarlılık, kesinlik ve F1-skoru gibi metrikler hata matrisi üzerinden elde edilebilen metriklerdir. Hata matrisi, tahmin edilen değerlerin ve gerçek değerlerin karşılaştırılmasını sağlar.

#### **3.8.1. Hata matrisi (Confusion matrix)**

Karmaşıklık matrisi olarak da adlandırılan hata matrisi modelin performansının değerlendirilmesini sağlayan iki satır ve iki sütundan oluşan bir tablodur (Cihan, 2020). Bu tablo doğru pozitif (DP, true positive - TP), yanlış pozitif (YP, false positive - FP), doğru negatif (DN, true negative - TN) ve yanlış negatif (YN, false negative - FN) sayılarını gösterir. Hata matrisi tahmin edilen değerler ile gerçek değerleri karşılaştırarak modelin performansını özetler (Vezakis ve ark., 2023).

		Tahmin	
		0-N	1-P
Gerçek	0-N	DN	YP
	1-P	YN	DP

Şekil 3.22. Hata matrisi

Doğru negatif: Gerçek durumun negatif, tahmin durumunun da negatif olduğu anlamına gelir.

Yanlış pozitif: Gerçek durumun negatif, tahmin durumunun ise pozitif olduğu anlamına gelir.

Yanlış negatif: Gerçek durumun pozitif, tahmin durumunun ise negatif olduğu anlamına gelir.

Doğru pozitif: Gerçek durumun pozitif, tahmin durumunun da pozitif olduğu anlamına gelir.

Yanmış alanların tespiti ele alındığında;

Doğru negatif: Yanmamış alanın yanmamış alan olarak belirlendiği anlamına gelir.

Yanlış pozitif: Yanmamış alanın yanmış alan olarak belirlendiği anlamına gelir.

Yanlış negatif: Yanmış alanın yanmamış alan olarak belirlendiği anlamına gelir.

Doğru pozitif : Yanmış alanın yanmış alan olarak belirlendiği anlamına gelir.

		Tahmin	
		0-N	1-P
Gerçek	0-N	DN=40	YP=4
	1-P	YN=2	DP=17

Şekil 3.23. Hata matrisi örneği

Şekil 3.23'te yanmış alanların tespiti sonucunda hesaplanan hata matrisinin verildiği varsayalım. Bu durumda verilen hata matrisi incelendiğinde 19 tane yanmış alanın mevcut olduğu, bunlardan 17 tanesinin doğru bilindiği söylenebilmektedir. Ayrıca 44 tane yanmamış alan olduğu ancak bunların 40 tanesinin doğru bilindiği söylenebilmektedir.

### 3.8.2. Genel doğruluk (Overall accuracy – OA)


Doğruluk yapılan tahminlerden doğru olanların sayısının toplam sayıya bölünmesi ile elde edilen metriktir. Doğruluk metriğinin nasıl hesaplanacağı denklem 3.5'te verilmiştir. Doğruluk hesabının hata matrisi üzerinden yapılması için hata matrisinin köşegenlerinde bulunan elemanların toplam değerinin, matrisin bütün elemanlarının toplam değerine bölünmesi gerekir (Saralioğlu, 2020). Bu ifadenin karşılığı denklem 3.6'da gösterilmiştir.

$$\text{Doğruluk} = \frac{\text{Doğru tahmin edilen piksellerin sayısı}}{\text{Toplam tahmin edilen piksellerin sayısı}} \quad (3.5)$$

$$\text{Doğruluk} = \frac{DP+DN}{DP+YP+DN+YN} \quad (3.6)$$



Şekil 3.23'teki hata matrisine göre doğruluk değeri hesaplandığında  $(17+40)/(17+4+40+2)=0.90$  sonucu elde edilir. Yani doğruluk %90 olarak hesaplanmıştır.



Şekil 3.24. (a) Görüntü, (b) referans ve (c) tahmin

Doğruluk metriği her zaman iyi bir değerlendirme metriği olmayabilir. Bunu açıklamak için Şekil 3.24(a) ve Şekil 3.24(b)'de bu çalışmada kullanılan veri setinden birer örnek gösterilmiştir. Burada Şekil 3.27(a)'daki görüntü segmentasyon işlemine tabi tutulacak görüntü, Şekil 3.24(b)'deki görüntü ise maske yani modelin nasıl segmente olması gerektiğini gösteren görüntüdür. Beyaz alanlar yanmış alanlara, siyah alanlar ise yanmamış alanlara karşılık gelmektedir. Yanmış alanların gösterilmesi amacıyla soldaki görüntüye segmentasyon uygulandığı ve doğruluğun %90 olarak hesaplandığı varsayalım. Ancak segmentasyon sonucuna bakıldığında Şekil 3.24(c)'de verildiği gibi yanmış alan olarak belirlenen herhangi bir yerin mevcut olmadığı görülsün. Bu varsayımda doğruluk değeri iyi çıkmış olmasına rağmen segmentasyon sonucu beklendiği gibi gelmemektedir. Böyle bir durumla karşılaşılmasının sebebi, yanmamış olarak etiketlenen alanın görüntüdeki baskınlığıdır. Bu durum segmentasyon alanları dengeli bir şekilde dağılmadığında ortaya çıkar. Varsayılan örnek göz önüne alındığında buradaki bir sınıfın orijinal görüntüde %90'lık bir kısımdan oluştuğu söylenebilir. Örnekte bu sınıf yanmamış alanlardır. Eğer segmentasyon sonucunda tüm pikseller bu sınıf olarak sınıflandırılırsa, piksellerin %90'ı doğru sınıflandırılmış olur, geri kalan %10'u ise yanlış sınıflandırılır. Bu durumda yüksek bir doğruluk değeri elde edilir. Dolayısıyla doğruluğun yüksek olması her zaman segmentasyon sonucunun iyi olduğu anlamına gelmeyebilir. Bu yüzden doğruluk metriğine ek olarak farklı metrikler geliştirilmiştir.

### 3.8.3. Duyarlılık (Recall)

Duyarlılık, belli bir sınıfa ait olan bir deęerin sınıflandırma işleminde sonucunda doğru sınıflandırılmış olma olasılığının ne olduğunu belirten metriktir (Saraliođlu, 2020). Yani duyarlılık, gerçekte pozitif olanların kaç tanesinin tahminde de pozitif olarak tanımlandığını belirtir (Göksu, 2022). Yanmış alanların gösterilmesi örneğinde, gerçekte yanmış alan olan piksellerin kaç tanesinin bu şekilde belirlendiđi duyarlılık ile ifade edilir. Duyarlılık metriğinin hesaplanması denklem 3.7’de verilmiştir.

$$\text{Duyarlılık} = \frac{DP}{DP + YN} \quad (3.7)$$

Şekil 3.23’teki hata matrisine göre duyarlılık deęeri hesaplandığında  $(17)/(17+2)=0.89$  sonucu elde edilir.

### 3.8.4. Kesinlik (Precision)

Kesinlik bir deęerin belli bir sınıfta olduğuna yönelik olarak yapılan tahmin sonucunda, o deęerin gerçekten o sınıfa ait olması ihtimalinin ne olduğunu gösterir (Saraliođlu, 2020). Pozitif tahmini (predictive) deęeri (Shi ve ark., 2022) anlamına da gelen kesinlik, tahminde pozitif olarak belirlenenlerin gerçekte ne kadarının pozitif olarak tanımlandığını belirtir (Göksu, 2022). Yanmış alanların gösterilmesi örneğinde, yanmış alan olarak belirlenen piksellerin gerçekte ne kadarının yanmış olduğu kesinlik ile ifade edilir. Kesinlik metriğinin hesaplanması denklem 3.8’de verilmiştir.

$$\text{Kesinlik} = \frac{DP}{DP + YP} \quad (3.8)$$

Şekil 3.23’teki hata matrisine göre kesinlik deęeri hesaplandığında  $(17)/(17+4)=0.81$  sonucu elde edilir.

### 3.8.5. F1-skoru (F1-score)

F skoru olarak da adlandırılan F1-skoru (Saralioğlu, 2020) yapılan tahminlerde kesinlik ve duyarlılık değerlerinin ikisini birden dikkate alan metriktir. Eşit dağılmayan veri setleri için model seçiminde hatalar yapmaması, tercih edilmesinin sebeplerindedir. F1-skorunun hesabı kesinlik ve duyarlılık değerlerinin harmonik ortalaması alınarak gerçekleştirilir (Farasin ve ark., 2020). Bu metriğin hesabı denklem 3.9’da verilmiştir. F1-skoru değeri yüksek ise YP ve YN değerleri düşük demektir (Brugnara ve ark., 2020). Şekil 3.23’teki hata matrisine göre F1-skoru metriği hesaplandığında  $(2*0.81*0.89)/(0.81+0.89)=0.85$  sonucu elde edilir.

$$F_1 = \frac{2 * (Kesinlik * Duyarlilik)}{Kesinlik + Duyarlilik} \quad (3.9)$$

### 3.8.6. Jaccard skoru (Kesişim bölü birleşim, Intersection over union - IoU)

Jaccard indeksi olarak da adlandırılan (Clarisse, 2021) Jaccard skoru, tahmin edilen bölge ile gerçek bölge arasındaki benzerliği ölçen metriktir (Huang, 2021). Tahmin edilen bölge ile gerçek bölgenin kesişiminin (intersection) bu bölgelerin birleşimine (union) bölünmesi ile elde edilir (Göksu, 2022). Jaccard hesaplanması denklem 3.10 ve 3.11’de verilmiştir. Burada A tahmin edilen bölgeye ve B gerçek bölgeye karşılık gelmektedir.

$$\text{Jaccard} = \frac{(A \cap B)}{(A \cup B)} = \frac{\text{İki bölgenin kesişimi}}{\text{İki bölgenin birleşimi}} \quad (3.10)$$

$$\text{Jaccard} = \frac{DP}{DP+YP+YN} \quad (3.11)$$

Jaccard sonucu büyük bir değer olarak hesaplanmışsa bu durum çakışma bölgesinin büyük olduğu anlamına gelir (Göksu, 2022). Bununla birlikte Salvatore ve ark. (2018) yaptıkları çalışmada bu metriğin küçük veri setleri için sürekli olarak düşük değerler verdiğini, veri setinin boyutunun artmasıyla metrik değerinin de arttığını belirtmişlerdir.

### 3.9. Uygulama

Bu tez çalışması kapsamında Landsat-8 uydu görüntüleri kullanılarak yanmış alanlarının segmentasyonu gerçekleştirilmiştir. Tezin devamında çalışmada kullanılan platform, kullanılan derin öğrenme yapısı ve veri seti, veri setinin ve hiper parametrelerin ayarlanması açıklanmıştır.

#### 3.9.1. Kullanılan platform

Bu tez kapsamında yapılan işlemler Python programlama dili kullanılarak gerçekleştirilmiştir. Çalışmada esas olarak TensorFlow arka ucuna sahip Keras kullanılmıştır. Uygulamaların bir kısmı bilgisayar üzerinden, bir kısmı ise Google Colaboratory (Colab) üzerinden gerçekleştirilmiştir. Çalışmada kullanılan bilgisayar modeli Lenovo Legion Y530 olup Intel® Core™ i7-8750H CPU @ 2.20GHz işlemciye ve NVIDIA GeForce GTX 1050 Ti 4 GB ekran kartına sahiptir. Uygulamada ön işlemler bilgisayar üzerinden Anaconda Spyder editörü kullanılarak gerçekleştirilmiştir. Bahsi geçen ön işlemler uydu görüntülerinden istenilen bant kombinasyonlarının oluşturulması, veri setinin istenen boyutlarda olacak şekilde bölme işlemine tabi tutulması, veri setinin eğitim, doğrulama ve test veri seti olarak istenen oranlarda ve rastgele olarak ayrılması, veri setine tercih edilen veri artırımı yöntemlerinin uygulanması gibi işlemlerdir. Ancak bu işlemler sonucunda elde edilen veri seti ile yapılması gereken eğitim aşaması bilgisayar üzerinde gerçekleştirilememiş, özellikle RAM konusunda yetersizliklerle karşılaşmıştır. Dolayısıyla bilgisayar üzerinde oluşturulan veri setleri Google Colab üzerinde eğitim ve test işlemlerine tabi tutulmuştur. Bunun için Google Drive platformunda Colab Notebooks klasörü içine, Spyder'da ön hazırlığı tamamlanan veriler yüklenmiş ve aynı klasörde kod dosyaları oluşturulmuştur. Google Colab'ın verileri Google Drive üzerinden kullanması sağlanmıştır.

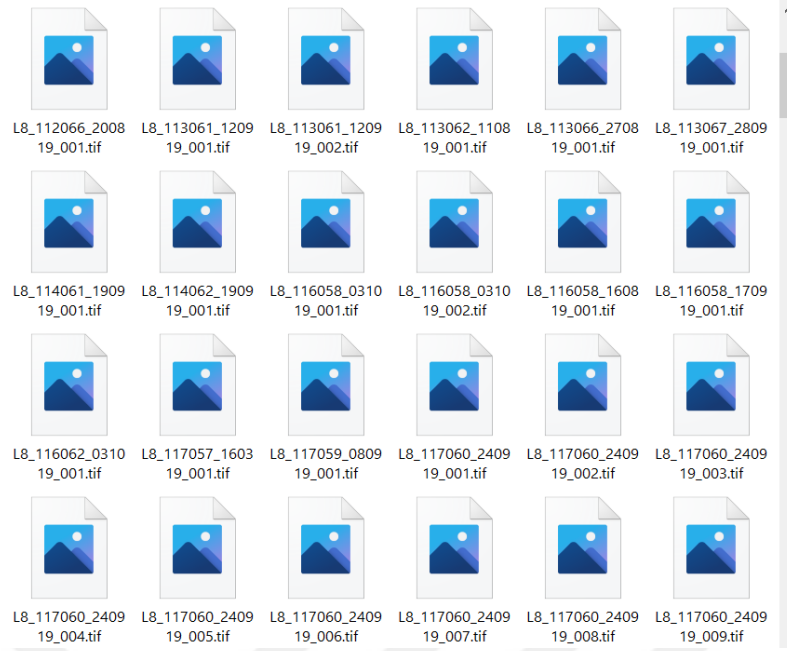
Google Colab, Google tarafından sağlanan bir bulut hizmetidir. İşlemler internet bağlantısı aracılığıyla ve Jupyter Notebook üzerinden gerçekleştirilmiştir. Google Drive ile bağlantı kurmak mümkündür. Uygulamada ilk başta Google Colab'ın 12.7 GB RAM sağlayan ücretsiz versiyonu kullanılmıştır. Ancak çalışmanın ilerleyen aşamalarında ücretsiz versiyonun sınırlı süre ve kaynaklar sunduğu görülmüş, bu sebeple çalışma sırasında zaman zaman eğitim süreci henüz tamamlanmadan sistemle olan bağlantının kesilmesi ve bir süre boyunca sisteme bağlanmaya izin verilmemesi gibi durumlarla

karşılaşılmıştır. Bu gibi kısıtlamalardan dolayı ücretli olan Google Colab Pro versiyonuna geçilerek çalışmalar tamamlanmıştır. Google Colab Pro'nun aylık 100 birimlik kaynak sunduğu görülmüş, 100 birim bitmediği takdirde sistemden herhangi bir kopma gerçekleşmemiş, böylelikle eğitim süreçleri kesintiye uğramadan tamamlanabilmiştir. Eğitim işleminin ardından test aşaması ve doğruluk analizleri yine Google Colab Pro üzerinden gerçekleştirilmiştir. Elde edilen bütün sonuçların Google Drive platformuna kaydedilmesi sağlanmıştır.

### 3.9.2. Kullanılan Derin Öğrenme Yapısı ve Veri Seti

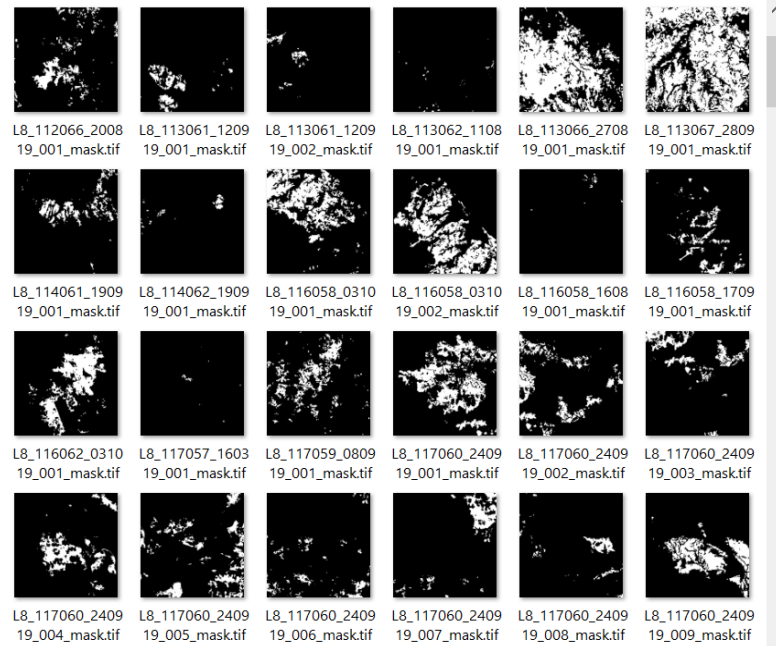
Bu çalışmada yöntem olarak derin öğrenme mimarilerinden biri olan U-Net mimarisi tercih edilmiştir. Materyal olarak Prabowo ve ark. (2022a) tarafından oluşturulan “Dataset of Deep Learning from Landsat-8 Satellite Images for Estimating Burned Areas in Indonesia” adlı veri seti kullanılmıştır. Sunulan veri setinin zaman içerisinde güncellendiği ve çeşitli versiyonlarının oluşturulduğu görülmüş olup bu tez çalışması kapsamında versiyon 2 (dosya adı: fs7mtkg2wk-2) kullanılmıştır. Endonezya'daki yanmış alanların tespiti için derin öğrenme çalışmalarında kullanılmak üzere oluşturulan bu veri seti 512x512xn boyutlarında Landsat-8 görüntülerinden oluşmakta ve üç grupta sunulmaktadır. Burada n bant sayısına karşılık gelmektedir ve her bir grupta 227 adet görüntü mevcuttur.

Birinci grupta 8 banttan oluşan multispektral görüntüler bulunmaktadır. Bu görüntüler kıyı/aerosol, mavi, yeşil, kırmızı, yakın kızılötesi, kısa dalga kızılötesi-1, kısa dalga kızılötesi-2 ve sirrus bantlarından oluşmaktadır. Bu gruptaki görüntüler uint16 formatındadır diğer bir ifadeyle 16 bit işaretli tamsayı (unsigned integer) formatındadır. Birinci gruba ait dizin içeriği Şekil 3.25'te gösterilmiştir.




Şekil 3.25. Veri setindeki birinci grubun dizin içeriği

İkinci grupta multispektral görüntülerin karşılığı olan maskeler bulunmaktadır. Siyah-beyaz ikili görüntüler halindeki bu maskeler tek bantlıdır. Bu görüntülerde yanmış alanlar 1 ile yanmamış alanlar ise 0 ile temsil edilir. İkinci gruptaki görüntüler uint8 formatındadır yani 8 bit işaretli tamsayı formatındadır. İkinci gruba ait dosyaların ön izleme görüntüleri Şekil 3.26’da verilmiştir.



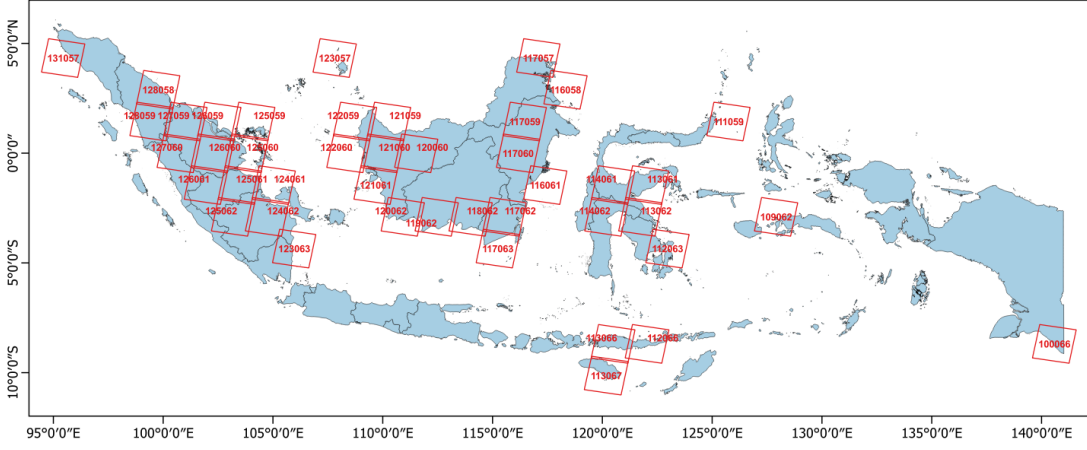
Şekil 3.26. Veri setindeki ikinci grubun ön izleme görüntüleri

Üçüncü grupta kısa dalga kızılötesi-2, yakın kızılötesi ve kırmızı bant kombinasyonundan oluşan 3 bantlı görüntüler mevcuttur. Üçüncü gruptaki görüntüler uint8 formatındadır. Üçüncü gruba ait dosyaların ön izleme görüntüleri Şekil 3.27’de verilmiştir.



Şekil 3.27. Veri setindeki üçüncü grubun ön izleme görüntüleri

Veri setindeki görüntüler GeoTIFF dosya formatında olup WGS 1984 (World Geodetic System 1984 – Dünya Jeodezik Sistemi 1984) datumundadır. Görüntülerin bir kısmı orman, su kütlesi, çıplak arazi, bulut, bulut gölgesi gibi bölgeler içerirken bir kısmı halen yanmakta olan bölgelere ait dumanlardan oluşmaktadır. Görüntülerin bir kısmı ise herhangi bir yanmış alanın olmadığı bölgeleri içermektedir (Prabowo ve ark., 2022a). Şekil 3.28’de görüntülerin çalışma bölgesindeki konumları gösterilmiştir.



Şekil 3.28. Seçilen Landsat-8 görüntülerinin konumları (Prabowo ve ark., 2022b)

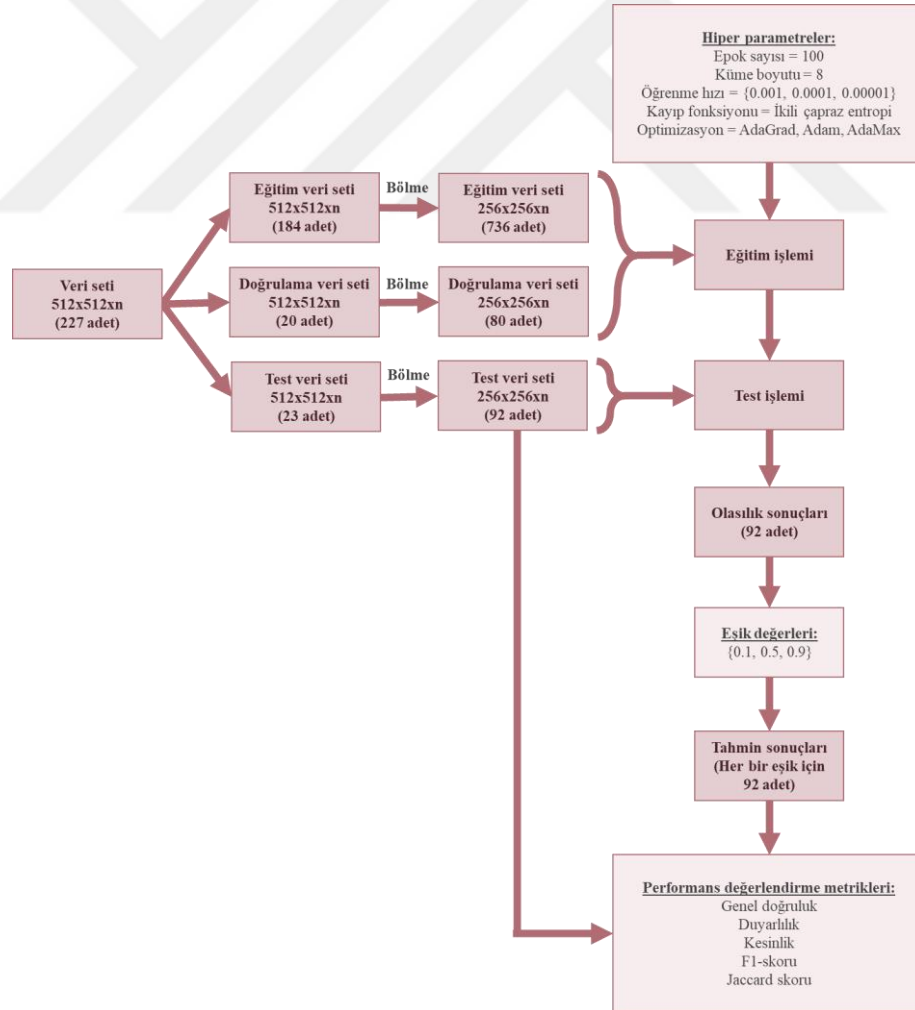
### 3.9.3. Veri setinin ve hiper parametrelerin ayarlanması

Öncelikle veri setinde birinci gruptaki uint16 formatındaki multispektral görüntüler uint8 formatına dönüştürülmüştür. Elde edilen görüntüler ve ikinci grupta karşılığı olan maskeler eğitim, doğrulama ve test aşamalarında kullanılmak üzere üçe ayrılmıştır. Bunun için toplam veri setinin %10'luk kısmı alınarak test veri seti, kalan kısmın %10'luk kısmı alınarak ise doğrulama veri seti oluşturulmuş ve en son kalan kısım eğitim veri seti olarak kullanılmıştır. Bu süreçte görüntülerin rastgele olarak ayrılması sağlanmıştır. Ayrılma süreci sonucunda eğitim için 184 adet, doğrulama için 20 adet ve test için 23 adet görüntü ve bu görüntülere karşılık gelen maskeler elde edilmiştir. Daha sonra 512x512xn boyutlarında olan bu veri seti 256x256xn boyutlarında olacak şekilde görüntü bölme işlemine tabi tutulmuştur. Bunun sonucunda veri sayısında artış meydana gelerek toplamda 908 adet görüntü ve maskesi elde edilmiştir. Sonuç olarak eğitim için 736 adet, doğrulama için 80 adet ve test için 92 adet görüntü ve bu görüntülere karşılık gelen maskeler elde edilmiştir.

Uygulamada girdi veri seti uint formatından float formatına dönüştürülmüştür. Daha sonra 0 ile 1 arasında olacak şekilde normalize edilmiştir. Küme boyutu 8 tercih edilmiştir. Öğrenme hızı için 0.001; 0.0001 ve 0.00001 değerleri denenerek en uygun olan değer kullanılması tercih edilmiştir. Epok sayısı 100 olarak kullanılmıştır. Kayıp fonksiyonu için ikili çapraz entropi kullanılmıştır. Optimizasyon algoritması için literatürdeki çalışmalarda sıklıkla tercih edildiği görülen (Park ve Lee, 2019; Farasin ve ark., 2020; Khryashchev ve Larionov, 2020; Knopp ve ark., 2020; Pinto ve ark., 2020; Prabowo ve ark., 2022b) Adam algoritması kullanılmıştır. Daha sonra en iyi ve en kötü



sonuçları veren bant kombinasyonunda AdaGrad ve AdaMax optimizasyon algoritmaları da kullanılarak karşılaştırma yapılmıştır. Aktivasyon fonksiyonu olarak U-Net mimarisinde de kullanıldığı üzere ReLU aktivasyon fonksiyonu ve son katmanda sigmoid aktivasyon fonksiyonu kullanılmıştır. Sigmoid aktivasyon fonksiyonu sayesinde çıktı değerlerinin 0-1 arasında olan olasılık değerlerinden oluşması sağlanmıştır. Böylelikle olasılık sonuçları elde edilmiştir. Bu sonuçlara eşik değeri uygulanmıştır. Olasılık sonuçlarında eşik değerden küçük olan değerler 0 değerine, büyük olan değerler ise 1 değerine dönüştürülmüştür. Dolayısıyla sonuçların sadece 0 ve 1 değerlerinden oluşması sağlanmıştır. Eşik değeri için 0.1, 0.5 ve 0.9 olmak üzere üç farklı değer tercih edilmiştir. Değerlendirmelere göre en iyi sonuçları veren kombinasyonda eğitim veri setine  $90^\circ$ ,  $180^\circ$  ve  $270^\circ$  döndürme işlemi uygulanarak veri artırımı gerçekleştirilmiştir.  $90^\circ$ ,  $180^\circ$  ve  $270^\circ$  döndürme sonucunda eğitim veri seti için 2208 adet görüntü ve maskesi elde edilmiştir. Şekil 3.29'da iş akış şeması gösterilmiştir.



Şekil 3.29. İş akış şeması

## 4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA

Bu tez çalışmasında yanmış alanların uydu görüntülerinden tespiti için çeşitli girdiler kullanılmıştır. 256x256xn boyutlarındaki ürünler U-net mimarisine girdi olarak verilmiş, eğitim ve test işlemlerinin ardından 256x256x1 boyutlarında çıktı ürünler elde edilmiştir. Girdi ürünlerde, hiper parametrelerde ve eşik değer seçiminde bazı değişiklikler yapılarak bunların sonuçlar üzerindeki etkisi incelenmiş ve uygun modelin oluşturulması amaçlanmıştır. Bu amaçla tezin devamı üç farklı bölümde ele alınmıştır. Birinci bölüm “4.1. Bant Kombinasyonlarının Karşılaştırılması” başlığı altında incelenmiştir. Burada 6 farklı bant kombinasyonu kullanılarak sonuçlar karşılaştırılmış, en iyi ve en kötü sonucu veren kombinasyonlar tespit edilmiştir. İkinci bölüm “4.2. Optimizasyon Algoritmalarının Karşılaştırılması” başlığı altında incelenmiştir. Bu başlıkta, birinci bölümde en iyi ve en kötü sonucu veren kombinasyonlar kullanılarak optimizasyon algoritmaları değiştirilmiş ve sonuçlar incelenmiştir. Üçüncü bölüm “4.3. Nihai Modelin Oluşturulması” başlığı altında incelenmiştir. Bu bölümde ilk iki bölümde elde edilen sonuçlar özetlenerek en iyi sonucu veren model belirlenmiştir. Bu bölümde ayrıca eğitim veri setine 90°, 180° ve 270° döndürme uygulanmasıyla veri artırımı yapılan veri seti, belirlenen nihai modele girdi olarak verilmiş ve elde edilen sonuçlar değerlendirilmiştir. Ayrıca her bölümde tahmin sonuçlarının oluşturulması için 0.1, 0.5, 0.9 eşik değerleri kullanılmış ve bunların sonuçlar üzerindeki etkisi de incelenmiştir. Ek olarak test görüntülerinden 5 tanesi seçilerek bunlara ait olan olasılık ve tahmin sonuçları gösterilmiştir (Şekil 4.2-Şekil 4.11 arası ve Şekil 4.14). Tahmin sonuçları olasılık haritaları üzerinden elde edilmiş, eşik değerinin 0.1, 0.5 ve 0.9 olarak alındığı üç farklı durum için paylaşılmıştır. Doğruluk metriklerinden genel doğruluk, duyarlılık, kesinlik, F1-skoru ve Jaccard skoru kullanılmıştır. Her bir test görüntüsü için elde edilen metrik sonuçları Excel dosyasına kaydedilmiştir. Kaydedilen sonuçların minimum, maksimum, ortalama ve standart sapma değerleri hesaplatılarak her bir metrik için istatistiksel bir inceleme de gerçekleştirilmiştir. Ayrıca test görüntüleri arasından seçilen 5 görüntü görsel olarak ve bu metrikler de dikkate alınarak incelenmiştir.

### 4.1. Bant Kombinasyonlarının Karşılaştırılması

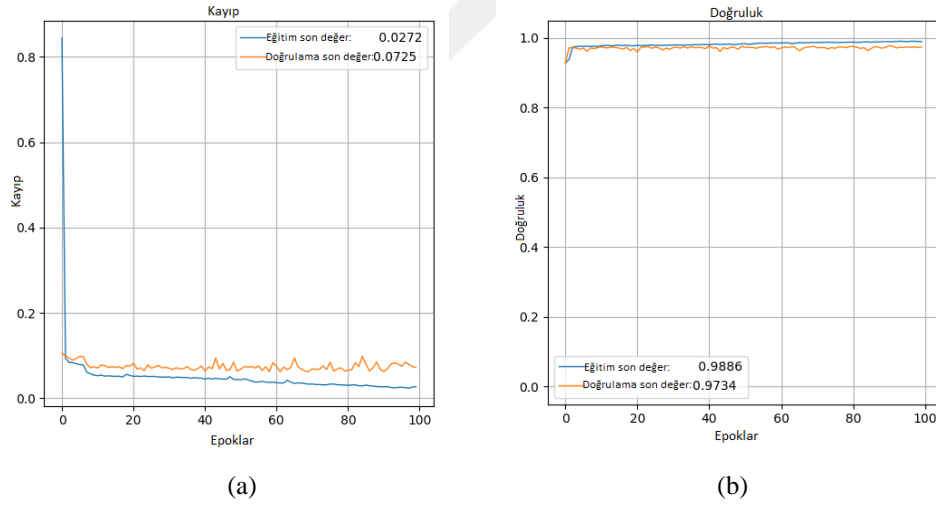
Çalışmanın bu bölümünde görüntüler 6 farklı kombinasyonda seçilerek modele girdi olarak verilmiştir. Bunlar 7,5,4; 5,3,7; 5,4,3; 4,3,2; 4,3,2,5 ve 2,3,4,5,6,7

kombinasyonlarıdır. Çalışmada kullanılan bant kombinasyonları, kullanıldıkları öğrenme oranları, optimizasyon algoritmaları ve eğitim süreleri Çizelge 4.1’de özetlenmiştir.

**Çizelge 4.1.** Eğitim ile ilgili bilgiler

No	Bantlar	Öğrenme Hızı	Optimizasyon	Süre
1	7,5,4	0.001	Adam	1 saat 36 dakika
2	5,3,7	0.001	Adam	1 saat 37 dakika
3	5,4,3	0.0001	Adam	1 saat 53 dakika
4	4,3,2	0.00001	Adam	1 saat 50 dakika
5	4,3,2,5	0.001	Adam	1 saat 45 dakika
6	2,3,4,5,6,7	0.00001	Adam	1 saat 54 dakika

Çizelge 4.1’de belirtilen bant kombinasyonlarındaki eğitim ve doğrulama veri setleri kullanılarak her bir kombinasyon için eğitim işlemi gerçekleştirilmiştir. Eğitim süresi her biri yaklaşık 1 buçuk ile 2 saat arasında değişmektedir. 7,5,4 bant kombinasyonu için eğitim sonucunda elde edilen kayıp ve doğruluk grafikleri Şekil 4.1’de gösterilmiştir. Diğer kombinasyonlardan elde edilen grafikler ise EK-1’de verilmiştir.



**Şekil 4.1.** Bant kombinasyonu 7,5,4 için (a) kayıp ve (b) doğruluk grafikleri

Test işlemi için Çizelge 4.1’de belirtilen bant kombinasyonlarındaki test veri setleri modele girdi olarak verilmiş ve test işlemi gerçekleştirilmiştir. 92 adet test görüntüsünden 5 adeti tezde gösterilmiş, bu görüntülere harita olarak sırasıyla EK-2 ile EK-6 arasında yer verilmiştir. Bu 5 görüntü test görüntülerinin sırasıyla 1., 15., 18., 55. ve 78. görüntüleridir. Görüntü 1’de az miktarda yanmış alanla birlikte bulutlar ve bulut gölgeleri mevcuttur. Görüntü 15 ve 18’de yol vardır. Bununla birlikte yanmış alan miktarı

görüntü 18’de daha fazladır. Görüntü 55’te yanmış alan mevcut olmamakla birlikte yangına ait olan dumanlar mevcuttur. Görüntü 78’de ise yanmış alanlar, tarım alanları, bulutlar ve bulut gölgeleri bulunmaktadır.

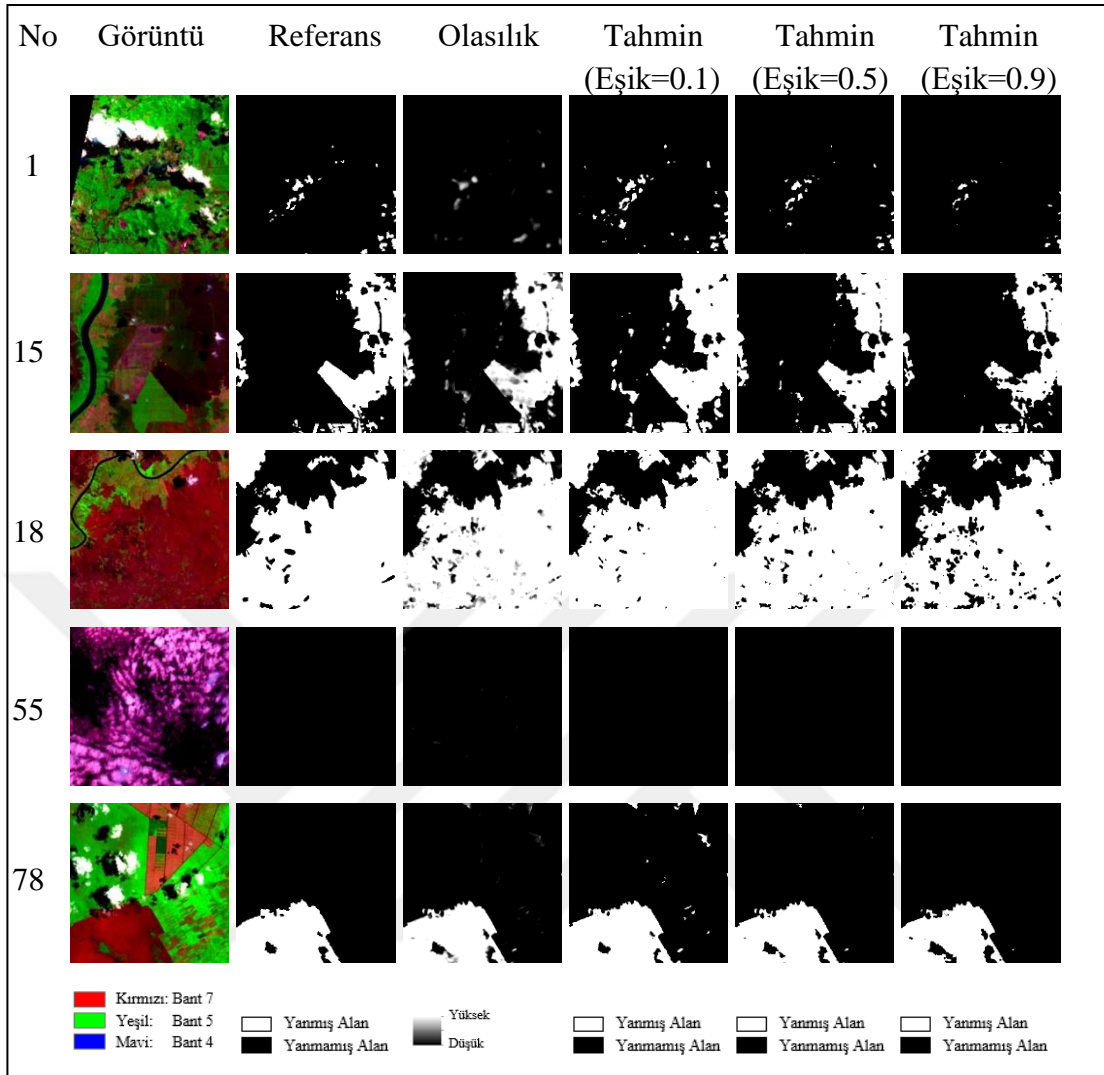
Aşağıda 5 adet test görüntüsü gösterilmiş, daha sonra sırasıyla bu görüntülere ait olan referans verileri, modelin test aşaması sonucu ürettiği olasılık haritaları, eşik değerin 0.1, 0.5 ve 0.9 olarak alınmasıyla olasılık haritaları üzerinden elde edilen ikili tahmin görüntüleri gösterilmiştir. Devamında görüntülere dair doğruluk metrikleri eşik değerin 0.1, 0.5 ve 0.9 olduğu durumlar için tablo halinde sunulmuştur.

#### 4.1.1. Bant kombinasyonu 7,5,4 için test görüntülerini değerlendirme

Şekil 4.2 incelendiğinde,

Görüntü 1’de kırmızı ile gösterilen yanmış alanlarının referans verisine yakın tespit edildiği görülmektedir. Eşik değerin 0.1 olduğu durumda, referans verisinde belirtilmeyen ancak görüntüde yanmış alan olarak gözükken sol alt bölgenin de tespit edilebildiği söylenebilir. Bu durumda derin öğrenmenin referans verisinde olmayan yanmış alanları da tespit edebildiği yorumu yapılabilir. Eşik değerin 0.9 olarak alındığı durum ise pek doğru sonuç vermemektedir. Çizelge 4.2’ye göre yanmış alanlara dair olan duyarlılık, F1-skoru ve Jaccard skoru metrikleri eşik değerin 0.9 olarak alındığı durumda diğer durumlardan daha düşük değerler vermektedir. Duyarlılık değerleri incelendiğinde gerçekte yanmış alan olan bölgelerin tahminde eşik değer 0.9 iken sadece %31.80’i yanmış olarak belirlenebilmişken, eşik değer 0.1 için bu oran %82.76 olmuştur. F1-skoru değerleri ise eşik değerin 0.1, 0.5 ve 0.9 olduğu durumlar için sırasıyla %72.83, %71.66 ve %48.22’dir.

Görüntü 15’te yolun yanmış alan ile karıştırılmadığı ve derin öğrenmenin bu konuda başarılı olduğu görülmektedir. Eşik değerin 0.1 olarak seçildiği durumda yolun sağ kısmındaki alanların gerçekte yanmamış olmasına rağmen tahminde yanmış olarak gösterildiği görülmektedir. Eşik değerin 0.9 olduğu durumda ise gerçekte yanmış alan olan bazı bölgeler tahminde yanmamış olarak gösterilmiştir. Çizelge 4.2’de yanmış alanlara dair olan duyarlılık değerleri incelendiğinde gerçekte yanmış alan olan bölgelerin tahminde eşik değer 0.1 iken %99.54’ünün yanmış olarak belirlendiği ancak eşik değer 0.9 iken bu oranın %83.19 olduğu görülmektedir. F1-skoru değerleri ise eşik değerin 0.1, 0.5 ve 0.9 olduğu durumlar için sırasıyla %86.14, %92.74 ve %89.85’tir.



Yanmış Alan

Yanmamış Alan

 Yanmış Alan
 
 Yanmamış Alan
 
 Yanmış Alan
 
 Yanmamış Alan
 

Şekil 4.2. Bant kombinasyonu 7,5,4 için 5 adet test görüntüsü, ilgili referans görüntüsü ve sonuçlar

Görüntü 18’de görüntü 15’te olduğu gibi yolun yanmış alan ile karıştırılmadığı görülmektedir. Eşik değerinin 0.9 olduğu durum diğerlerinden daha kötü sonuç vermektedir. Çizelge 4.2’ye göre eşik değer 0.9 iken yanmış alanlara dair olan duyarlılık değeri %90.74, F1-skoru değeri ise %94.74’tür. Bu değerler diğer eşiklerdekinden daha azdır. Bu durum yapılan yorumla paralellik göstermektedir.

Görüntü 55’te gerçekte hiç yanmış alan olmayan bölgenin tahminde de yanmamış alan olarak gösterildiği görülmektedir. Bu durumda derin öğrenmenin yanmamış alanlarda da başarılı olduğu sonucuna varılabilir. Çizelge 4.2 incelendiğinde yanmış alanlara dair olan duyarlılık, kesinlik ve F1-skoru metriklerinin hesaplanmadığı görülmektedir. Bu durum görüntüde ve tahminde hiç yanmış alan olmamasından kaynaklanmaktadır. Ayrıca bu durumun sonucu olarak aynı metriklerin yanmamış

alanlara dair sonuçları incelendiğinde 1 olarak hesaplandığı görülmektedir. Doğruluk metriği de 1 olarak hesaplanmıştır. Bu durum sonucun %100 doğru olduğu anlamına gelir.

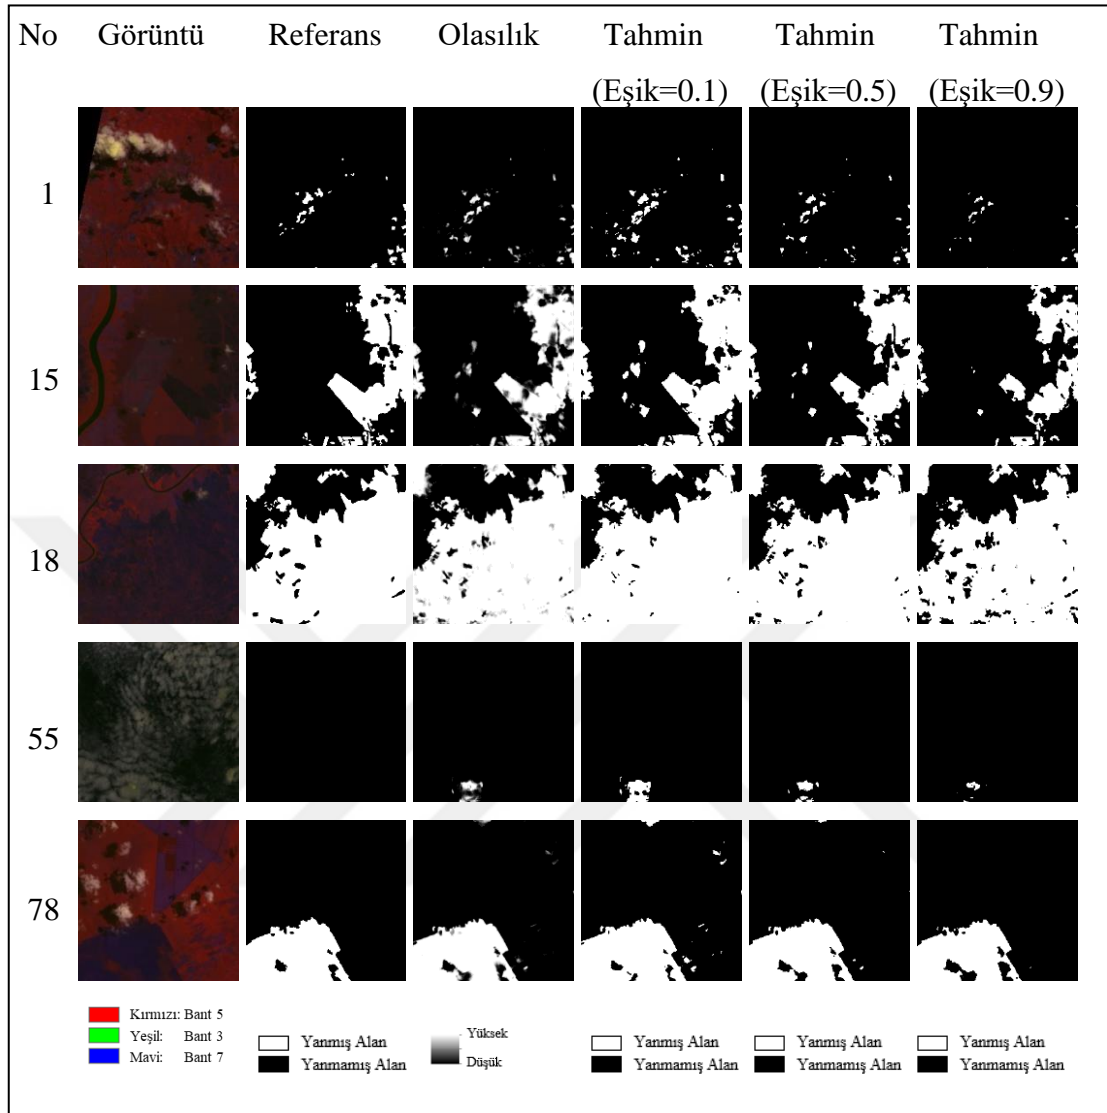
Görüntü 78’de bulut ve gölgelerinin yanmış alan sonucunu olumsuz etkilemediği görülmektedir. Bununla birlikte eşik değer 0.1 iken tarım alanlarının bir kısmı yanmış alana dahil edilmiştir. 0.5 eşiginde ise bu dahil edilme çok azdır. Çizelge 4.2’de yanmış alanlara dair kesinlik metriği incelendiğinde eşik değer 0.1 iken tahminde yanmış alanların %92.79’unun gerçekte yanmış alanlara karşılık geldiği görülürken, eşik değer 0.5 olduğunda bu değer %98.28 olmaktadır. Eşik 0.9 olduğunda ise gerçekte yanmış alan olan bazı kısımların tahminde yanmamış olarak belirtildiği görülmektedir. Yanmış alanlara dair duyarlılık metriği incelendiğinde eşik değerler için sırasıyla %99.34, %96.43 ve %91.27 değerlerini aldığı görülmektedir. 0.9 eşiği daha düşük değerlerle sonuçlanmıştır. F1-skoru değerleri ise sırasıyla %95.95, %97.35 ve %95.19’dur.

**Çizelge 4.2.** Bant kombinasyonu 7,5,4 için 5 adet test görüntüsüne dair doğruluk metrikleri

Eşik	Görüntü No.	Doğruluk	Duyarlılık 0.0*	Duyarlılık 1.0*	Kesinlik 0.0*	Kesinlik 1.0*	F1-Skoru 0.0*	F1-Skoru 1.0*	Jaccard Skoru
0.1	1	0.9887	0.9917	0.8276	0.9968	0.6502	0.9943	0.7283	0.5727
	15	0.9282	0.9088	0.9954	0.9985	0.7591	0.9516	0.8614	0.7565
	18	0.9576	0.8529	0.9971	0.9909	0.9473	0.9168	0.9716	0.9447
	55	1.0000	1.0000	x*	1.0000	x*	1.0000	x*	0.0000
	78	0.9849	0.9831	0.9934	0.9985	0.9279	0.9907	0.9595	0.9222
0.5	1	0.9915	0.9990	0.5883	0.9924	0.9166	0.9957	0.7166	0.5584
	15	0.9663	0.9676	0.9618	0.9887	0.8954	0.9780	0.9274	0.8646
	18	0.9659	0.9368	0.9768	0.9384	0.9762	0.9376	0.9765	0.9541
	55	1.0000	1.0000	x*	1.0000	x*	1.0000	x*	0.0000
	78	0.9906	0.9963	0.9643	0.9922	0.9828	0.9943	0.9735	0.9483
0.9	1	0.9875	1.0000	0.3180	0.9875	0.9974	0.9937	0.4822	0.3177
	15	0.9579	0.9943	0.8319	0.9535	0.9768	0.9735	0.8985	0.8158
	18	0.9268	0.9784	0.9074	0.7993	0.9911	0.8798	0.9474	0.9001
	55	1.0000	1.0000	x*	1.0000	x*	1.0000	x*	0.0000
	78	0.9834	0.9989	0.9127	0.9812	0.9946	0.9900	0.9519	0.9082

\* 0.0 yanmamış, 1.0 yanmış alanlara; x metrik hesaplanmadığı durumlara karşılık gelmektedir.

#### 4.1.2. Bant kombinasyonu 5,3,7 için test görüntülerini değerlendirme



Şekil 4.3. Bant kombinasyonu 5,3,7 için 5 adet test görüntüsü, ilgili referans görüntüsü ve sonuçlar

Şekil 4.3 incelendiğinde bu kombinasyonda yanmış alanların lacivert mor tonlarında gözüktüğü söylenebilir. Buradaki sonuçlar 7,5,4 bant kombinasyonundaki sonuçlarla karşılaştırıldığında;

Görüntü 15’te yolun burada da yanmış alan ile karıştırılmadığı görülmektedir. Ancak halen yolun sağ kısmındaki bazı bölgeler referans verisinde yanmamış olarak belirtilmesine rağmen tahminde yanmış olarak gösterilmekte, üstelik 7,5,4 bant kombinasyonuna göre daha fazla alan olarak görülmektedir. Çizelge 4.3’te yanmış alanlara dair olan duyarlılık değerleri incelendiğinde gerçekte yanmış alan olan bölgelerin tahminde eşik değer 0.1 iken %97.05’inin yanmış olarak belirlendiği ve eşik değer 0.9 iken ise bu oranın %69.93 olduğu görülmektedir. Bu değerlerin 7,5,4 kombinasyonundaki

değerlerden daha düşük olarak sonuçlanması yapılan yorumla paralellik göstermektedir ve 7,5,4 kombinasyonunun bu konuda daha başarılı olduğu görülmektedir. F1-skoru değerleri ise eşik değer 0.1, 0.5 ve 0.9 olduğu durumlar için sırasıyla %86.55, %89.26 ve %81.43'tür.

Görüntü 55'te gerçekte hiç yanmış alan olmamasına rağmen tahminde yanmış alan tespit edildiği görülmektedir. 7,5,4 kombinasyonunun bu konuda daha başarılıdır. Çizelge 4.3'te yanmış alanlara dair olan duyarlılık, kesinlik ve F1-skoru metriklerinin 0 olduğu görülmektedir. Bu durum görüntüde hiç yanmış alan olmaması ama tahminde yanmış alanlar olmasından kaynaklanmaktadır. Ayrıca yanmamış alanlara dair kesinlik sonucu 1 gelmiştir çünkü tahminde yanmamış olarak belirtilenlerin tamamı gerçekte de yanmamıştır. Bununla birlikte doğruluk metriğinin ve yanmamış alanlara dair duyarlılık ve F1-skoru sonuçlarının yaklaşık olarak %99 olduğu görülmektedir. Bu durum gerçekte yanmamış alanların tahminde bir kısmının yanmış olmasından kaynaklanmaktadır.

**Çizelge 4.3.** Bant kombinasyonu 5,3,7 için 5 adet test görüntüsüne dair doğruluk metrikleri

Eşik	Görüntü No.	Doğruluk	Duyarlılık 0.0*	Duyarlılık 1.0*	Kesinlik 0.0*	Kesinlik 1.0*	F1-Skoru 0.0*	F1-Skoru 1.0*	Jaccard Skoru
0.1	1	0.9803	0.9838	0.7908	0.9961	0.4754	0.9899	0.5938	0.4223
	15	0.9324	0.9214	0.9705	0.9908	0.7810	0.9549	0.8655	0.7629
	18	0.9485	0.8532	0.9845	0.9539	0.9468	0.9008	0.9653	0.9329
	55	0.9846	0.9846	0.0000	1.0000	0.0000	0.9923	0.0000	0.0000
	78	0.9833	0.9823	0.9875	0.9972	0.9245	0.9897	0.9550	0.9139
0.5	1	0.9868	0.9948	0.5565	0.9918	0.6657	0.9933	0.6062	0.4349
	15	0.9522	0.9712	0.8864	0.9673	0.8989	0.9693	0.8926	0.8060
	18	0.9566	0.9260	0.9681	0.9162	0.9720	0.9211	0.9700	0.9418
	55	0.9927	0.9927	0.0000	1.0000	0.0000	0.9964	0.0000	0.0000
	78	0.9886	0.9946	0.9612	0.9915	0.9750	0.9931	0.9681	0.9381
0.9	1	0.9857	0.9988	0.2778	0.9867	0.8117	0.9927	0.4140	0.2610
	15	0.9286	0.9947	0.6993	0.9197	0.9747	0.9558	0.8143	0.6868
	18	0.9304	0.9742	0.9138	0.8099	0.9895	0.8845	0.9502	0.9051
	55	0.9971	0.9971	0.0000	1.0000	0.0000	0.9985	0.0000	0.0000
	78	0.9825	0.9991	0.9067	0.9799	0.9952	0.9894	0.9489	0.9028

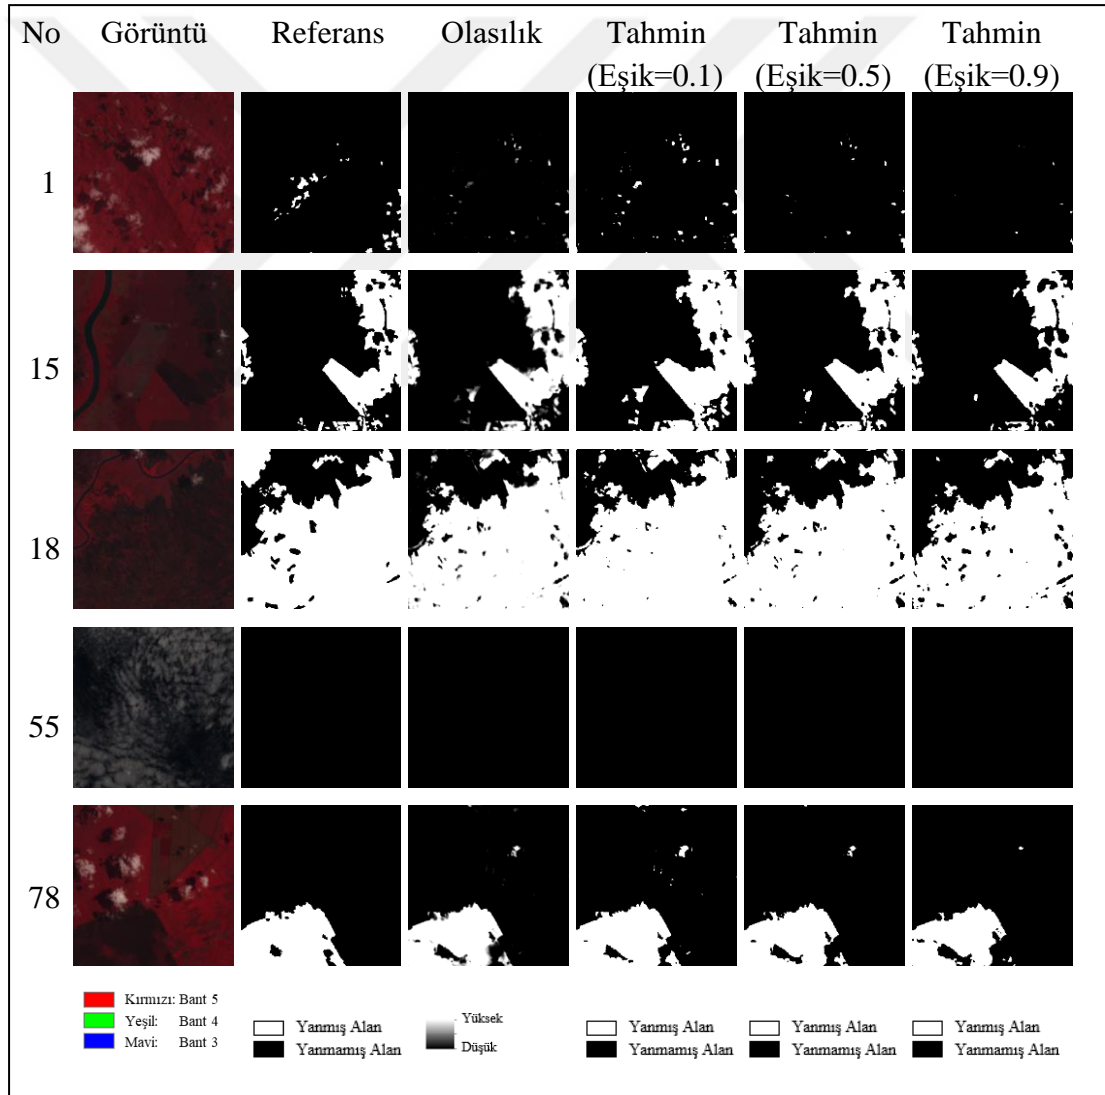
\* 0.0 yanmamış, 1.0 yanmış alanlara karşılık gelmektedir.



#### 4.1.3. Bant kombinasyonu 5,4,3 için test görüntülerini değerlendirme

Şekil 4.4'teki sonuçlar önceki bant kombinasyonlarındaki sonuçlarla karşılaştırıldığında;

Görüntü 1'de tahmin sonuçlarının referans verisi ile benzerlik göstermediği görülmektedir. Burada iyi bir sonuç elde edilememiş, derin öğrenme başarısız olmuştur. Çizelge 4.4'te yanmış alanlara dair F1-skoru değerlerinin eşik değerinin 0.1, 0.5 ve 0.9 olduğu durumlar için sırasıyla %36.92, %21.79 ve %8.08 olduğu görülmektedir. Bu değerler önceki kombinasyondakilere göre çok düşüktür. Bu durum yapılan yorumla paralellik göstermektedir.



Şekil 4.4. Bant kombinasyonu 5,4,3 için 5 adet test görüntüsü, ilgili referans görüntüsü ve sonuçlar

Görüntü 15'te burada da yolun yanmış alan ile karıştırılmadığı görülmektedir. Üstelik burada yolun sağ kısmındaki bölgeler önceki kombinasyonlarda olduğunun aksine yanmış bölgelerle karıştırılmamıştır. Buradaki sonuçlar referans verisine daha çok benzemektedir. Çizelge 4.4'te yanmış alanlara dair F1-skoru değerleri incelendiğinde eşik değerinin 0.1, 0.5 ve 0.9 olduğu durumlar için sırasıyla %87.13, %92.70 ve %92.15 olduğu görülmektedir. Bu değerler genel olarak önceki kombinasyondakilere göre daha yüksektir.

**Çizelge 4.4.** Bant kombinasyonu 5,4,3 için 5 adet test görüntüsüne dair doğruluk metrikleri

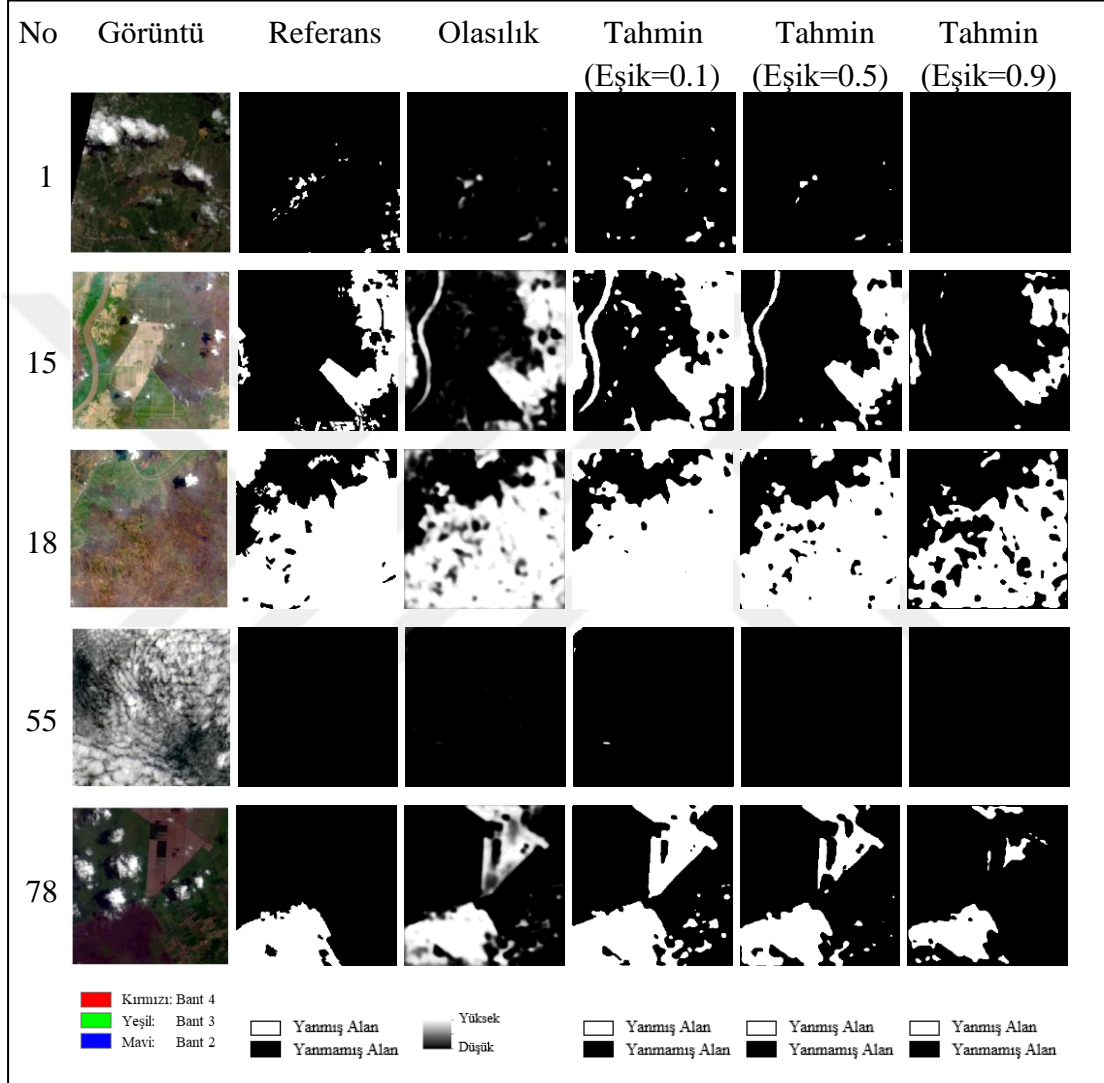
Eşik	Görüntü No.	Doğruluk	Duyarlılık 0.0*	Duyarlılık 1.0*	Kesinlik 0.0*	Kesinlik 1.0*	F1-Skoru 0.0*	F1-Skoru 1.0*	Jaccard Skoru
0.1	1	0.9810	0.9935	0.3054	0.9872	0.4668	0.9903	0.3692	0.2264
	15	0.9341	0.9162	0.9960	0.9988	0.7743	0.9557	0.8713	0.7719
	18	0.9279	0.8573	0.9545	0.8765	0.9467	0.8668	0.9506	0.9058
	55	1.0000	1.0000	x*	1.0000	x*	1.0000	x*	0.0000
	78	0.9834	0.9899	0.9538	0.9899	0.9540	0.9899	0.9539	0.9118
0.5	1	0.9827	0.9985	0.1322	0.9841	0.6196	0.9913	0.2179	0.1223
	15	0.9659	0.9655	0.9672	0.9903	0.8901	0.9777	0.9270	0.8640
	18	0.9353	0.9332	0.9361	0.8463	0.9738	0.8876	0.9546	0.9131
	55	1.0000	1.0000	x*	1.0000	x*	1.0000	x*	0.0000
	78	0.9783	0.9963	0.8963	0.9777	0.9815	0.9869	0.9370	0.8814
0.9	1	0.9823	0.9998	0.0427	0.9825	0.7612	0.9911	0.0808	0.0421
	15	0.9663	0.9905	0.8827	0.9669	0.9639	0.9786	0.9215	0.8545
	18	0.9220	0.9723	0.9031	0.7908	0.9886	0.8722	0.9439	0.8938
	55	1.0000	1.0000	x*	1.0000	x*	1.0000	x*	0.0000
	78	0.9672	0.9988	0.8228	0.9626	0.9932	0.9804	0.9000	0.8183

\* 0.0 yanmamış, 1.0 yanmış alanlara; x metrik hesaplanmadığı durumlara karşılık gelmektedir.

#### 4.1.4. Bant kombinasyonu 4,3,2 için test görüntülerini değerlendirme

Şekil 4.5'teki sonuçlar önceki kombinasyonlardaki sonuçlarla karşılaştırıldığında; Görüntü 15'te yolun yanmış alan olarak sınıflandırıldığı görülmektedir. Derin öğrenme burada yol ile yanmış alanının ayrımını yapamamıştır. Eşik değerinin 0.9 olarak alındığı durumda yolun büyük bir kısmı yanmış alana dahil edilmiyor olması avantaj sağlıyor gibi gözükse de yanmış alanının çeşitli kısımlarının da yanmamış alan olarak sınıflandırılması dezavantaj sağlamaktadır. Yol haricinde referans verisine en yakın tespitin yapıldığı eşik değeri 0.5 değeri olarak gözükmektedir. Eşik değerinin 0.1 olarak seçildiği durumda ise yolun sağ kısmındaki alanlar yanmamış olmasına rağmen yanmış

olarak gösterildiğinden iyi sonuç vermemektedir. Çizelge 4.5'te yanmış alanlara dair F-1 skoru değerleri incelendiğinde eşik değerin 0.1, 0.5 ve 0.9 olduğu durumlar için sırasıyla %72.61, %84.15 ve %73.39 olduğu görülmektedir. Bu değerler önceki kombinasyondakilere göre daha düşüktür. F1-skoruna göre en iyi sonuç eşik değerinin 0.5 olduğu durumda verilmiştir.



Şekil 4.5. Bant kombinasyonu 4,3,2 için 5 adet test görüntüsü, ilgili referans görüntüsü ve sonuçlar

Görüntü 18'de yolun yanmış alan ile karıştırılmadığı görülmektedir. Eşik değeri 0.1 iken referans verisine göre yanmamış olarak belirtilen bazı alanların yanmış gösterildiği görülmektedir. Eşik 0.5 iken referans verisinde yanmış olan bazı bölgelerin tahminde yanmamış olarak gösterildiği görülmektedir. Eşik 0.9 olunca ise en kötü sonuç elde edilmiştir. Çizelge 4.5'e göre eşik değerinin 0.9 olduğu durumda yanmış alanlara dair olan F1-skoru %81.87 ile diğer eşiklerden daha düşük bir değer almıştır.

Görüntü 78’de bulut ve gölgelerinin yanmış alan sonucunu olumsuz etkilemediği ancak tarım alanlarının bir kısmının yanmış alanlar ile karıştırıldığı görülmektedir. Eşik değeri 0.1 iken bu durum daha fazladır. Çizelge 4.5’te yanmış alanlara dair olan kesinlik değeri incelendiğinde tahmindeki yanmış alanların sadece %51.19’unun gerçekte de yanmış alana karşılık geldiği görülmektedir. Bu oran diğer eşiklere göre daha azdır. F1-skoru incelendiğinde en iyi sonuç %71.07 ile eşğin 0.5 olduğu durumda elde edilmiştir.

**Çizelge 4.5.** Bant kombinasyonu 4,3,2 için 5 adet test görüntüsüne dair doğruluk metrikleri

Eşik	Görüntü No.	Doğruluk	Duyarlılık 0.0*	Duyarlılık 1.0*	Kesinlik 0.0*	Kesinlik 1.0*	F1-Skoru 0.0*	F1-Skoru 1.0*	Jaccard Skoru
0.1	1	0.9753	0.9854	0.4326	0.9894	0.3546	0.9874	0.3897	0.2420
	15	0.8329	0.7878	0.9891	0.9960	0.5736	0.8797	0.7261	0.5700
	18	0.9227	0.7692	0.9806	0.9372	0.9185	0.8449	0.9485	0.9021
	55	0.9978	0.9978	0.0000	1.0000	0.0000	0.9989	0.0000	0.0000
	78	0.8284	0.7973	0.9706	0.9920	0.5119	0.8840	0.6703	0.5041
0.5	1	0.9827	0.9981	0.1498	0.9844	0.5967	0.9912	0.2395	0.1360
	15	0.9231	0.9265	0.9114	0.9731	0.7816	0.9492	0.8415	0.7264
	18	0.9116	0.9105	0.9121	0.7960	0.9643	0.8494	0.9375	0.8823
	55	1.0000	1.0000	x*	1.0000	x*	1.0000	x*	0.0000
	78	0.8747	0.8787	0.8566	0.9655	0.6073	0.9200	0.7107	0.5512
0.9	1	0.9818	1.0000	0.0000	0.9818	0.0000	0.9908	0.0000	0.0000
	15	0.9021	0.9884	0.6029	0.8961	0.9375	0.9400	0.7339	0.5796
	18	0.7760	0.9885	0.6960	0.5506	0.9938	0.7073	0.8187	0.6930
	55	1.0000	1.0000	x*	1.0000	x*	1.0000	x*	0.0000
	78	0.9027	0.9656	0.6155	0.9198	0.7969	0.9422	0.6946	0.5321

\* 0.0 yanmamış, 1.0 yanmış alanlara; x metrik hesaplanmadığı durumlara karşılık gelmektedir.

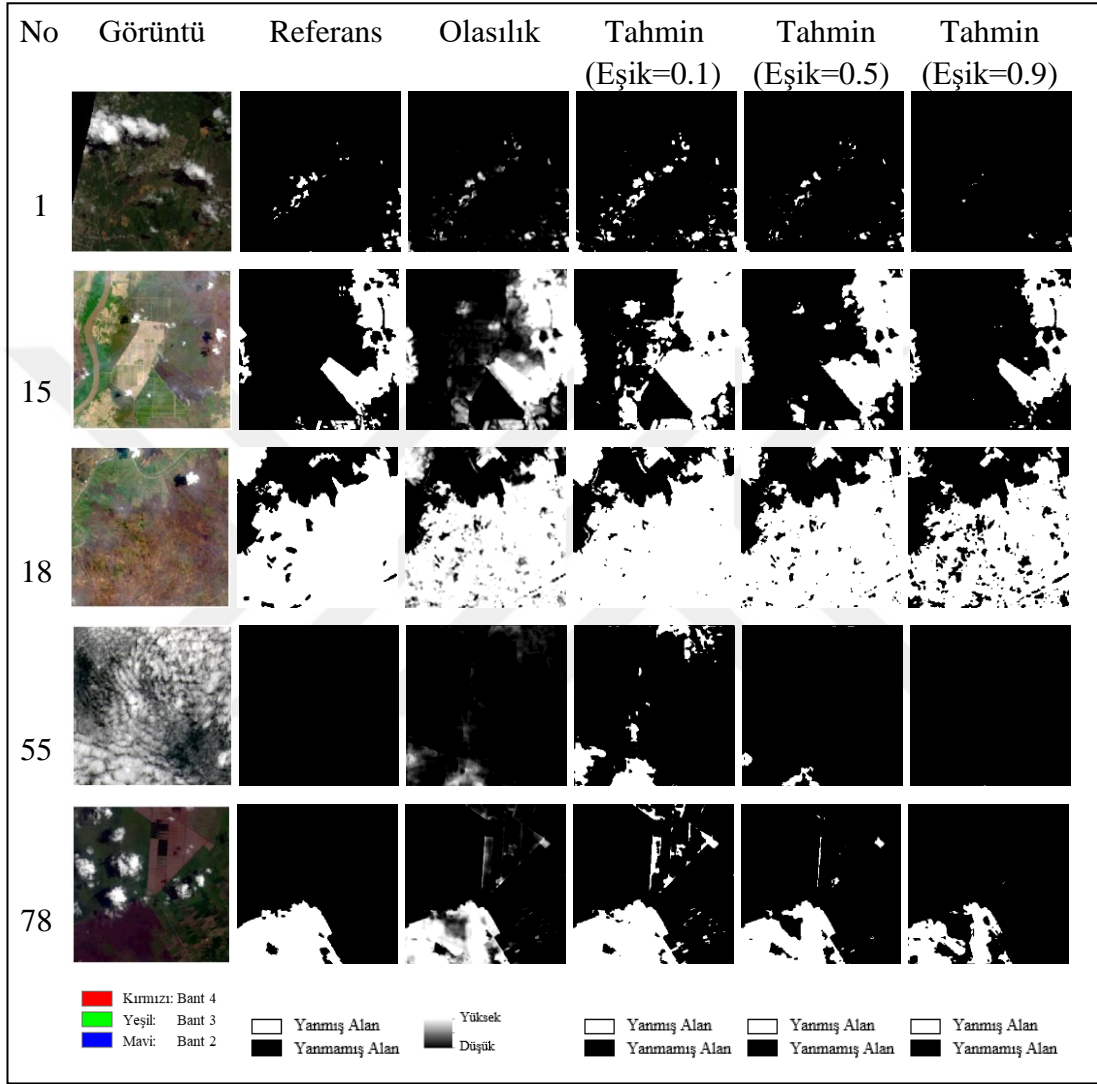
#### 4.1.5. Bant kombinasyonu 4,3,2,5 için test görüntülerini değerlendirme

Şekil 4.6’daki sonuçlar önceki kombinasyonlardaki sonuçlarla karşılaştırıldığında;

Görüntü 55’te en kötü sonucun bu kombinasyonda verildiği görülmektedir. Çizelge 4.6’da yanmış alanlara doğruluk metriğinin eşik değerinin 0.1 ve 0.5 olduğu durumlar için sırasıyla %91.42 ve %98.63 değerlerini aldığı ve bu değerlerin diğer kombinasyondakilerden daha düşük olduğu görülmektedir.

Görüntü 78’de tarım alanlarının bir kısmının yanmış alanlarla karıştırıldığı, sonucun 4,3,2 kombinasyonundakinden daha iyi olduğu ancak diğerlerinden daha kötü olduğu görülmektedir. Çizelge 4.6’a göre eşik değerinin 0.1, 0.5 ve 0.9 olduğu durumlar

için yanmış alanlara dair olan kesinlik değerleri sırasıyla %80.89, %95.59 ve %99.85, F1-skoru değerleri ise sırasıyla %88.91, %91.00 ve %77.09 değerlerini almıştır. Genel olarak bu değerlerin 4,3,2 kombinasyonundakinden daha yüksek, diğerlerinden daha düşük olduğu görülmektedir.



Şekil 4.6. Bant kombinasyonu 4,3,2,5 için 5 adet test görüntüsü, ilgili referans görüntüsü ve sonuçlar

Çizelge 4.6. Bant kombinasyonu 4,3,2,5 için 5 adet test görüntüsüne dair doğruluk metrikleri

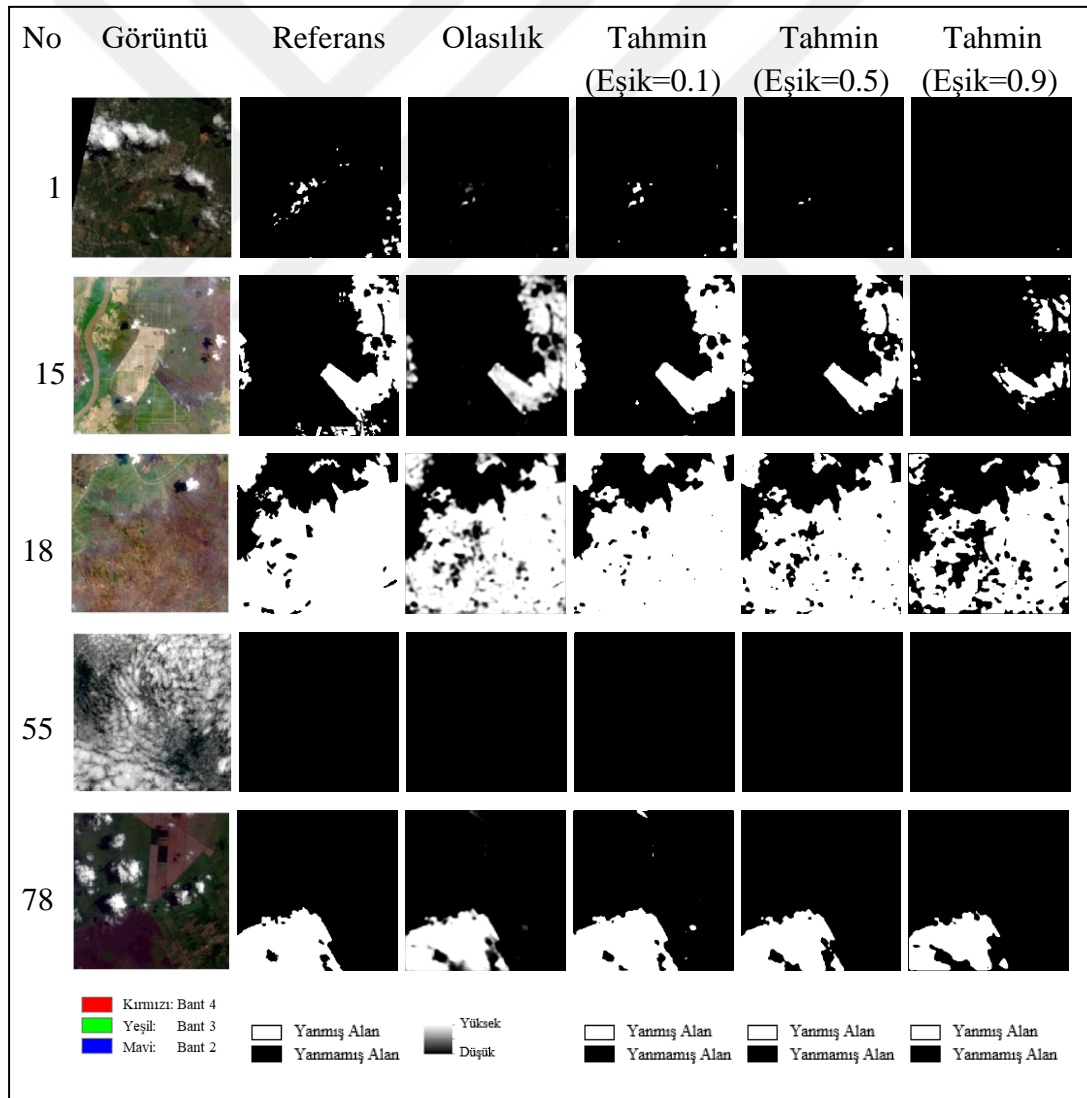
Eşik	Görüntü No.	Doğruluk	Duyarlılık 0.0*	Duyarlılık 1.0*	Kesinlik 0.0*	Kesinlik 1.0*	F1-Skoru 0.0*	F1-Skoru 1.0*	Jaccard Skoru
0.1	1	0.9727	0.9759	0.8033	0.9963	0.3820	0.9860	0.5178	0.3493
	15	0.7905	0.7300	0.9999	1.0000	0.5167	0.8439	0.6814	0.5167
	18	0.9494	0.8214	0.9976	0.9924	0.9368	0.8988	0.9663	0.9347
	55	0.9142	0.9142	0.0000	1.0000	0.0000	0.9552	0.0000	0.0000
	78	0.9558	0.9489	0.9869	0.9970	0.8089	0.9724	0.8891	0.8003

Çizelge 4.6. Bant kombinasyonu 4,3,2,5 için 5 adet test görüntüsüne dair doğruluk metrikleri (devamı)

0.5	1	0.9847	0.9938	0.4979	0.9907	0.5980	0.9922	0.5434	0.3730
	15	0.9209	0.9007	0.9909	0.9971	0.7423	0.9464	0.8488	0.7373
	18	0.9577	0.9291	0.9685	0.9174	0.9732	0.9232	0.9708	0.9433
	55	0.9863	0.9863	0.0000	1.0000	0.0000	0.9931	0.0000	0.0000
	78	0.9691	0.9912	0.8684	0.9717	0.9559	0.9814	0.9100	0.8349
0.9	1	0.9828	0.9992	0.1021	0.9836	0.6971	0.9913	0.1781	0.0978
	15	0.9571	0.9900	0.8431	0.9562	0.9606	0.9728	0.8980	0.8149
	18	0.8819	0.9842	0.8433	0.7030	0.9930	0.8201	0.9120	0.8383
	55	1.0000	1.0000	0.0000	1.0000	0.0000	1.0000	0.0000	0.0000
	78	0.9330	0.9998	0.6279	0.9246	0.9985	0.9607	0.7709	0.6273

\* 0.0 yanmamış, 1.0 yanmış alanlara karşılık gelmektedir.

#### 4.1.6. Bant kombinasyonu 2,3,4,5,6,7 için test görüntülerini değerlendirme



Şekil 4.7. Bant kombinasyonu 2,3,4,5,6,7 için 5 adet test görüntüsü, ilgili referans görüntüsü ve sonuçlar

Şekil 4.7'deki sonuçlar önceki kombinasyonlardaki sonuçlarla karşılaştırıldığında;

Görüntü 1'de sonuçların referans verisi ile benzerlik göstermediği görülmektedir. Çizelge 4.7'e göre yanmış alanlara dair olan F1-skoru değerleri eşik değerinin 0.1, 0.5 ve 0.9 olduğu durumlar için sırasıyla %49.09, %11.65 ve %1.50 olmakla birlikte bu değerler 7,5,4 kombinasyonuna göre çok düşüktür.

**Çizelge 4.7.** Bant kombinasyonu 2,3,4,5,6,7 için 5 adet test görüntüsüne dair doğruluk metrikleri

Eşik	Görüntü No.	Doğruluk	Duyarlılık 0.0*	Duyarlılık 1.0*	Kesinlik 0.0*	Kesinlik 1.0*	F1-Skoru 0.0*	F1-Skoru 1.0*	Jaccard Skoru
0.1	1	0.9872	0.9993	0.3372	0.9878	0.9016	0.9935	0.4909	0.3253
	15	0.9549	0.9702	0.9020	0.9717	0.8972	0.9709	0.8996	0.8176
	18	0.9507	0.8415	0.9918	0.9748	0.9432	0.9033	0.9669	0.9359
	55	1.0000	1.0000	0.0000	1.0000	0.0000	1.0000	0.0000	0.0000
	78	0.9881	0.9890	0.9842	0.9965	0.9514	0.9927	0.9675	0.9371
0.5	1	0.9829	1.0000	0.0619	0.9829	0.9867	0.9914	0.1165	0.0619
	15	0.9443	0.9964	0.7639	0.9360	0.9838	0.9652	0.8600	0.7544
	18	0.9370	0.9410	0.9354	0.8459	0.9768	0.8909	0.9557	0.9151
	55	1.0000	1.0000	x*	1.0000	x*	1.0000	x*	0.0000
	78	0.9815	0.9982	0.9049	0.9796	0.9912	0.9888	0.9461	0.8976
0.9	1	0.9819	1.0000	0.0075	0.9819	1.0000	0.9909	0.0150	0.0075
	15	0.8557	1.0000	0.3557	0.8432	0.9996	0.9149	0.5247	0.3557
	18	0.8299	0.9934	0.7683	0.6177	0.9968	0.7617	0.8677	0.7664
	55	1.0000	1.0000	x*	1.0000	x*	1.0000	x*	0.0000
	78	0.9590	0.9998	0.7729	0.9526	0.9986	0.9756	0.8714	0.7721

\* 0.0 yanmamış, 1.0 yanmış alanlara; x metrik hesaplanmadığı durumlara karşılık gelmektedir.

Bant kombinasyonlarının her biri için 1, 15, 18, 55 ve 78 numaralı görüntüler kullanılarak elde edilen hata matrisleri EK-7 ile EK-9 arasında gösterilmiştir.

#### 4.1.7. Bant kombinasyonları için istatistiksel değerlendirme

Aşağıda ise 92 adet test görüntüsü için hesaplanan doğruluk metriklerinin minimum, maksimum, ortalama ve standart sapma değerleri gösterilmiştir. Bunlar da yukarıda olduğu gibi Adam optimizasyon algoritması ve farklı bant kombinasyonları kullanılarak elde edilen sonuçlardır. Sütunlarda ortalamalar arasındaki en yüksek değerler koyu olarak gösterilmiştir.

Çizelge 4.8'deki 7,5,4 bant kombinasyonunda ortalama değerleri incelendiğinde en yüksek doğruluğa %97.43 ile eşik değerin 0.5 olduğu durumda ulaşılmıştır. Yanmış alanlara dair ortalama duyarlılık değeri en yüksek %83.64 ile eşik değerin 0.1 olduğu durumda, ortalama kesinlik değeri en yüksek %93.66 ile eşik değerin 0.9 olduğu durumda, ortalama F1-skoru değeri en yüksek %76.01 ile eşik değerin 0.5 olduğu durumda elde edilmiştir. Yanmamış alanlar için ise ortalama duyarlılık değeri en yüksek %99.85 ile eşik değerin 0.9 olduğu durumda, ortalama kesinlik değeri en yüksek %98.78 ile eşik değerin 0.1 olduğu durumda, ortalama F1-skoru değeri en yüksek %98.18 ile eşik değerin 0.5 olduğu durumda elde edilmiştir. Ortalama Jaccard skoru ise %63.99 değeri ile eşik değeri 0.1 iken en yüksek değeri almıştır.

Çizelge 4.8. Bant kombinasyonu 7,5,4 için doğruluk metriklerinin istatistiksel sonuçları

Eşik	İstatistik	Doğruluk	Duyarlılık 0.0*	Duyarlılık 1.0*	Kesinlik 0.0*	Kesinlik 1.0*	F1-Skoru 0.0*	F1-Skoru 1.0*	Jaccard Skoru
0.1	Min.	0.7919	0.7290	0.0000	0.7674	0.0000	0.8161	0.0000	0.0000
	Maks.	1.0000	1.0000	1.0000	1.0000	0.9682	1.0000	0.9734	0.9482
	Ort.	0.9741	0.9749	<b>0.8364</b>	<b>0.9878</b>	0.7047	0.9809	0.7509	<b>0.6399</b>
	Std.	0.0339	0.0412	0.2771	0.0323	0.2745	0.0327	0.2654	0.2717
0.5	Min.	0.7401	0.9229	0.0000	0.6792	0.0000	0.7974	0.0000	0.0000
	Maks.	1.0000	1.0000	0.9768	1.0000	0.9994	1.0000	0.9765	0.9541
	Ort.	<b>0.9743</b>	0.9924	0.7203	0.9728	0.8411	<b>0.9818</b>	<b>0.7601</b>	0.6328
	Std.	0.0411	0.0134	0.2612	0.0557	0.2579	0.0353	0.2467	0.2815
0.9	Min.	0.6572	0.9784	0.0000	0.4963	0.0000	0.6595	0.0000	0.0000
	Maks.	1.0000	1.0000	0.9192	1.0000	1.0000	1.0000	0.9536	0.9113
	Ort.	0.9609	<b>0.9985</b>	0.5268	0.9527	<b>0.9366</b>	0.9730	0.6382	0.4788
	Std.	0.0599	0.0033	0.2644	0.0822	0.2002	0.0514	0.2626	0.2888

\* 0.0 yanmamış, 1.0 yanmış alanlara karşılık gelmektedir.

Çizelge 4.9'daki 5,3,7 bant kombinasyonunda ortalama değerleri incelendiğinde en yüksek doğruluğa %97.22 ile eşik değerin 0.5 olduğu durumda ulaşılmıştır. Yanmış alanlara dair ortalama duyarlılık değeri en yüksek %80.96 ile eşik değerin 0.1 olduğu durumda, ortalama kesinlik değeri en yüksek %89.98 ile eşik değerin 0.9 olduğu durumda, ortalama F1-skoru değeri en yüksek %75.39 ile eşik değerin 0.5 olduğu durumda elde edilmiştir. Yanmamış alanlar için ise ortalama duyarlılık değeri en yüksek %99.80 ile eşik değerin 0.9 olduğu durumda, ortalama kesinlik değeri en yüksek %98.20 ile eşik değerin 0.1 olduğu durumda, ortalama F1-skoru değeri en yüksek %97.98 ile eşik



değerin 0.5 olduğu durumda elde edilmiştir. Ortalama Jaccard skoru ise %62.43 ile eşik değer 0.5 iken en yüksek değeri almıştır.

**Çizelge 4.9.** Bant kombinasyonu 5,3,7 için doğruluk metriklerinin istatistiksel sonuçları

Eşik	İstatistik	Doğruluk	Duyarlılık 0.0*	Duyarlılık 1.0*	Kesinlik 0.0*	Kesinlik 1.0*	F1-Skoru 0.0*	F1-Skoru 1.0*	Jaccard Skoru
0.1	Min.	0.7421	0.7604	0.0000	0.6944	0.0000	0.7600	0.0000	0.0000
	Maks.	1.0000	1.0000	1.0000	1.0000	0.9472	1.0000	0.9653	0.9329
	Ort.	0.9700	0.9745	<b>0.8096</b>	<b>0.9820</b>	0.6779	0.9778	0.7260	0.6065
	Std.	0.0408	0.0370	0.2815	0.0489	0.2645	0.0398	0.2613	0.2651
0.5	Min.	0.6854	0.9064	0.0000	0.6165	0.0000	0.7339	0.0000	0.0000
	Maks.	1.0000	1.0000	0.9886	1.0000	0.9943	1.0000	0.9739	0.9492
	Ort.	<b>0.9722</b>	0.9910	0.7180	0.9709	0.8247	<b>0.9798</b>	<b>0.7539</b>	<b>0.6243</b>
	Std.	0.0480	0.0148	0.2669	0.0657	0.2474	0.0426	0.2457	0.2787
0.9	Min.	0.6094	0.9716	0.0000	0.4708	0.0000	0.6342	0.0000	0.0000
	Maks.	1.0000	1.0000	0.9299	1.0000	1.0000	1.0000	0.9614	0.9257
	Ort.	0.9608	<b>0.9980</b>	0.5259	0.9532	<b>0.8998</b>	0.9729	0.6333	0.4935
	Std.	0.0647	0.0042	0.2723	0.0860	0.2509	0.0549	0.2748	0.2831

\* 0.0 yanmamış, 1.0 yanmış alanlara karşılık gelmektedir.

Çizelge 4.10'daki 5,4,3 bant kombinasyonunda ortalama değerler incelendiğinde en yüksek doğruluğa %96.79 ile eşik değer 0.1 olduğu durumda ulaşılmıştır. Yanmış alanlara dair ortalama duyarlılık değeri en yüksek %73.93 ile eşik değer 0.1 olduğu durumda, ortalama kesinlik değeri en yüksek %86.10 ile eşik değer 0.9 olduğu durumda, ortalama F1-skoru değeri en yüksek %71.36 ile eşik değer 0.1 olduğu durumda elde edilmiştir. Yanmamış alanlar için ise ortalama duyarlılık değeri en yüksek %99.67 ile eşik değer 0.9 olduğu durumda, ortalama kesinlik değeri en yüksek %97.78 ile eşik değer 0.1 olduğu durumda, ortalama F1-skoru değeri en yüksek %97.68 ile eşik değer 0.5 olduğu durumda elde edilmiştir. Ortalama Jaccard skoru ise %57.04 ile eşik değer 0.1 iken en yüksek değeri almıştır.

**Çizelge 4.10.** Bant kombinasyonu 5,4,3 için doğruluk metriklerinin istatistiksel sonuçları

Eşik	İstatistik	Doğruluk	Duyarlılık 0.0*	Duyarlılık 1.0*	Kesinlik 0.0*	Kesinlik 1.0*	F1-Skoru 0.0*	F1-Skoru 1.0*	Jaccard Skoru
0.1	Min.	0.7062	0.6758	0.0000	0.6783	0.0000	0.6968	0.0000	0.0000
	Maks.	1.0000	1.0000	1.0000	1.0000	0.9746	1.0000	0.9756	0.9524
	Ort.	<b>0.9679</b>	0.9746	<b>0.7393</b>	<b>0.9778</b>	0.7145	0.9758	<b>0.7136</b>	<b>0.5704</b>
	Std.	0.0455	0.0455	0.2659	0.0528	0.2613	0.0468	0.2559	0.2803

**Çizelge 4.10.** Bant kombinasyonu 5,4,3 için doğruluk metriklerinin istatistiksel sonuçları (devamı)

0.5	Min.	0.6685	0.8418	0.0000	0.6233	0.0000	0.7277	0.0000	0.0000
	Maks.	1.0000	1.0000	0.9913	1.0000	1.0000	1.0000	0.9546	0.9131
	Ort.	0.9673	0.9903	0.5962	0.9653	0.8114	<b>0.9768</b>	0.6688	0.5243
	Std.	0.0499	0.0209	0.2786	0.0657	0.2700	0.0447	0.2700	0.2865
0.9	Min.	0.6141	0.9384	0.0000	0.5438	0.0000	0.6886	0.0000	0.0000
	Maks.	1.0000	1.0000	0.9031	1.0000	1.0000	1.0000	0.9439	0.8938
	Ort.	0.9577	<b>0.9967</b>	0.4399	0.9505	<b>0.8610</b>	0.9713	0.5496	0.4029
	Std.	0.0609	0.0087	0.2758	0.0804	0.2874	0.0511	0.2876	0.2820

\* 0.0 yanmamış, 1.0 yanmış alanlara karşılık gelmektedir.

Çizelge 4.11'deki 4,3,2 bant kombinasyonunda ortalama değerleri incelendiğinde en yüksek doğruluğa %95.18 ile eşik değerin 0.5 olduğu durumda ulaşılmıştır. Yanmış alanlara dair ortalama duyarlılık değeri en yüksek %62.97 ile eşik değerin 0.1 olduğu durumda, ortalama kesinlik değeri en yüksek %69.62 ile eşik değerin 0.5 olduğu durumda, ortalama F1-skoru değeri en yüksek %53.96 ile eşik değerin 0.1 olduğu durumda elde edilmiştir. Yanmamış alanlar için ise ortalama duyarlılık değeri en yüksek %99.70 ile eşik değerin 0.9 olduğu durumda, ortalama kesinlik değeri en yüksek %97.57 ve ortalama F1-skoru değeri en yüksek %96.66 ile eşik değerin 0.5 olduğu durumlarda elde edilmiştir. Ortalama Jaccard skoru ise %42.33 değeri ile eşik değeri 0.1 iken en yüksek değeri almıştır.

**Çizelge 4.11.** Bant kombinasyonu 4,3,2 için doğruluk metriklerinin istatistiksel sonuçları

Eşik	İstatistik	Doğruluk	Duyarlılık 0.0*	Duyarlılık 1.0*	Kesinlik 0.0*	Kesinlik 1.0*	F1-Skoru 0.0*	F1-Skoru 1.0*	Jaccard Skoru
0.1	Min.	0.7041	0.4276	0.0000	0.7534	0.0000	0.5760	0.0000	0.0000
	Maks.	1.0000	1.0000	0.9911	1.0000	0.9185	1.0000	0.9485	0.9021
	Ort.	0.9436	0.9444	<b>0.6297</b>	<b>0.9757</b>	0.5177	0.9575	<b>0.5396</b>	<b>0.4233</b>
	Std.	0.0660	0.0941	0.3374	0.0443	0.2865	0.0672	0.2996	0.2692
0.5	Min.	0.6819	0.7474	0.0000	0.6151	0.0000	0.6748	0.0000	0.0000
	Maks.	1.0000	1.0000	0.9340	1.0000	1.0000	1.0000	0.9375	0.8823
	Ort.	<b>0.9518</b>	0.9833	0.4249	0.9522	<b>0.6962</b>	<b>0.9666</b>	0.4882	0.3650
	Std.	0.0594	0.0392	0.3167	0.0711	0.3366	0.0527	0.3206	0.2885
0.9	Min.	0.5337	0.9410	0.0000	0.3396	0.0000	0.4994	0.0000	0.0000
	Maks.	1.0000	1.0000	0.7397	1.0000	1.0000	1.0000	0.8389	0.7224
	Ort.	0.9302	<b>0.9970</b>	0.1997	0.9222	0.6904	0.9543	0.2782	0.1786
	Std.	0.0891	0.0097	0.2212	0.1119	0.4409	0.0752	0.2784	0.2129

\* 0.0 yanmamış, 1.0 yanmış alanlara karşılık gelmektedir.

Çizelge 4.12'deki 4,3,2,5 bant kombinasyonunda ortalama değerleri incelendiğinde en yüksek doğruluğa %96.77 ile eşik değerin 0.5 olduğu durumda ulaşılmıştır. Yanmış alanlara dair ortalama duyarlılık değeri en yüksek %81.31 ile eşik değerin 0.1 olduğu durumda, ortalama kesinlik değeri en yüksek %85.20 ile eşik değerin 0.9 olduğu durumda, ortalama F1-skoru değeri en yüksek %67.64 ile eşik değerin 0.5 olduğu durumda elde edilmiştir. Yanmamış alanlar için ise ortalama duyarlılık değeri en yüksek %99.77 ile eşik değerin 0.9 olduğu durumda, ortalama kesinlik değeri en yüksek %99.00 ile eşik değerin 0.1 olduğu durumda, ortalama F1-skoru değeri en yüksek %67.64 ile eşik değerin 0.5 olduğu durumda elde edilmiştir. Ortalama Jaccard skoru ise %55.64 değeri ile eşik değeri 0.1 iken en yüksek değeri almıştır.

Çizelge 4.12. Bant kombinasyonu 4,3,2,5 için doğruluk metriklerinin istatistiksel sonuçları

Eşik	İstatistik	Doğruluk	Duyarlılık 0.0*	Duyarlılık 1.0*	Kesinlik 0.0*	Kesinlik 1.0*	F1-Skoru 0.0*	F1-Skoru 1.0*	Jaccard Skoru
0.1	Min.	0.7248	0.4538	0.0000	0.7929	0.0000	0.6034	0.0000	0.0000
	Maks.	1.0000	1.0000	1.0000	1.0000	0.9960	1.0000	0.9663	0.9347
	Ort.	0.9509	0.9396	<b>0.8131</b>	<b>0.9900</b>	0.5996	0.9620	0.6721	0.5550
	Std.	0.0601	0.0941	0.2983	0.0282	0.2781	0.0640	0.2803	0.2725
0.5	Min.	0.7191	0.8097	0.0000	0.6348	0.0000	0.7117	0.0000	0.0000
	Maks.	1.0000	1.0000	0.9909	1.0000	1.0000	1.0000	0.9708	0.9433
	Ort.	<b>0.9677</b>	0.9806	0.6391	0.9730	0.7548	<b>0.9764</b>	<b>0.6764</b>	<b>0.5564</b>
	Std.	0.0455	0.0369	0.2925	0.0556	0.2992	0.0448	0.2854	0.2850
0.9	Min.	0.6261	0.9581	0.0000	0.4330	0.0000	0.6006	0.0000	0.0000
	Maks.	1.0000	1.0000	0.8481	1.0000	1.0000	1.0000	0.9127	0.8395
	Ort.	0.9490	<b>0.9977</b>	0.3471	0.9407	<b>0.8520</b>	0.9658	0.4513	0.3215
	Std.	0.0692	0.0062	0.2765	0.0917	0.3124	0.0594	0.3046	0.2783

\* 0.0 yanmamış, 1.0 yanmış alanlara karşılık gelmektedir.

Çizelge 4.13'teki 2,3,4,5,6,7 bant kombinasyonunda ortalama değerleri incelendiğinde en yüksek doğruluğa %96.09 ile eşik değerin 0.1 olduğu durumda ulaşılmıştır. Yanmış alanlara dair ortalama duyarlılık değeri en yüksek %60.71 ile eşik değerin 0.1 olduğu durumda, ortalama kesinlik değeri en yüksek %86.01 ile eşik değerin 0.5 olduğu durumda, ortalama F1-skoru değeri en yüksek %62.63 ile eşik değerin 0.1 olduğu durumda elde edilmiştir. Yanmamış alanlar için ise ortalama duyarlılık değeri en yüksek %99.97 ile eşik değerin 0.9 olduğu durumda, ortalama kesinlik değeri en yüksek %96.49 ile eşik değerin 0.1 olduğu durumda, ortalama F1-skoru değeri en yüksek %97.33

ile eşik değerin 0.1 olduğu durumda elde edilmiştir. Ortalama Jaccard skoru ise %52.08 ile eşik değeri 0.1 iken en yüksek değeri almıştır.

**Çizelge 4.13.** Bant kombinasyonu 2,3,4,5,6,7 için doğruluk metriklerinin istatistiksel sonuçları

Eşik	İstatistik	Doğruluk	Duyarlılık 0.0*	Duyarlılık 1.0*	Kesinlik 0.0*	Kesinlik 1.0*	F1-Skoru 0.0*	F1-Skoru 1.0*	Jaccard Skoru
0.1	Min.	0.5833	0.8322	0.0000	0.5630	0.0000	0.7079	0.0000	0.0000
	Maks.	1.0000	1.0000	0.9918	1.0000	1.0000	1.0000	0.9675	0.9371
	Ort.	<b>0.9609</b>	0.9857	<b>0.6071</b>	<b>0.9649</b>	0.7434	<b>0.9733</b>	<b>0.6263</b>	<b>0.5208</b>
	Std.	0.0722	0.0299	0.3540	0.0800	0.2813	0.0524	0.3219	0.3116
0.5	Min.	0.5663	0.9410	0.0000	0.4596	0.0000	0.6209	0.0000	0.0000
	Maks.	1.0000	1.0000	0.9566	1.0000	1.0000	1.0000	0.9690	0.9398
	Ort.	0.9525	0.9964	0.4637	0.9474	<b>0.8601</b>	0.9685	0.5509	0.4088
	Std.	0.0823	0.0092	0.3187	0.0967	0.2850	0.0624	0.3275	0.3191
0.9	Min.	0.4677	0.9934	0.0000	0.3160	0.0000	0.4796	0.0000	0.0000
	Maks.	1.0000	1.0000	0.8603	1.0000	1.0000	1.0000	0.9236	0.8580
	Ort.	0.9331	<b>0.9997</b>	0.2564	0.9256	0.8018	0.9567	0.3501	0.2307
	Std.	0.0992	0.0010	0.2469	0.1153	0.3943	0.0772	0.2985	0.2458

\* 0.0 yanmamış, 1.0 yanmış alanlara karşılık gelmektedir.

Yanmış alanlar için yukarıda uygulamaları gerçekleştirilmiş olan kombinasyonların genel olarak eşik değerin 0.1 ve 0.5 olduğu durumlarda daha iyi sonuçlar verdiği görülmektedir. Eşik değerin 0.9 olduğu durumlarda ise daha kötü sonuçlarla karşılaşmıştır. Bantlar açısından incelendiğinde en iyi sonuçları veren kombinasyon 7,5,4 olarak gözükmektedir. Bununla birlikte en iyi sonuçları veren ikinci kombinasyon 5,3,7 kombinasyonudur. En kötü sonucu veren kombinasyon ise 4,3,2 kombinasyonu olmaktadır.

## 4.2. Optimizasyon Algoritmalarının Karşılaştırılması

Bir önceki bölümde Adam optimizasyon algoritması kullanılmış ve bant kombinasyonlarından 7,5,4 kombinasyonu en iyi sonucu vermiştir. Bu sebeple çalışmanın bu bölümünde 7,5,4 kombinasyonu ile derin öğrenme modelinde eğitim işleminde Adam optimizasyon algoritmasına ek olarak AdaGrad ve AdaMax optimizasyon algoritmaları da kullanılmıştır. Ayrıca bir önceki bölümde en kötü sonucu veren 4,3,2 bant kombinasyonu da kullanılarak aynı işlemler tekrarlanmıştır. Sürece ilişkin bilgiler Çizelge 4.14'te özetlenmiştir.

Çizelge 4.14. Eğitim ile ilgili bilgiler

No	Bantlar	Öğrenme Hızı	Optimizasyon	Süre
7	7,5,4	0.001	AdaGrad	1 saat 47 dakika
8	7,5,4	0.001	AdaMax	1 saat 46 dakika
9	4,3,2	0.00001	AdaGrad	1 saat 56 dakika
10	4,3,2	0.00001	AdaMax	1 saat 57 dakika

Çizelge 4.14'te belirtilen bant kombinasyonlarındaki eğitim ve doğrulama veri setleri kullanılarak her bir kombinasyon için eğitim işlemi gerçekleştirilmiştir. Eğitim süresi her biri yaklaşık 1 buçuk ile 2 saat arasında değişmektedir. Eğitim sonucu elde edilen kayıp ve doğruluk grafikleri EK-1'de verilmiştir. Test işlemi için Çizelge 4.14'te belirtilen bant kombinasyonlarındaki test veri setleri modele girdi olarak verilmiştir.

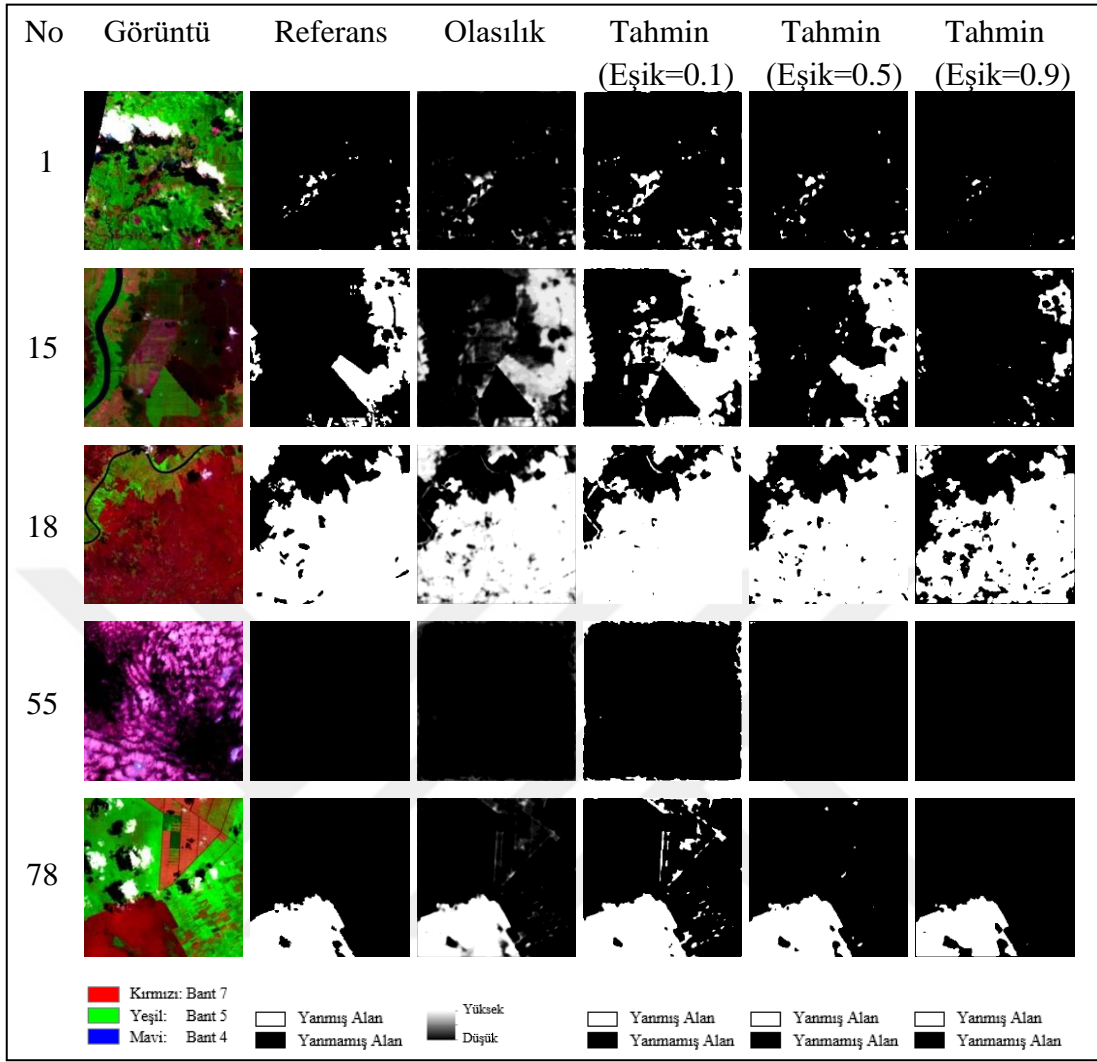
#### 4.2.1. Bant kombinasyonu 7,5,4 ve AdaGrad algoritması için test görüntülerini değerlendirme

Şekil 4.8'deki sonuçlar 7,5,4 bant kombinasyonu ve Adam algoritması kullanılan sonuçlarla karşılaştırıldığında;

Görüntü 15'te eşik değer 0.1 iken yanmış alanın solundaki tarım alanının yanmış alan olarak karıştırıldığı görülmektedir. Çizelge 4.15'te yanmış alanlara dair olan kesinlik değerine göre tahminde yanmış olarak belirlenen alanların sadece %55.16'sının gerçekte de yanmış olduğu görülmektedir. Bu oran Adam kullanıldığında %75.91 idi. Eşik değer 0.9 iken yanmış alanların çoğu tespit edilememiştir. Çizelge 4.15'te yanmış alanlara dair olan duyarlılık değerleri incelendiğinde gerçekte yanmış olarak belirlenen alanların sadece %25.57'sinin tahminde de yanmış olduğu görülmektedir. F1-skoru sonuçları ise eşik değer 0.1, 0.5 ve 0.9 iken sırasıyla %71.03, %90.52 ve %40.73'tür.

Görüntü 18'de eşik değer 0.1 iken yolun yanmış alan ile karıştırıldığı, referansta yanmamış olan bazı kısımların da tahminde yanmış olarak belirlendiği görülmektedir. Çizelge 4.15'te yanmış alanlara dair olan F1-skoru sonuçları incelendiğinde en yüksek değer %97.29 ile eşik değer 0.5 iken elde edilmiştir.

Görüntü 78'de eşik değeri 0.1 iken tarım alanlarının bir kısmının yanmış alanlar ile karıştırıldığı görülmektedir. Çizelge 4.15'te yanmış alanlara dair olan kesinlik değerinin eşik değer 0.1 iken %78.03 ile diğer eşiklerden daha düşük olduğu görülmektedir. F1-skoru sonuçları incelendiğinde en yüksek değer %97.52 ile eşik değer 0.5 iken elde edilmiştir.



Şekil 4.8. Bant kombinasyonu 7,5,4 ve AdaGrad algoritması için 5 adet test görüntüsü, ilgili referans görüntüsü ve sonuçlar

Çizelge 4.15. Bant kombinasyonu 7,5,4 ve AdaGrad algoritması için 5 adet test görüntüsüne dair doğruluk metrikleri

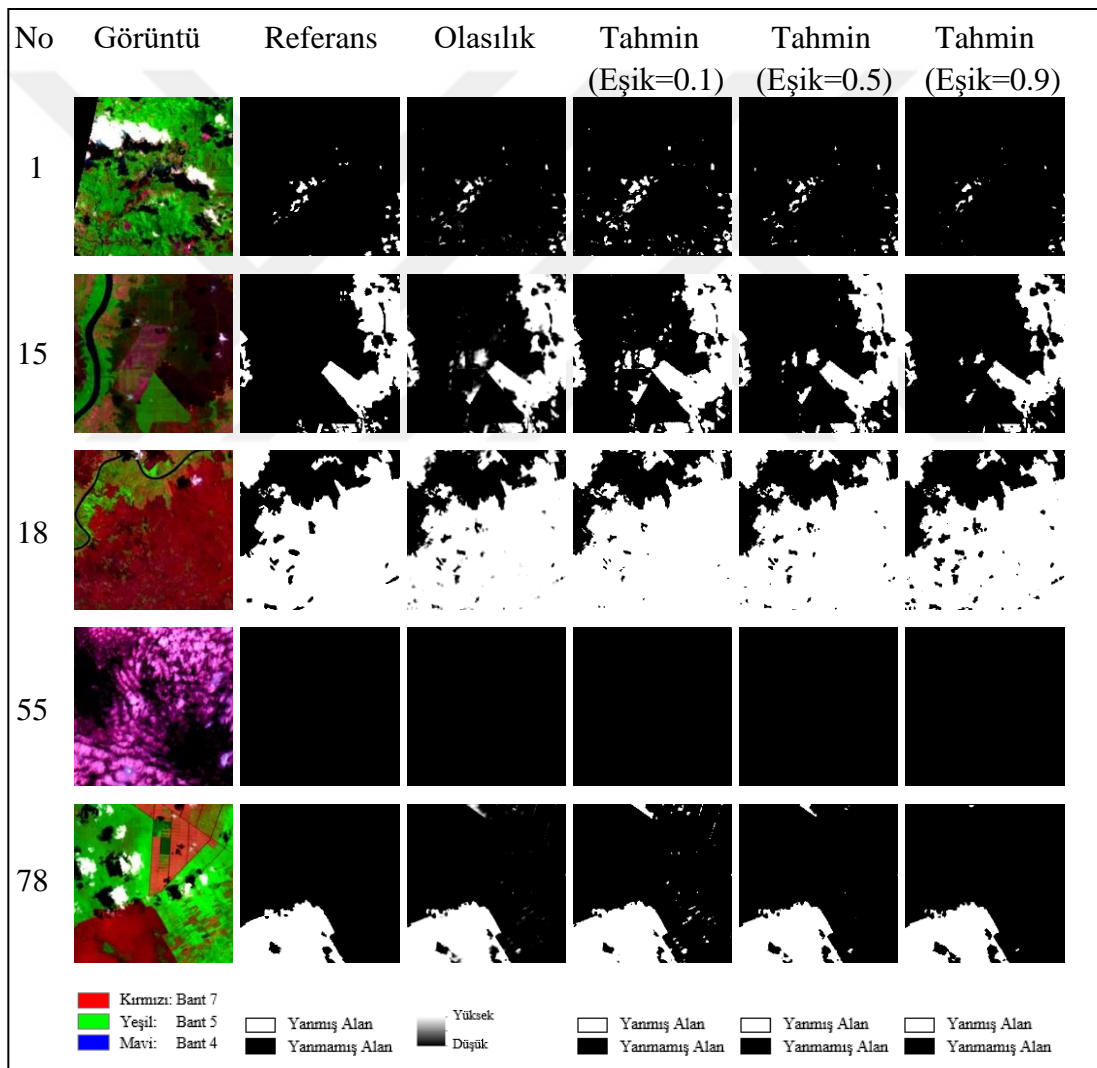
Eşik	Görüntü No.	Doğruluk	Duyarlılık 0.0*	Duyarlılık 1.0*	Kesinlik 0.0*	Kesinlik 1.0*	F1-Skoru 0.0*	F1-Skoru 1.0*	Jaccard Skoru
0.1	1	0.9594	0.9607	0.8887	0.9979	0.2957	0.9789	0.4438	0.2852
	15	0.8178	0.7661	0.9970	0.9989	0.5516	0.8671	0.7103	0.5507
	18	0.9263	0.7319	0.9996	0.9986	0.9082	0.8447	0.9517	0.9079
	55	0.9674	0.9674	0.0000	1.0000	0.0000	0.9834	0.0000	0.0000
	78	0.9492	0.9384	0.9985	0.9996	0.7803	0.9681	0.8760	0.7793
0.5	1	0.9842	0.9923	0.5515	0.9917	0.5696	0.9920	0.5604	0.3892
	15	0.9556	0.9586	0.9454	0.9838	0.8682	0.9710	0.9052	0.8268
	18	0.9603	0.9030	0.9820	0.9496	0.9641	0.9257	0.9729	0.9473
	55	0.9997	0.9997	0.0000	1.0000	0.0000	0.9998	0.0000	0.0000
	78	0.9910	0.9921	0.9858	0.9969	0.9648	0.9945	0.9752	0.9516

**Çizelge 4.15.** Bant kombinasyonu 7,5,4 ve AdaGrad algoritması için 5 adet test görüntüsüne dair doğruluk metrikleri (devamı)

0.9	1	0.9843	0.9997	0.1573	0.9846	0.8952	0.9921	0.2676	0.1545
	15	0.8333	1.0000	0.2557	0.8231	0.9997	0.9030	0.4073	0.2557
	18	0.8973	0.9867	0.8636	0.7316	0.9942	0.8402	0.9243	0.8593
	55	1.0000	1.0000	x*	1.0000	x*	1.0000	x*	0.0000
	78	0.9805	0.9988	0.8968	0.9779	0.9938	0.9882	0.9428	0.8918

\* 0.0 yanmamış, 1.0 yanmış alanlara; x metrik hesaplanmadığı durumlara karşılık gelmektedir.

#### 4.2.2. Bant kombinasyonu 7,5,4 ve AdaMax algoritması test görüntülerini değerlendirme



**Şekil 4.9.** Bant kombinasyonu 7,5,4 ve AdaMax algoritması için 5 adet test görüntüsü, ilgili referans görüntüsü ve sonuçlar

Şekil 4.9'daki sonuçlar 7,5,4 bant kombinasyonunda Adam ve AdaGrad algoritmaları kullanılan sonuçlarla karşılaştırıldığında;

Görüntü 15'te eşik değeri 0.1 olduğu durumda yanmış alanın solundaki tarım alanının yanmış alan olarak karıştırıldığı ancak bunun AdaGrad'ta olduğundan daha az olduğu görülmektedir. Çizelge 4.16'ya göre eşik değer 0.1 için yanmış alanlara dair olan F1-skoru değeri %85.63'tür. Bu değer Adam'daki ile neredeyse aynı, AdaGrad'takinden ise daha fazladır. Bu durum yapılan yorumla paralellik göstermektedir.

**Çizelge 4.16.** Bant kombinasyonu 7,5,4 ve AdaMax algoritması için 5 adet test görüntüsüne dair doğruluk metrikleri

Eşik	Görüntü No.	Doğruluk	Duyarlılık 0.0*	Duyarlılık 1.0*	Kesinlik 0.0*	Kesinlik 1.0*	F1-Skoru 0.0*	F1-Skoru 1.0*	Jaccard Skoru
0.1	1	0.9807	0.9828	0.8669	0.9975	0.4830	0.9901	0.6204	0.4497
	15	0.9263	0.9105	0.9810	0.9940	0.7598	0.9504	0.8563	0.7488
	18	0.9543	0.8390	0.9978	0.9931	0.9427	0.9095	0.9695	0.9407
	55	1.0000	1.0000	0.0000	1.0000	0.0000	1.0000	0.0000	0.0000
	78	0.9806	0.9777	0.9937	0.9986	0.9072	0.9881	0.9485	0.9020
0.5	1	0.9912	0.9964	0.7088	0.9946	0.7864	0.9955	0.7456	0.5944
	15	0.9583	0.9614	0.9475	0.9845	0.8764	0.9728	0.9105	0.8358
	18	0.9701	0.9215	0.9884	0.9676	0.9709	0.9440	0.9796	0.9600
	55	1.0000	1.0000	x*	1.0000	x*	1.0000	x*	0.0000
	78	0.9879	0.9923	0.9678	0.9929	0.9648	0.9926	0.9663	0.9348
0.9	1	0.9898	0.9997	0.4586	0.9900	0.9665	0.9948	0.6220	0.4514
	15	0.9577	0.9879	0.8531	0.9588	0.9530	0.9731	0.9003	0.8187
	18	0.9616	0.9723	0.9576	0.8962	0.9892	0.9327	0.9731	0.9477
	55	1.0000	1.0000	x*	1.0000	x*	1.0000	x*	0.0000
	78	0.9850	0.9980	0.9261	0.9840	0.9900	0.9909	0.9570	0.9175

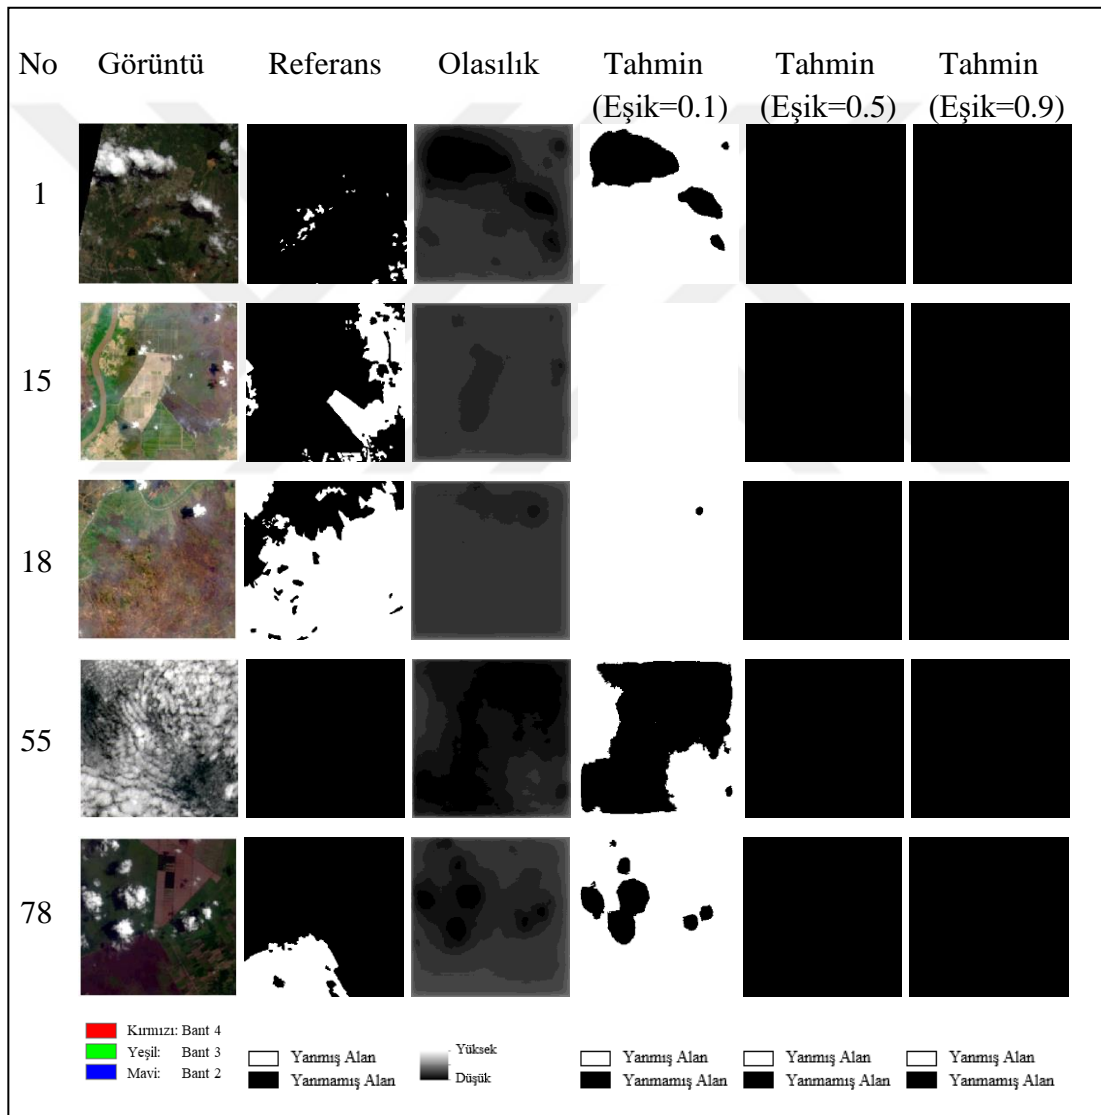
\* 0.0 yanmamış, 1.0 yanmış alanlara; x metrik hesaplanmadığı durumlara karşılık gelmektedir.

#### 4.2.3. Bant kombinasyonu 4,3,2 ve AdaGrad algoritması için test görüntülerini değerlendirme

Şekil 4.10 incelendiğinde olasılık ve tahmin sonuçlarının iyi olmadığı, derin öğrenmenin burada başarısız olduğu görülmektedir. Çizelge 4.17'deki sonuçlar incelendiğinde de çok düşük değerlerle karşılaşılmaktadır. Yüksek sonuçlanan bazı değerler ise sonuçların iyi olduğu anlamına gelmemektedir. Örnek olarak görüntü 18'de eşik değerin 0.1 olduğu durumda doğruluk %72.83, Jaccard skoru %72.78, yanmış alanlar için duyarlılık %100, kesinlik %72.78 ve F1-skoru %84.24 olmuştur. Bunun sebebi



gerçekte yanmış olan alanların tamamının tahminde de yanmış olarak belirtilmiş olmasıdır. Ayrıca tahminde yanmış olarak belirtilen alanların çoğu gerçekte de yanmıştır. Ancak tahmine bakıldığında sonucun neredeyse tamamının yanmış olarak belirtildiği, dolayısıyla yanmış alanın doğru tespit edilemediği görülmektedir. Ancak kesişme çok olduğu için metrik sonuçları yüksek çıkmıştır. Aynı görüntüde yanmamış alanlar için duyarlılık değeri incelendiğinde gerçekte yanmamış olan alanların tahminde sadece %0.74'ünün yanmamış olarak tespit edilebildiğinin görülmesi de yapılan yorumla paralellik göstermektedir.



**Şekil 4.10.** Bant kombinasyonu 4,3,2 ve AdaGrad algoritması için 5 adet test görüntüsü, ilgili referans görüntüsü ve sonuçlar

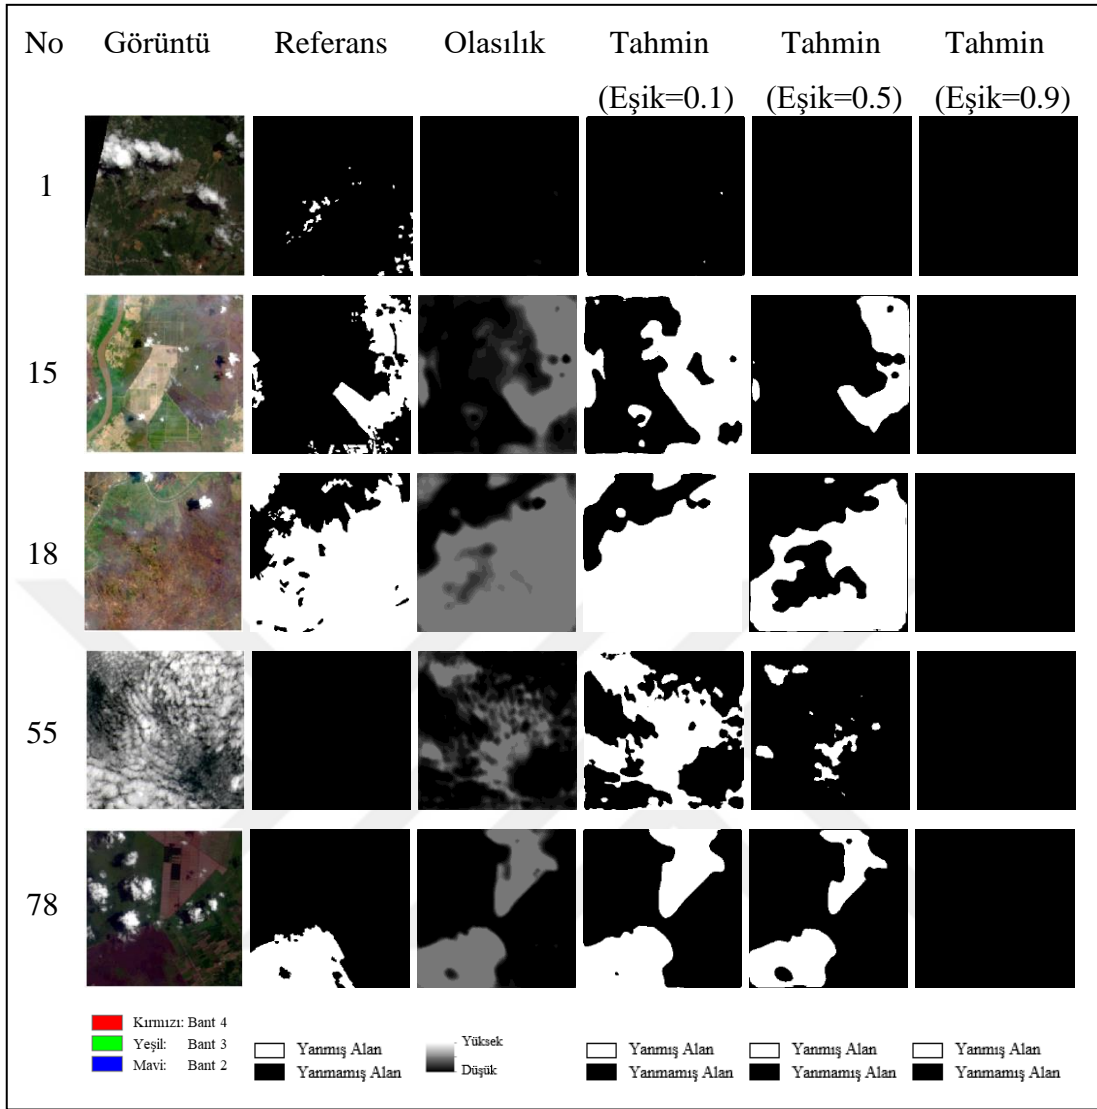
**Çizelge 4.17.** Bant kombinasyonu 4,3,2 ve AdaGrad algoritması için 5 adet test görüntüsüne dair doğruluk metrikleri

Eşik	Görüntü No.	Doğruluk	Duyarlılık 0.0*	Duyarlılık 1.0*	Kesinlik 0.0*	Kesinlik 1.0*	F1-Skoru 0.0*	F1-Skoru 1.0*	Jaccard Skoru
0.1	1	0.2066	0.1920	0.9908	0.9991	0.0223	0.3221	0.0436	0.0223
	15	0.2240	0.0000	1.0000	0.0000	0.2240	0.0000	0.3660	0.2240
	18	0.7283	0.0074	1.0000	0.9925	0.7278	0.0146	0.8424	0.7278
	55	0.6130	0.6130	0.0000	1.0000	0.0000	0.7601	0.0000	0.0000
	78	0.2899	0.1349	0.9975	0.9959	0.2016	0.2377	0.3354	0.2015
0.5	1	0.9818	1.0000	0.0000	0.9818	0.0000	0.9908	0.0000	0.0000
	15	0.7760	1.0000	0.0000	0.7760	0.0000	0.8739	0.0000	0.0000
	18	0.2737	1.0000	0.0000	0.2737	0.0000	0.4297	0.0000	0.0000
	55	1.0000	1.0000	x*	1.0000	x*	1.0000	x*	0.0000
	78	0.8203	1.0000	0.0000	0.8203	0.0000	0.9013	0.0000	0.0000
0.9	1	0.9818	1.0000	0.0000	0.9818	0.0000	0.9908	0.0000	0.0000
	15	0.7760	1.0000	0.0000	0.7760	0.0000	0.8739	0.0000	0.0000
	18	0.2737	1.0000	0.0000	0.2737	0.0000	0.4297	0.0000	0.0000
	55	1.0000	1.0000	x*	1.0000	x*	1.0000	x*	0.0000
	78	0.8203	1.0000	0.0000	0.8203	0.0000	0.9013	0.0000	0.0000

\* 0.0 yanmamış, 1.0 yanmış alanlara; x metrik hesaplanmadığı durumlara karşılık gelmektedir.

#### 4.2.4. Bant kombinasyonu 4,3,2 ve AdaMax algoritması için test görüntülerini değerlendirme

Şekil 4.11'deki sonuçların AdaGrad algoritması ile elde edilen sonuçlardan daha iyi olduğu görülmekle birlikte derin öğrenmenin burada çok başarılı olduğu söylenemez. Özellikle eşik değeri 0.9 olduğunda elde edilen sonuçlarda yanmış alanlar tespit edilememiştir. Çizelge 4.18'deki yanmış alanlar için duyarlılık, kesinlik ve F1-skoru değerleri incelendiğinde %0 oldukları görülmektedir.



Şekil 4.11. Bant kombinasyonu 4,3,2 ve AdaMax algoritması için 5 adet test görüntüsü, ilgili referans görüntüsü ve sonuçlar

Çizelge 4.18. Bant kombinasyonu 4,3,2 ve AdaMax algoritması için 5 adet test görüntüsüne dair doğruluk metrikleri

Eşik	Görüntü No.	Doğruluk	Duyarlılık 0.0*	Duyarlılık 1.0*	Kesinlik 0.0*	Kesinlik 1.0*	F1-Skoru 0.0*	F1-Skoru 1.0*	Jaccard Skoru
0.1	1	0.9811	0.9993	0.0000	0.9818	0.0000	0.9904	0.0000	0.0000
	15	0.7349	0.6615	0.9892	0.9953	0.4576	0.7948	0.6257	0.4553
	18	0.9063	0.6956	0.9857	0.9483	0.8958	0.8026	0.9386	0.8843
	55	0.5508	0.5508	0.0000	1.0000	0.0000	0.7104	0.0000	0.0000
	78	0.8288	0.8079	0.9241	0.9798	0.5131	0.8856	0.6598	0.4924

**Çizelge 4.18.** Bant kombinasyonu 4,3,2 ve AdaMax algoritması için 5 adet test görüntüsüne dair doğruluk metrikleri (devamı)

0.5	1	0.9818	1.0000	0.0000	0.9818	0.0000	0.9908	0.0000	0.0000
	15	0.9214	0.9664	0.7657	0.9346	0.8680	0.9502	0.8136	0.6858
	18	0.7802	0.9474	0.7171	0.5579	0.9731	0.7023	0.8257	0.7032
	55	0.9463	0.9463	0.0000	1.0000	0.0000	0.9724	0.0000	0.0000
	78	0.8701	0.8881	0.7883	0.9504	0.6067	0.9182	0.6857	0.5217
0.9	1	0.9818	1.0000	0.0000	0.9818	0.0000	0.9908	0.0000	0.0000
	15	0.7760	1.0000	0.0000	0.7760	0.0000	0.8739	0.0000	0.0000
	18	0.2737	1.0000	0.0000	0.2737	0.0000	0.4297	0.0000	0.0000
	55	1.0000	1.0000	x*	1.0000	x*	1.0000	x*	0.0000
	78	0.8203	1.0000	0.0000	0.8203	0.0000	0.9013	0.0000	0.0000

\* 0.0 yanmamış, 1.0 yanmış alanlara; x metrik hesaplanmadığı durumlara karşılık gelmektedir.

Optimizasyon algoritmaları için 1, 15, 18, 55 ve 78 numaralı görüntüler kullanılarak elde edilen hata matrisleri EK-10'da gösterilmiştir.

#### 4.2.5. Optimizasyon algoritmaları için istatistiksel değerlendirme

Adam, AdaGrad ve AdaMax algoritmaları için 7,5,4 ve 4,3,2 bant kombinasyonlarındaki değerlendirme metrikleri istatistiksel olarak sırasıyla Çizelge 4.19 ve Çizelge 4.20'de gösterilmiştir. Çizelgelerde eşik değerin 0.1, 0.5 ve 0.9 olarak alındığı durumdaki sonuçlara ayrı ayrı yer verilmiştir. Sütunlarda ortalamalar arasındaki en yüksek değerler koyu olarak gösterilmiştir.

Çizelge 4.19'da eşik değerin 0.1 olduğu durumda en iyi doğruluk değerini %97.41 ile Adam algoritmasının verdiği görülmektedir. Eşik değerin 0.5 ve 0.9 olduğu durumlarda ise en yüksek doğruluk değerlerini sırasıyla %97.58 ve %96.82 ile AdaMax algoritmasının verdiği görülmektedir. En yüksek doğruluğa AdaMax algoritması ile eşik değeri 0.5 iken ulaşılmıştır. Yanmış alanlara dair sonuçlar incelendiğinde, eşik değerin 0.1, 0.5 ve 0.9 olduğu durumlarda en iyi ortalama duyarlılık değerlerini sırasıyla %84.54, %77.75 ve %61.99 ile AdaMax algoritmasının verdiği, en iyi ortalama kesinlik değerlerini sırasıyla %70.47, %84.11 ve %93.66 ile Adam algoritmasının verdiği görülmektedir. En iyi ortalama F1-skoru değerini eşik değerin 0.1 olduğu durumda %75.09 ile Adam algoritmasının verdiği, eşik değerin 0.5 ve 0.9 olduğu durumlarda ise sırasıyla %77.64 ve %71.47 ile AdaMax algoritmasının verdiği görülmektedir. Yanmamış alanlara dair sonuçlar incelendiğinde, en iyi duyarlılık değerlerini eşik değerin 0.1 ve 0.5 olduğu durumda sırasıyla %97.49 ve %99.24 ile Adam algoritmasının verdiği,

eşik değerin 0.9 olduğu durumda %99.92 ile AdaGrad algoritmasının verdiği görülmektedir. En iyi kesinlik değerlerini eşik değerin 0.1 olduğu durumda %99.03 ile AdaGrad algoritmasının verdiği, eşik değerin 0.5 ve 0.9 olduğu durumda sırasıyla %97.73 ve %96.19 ile AdaMax algoritmasının verdiği görülmektedir. En iyi ortalama Jaccard skoru değeri ise eşik değerin 0.1 olduğu durumda %63.99 ile Adam algoritmasının verdiği, eşik değerin 0.5 ve 0.9 olduğu durumda ise sırasıyla %65.13 ve %55.88 ile AdaMax algoritmasının verdiği görülmektedir.

Çizelge 4.20’de eşik değerlerin üçü için de en iyi doğruluk değerlerini sırasıyla %94.36, %95.18 ve %93.02 ile Adam algoritmasının verdiği görülmektedir. En yüksek doğruluğa eşik değeri 0.5 iken ulaşılmıştır. Yanmamış alanlara dair sonuçlar incelendiğinde, en iyi duyarlılık değerini eşik değerin 0.1 olduğu durumda %94.44 ile Adam algoritmasının verdiği, eşik değerin 0.5 olduğu durumda %100 ile AdaGrad algoritmasının, eşik değerin 0.9 olduğu durumda da %100 ile AdaGrad ve AdaMax algoritmalarının verdiği görülmektedir. Eşik değerin 0.1, 0.5 ve 0.9 olduğu durumlarda en iyi ortalama kesinlik değerlerini sırasıyla %97.57, %95.22 ve %92.22 ile Adam algoritmasının verdiği, en iyi ortalama F1-skoru değerlerini de sırasıyla %95.75, %96.66 ve %95.43 ile Adam algoritmasının verdiği görülmektedir. En iyi ortalama Jaccard skoru değeri ise aynı eşik değerler için sırasıyla %42.33, %36.50 ve %17.86 ile Adam algoritmasının verdiği görülmektedir.

7,5,4 ve 4,3,2 bant kombinasyonları ile yapılan değerlendirmeler incelendiğinde en yüksek sonuçlara genellikle 7,5,4 bant kombinasyonu ve AdaMax algoritması kullanıldığında ulaşıldığı görülmektedir.

**Çizelge 4.19.** Bant kombinasyonu 7,5,4 ve optimizasyon algoritmaları için doğruluk metriklerinin istatistiksel sonuçları

Eşik = 0.1									
Opt.	İstatistik	Doğruluk	Duyarlılık 0.0*	Duyarlılık 1.0*	Kesinlik 0.0*	Kesinlik 1.0*	F1- Skoru 0.0*	F1- Skoru 1.0*	Jaccard Skoru
Adam	Min.	0.7919	0.7290	0.0000	0.7674	0.0000	0.8161	0.0000	0.0000
	Maks.	1.0000	1.0000	1.0000	1.0000	0.9682	1.0000	0.9734	0.9482
	Ort.	<b>0.9741</b>	<b>0.9749</b>	0.8364	0.9878	<b>0.7047</b>	<b>0.9809</b>	<b>0.7509</b>	<b>0.6399</b>
	Std.	0.0339	0.0412	0.2771	0.0323	0.2745	0.0327	0.2654	0.2717
AdaGrad	Min.	0.7756	0.4767	0.0000	0.7777	0.0000	0.6395	0.0000	0.0000
	Maks.	0.9980	0.9982	1.0000	1.0000	0.9659	0.9990	0.9643	0.9310
	Ort.	0.9589	0.9506	0.8301	<b>0.9903</b>	0.5831	0.9683	0.6613	0.5489
	Std.	0.0440	0.0780	0.2931	0.0300	0.2851	0.0531	0.2840	0.2655
AdaMax	Min.	0.7608	0.7689	0.0000	0.7294	0.0000	0.7943	0.0000	0.0000
	Maks.	1.0000	1.0000	1.0000	1.0000	0.9589	1.0000	0.9741	0.9496
	Ort.	0.9707	0.9703	<b>0.8459</b>	0.9875	0.6477	0.9785	0.7181	0.6094
	Std.	0.0374	0.0399	0.2914	0.0394	0.2772	0.0363	0.2770	0.2725
Eşik = 0.5									
Opt.	İstatistik	Doğruluk	Duyarlılık 0.0*	Duyarlılık 1.0*	Kesinlik 0.0*	Kesinlik 1.0*	F1- Skoru 0.0*	F1- Skoru 1.0*	Jaccard Skoru
Adam	Min.	0.7401	0.9229	0.0000	0.6792	0.0000	0.7974	0.0000	0.0000
	Maks.	1.0000	1.0000	0.9768	1.0000	0.9994	1.0000	0.9765	0.9541
	Ort.	0.9743	<b>0.9924</b>	0.7203	0.9728	<b>0.8411</b>	0.9818	0.7601	0.6328
	Std.	0.0411	0.0134	0.2612	0.0557	0.2579	0.0353	0.2467	0.2815
AdaGrad	Min.	0.7020	0.8877	0.0000	0.6463	0.0000	0.7683	0.0000	0.0000
	Maks.	1.0000	1.0000	0.9858	1.0000	1.0000	1.0000	0.9752	0.9516
	Ort.	0.9700	0.9899	0.6376	0.9698	0.7938	0.9789	0.6799	0.5692
	Std.	0.0472	0.0197	0.3082	0.0618	0.2926	0.0401	0.2878	0.2903
AdaMax	Min.	0.7264	0.9083	0.0000	0.6623	0.0000	0.7661	0.0000	0.0000
	Maks.	1.0000	1.0000	1.0000	1.0000	0.9936	1.0000	0.9796	0.9600
	Ort.	<b>0.9758</b>	0.9887	<b>0.7775</b>	<b>0.9773</b>	0.7983	<b>0.9823</b>	<b>0.7764</b>	<b>0.6513</b>
	Std.	0.0410	0.0169	0.2485	0.0567	0.2563	0.0376	0.2416	0.2757
Eşik = 0.9									
Opt.	İstatistik	Doğruluk	Duyarlılık 0.0*	Duyarlılık 1.0*	Kesinlik 0.0*	Kesinlik 1.0*	F1- Skoru 0.0*	F1- Skoru 1.0*	Jaccard Skoru
Adam	Min.	0.6572	0.9784	0.0000	0.4963	0.0000	0.6595	0.0000	0.0000
	Maks.	1.0000	1.0000	0.9192	1.0000	1.0000	1.0000	0.9536	0.9113
	Ort.	0.9609	0.9985	0.5268	0.9527	<b>0.9366</b>	0.9730	0.6382	0.4788
	Std.	0.0599	0.0033	0.2644	0.0822	0.2002	0.0514	0.2626	0.2888
AdaGrad	Min.	0.5083	0.9816	0.0000	0.3337	0.0000	0.5000	0.0000	0.0000
	Maks.	1.0000	1.0000	0.8987	1.0000	1.0000	1.0000	0.9451	0.8960
	Ort.	0.9427	<b>0.9992</b>	0.3759	0.9354	0.9173	0.9624	0.4816	0.3395
	Std.	0.0898	0.0025	0.2823	0.1069	0.2414	0.0712	0.3052	0.2865
AdaMax	Min.	0.6680	0.9642	0.0000	0.5272	0.0000	0.6817	0.0000	0.0000
	Maks.	1.0000	1.0000	0.9576	1.0000	1.0000	1.0000	0.9731	0.9477
	Ort.	<b>0.9682</b>	0.9969	<b>0.6199</b>	<b>0.9619</b>	0.9014	<b>0.9776</b>	<b>0.7147</b>	<b>0.5588</b>
	Std.	0.0533	0.0057	0.2443	0.0745	0.2186	0.0471	0.2285	0.2773

\* 0.0 yanmamış, 1.0 yanmış alanlara karşılık gelmektedir.

**Çizelge 4.20.** Bant kombinasyonu 4,3,2 ve optimizasyon algoritmaları için doğruluk metriklerinin istatistiksel sonuçları

Eşik = 0.1									
Opt.	İstatistik	Doğruluk	Duyarlılık 0.0*	Duyarlılık 1.0*	Kesinlik 0.0*	Kesinlik 1.0*	F1- Skoru 0.0*	F1- Skoru 1.0*	Jaccard Skoru
Adam	Min.	0.7041	0.4276	0.0000	0.7534	0.0000	0.5760	0.0000	0.0000
	Maks.	1.0000	1.0000	0.9911	1.0000	0.9185	1.0000	0.9485	0.9021
	Ort.	<b>0.9436</b>	<b>0.9444</b>	0.6297	<b>0.9757</b>	<b>0.5177</b>	<b>0.9575</b>	<b>0.5396</b>	<b>0.4233</b>
	Std.	0.0660	0.0941	0.3374	0.0443	0.2865	0.0672	0.2996	0.2692
AdaGrad	Min.	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000
	Maks.	0.9010	0.9289	1.0000	1.0000	0.7534	0.9476	0.8594	0.7534
	Ort.	0.3156	0.2439	<b>0.7598</b>	0.7132	0.1126	0.2911	0.1621	0.1041
	Std.	0.2906	0.3287	0.3862	0.4290	0.1532	0.3489	0.1982	0.1512
AdaMax	Min.	0.5508	0.1465	0.0000	0.7735	0.0000	0.2529	0.0000	0.0000
	Maks.	0.9998	1.0000	0.9959	1.0000	0.9980	0.9999	0.9386	0.8843
	Ort.	0.9227	0.9247	0.3938	0.9685	0.4956	0.9364	0.3877	0.3010
	Std.	0.1049	0.1622	0.3842	0.0409	0.3506	0.1163	0.3435	0.2903
Eşik = 0.5									
Opt.	İstatistik	Doğruluk	Duyarlılık 0.0*	Duyarlılık 1.0*	Kesinlik 0.0*	Kesinlik 1.0*	F1- Skoru 0.0*	F1- Skoru 1.0*	Jaccard Skoru
Adam	Min.	0.6819	0.7474	0.0000	0.6151	0.0000	0.6748	0.0000	0.0000
	Maks.	1.0000	1.0000	0.9340	1.0000	1.0000	1.0000	0.9375	0.8823
	Ort.	<b>0.9518</b>	0.9833	<b>0.4249</b>	<b>0.9522</b>	<b>0.6962</b>	<b>0.9666</b>	<b>0.4882</b>	<b>0.3650</b>
	Std.	0.0594	0.0392	0.3167	0.0711	0.3366	0.0527	0.3206	0.2885
AdaGrad	Min.	0.2466	1.0000	0.0000	0.2466	0.0000	0.3956	0.0000	0.0000
	Maks.	1.0000	1.0000	0.0000	1.0000	0.0000	1.0000	0.0000	0.0000
	Ort.	0.8950	<b>1.0000</b>	0.0000	0.8950	0.0000	0.9364	0.0000	0.0000
	Std.	0.1492	0.0000	0.0000	0.1492	0.0000	0.1063	0.0000	0.0000
AdaMax	Min.	0.6090	0.5954	0.0000	0.5119	0.0000	0.5505	0.0000	0.0000
	Maks.	1.0000	1.0000	0.9359	1.0000	1.0000	1.0000	0.9472	0.8996
	Ort.	0.9351	0.9841	0.2019	0.9322	0.4311	0.9556	0.2433	0.1745
	Std.	0.0741	0.0511	0.2931	0.0946	0.4589	0.0706	0.3224	0.2634
Eşik = 0.9									
Opt.	İstatistik	Doğruluk	Duyarlılık 0.0*	Duyarlılık 1.0*	Kesinlik 0.0*	Kesinlik 1.0*	F1- Skoru 0.0*	F1- Skoru 1.0*	Jaccard Skoru
Adam	Min.	0.5337	0.9410	0.0000	0.3396	0.0000	0.4994	0.0000	0.0000
	Maks.	1.0000	1.0000	0.7397	1.0000	1.0000	1.0000	0.8389	0.7224
	Ort.	<b>0.9302</b>	0.9970	<b>0.1997</b>	<b>0.9222</b>	<b>0.6904</b>	<b>0.9543</b>	<b>0.2782</b>	<b>0.1786</b>
	Std.	0.0891	0.0097	0.2212	0.1119	0.4409	0.0752	0.2784	0.2129
AdaGrad	Min.	0.2466	1.0000	0.0000	0.2466	0.0000	0.3956	0.0000	0.0000
	Maks.	1.0000	1.0000	0.0000	1.0000	0.0000	1.0000	0.0000	0.0000
	Ort.	0.8950	<b>1.0000</b>	0.0000	0.8950	0.0000	0.9364	0.0000	0.0000
	Std.	0.1492	0.0000	0.0000	0.1492	0.0000	0.1063	0.0000	0.0000
AdaMax	Min.	0.2466	1.0000	0.0000	0.2466	0.0000	0.3956	0.0000	0.0000
	Maks.	1.0000	1.0000	0.0000	1.0000	0.0000	1.0000	0.0000	0.0000
	Ort.	0.8950	<b>1.0000</b>	0.0000	0.8950	0.0000	0.9364	0.0000	0.0000
	Std.	0.1492	0.0000	0.0000	0.1492	0.0000	0.1063	0.0000	0.0000

\* 0.0 yanmamış, 1.0 yanmış alanlara karşılık gelmektedir.

### 4.3. Nihai Modelin Oluşturulması

Çalışmanın bu bölümünde önceki iki bölümde yapılan uygulama sonuçları özetlenmiş ve yapılan uygulamalar arasında en iyi sonuçları veren kombinasyon belirlenmiştir. Belirlenen kombinasyonda eğitim veri setine  $90^\circ$ ,  $180^\circ$  ve  $270^\circ$  döndürme uygulanıp veri artırımı gerçekleştirildikten sonra, eğitim ve test işlemleri gerçekleştirilmiştir. Bu şekilde nihai model sonuçları elde edilmiştir.

Çizelge 4.21’de önceki iki bölümde elde edilen sonuçlar özetlenmiştir. Sütunlardaki en yüksek değerler koyu olarak gösterilmiştir. Çizelge 4.21’e göre eğitim doğruluklarının %90’nın üzerinde olduğu görülmektedir. Test sonuçları arasında en yüksek doğruluk ve F1-skoru değerleri 8 numaralı modelde eşik değerinin 0.5 olduğu durumda elde edilmiştir. Bu değerler sırasıyla %97.58 ve %77.64’tür.


Çizelge 4.21. Bütün kombinasyonlar için eğitim ve test sonuçları

ÖZELLİKLER			EĞİTİM	TEST					
No	Bantlar	Optimizasyon	Doğruluk	Doğruluk			F1-skoru 1.0*		
				Eşik =0.1	Eşik =0.5	Eşik =0.9	Eşik =0.1	Eşik =0.5	Eşik =0.9
1	7,5,4	Adam	0.9886	<b>0.9741</b>	0.9743	0.9609	<b>0.7509</b>	0.7601	0.6382
2	5,3,7	Adam	0.9909	0.9700	0.9722	0.9608	0.7260	0.7539	0.6333
3	5,4,3	Adam	0.9916	0.9679	0.9673	0.9577	0.7136	0.6688	0.5496
4	4,3,2	Adam	0.9776	0.9436	0.9518	0.9302	0.5396	0.4882	0.2782
5	4,3,2,5	Adam	0.9806	0.9509	0.9677	0.9490	0.6721	0.6764	0.4513
6	2,3,4,5,6,7	Adam	0.9849	0.9609	0.9525	0.9331	0.5208	0.4088	0.2307
7	7,5,4	AdaGrad	0.9827	0.9589	0.9700	0.9427	0.6613	0.6799	0.4816
8	7,5,4	AdaMax	0.9907	0.9707	<b>0.9758</b>	<b>0.9682</b>	0.7181	<b>0.7764</b>	<b>0.7147</b>
9	4,3,2	AdaGrad	0.9286	0.3156	0.895	0.895	0.1621	0.0000	0.0000
10	4,3,2	AdaMax	0.9556	0.9227	0.9351	0.895	0.3877	0.2433	0.0000

\* 1.0 yanmış alanlara karşılık gelmektedir.

Uygulama sonucunda 8. kombinasyonun diğer kombinasyonlardan daha yüksek sonuçlar verdiği görülmüştür. Bu kombinasyonda 7,5,4 bantları ve AdaMax optimizasyon algoritması kullanılmıştır. Dolayısıyla nihai model için 7,5,4 bant kombinasyonu kullanılmış, bu bant kombinasyonundaki eğitim veri setine  $90^\circ$ ,  $180^\circ$  ve  $270^\circ$  döndürme işlemi uygulanmıştır. Şekil 4.12’de eğitim veri setinden bir görüntü ve bu görüntüye  $90^\circ$ ,  $180^\circ$  ve  $270^\circ$  döndürme uygulanması sonucunda elde edilen yeni görüntüler gösterilmiştir.



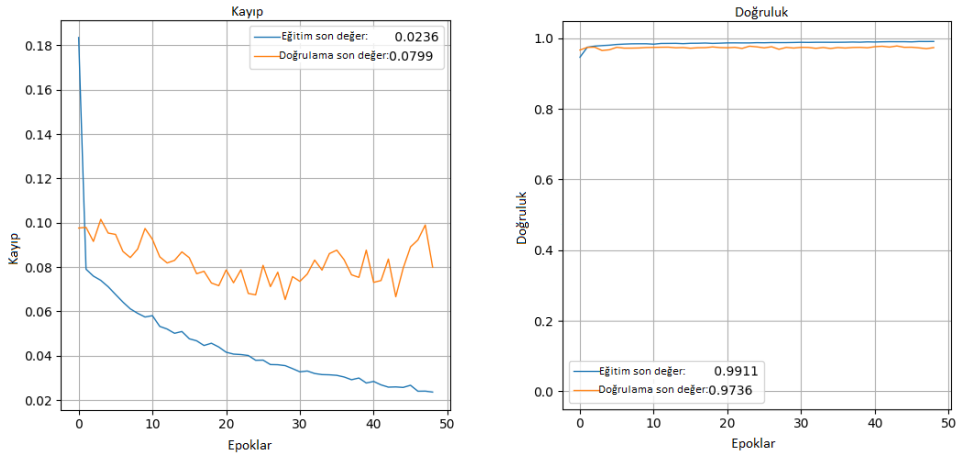


Şekil 4.12. Orijinal görüntü ve bu görüntüye 90°, 180° ve 270° döndürme uygulanması

Eğitim veri seti oluşturulduktan sonra AdaMax optimizasyon algoritması kullanılarak eğitim işlemi gerçekleştirilmiştir. Eğitim işleminde epok sayısı maksimum 100 olarak belirlenmiş olup, bununla birlikte erken durdurma uygulanmıştır. Eğitim 49. epokta erken durdurma ile otomatik olarak durdurulmuştur. Sürece ilişkin bilgiler Çizelge 4.22’de özetlenmiştir. Eğitim sonucunda elde edilen kayıp ve doğruluk grafikleri Şekil 4.13’te gösterilmiştir. Şekil 4.13 incelendiğinde eğitim ve doğrulama veri setleri için kayıp değerlerinin 0’a, doğruluk değerlerinin 1’e yaklaştığı görülmektedir.

Çizelge 4.22. Eğitim ile ilgili bilgiler

No	Bantlar	Öğrenme Hızı	Optimizasyon	Veri Artırımı	Süre
11	7,5,4	0.001	AdaMax	90°, 180°, 270° döndürme	2 saat 29 dakika

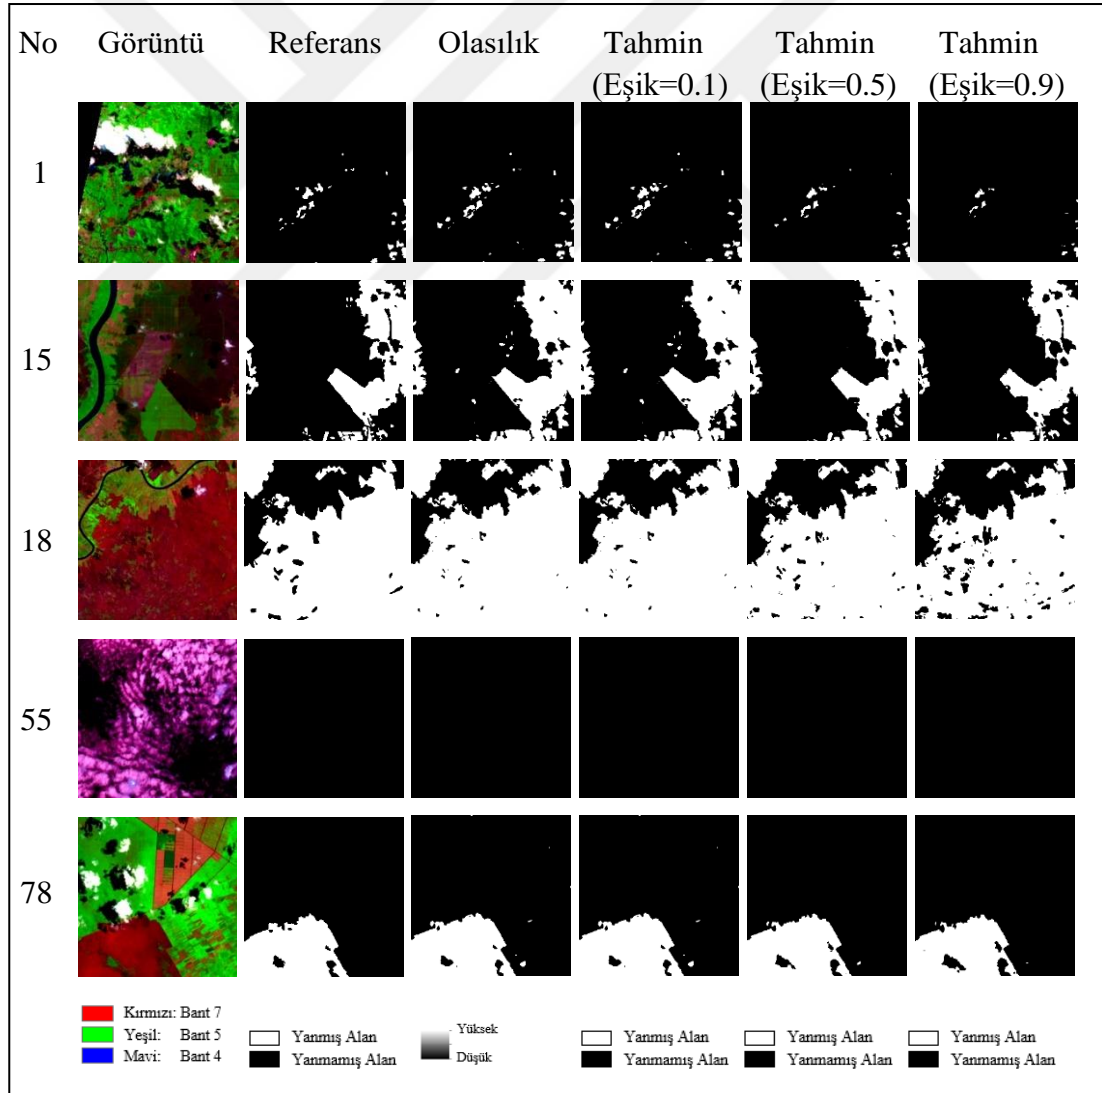


Şekil 4.13. Nihai model için (a) kayıp ve (b) doğruluk grafikleri

### 4.3.1. Nihai model için test görüntülerini değerlendirme

Şekil 4.14'teki sonuçlar AdaMax algoritması kullanılarak 7,5,4 bant kombinasyonunda 90°, 180°, 270° döndürme yapılmamış sonuçlarla karşılaştırıldığında;

Test görüntülerinden 5 adeti için de tahmin sonuçlarının referans verisine çok yakın olduğu görülmektedir. Bu durumda eğitim veri setine 90°, 180° ve 270° döndürme uygulanmasının buradaki sonuçlara önemli ölçüde olumlu katkı sağladığı söylenebilmektedir. Çizelge 4.23'e göre 90°, 180° ve 270° döndürme yapıldığı durumda elde edilen metrik değerlerin, döndürme yapılmadan elde edilen metrik değerlere göre genellikle daha iyi olduğu görülmektedir. Bu durumda tahminde yanlış olarak belirtilen yerlerin gerçekte de yanlış alanlara karşılık gelmesi veri artırımı yapıldığı durumda daha iyi sonuçlanmıştır.



Şekil 4.14. Nihai model için 5 adet test görüntüsü, ilgili referans görüntüsü ve sonuçlar

**Çizelge 4.23.** 8 ve 11 numaralı kombinasyonlar için 5 adet test görüntüsüne dair doğruluk metrikleri

Eşik	Görüntü No.	90°, 180° ve 270° Döndürme	Doğruluk	Duyarlılık 0.0*	Duyarlılık 1.0*	Keskinlik 0.0*	Keskinlik 1.0*	F1-Skoru 0.0*	F1-Skoru 1.0*	Jaccard Skoru	
0.1	1	yok	0.9807	0.9828	0.8669	0.9975	0.4830	0.9901	0.6204	0.4497	
		var	0.9921	0.9944	0.8661	0.9975	0.7425	0.9960	0.7995	0.6660	
	15	yok	0.9263	0.9105	0.9810	0.9940	0.7598	0.9504	0.8563	0.7488	
		var	0.9331	0.9171	0.9885	0.9964	0.7749	0.9551	0.8687	0.7679	
	18	yok	0.9543	0.8390	0.9978	0.9931	0.9427	0.9095	0.9695	0.9407	
		var	0.9545	0.8352	0.9994	0.9980	0.9415	0.9094	0.9696	0.9410	
	55	yok	1.0000	1.0000	0.0000	1.0000	0.0000	1.0000	0.0000	0.0000	
		var	1.0000	1.0000	x*	1.0000	x*	1.0000	x*	0.0000	
	78	yok	0.9806	0.9777	0.9937	0.9986	0.9072	0.9881	0.9485	0.9020	
		var	0.9908	0.9902	0.9936	0.9986	0.9568	0.9944	0.9749	0.9510	
	0.5	1	yok	0.9912	0.9964	0.7088	0.9946	0.7864	0.9955	0.7456	0.5944
			var	0.9920	0.9993	0.5958	0.9925	0.9418	0.9959	0.7299	0.5747
		15	yok	0.9583	0.9614	0.9475	0.9845	0.8764	0.9728	0.9105	0.8358
			var	0.9630	0.9622	0.9660	0.9899	0.8805	0.9758	0.9213	0.8541
18		yok	0.9701	0.9215	0.9884	0.9676	0.9709	0.9440	0.9796	0.9600	
		var	0.9720	0.9258	0.9894	0.9704	0.9725	0.9476	0.9809	0.9625	
55		yok	1.0000	1.0000	x*	1.0000	x*	1.0000	x*	0.0000	
		var	1.0000	1.0000	x*	1.0000	x*	1.0000	x*	0.0000	
78		yok	0.9879	0.9923	0.9678	0.9929	0.9648	0.9926	0.9663	0.9348	
		var	0.9920	0.9965	0.9714	0.9937	0.9838	0.9951	0.9776	0.9561	
0.9		1	yok	0.9898	0.9997	0.4586	0.9900	0.9665	0.9948	0.6220	0.4514
			var	0.9878	1.0000	0.3305	0.9877	1.0000	0.9938	0.4969	0.3305
		15	yok	0.9577	0.9879	0.8531	0.9588	0.9530	0.9731	0.9003	0.8187
			var	0.9688	0.9881	0.9019	0.9721	0.9562	0.9800	0.9283	0.8662
	18	yok	0.9616	0.9723	0.9576	0.8962	0.9892	0.9327	0.9731	0.9477	
		var	0.9501	0.9809	0.9385	0.8573	0.9924	0.9149	0.9647	0.9318	
	55	yok	1.0000	1.0000	x*	1.0000	x*	1.0000	x*	0.0000	
		var	1.0000	1.0000	x*	1.0000	x*	1.0000	x*	0.0000	
	78	yok	0.9850	0.9980	0.9261	0.9840	0.9900	0.9909	0.9570	0.9175	
		var	0.9862	0.9988	0.9284	0.9845	0.9942	0.9916	0.9602	0.9234	

\* 0.0 yanmamış, 1.0 yanmış alanlara; x metrik hesaplanmadığı durumlara karşılık gelmektedir.

Nihai model için 1, 15, 18, 55 ve 78 numaralı görüntüler kullanılarak elde edilen hata matrisleri EK-11’de gösterilmiştir.

#### 4.3.2. Nihai model için istatistiksel değerlendirme

Çizelge 4.24’te 92 adet test görüntüsü için hesaplanan doğruluk metriklerinin minimum, maksimum, ortalama ve standart sapma değerleri gösterilmiştir. Bunlar 7,5,4

bant kombinasyonunda AdaMax optimizasyon algoritması kullanılarak elde edilen sonuçlardır. Sütunlarda ortalamalar arasındaki en yüksek değerler koyu olarak gösterilmiştir.

Çizelge 4.24'teki ortalama değerler incelendiğinde en yüksek doğruluğa %97.76 ile eşik değerin 0.5 olduğu durumda ulaşılmıştır. Yanmış alanlara dair ortalama duyarlılık değeri en yüksek %85.90 ile eşik değerin 0.1 olduğu durumda, ortalama kesinlik değeri en yüksek %91.80 ile eşik değerin 0.9 olduğu durumda, ortalama F1-skoru değeri en yüksek %79.38 ile eşik değerin 0.5 olduğu durumda elde edilmiştir. Yanmamış alanlar için ise ortalama duyarlılık değeri en yüksek %99.71 ile eşik değerin 0.9 olduğu durumda, ortalama kesinlik değeri en yüksek %98.88 ile eşik değerin 0.1 olduğu durumda, ortalama F1-skoru değeri en yüksek %98.36 ile eşik değerin 0.5 olduğu durumda elde edilmiştir. Ortalama Jaccard skoru ise %66.32 değeri ile eşik değeri 0.5 iken en yüksek değeri almıştır.

**Çizelge 4.24.** Nihai model için doğruluk metriklerinin istatistiksel sonuçları

Eşik	İstatistik	Doğruluk	Duyarlılık 0.0*	Duyarlılık 1.0*	Kesinlik 0.0*	Kesinlik 1.0*	F1- Skoru 0.0*	F1- Skoru 1.0*	Jaccard Skoru
0.1	Min.	0.7728	0.6819	0.0000	0.7399	0.0000	0.7751	0.0000	0.0000
	Maks.	1.0000	1.0000	1.0000	1.0000	0.9568	1.0000	0.9749	0.9510
	Ort.	0.9717	0.9696	<b>0.8590</b>	<b>0.9888</b>	0.6891	0.9786	0.7554	0.6221
	Std.	0.0371	0.0479	0.2549	0.0348	0.2411	0.0376	0.2375	0.2660
0.5	Min.	0.7402	0.8903	0.0000	0.6803	0.0000	0.7967	0.0000	0.0000
	Maks.	1.0000	1.0000	0.9894	1.0000	1.0000	1.0000	0.9809	0.9625
	Ort.	<b>0.9776</b>	0.9888	0.7755	0.9795	0.8342	<b>0.9836</b>	<b>0.7938</b>	<b>0.6632</b>
	Std.	0.0378	0.0190	0.2486	0.0497	0.2313	0.0336	0.2293	0.2796
0.9	Min.	0.6727	0.9714	0.0000	0.5525	0.0000	0.7049	0.0000	0.0000
	Maks.	1.0000	1.0000	0.9385	1.0000	1.0000	1.0000	0.9659	0.9340
	Ort.	0.9684	<b>0.9971</b>	0.5968	0.9619	<b>0.9180</b>	0.9777	0.6974	0.5378
	Std.	0.0513	0.0059	0.2578	0.0724	0.2208	0.0451	0.2463	0.2898

\* 0.0 yanmamış, 1.0 yanmış alanlara karşılık gelmektedir.

Çizelge 4.25'te 8 ve 11 numaralı kombinasyonlara dair sonuçlar özetlenmiştir. Sütunlardaki en yüksek değerler koyu olarak gösterilmiştir. Çizelge 4.25 incelendiğinde eğitim veri setine 90°, 180° ve 270° döndürme uygulanmasının sonuçlar üzerinde olumlu etkisi olduğu görülmektedir.

Çizelge 4.25. 8 ve 11 numaralı kombinasyonlar için eğitim ve test sonuçları

ÖZELLİKLER				EĞİTİM	TEST					
No	Bantlar	Optimizasyon	90°, 180° ve 270° Döndürme	Doğruluk	Doğruluk			F1-skoru 1.0*		
					Eşik =0.1	Eşik =0.5	Eşik =0.9	Eşik =0.1	Eşik =0.5	Eşik =0.9
8	7,5,4	AdaMax	Yok	0.9907	0.9707	0.9758	0.9682	0.7181	0.7764	<b>0.7147</b>
11	7,5,4	AdaMax	Var	0.9911	<b>0.9717</b>	<b>0.9776</b>	<b>0.9684</b>	<b>0.7554</b>	<b>0.7938</b>	0.6974

Bu çalışmada Prabowo ve ark. (2022b) tarafından paylaşılan veri seti kullanılmıştır. Veri setinin paylaşıldığı çalışmadan farklı olarak bu çalışmada; farklı kombinasyonlar ve farklı eşik değerler kullanılmış, bunların sonuçlar üzerindeki etkileri incelenmiştir. Bu çalışmada kullanılan kombinasyonlar Adam optimizasyon algoritması ile 7,5,4; 5,3,7; 5,4,3; 4,3,2; 4,3,2,5 ve 2,3,4,5,6,7 bantlarının kullanımı; AdaGrad ve AdaMax algoritmaları ile 7,5,4 ve 4,3,2 bantlarının kullanımı olmak üzere toplamda 10 tanedir. Elde edilen sonuçlar değerlendirildiğinde, farklı bant kombinasyonlarının modelin performansı etkilediği görülmüştür. Bant kombinasyonu 7,5,4 olduğunda daha iyi sonuçlara ulaşılırken; 4,3,2 olduğunda daha kötü sonuçlara ulaşılmıştır. Farklı optimizasyon algoritmalarının kullanılması da sonuçları etkilemiştir. 7,5,4 bantları AdaMax optimizasyon algoritması ile kullanıldığında ve 4,3,2 bantları Adam optimizasyon algoritması ile kullanıldığında; diğer optimizasyon algoritmalarının kullanımına göre daha iyi sonuçlar elde edilmiştir. Bunlarla birlikte test sonuçları için kullanılan eşik değer seçimi de sonuçlar üzerinde etkili olmuştur. Eşik değer 0.1 ve 0.5 olduğunda daha iyi sonuçlara ulaşılmışken, 0.9 olduğunda daha kötü sonuçlara ulaşılmıştır. Ayrıca eğitim veri setine veri artırımı uygulanmasının sonuçları etkilediği; 90°, 180° ve 270° döndürme uygulanması ile elde edilen sonuçların, döndürme uygulanmadığı duruma göre daha iyi olduğu görülmüştür.

Sonuçta bu tez çalışması kapsamında oluşturulan nihai modelde eğitim aşaması sonucunda eğitim ve doğrulama veri setleri için elde edilen kayıp değerleri sırasıyla 0.0236 ve 0.0799 olmuştur. Prabowo ve ark. (2022b) tarafından yapılan çalışmada ise kayıp değeri 0.07 olarak belirtilmiştir. Tez çalışması kapsamında oluşturulan nihai modelde, test aşaması sonucunda en yüksek değerler eşik değer 0.5 iken elde edilmiş; bu eşik değerinde ortalama doğruluk %97.76, ortalama Jaccard skoru %66.32, yanlış alanlar için ortalama duyarlılık %75.55, ortalama kesinlik %83.42 ve ortalama F1-skoru değeri %79.38 olarak hesaplanmıştır.

## 5. SONUÇLAR

Çalışmada yanmış alanların derin öğrenme ile tespit edilmesi ve bu sırada etkili olabilecek bazı faktörlerin incelenmesi amaçlanmıştır. Bunun için farklı bant kombinasyonları ve optimizasyon algoritmaları kullanılmış, sonuçlar incelenmiştir. Bununla birlikte her kombinasyonda tahmin sonuçlarının oluşturulması için 0.1, 0.5 ve 0.9 olmak üzere üç farklı eşik değeri kullanılmış ve eşik değerlerinin sonuçlar üzerindeki etkisi incelenmiştir. Son olarak eğitim veri setine veri artırımı uygulanarak veri artırımının sonuçlar üzerindeki etkisi incelenmiştir. Bu işlem adımları üç bölümde gerçekleştirilmiştir.

İlk bölümde farklı bant kombinasyonları modele girdi olarak verilmiştir. Bu kombinasyonlar 7,5,4; 5,3,7; 5,4,3; 4,3,2; 4,3,2,5 ve 2,3,4,5,6,7 kombinasyonlarıdır. Her bir kombinasyonda küme boyutu, aktivasyon fonksiyonu, optimizasyon algoritması ve epok sayısı için aynı değerler kullanılmış, öğrenme oranı için ise ilgili kombinasyonda en iyi sonucu veren değer tercih edilmiştir. 6 farklı bant kombinasyonu arasında 7,5,4 kombinasyonu diğerlerine göre en iyi sonuçları vermiştir. En iyi ikinci sonucu veren bant kombinasyonu 5,3,7 kombinasyonudur. Sonuçlar arasında en kötü sonucu veren bant kombinasyonu ise 4,3,2 kombinasyonu olmuştur.

İkinci bölümde ilk bölümde en iyi sonucu veren 7,5,4 bant kombinasyonu ve en kötü sonucu veren 4,3,2 bant kombinasyonu, farklı optimizasyon algoritmaları ile ele alınmıştır. İlk bölümde Adam algoritması ile kullanılan bu bant kombinasyonları, bu bölümde AdaGrad ve AdaMax algoritmaları ile de kullanılmıştır. Küme boyutu, aktivasyon fonksiyonu ve epok sayısı ayarları değiştirilmemiştir. Değerlendirmelere göre AdaMax algoritması ile daha yüksek sonuçlara ulaşılmıştır.

Üçüncü bölümde ilk iki bölümde yapılan uygulamalar bir arada değerlendirilerek en iyi sonucu veren kombinasyon tespit edilmiş ve nihai modelin belirlenmesi gerçekleştirilmiştir. Değerlendirmelere göre en iyi sonuçların 7,5,4 bant kombinasyonunda AdaMax optimizasyon algoritması kullanılarak elde edildiği sonucuna varılmış ve bu kombinasyonda eğitim verisine 90°, 180° ve 270° döndürme uygulanmıştır. Küme boyutu, aktivasyon fonksiyonu ve epok sayısı ayarları değiştirilmemiş, ek olarak erken durdurma kullanılmıştır. Elde edilen sonuçların aynı bant kombinasyonunun ve optimizasyon algoritmasının kullanıldığı ancak veri artırımının uygulanmadığı durumda elde edilen sonuçlara göre daha iyi olduğu görülmüştür.

Sonuç olarak bazı kombinasyonlar için yolların ve tarım alanlarının yanmış alanlar ile karıştırılabildiği görülmüştür. Bulutlar genel olarak yanmış alanlar ile karıştırılmamıştır ancak bulutların altında yanmış alan olup olmadığı tespit edilememiştir. Ayrıca yangının devam ettiği bölgelerde oluşan dumanlar yanmış alanların tespitini zorlaştırmış, bazı kombinasyonlarda dumanların yanmış alanlar ile karıştırılmasına sebep olmuştur. Çalışmada kullanılan eşik değerler arasında eşik değerin 0.1 ve 0.5 olduğu durumlarda genel olarak daha iyi sonuçlarla karşılaşılmıştır. Bant kombinasyonlarından 7,5,4 (Kısa dalga kızılötesi-2, yakın kızılötesi, kırmızı) bant kombinasyonunun ve optimizasyon algoritmalarından AdaMax optimizasyon algoritmasının kullanılmasının diğer alternatiflere göre daha iyi sonuçlar verdiği görülmüştür. Eğitim veri setine 90°, 180° ve 270° döndürme uygulanması ile gerçekleştirilen veri artırımının sonuçlar üzerinde olumlu etkisi olduğu sonucuna varılmıştır. Ayrıca tez çalışması boyunca derin öğrenme uygulamaları için güçlü bir bilgisayar donanımının gerekli olduğu görülmüştür. Aksi takdirde eğitim süreçlerinin tamamlanamadan kesilmesi, RAM ya da GPU boyutlarının yeterli olmaması gibi durumlarla karşılaşılmıştır. Bu sebeplerden dolayı bu tez çalışması Google Colab Pro kullanılarak gerçekleştirilmiştir.

## KAYNAKLAR

- Abderrahim, N. Y. Q., Abderrahim, S. ve Rida, A., 2020, Road segmentation using u-net architecture, *2020 IEEE International conference of Moroccan Geomatics (Morgeo)*, 1-4.
- Abraham, A., 2005, Artificial neural networks, *Handbook of measuring system design*, 901-908.
- Ağgöl, B., 2021, Derin öğrenme kullanılarak sahte plakalı araç tespit sistemi geliştirilmesi, Yüksek Lisans, *Lisansüstü Eğitim Enstitüsü*, İstanbul Sabahattin Zaim Üniversitesi.
- Akca, S., 2020, Derin öğrenme ile harran ovası toprak tuzluluğunun tespiti, Yüksek Lisans, *Fen Bilimleri Enstitüsü*, Karadeniz Teknik Üniversitesi.
- Atlan, F. ve Pençe, İ., 2021, Yapay Zekâ ve Tıbbi Görüntüleme Teknolojilerine Genel Bakış, *Acta Infologica*, 5 (1), 207-230.
- Baatz, M. ve Schäpe, A., 2000, Multiresolution Segmentation : an optimization approach for high quality multi-scale image segmentation. *Angewandte Geographische Informations-Verarbeitung XII. Karlsruhe-Germany*: 12-23.
- Bayramoğlu, Z., 2021, Nesneye Yönelik Kural Tabanlı Sınıflandırma ve Derin Öğrenme Yöntemleri ile Otomatik Yol Çıkarımı Olanaklarının Araştırılması, Yüksek Lisans, *Fen Bilimleri Enstitüsü*, Yıldız Teknik Üniversitesi.
- Belenguer-Plomer, M. A., Tanase, M. A., Chuvieco, E. ve Bovolo, F., 2021, CNN-based burned area mapping using radar and optical data, *Remote Sensing of Environment*, 260, 112468.
- Brand, A. K. ve Manandhar, A., 2021, Semantic Segmentation of Burned Areas in Satellite Images Using a U-Net-Based Convolutional Neural Network, *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XLIII-B3-2021, 47-53.
- Brugnara, G., Isensee, F., Neuberger, U., Bonekamp, D., Petersen, J., Diem, R., Wildemann, B., Heiland, S., Wick, W. ve Bendszus, M., 2020, Automated volumetric assessment with artificial neural networks might enable a more accurate assessment of disease burden in patients with multiple sclerosis, *European Radiology*, 30 (4), 2356-2364.
- Casado-García, Á., Domínguez, C., García-Domínguez, M., Heras, J., Inés, A., Mata, E. ve Pascual, V., 2019, CLoDSA: a tool for augmentation in classification, localization, detection, semantic segmentation and instance segmentation tasks, *BMC bioinformatics*, 20 (1), 1-14.
- Cengil, E. ve Çınar, A., 2016, A new approach for image classification: convolutional neural network, *European Journal of Technique (EJT)*, 6 (2), 96-103.
- Cihan, M., 2020, Hiperspektral görüntüleme yöntemi kullanılarak yenidoğan sağlık durumlarının derin öğrenme metotları ile sınıflandırılması, Yüksek Lisans, *Lisansüstü Eğitim Enstitüsü*, Konya Teknik Üniversitesi.
- Ciresan, D. C., Giusti, A., Gambardella, L. M. ve Schmidhuber, J., 2012, Deep Neural Networks Segment Neuronal Membranes in Electron Microscopy Images, *NIPS'12: Proceedings of the 25th International Conference on Neural Information Processing Systems*, Lake Tahoe-Nevada-USA, 2843-2851.
- Clarisse, K. N. I., 2021, Üretken çekişmeli ağ ve UNet kullanılarak segmente edilmiş tomografi görüntülerden Covid-19 sınıflandırmasında farklı derin öğrenme mimarilerinin kullanımı, Yüksek Lisans, *Lisansüstü Eğitim Enstitüsü*, Konya Teknik Üniversitesi.



- Çölkesen, İ., Yomralıoğlu, T. ve Kavzoğlu, T., 2015, Obje tabanlı sınıflandırmada bölgeleme esasına dayalı ölçek parametresi tespiti: WorldView-2 uydu görüntüsü örneği, *Harita Dergisi*, 154, 9-18.
- Da Silva, I. N., Spatti, D. H., Flauzino, R. A., Liboni, L. H. B. ve dos Reis Alves, S. F., 2017, Artificial neural networks, *Cham: Springer International Publishing*, 39.
- Daşkin, Y. Ç., Şanlı, F. B., Özkan, T. ve Kartal, H., 2018, Derin öğrenme yöntemleri ile yüz görüntülerinden yaş kestirimi, *UZAL-CBS 2018*, Eskişehir.
- Dechter, R., 1986, Learning while searching in constraint-satisfaction problems, *AAAI'86: Proceedings of the Fifth AAAI National Conference on Artificial Intelligence*, Philadelphia, 178-183.
- Demirezen, M. U., Civrizoğlu, A. ve Yavanoğlu, U., 2021, Sualtı objelerinin makine öğrenmesi yöntemleri ile tespitinde zaman serisi-görüntü dönüşümü tabanlı yeni yaklaşımlar, *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 36 (3), 1399-1416.
- Demirtaş, M., Ahmet, 2018, Derin öğrenme yöntemleri ile duygu analizi ve aktivasyon fonksiyonlarının karşılaştırılması, Yüksek Lisans, *Fen Bilimleri Enstitüsü*, Atatürk Üniversitesi.
- Deng, J., Dong, W., Socher, R., Li, L.-J., Li, K. ve Fei-Fei, L., 2009, Imagenet: A large-scale hierarchical image database, *2009 IEEE conference on computer vision and pattern recognition*, 248-255.
- Deng, L. ve Yu, D., 2014, Deep learning: methods and applications, *Foundations and trends® in signal processing*, 7 (3-4), 197-387.
- Deniz, A., 2012, Afet yönetiminde coğrafi bilgi sistemi ve uzaktan algılama, *Karaelmas Fen ve Mühendislik Dergisi*, 2 (2), 53-61.
- Doğan, F. ve Türkoğlu, İ., 2019, Derin öğrenme modelleri ve uygulama alanlarına ilişkin bir derleme, *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, 10 (2), 409-445.
- Doğan, F., 2021, SatNet: Uydu görüntülerinden nesne tespiti için yeni bir derin öğrenme modeli, Doktora, *Fen Bilimleri Enstitüsü*, Fırat Üniversitesi.
- Doğan, İ., 2008, Uzaktan algılama verileri ile kıyı çizgisi değişiminin zamansal olarak belirlenmesi: Alaçatı örneği, Yüksek Lisans, *Fen Bilimleri Enstitüsü*, Yıldız Teknik Üniversitesi.
- Döş, M. E., 2020, Uzaktan Algılama Verilerinin Derin Öğrenme ile Sınıflandırılması, Yüksek Lisans, *Fen Bilimleri Enstitüsü*, Afyon Kocatepe Üniversitesi.
- Duchi, J., Hazan, E. ve Singer, Y., 2011, Adaptive subgradient methods for online learning and stochastic optimization, *Journal of machine learning research*, 12 (7).
- Erdem, F., 2018, Landsat-8 uydu görüntülerinden derin öğrenme algoritmaları kullanarak kıyı çizgisi çıkarımı, Yüksek Lisans, *Fen Bilimleri Enstitüsü*, Yıldız Teknik Üniversitesi.
- Erdem, F. ve Avdan, U., 2020, Comparison of different U-net models for building extraction from high-resolution aerial imagery, *International Journal of Environment and Geoinformatics*, 7 (3), 221-227.
- Ergün, O. F., 2023, Türkiye'de Orman Yangınları ve Gönüllülük, *Acil Yardım ve Afet Bilimi Dergisi*, 3 (1), 7-14.
- Erhandı, B., 2020, Derin öğrenme ile metin özetleme, Yüksek Lisans, *Fen Bilimleri Enstitüsü*, Sakarya Üniversitesi.
- Erkal, T. ve Değerliyurt, M., 2009, Türkiye'de afet yönetimi, *Doğu Coğrafya Dergisi*, 14 (22), 147-164.

- Farasin, A., Colomba, L., Palomba, G., Nini, G. ve Rossi, C., 2020, Supervised Burned Areas delineation by means of Sentinel-2 imagery and Convolutional Neural Networks, *Proceedings of the 17th International Conference on Information Systems for Crisis Response and Management (ISCRAM 2020)*, Blacksburg, VA, USA, 1060-1071.
- Gagné, C., Schoenauer, M., Parizeau, M. ve Tomassini, M., 2006, Genetic programming, validation sets, and parsimony pressure, *Genetic Programming: 9th European Conference, EuroGP 2006*, Budapest, Hungary, 109-120.
- Gazel, S. ve Bati, C. T., 2019, Derin sinir ağları ile en iyi modelin belirlenmesi: mantar verileri üzerine Keras uygulaması, *Yuzuncu Yıl University Journal of Agricultural Sciences*, 29 (3), 406-417.
- Goodfellow, I., Bengio, Y. ve Courville, A., 2016, Deep learning, MIT press, p.
- Göksu, T., 2022, Beyin kan damarlarının derin öğrenme sinir ağları kullanılarak analizi, Yüksek Lisans, *Lisansüstü Eğitim Enstitüsü*, Fatih Sultan Mehmet Vakıf Üniversitesi.
- Gu, S., Pednekar, M. ve Slater, R., 2019, Improve image classification using data augmentation and neural networks, *SMU Data Science Review*, 2 (2), 1.
- Gurusamy, V., Kannan, S. ve Nalini, G., 2013, Review on image segmentation techniques, *J Pharm Res*, 20125, 4548-4553.
- Güzel, Y. Y., 2021, Derin Öğrenme ile Yeşil Alanların Çıkarımı, Yüksek Lisans, *Fen Bilimleri Enstitüsü*, Yıldız Teknik Üniversitesi.
- Hafız, A. M. ve Bhat, G. M., 2020, A survey on instance segmentation: state of the art, *International journal of multimedia information retrieval*, 9 (3), 171-189.
- Hariharan, B., Arbeláez, P., Girshick, R. B. ve Malik, J., 2015, Hypercolumns for object segmentation and fine-grained localization, *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Boston-MA-USA, 447-456.
- Hinton, G. E., Osindero, S. ve Teh, Y.-W., 2006, A fast learning algorithm for deep belief nets, *Neural computation*, 18 (7), 1527-1554.
- Hu, X., Ban, Y. ve Nascetti, A., 2021, Uni-Temporal Multispectral Imagery for Burned Area Mapping with Deep Learning, *Remote Sensing*, 13 (8), 1509.
- Huang, B., 2021, Using Synthetic Satellite Imagery from Virtual Worlds to Train Deep Learning Models for Object Recognition, PhD, *Department of Electrical Computer Engineering*, Duke University.
- Huot, F., Hu, R. L., Ihme, M., Wang, Q., Burge, J., Lu, T., Hickey, J., Chen, Y.-F. ve Anderson, J., 2020, Deep learning models for predicting wildfires from historical remote-sensing data, *arXiv preprint arXiv:2010.07445*.
- Huppertz, R., Nakalembe, C., Kerner, H. R., Lachyan, R. ve Rischard, M., 2021, Using transfer learning to study burned area dynamics: A case study of refugee settlements in West Nile, Northern Uganda, *ArXiv*, abs/2107.14372.
- İnik, Ö. ve Ülker, E., 2017, Derin öğrenme ve görüntü analizinde kullanılan derin öğrenme modelleri, *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, 6 (3), 85-104.
- İnik, Ö., 2019, Derin öğrenme kullanarak ovaryum follikülerinin sınıflandırılması, Doktora, *Lisansüstü Eğitim Enstitüsü*, Konya Teknik Üniversitesi.
- Jin, R. ve Niu, Q., 2021, Automatic fabric defect detection based on an improved YOLOv5, *Mathematical Problems in Engineering*, 2021, 1-13.
- Karademir, T., 2019, Voleybol müsabakalarında Derin öğrenme Temelli Oyuncu örüntülü Takip yazılımı geliştirilmesi, Yüksek Lisans, *Sağlık Bilimleri Enstitüsü*, Marmara Üniversitesi.

- Karagöl, S., Bayram, B., Erdem, F. ve BAKİRMAN, T., 2021, Aktarımlı Öğrenme ile SENTINEL-2 Görüntülerinden Kıyı Çizgisi Bölütlemesi, *Türkiye Uzaktan Algılama Dergisi*, 3 (1), 1-7.
- Karki, S. ve Kulkarni, S., 2021, Ship detection and segmentation using unet, *2021 International Conference on Advances in Electrical, Computing, Communication and Sustainable Technologies (ICAECT)*, Bhilai-India, 1-7.
- Kaur, P., Khehra, B. S. ve Mavi, E. B. S., 2021, Data augmentation for object detection: A review, *2021 IEEE International Midwest Symposium on Circuits and Systems (MWSCAS)*, 537-543.
- Kaya, B. ve Önal, M., 2021, COVID-19 Tespiti için Akciğer BT Görüntülerinin Bölütlenmesi, *Avrupa Bilim ve Teknoloji Dergisi* (28), 1296-1303.
- Kholkin, V., Druzhina, O., Vatnik, V., Kulagin, M., Karimov, T. ve Butusov, D., 2023, Comparing Reservoir Artificial and Spiking Neural Networks in Machine Fault Detection Tasks, *Big Data and Cognitive Computing*, 7 (2), 110.
- Khosla, C. ve Saini, B. S., 2020, Enhancing performance of deep learning models with different data augmentation techniques: A survey, *2020 International Conference on Intelligent Engineering and Management (ICIEM)*, 79-85.
- Khryashchev, V. ve Larionov, R., 2020, Wildfire segmentation on satellite images using deep learning, *2020 Moscow Workshop on Electronic and Networking Technologies (MWENT)*, Moscow-Russia, 1-5.
- Kingma, D. P. ve Ba, J., 2014, Adam: A method for stochastic optimization, *arXiv preprint arXiv:1412.6980*.
- Knopp, L., Wieland, M., Rättich, M. ve Martinis, S., 2020, A Deep Learning Approach for Burned Area Segmentation with Sentinel-2 Data, *Remote. Sens.*, 12, 2422.
- Knopp, L., 2021, Development of a Burned Area Processor Based on Sentinel-2 Data Using Deep Learning, *PFG – Journal of Photogrammetry, Remote Sensing and Geoinformation Science*, 89 (4), 357-358.
- Krenker, A., Bešter, J. ve Kos, A., 2011, Introduction to the artificial neural networks, *Artificial Neural Networks: Methodological Advances and Biomedical Applications. InTech*, 1-18.
- Krizhevsky, A., Sutskever, I. ve Hinton, G. E., 2012, Imagenet Classification with Deep Convolutional Neural Networks, *Advances in Neural Information Processing Systems 25 (NIPS 2012)*, Lake Tahoe-Nevada-USA.
- Kutlu, Ö., 2019, İnsansız hava aracı ile elde edilen görüntülerin derin öğrenme yöntemleri ile analizi, Yüksek Lisans, *Fen Bilimleri Enstitüsü*, Marmara Üniversitesi.
- Kuznetsova, A., Rom, H., Alldrin, N., Uijlings, J., Krasin, I., Pont-Tuset, J., Kamali, S., Popov, S., Mallocci, M. ve Kolesnikov, A., 2020, The open images dataset v4: Unified image classification, object detection, and visual relationship detection at scale, *International Journal of Computer Vision*, 128 (7), 1956-1981.
- LeCun, Y., Bottou, L., Bengio, Y. ve Haffner, P., 1998, Gradient-based learning applied to document recognition, *Proc. IEEE*, 86, 2278-2324.
- Lee, I. K., Trinder, J. C. ve Sowmya, A., 2020, Application of U-Net Convolutional Neural Network to Bushfire Monitoring in Australia with Sentinel-1/-2 Data, *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XLIII-B1-2020, 573-578.
- Lee, S. ve You, D., 2019, Data-driven prediction of unsteady flow over a circular cylinder using deep learning, *Journal of Fluid Mechanics*, 879, 217-254.
- Lin, T.-Y., Maire, M., Belongie, S., Hays, J., Perona, P., Ramanan, D., Dollár, P. ve Zitnick, C. L., 2014, Microsoft coco: Common objects in context, *Computer*

- Vision-ECCV 2014: 13th European Conference Proceedings*, Zurich-Switzerland, 740-755.
- Mahesh, B., 2020, Machine learning algorithms-a review, *International Journal of Science and Research (IJSR)*, 9, 381-386.
- Maskouni, F. H. ve Seydi, S. T., 2021, Forest Burned Area Mapping Using Bi-Temporal Sentinel-2 Imagery Based on a Convolutional Neural Network: Case Study in Golestan Forest, *Engineering Proceedings*, 10 (6).
- McCulloch, W. S. ve Pitts, W., 1943, A logical calculus of the ideas immanent in nervous activity, *The bulletin of mathematical biophysics*, 5 (4), 115-133.
- Mete, B. R., 2019, Derin öğrenme ile görüntü sınıflandırma, Yüksek Lisans, *Lisansüstü Eğitim Enstitüsü*, İstanbul Üniversitesi-Cerrahpaşa.
- Metlek, S. ve Çetiner, H., 2021, Matlab Ortamında Derin Öğrenme Uygulamaları, *İksad Publishing House*, Ankara, 1-80.
- Mohla, S., Mohla, S., Guha, A. ve Banerjee, B., 2020, Multimodal Noisy Segmentation based fragmented burn scars identification in Amazon Rainforest, *2020 IEEE International Conference on Systems, Man, and Cybernetics (SMC)*, 4122-4126.
- Murat, U., 2021, Glokom Hastalığının Evrişimli Sinir Ağı Mimarileri ile Tespiti, *Dokuz Eylül Üniversitesi Mühendislik Fakültesi Fen ve Mühendislik Dergisi*, 23 (68), 521-529.
- Muruganandham, S., 2016, Semantic segmentation of satellite images using deep learning, Master, *Department of Computer Science*, Luleå University of Technology
- Namin, A. H., Leboeuf, K., Muscedere, R., Wu, H. ve Ahmadi, M., 2009, Efficient hardware implementation of the hyperbolic tangent sigmoid function, *2009 IEEE International Symposium on Circuits and Systems*, 2117-2120.
- Ni, J., Gao, J., Li, J., Yang, H., Hao, Z. ve Han, Z., 2021, E-AlexNet: quality evaluation of strawberry based on machine learning, *Journal of Food Measurement and Characterization*, 15 (5), 4530-4541.
- Önün, F., 2019, Derin öğrenme ile yüksek çözünürlüklü hava görüntülerinde yolların tespit edilmesi, Yüksek Lisans, *Fen Bilimleri Enstitüsü*, Fırat Üniversitesi.
- Park, S.-W., 2020, Detection of forest fire burned area using Landsat satellite images and Deep learning, Master, *Department of Spatial Information Engineering*, Pukyong National University.
- Park, S., W., ve Lee, Y., W., 2019, Semantic Segmentation of Landsat Images for Detection of Wildfire-damaged Areas, *The 40th Asian Conference on Remote Sensing (ACRS 2019)*, Korea- Daejeon, 1-3.
- Patterson, J. ve Gibson, A., 2017, Deep learning: A practitioner's approach, *O'Reilly Media*, Sebastopol - CA, 1-971.
- Pinto, M. M., Libonati, R., Trigo, R. M., Trigo, I. F. ve DaCamara, C. C., 2020, A deep learning approach for mapping and dating burned areas using temporal sequences of satellite images, *ISPRS Journal of Photogrammetry and Remote Sensing*, 160, 260-274.
- Pinto, M. M., Trigo, R. M., Trigo, I. F. ve DaCamara, C. C., 2021, A Practical Method for High-Resolution Burned Area Monitoring Using Sentinel-2 and VIIRS, *Remote. Sens.*, 13, 1608.
- Prabowo, Y., Dimara Sakti, A., Adi Pradono, K., Amriyah, Q., Ulfa, K., Halim Rasyidy, F., Bengkulah, I., Thufaili Imdad, M., Ali, S. ve Arief, R., 2022a, Dataset of Deep Learning from Landsat-8 Satellite Images for Estimating Burned Areas in Indonesia [online], Mendeley Data, <https://data.mendeley.com/datasets/fs7mtkg2wk/2> [Ziyaret Tarihi: 3 Nisan 2023].

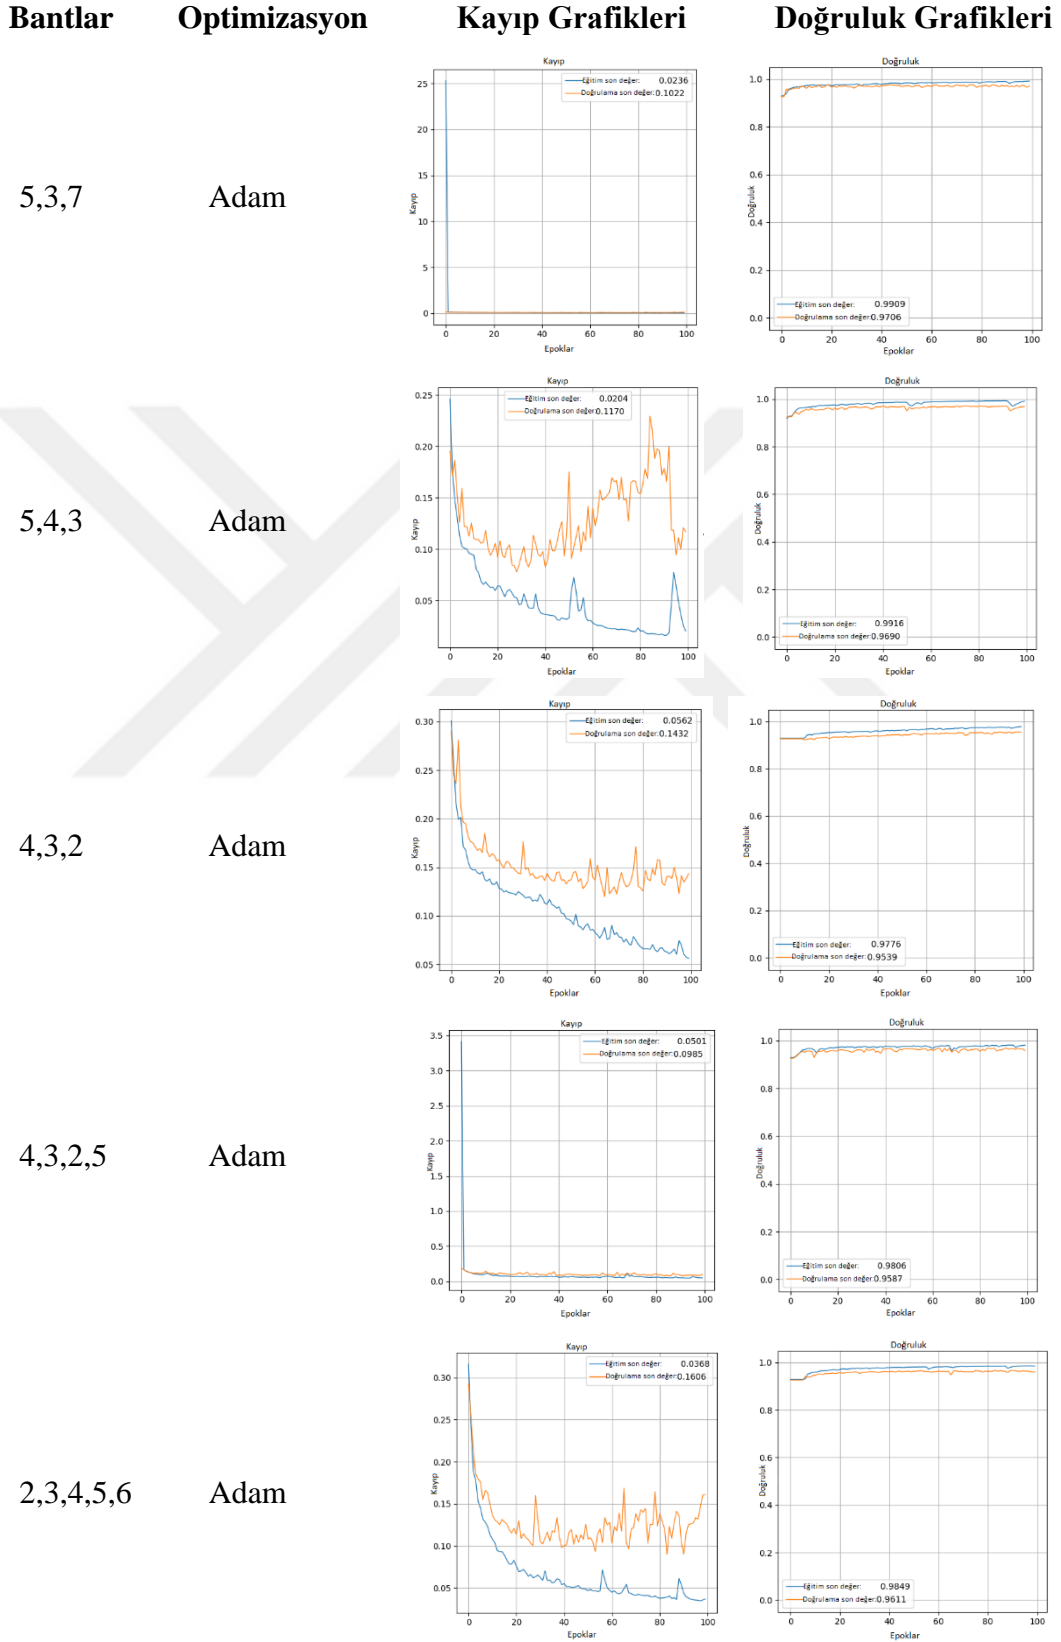
- Prabowo, Y., Sakti, A. D., Pradono, K. A., Amriyah, Q., Rasyidy, F. H., Bengkulah, I., Ulfa, K., Candra, D. S., Imdad, M. T. ve Ali, S., 2022b, Deep Learning Dataset for Estimating Burned Areas: Case Study, Indonesia, *Data*, 7 (6), 78.
- Rashkovetsky, D., 2020, Wildfire Detection from Multi-sensor Satellite Imagery Using a Deep Learning Approach, *the Department of Aerospace and Geodesy*, the Technical University of Munich.
- Rashkovetsky, D., Mauracher, F., Langer, M. ve Schmitt, M., 2021, Wildfire detection from multisensor satellite imagery using deep semantic segmentation, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 14, 7001-7016.
- Ronneberger, O., Fischer, P. ve Brox, T., 2015, U-Net: Convolutional Networks for Biomedical Image Segmentation, *ArXiv, abs/1505.04597*, 9351, 234-241.
- Sabuncu, A. ve Özener, H., 2019, Uzaktan algılama teknikleri ile yanmış alanların tespiti: İzmir Seferihisar orman yangını örneği, *Doğal Afetler ve Çevre Dergisi*, 5 (2), 317-328.
- Sadeghi, J. ve Askarinejad, H., 2012, Application of neural networks in evaluation of railway track quality condition, *Journal of mechanical science and technology*, 26, 113-122.
- Saglam, A. ve Baykan, N. A., 2017, Effects of color spaces and distance norms on graph-based image segmentation, *2017 3rd international conference on frontiers of signal processing (ICFSP)*, 130-135.
- Salvatore, S., Rand, K. D., Grytten, I., Ferkingstad, E., Domanska, D., Holden, L., Gheorghe, M., Mathelier, A., Glad, I. ve Sandve, G. K., 2018, Beware the Jaccard: the choice of metric is important and non-trivial in genomic colocalisation analysis, *bioRxiv*, 479253.
- Saralioğlu, B., 2022, Uzaktan algılanmış görüntülerde mask r-cnn kullanımı, Yüksek Lisans, *Fen Bilimleri Enstitüsü*, Karadeniz Teknik Üniversitesi.
- Saralioğlu, E., 2020, Derin öğrenme için kitle kaynak tabanlı etiketli veri üretimi ve çok bantlı görüntü sınıflandırma için bir 3d-2d cnn modeli, Doktora, *Fen Bilimleri Enstitüsü*, Karadeniz Teknik Üniversitesi.
- Sarıyıldız, H. İ., 2021, Uydu Görüntüleri ve İHA ile Derin Öğrenme Algoritmaları Kullanılarak Hasarlı Yapıların Tespit Edilmesi, Yüksek Lisans, *Lisansüstü Eğitim Enstitüsü*, Ondokuz Mayıs Üniversitesi.
- Sarp, G., Temurçin, K., Aldırmaz, Y. ve Baydoğan, E., 2018, Spatial analysis of forest fires using remote sensing technologies; a case of 2017 Mersin-Anamur forest fire, *Innovation and Global Issues in Multidisciplinary Sciences IV*, Antalya, 300.
- Saylan, İ. H. ve Çömert, R., 2019, Sentinel-2A ürünlerinin yanmış orman alanlarının haritalanmasındaki başarının araştırılması, *Türkiye Uzaktan Algılama Dergisi*, 1 (1), 8-15.
- Seydhosseini, M., Sajjadi, M. S. M. ve Tasdizen, T., 2013, Image Segmentation with Cascaded Hierarchical Models and Logistic Disjunctive Normal Networks, *2013 IEEE International Conference on Computer Vision*, 2168-2175.
- Seyrek, E. C., 2021, Hiperspektral görüntü sınıflandırma uygulamalarında makine ve derin öğrenme kullanımı, Yüksek Lisans, *Fen Bilimleri Enstitüsü*, Afyon Kocatepe Üniversitesi.
- Seyyarer, E., Ayata, F., Uçkan, T. ve Karci, A., 2020, Derin öğrenmede kullanılan optimizasyon algoritmalarının uygulanması ve kıyaslanması, *Computer Science*, 5 (2), 90-98.

- Shi, P., Duan, M., Yang, L., Feng, W., Ding, L. ve Jiang, L., 2022, An improved U-net image segmentation method and its application for metallic grain size statistics, *Materials*, 15 (13), 4417.
- Shijie, J., Ping, W., Peiyi, J. ve Siping, H., 2017, Research on data augmentation for image classification based on convolution neural networks, *2017 Chinese automation congress (CAC)*, 4165-4170.
- Shorten, C. ve Khoshgoftaar, T. M., 2019, A survey on image data augmentation for deep learning, *Journal of big data*, 6 (1), 1-48.
- Simonyan, K. ve Zisserman, A., 2014, Very deep convolutional networks for large-scale image recognition, *arXiv preprint arXiv:1409.1556*.
- Sivri, S., 2019, Farklı Derin Öğrenme Yaklaşımları ile Yolların Segmentasyonu, Yüksek Lisans, *Fen Bilimleri Enstitüsü*, Yıldız Teknik Üniversitesi.
- Soydaner, D., 2020, A comparison of optimization algorithms for deep learning, *International Journal of Pattern Recognition and Artificial Intelligence*, 34 (13), 2052013.
- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I. ve Salakhutdinov, R., 2014, Dropout: a simple way to prevent neural networks from overfitting, *The journal of machine learning research*, 15 (1), 1929-1958.
- Sunar, F. ve Özkan, C., 2001, Forest fire analysis with remote sensing data, *International Journal of Remote Sensing*, 22 (12), 2265-2277.
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V. ve Rabinovich, A., 2015, Going deeper with convolutions, *Proceedings of the IEEE conference on computer vision and pattern recognition*, 1-9.
- Şeker, A., Diri, B. ve Balık, H. H., 2017, Derin öğrenme yöntemleri ve uygulamaları hakkında bir inceleme, *Gazi Mühendislik Bilimleri Dergisi*, 3 (3), 47-64.
- Thoma, M., 2016, A survey of semantic segmentation, *arXiv preprint arXiv:1602.06541*.
- URL-1, Ormanlarımız [online], <https://webdosya.csb.gov.tr/db/bolu/icerikler/ormanlarimiz-201802222083128.pdf> [Ziyaret Tarihi: 21 Nisan 2023].
- URL-2, Resmi İstatistikler [online], <https://www.ogm.gov.tr/tr/e-kutuphane/resmi-istatistikler> [Ziyaret Tarihi: 21 Nisan 2023].
- URL-3, Landsat 8 [online], <https://www.usgs.gov/landsat-missions/landsat-8> [Ziyaret Tarihi: 24 Şubat 2023].
- Uyar, K., 2022, Konvolüsyonel sinir ağlarında ağ eğitiminin iyileştirilmesi, Doktora, *Fen Bilimleri Enstitüsü*, Selçuk Üniversitesi.
- Ünlü, E. I., 2019, Derin öğrenme ile görüntü bölütleme, Yüksek Lisans, *Fen Bilimleri Enstitüsü*, Fırat Üniversitesi.
- Vezakis, I. A., Lambrou, G. I. ve Matsopoulos, G. K., 2023, Deep Learning Approaches to Osteosarcoma Diagnosis and Classification: A Comparative Methodological Approach, *Cancers*, 15 (8), 2290.
- Wagle, S. A., Sampe, J., Mohammad, F. ve Ali, S. H. M., 2021, Effect of Data Augmentation in the Classification and Validation of Tomato Plant Disease with Deep Learning Methods, *Traitement du Signal*, 38 (6).
- Walczak, S., 2019, Artificial neural networks, In: Advanced methodologies and technologies in artificial intelligence, computer simulation, and human-computer interaction, Eds: IGI global, p. 40-53.
- Wieland, M., Li, Y. ve Martinis, S., 2019, Multi-sensor cloud and cloud shadow segmentation with a convolutional neural network, *Remote Sensing of Environment*.

- Wieland, M. ve Martinis, S., 2019, A Modular Processing Chain for Automated Flood Monitoring from Multi-Spectral Satellite Data, *Remote. Sens.*, 11, 2330.
- Xu, Y. ve Goodacre, R., 2018, On splitting training and validation set: a comparative study of cross-validation, bootstrap and systematic sampling for estimating the generalization performance of supervised learning, *Journal of analysis and testing*, 2 (3), 249-262.
- Yaqub, M., Feng, J., Zia, M. S., Arshid, K., Jia, K., Rehman, Z. U. ve Mehmood, A., 2020, State-of-the-art CNN optimizer for brain tumor segmentation in magnetic resonance images, *Brain Sciences*, 10 (7), 427.
- Yavuz, A., 2021, Derin öğrenme algoritmaları ile trafik işaret ve levhalarının tanımlanması, Yüksek Lisans, *Fen Bilimleri Enstitüsü*, Pamukkale Üniversitesi.
- Yiğit, A., 2017, İş süreçlerinde insan görüşünü derin öğrenme ile destekleme, Yüksek Lisans, *Fen Bilimleri Enstitüsü*, Trakya Üniversitesi
- Yiğit, A. ve Uysal, M., 2019, Afet yönetiminde uzaktan algılamanın kullanımı, *IdRc 2019 International Disaster & Resilience Congress*, 28.
- Yılmaz, E. Ö., 2020, Uzaktan algılanmış verilerin derin öğrenme yöntemiyle sınıflandırılması, Yüksek Lisans, *Fen Bilimleri Enstitüsü*, Gebze Teknik Üniversitesi.
- Zhang, Q., Ge, L., Zhang, R., Metternicht, G. I., Du, Z., Kuang, J. ve Xu, M., 2021, Deep-learning-based burned area mapping using the synergy of Sentinel-1&2 data, *Remote Sensing of Environment*, 264, 112575.

## EKLER

## EK-1 Eğitim Sonuçlarının Kayıp ve Doğruluk Grafikleri





## EK-1'in devamı

Bantlar



Optimizasyon

Kayıp Grafikleri

Doğruluk Grafikleri



7,5,4

AdaGrad





7,5,4

AdaMax





4,3,2

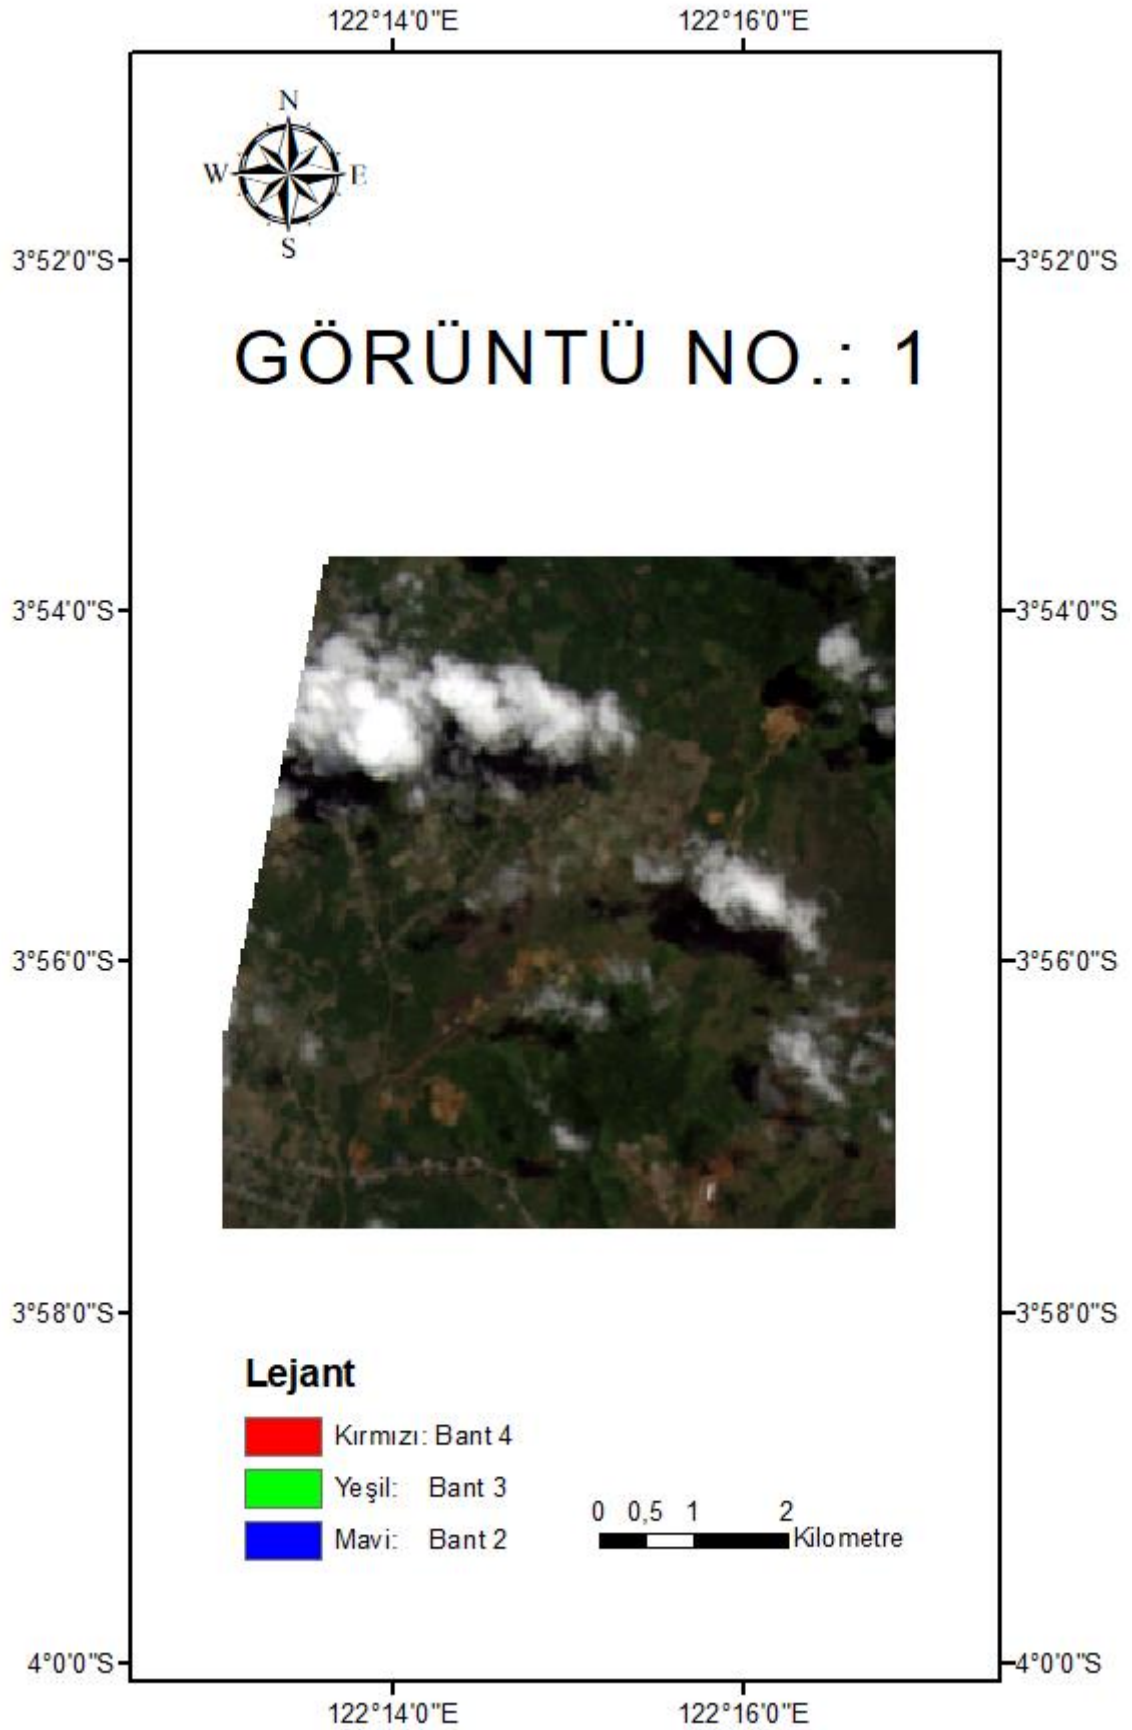
AdaGrad

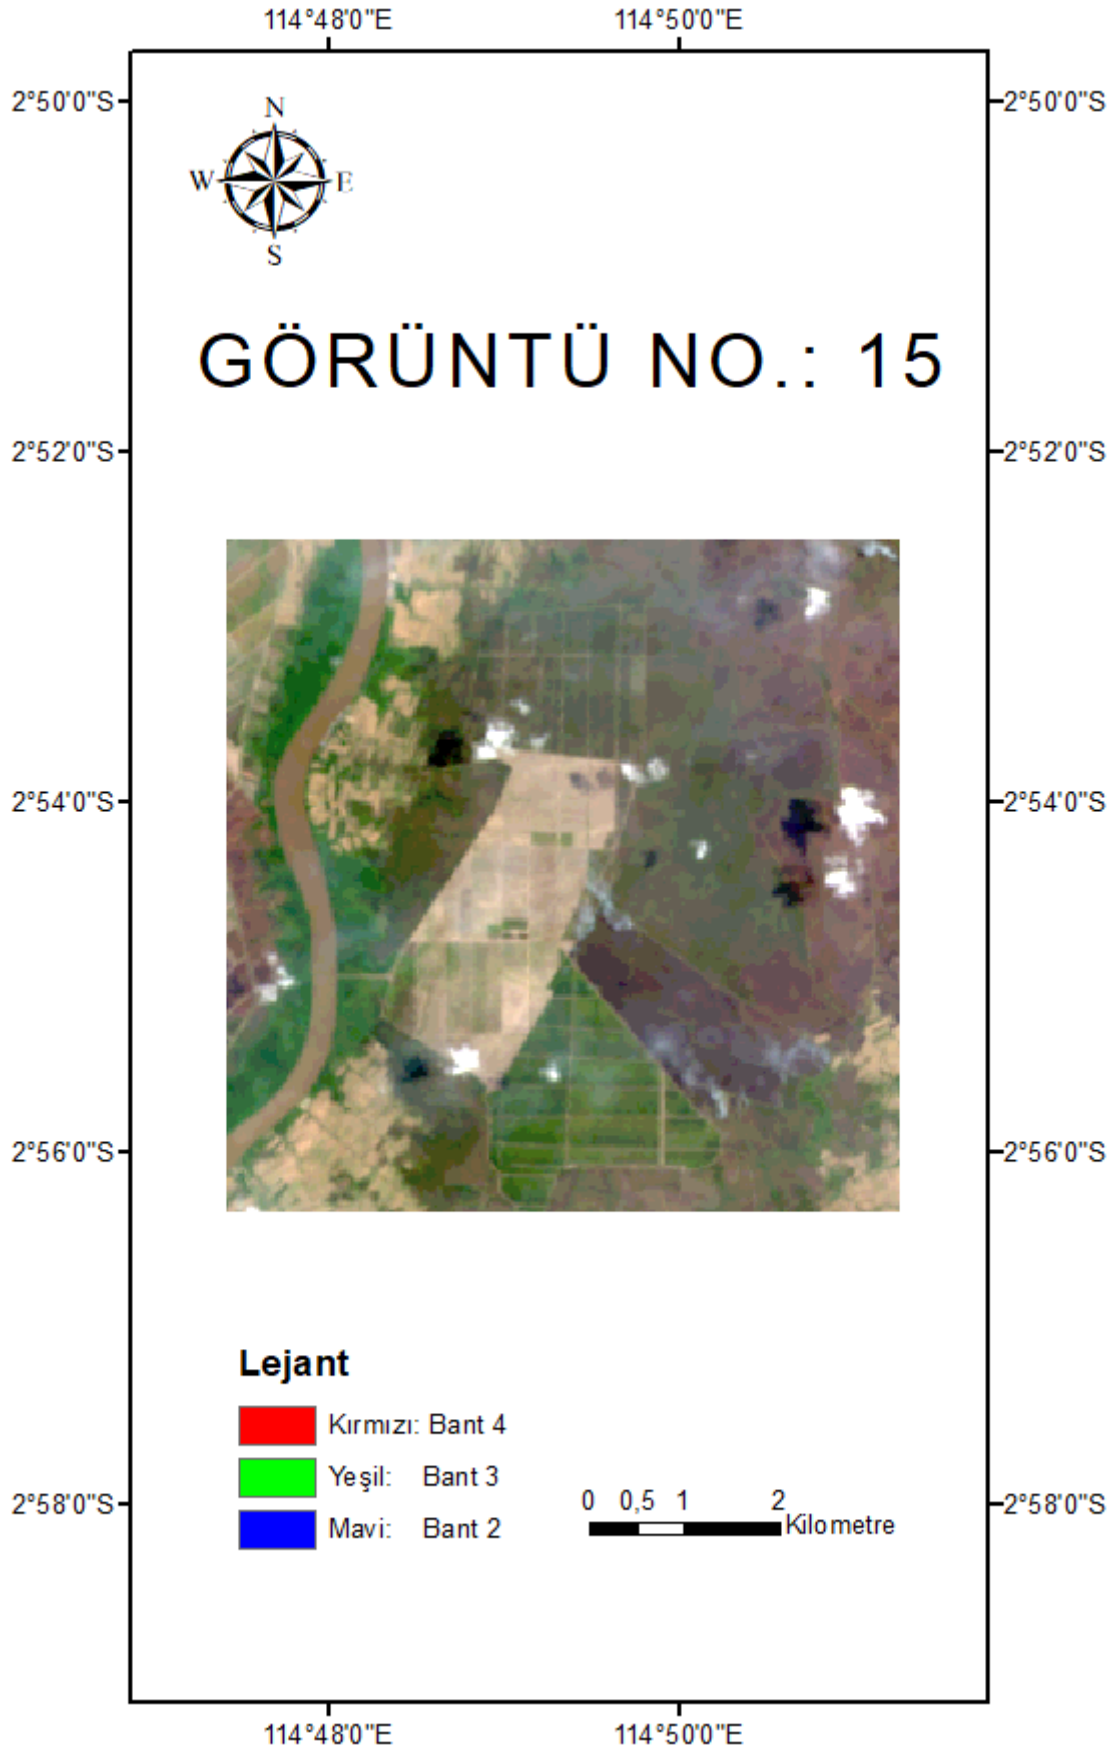


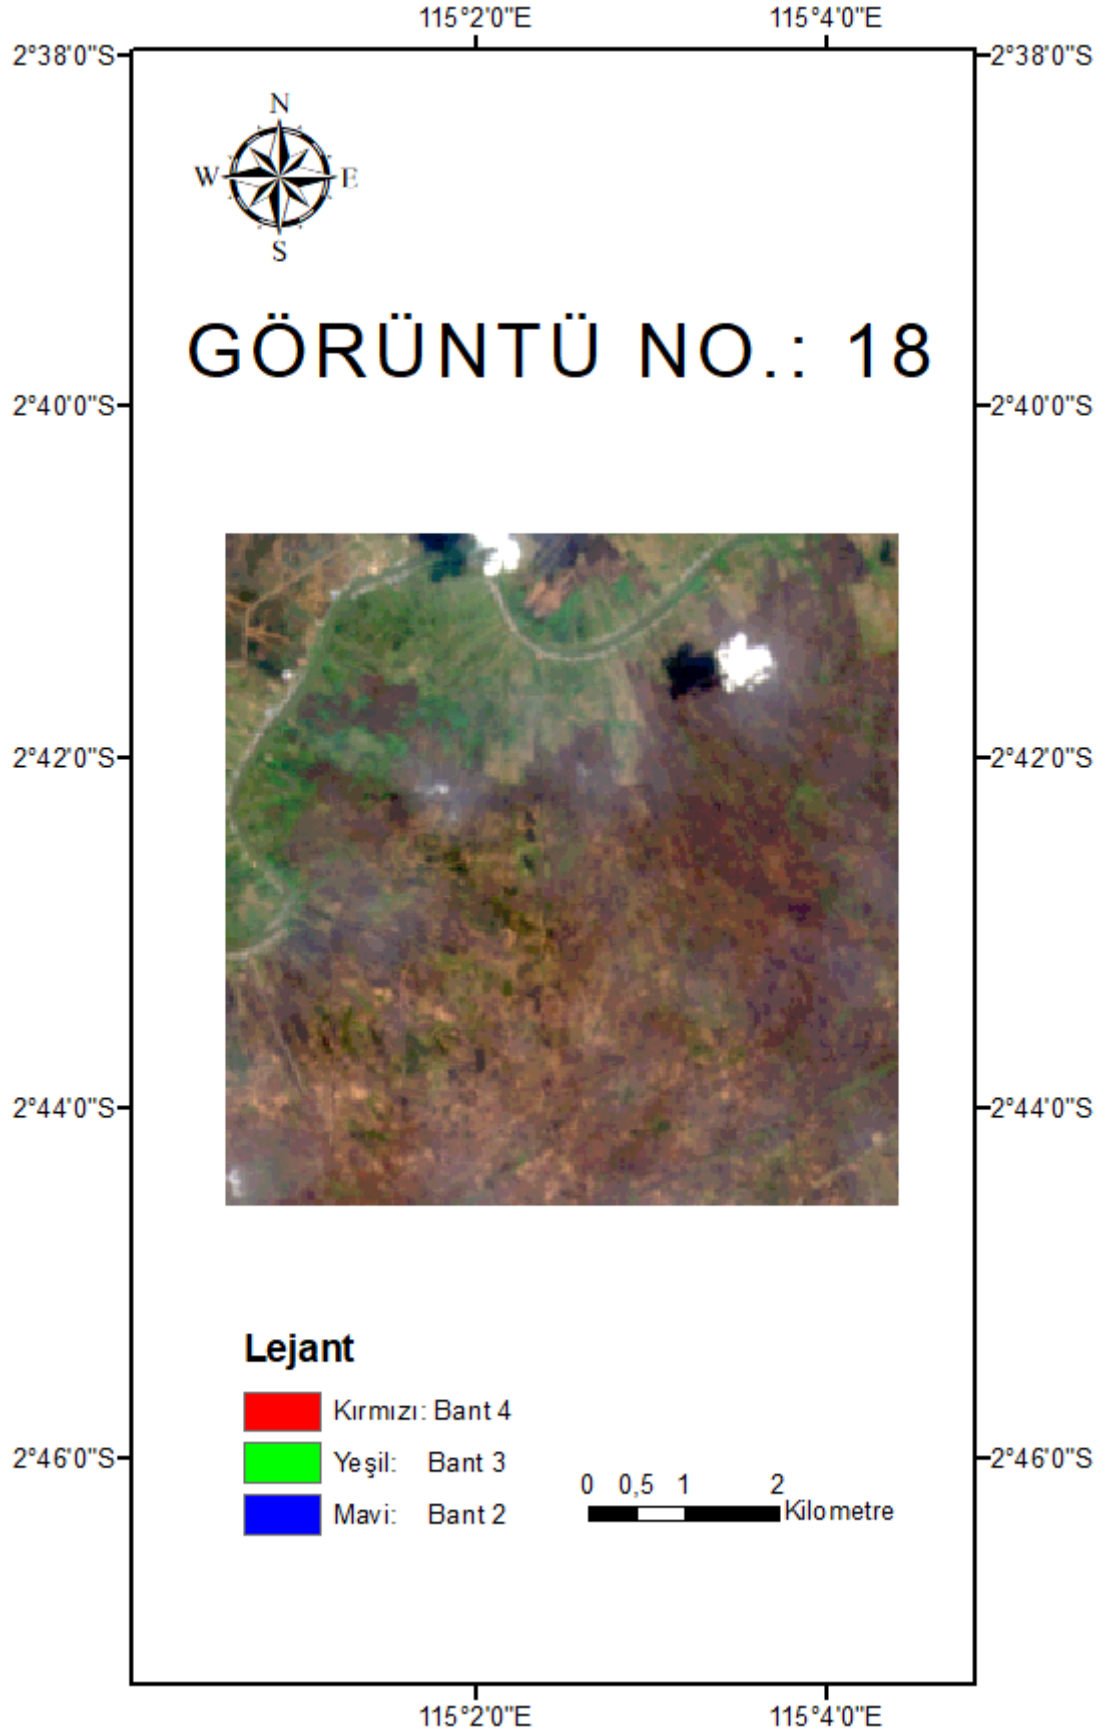
4,3,2


AdaMax

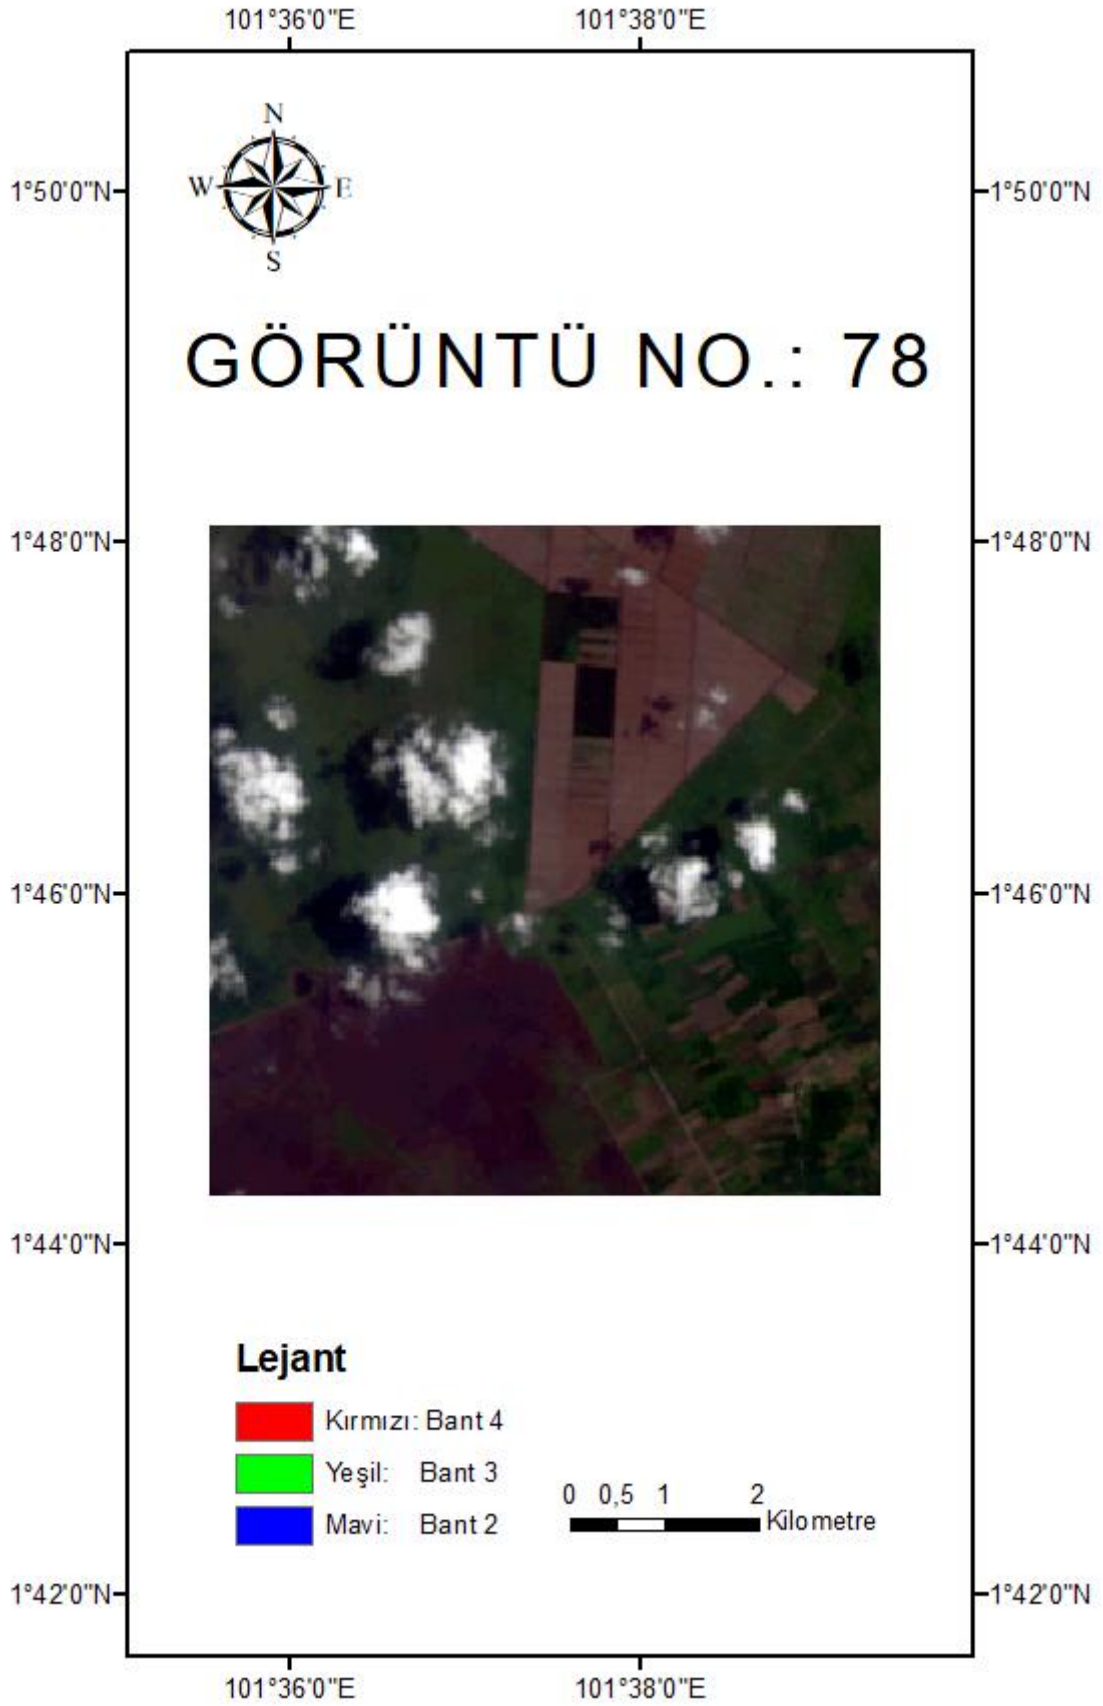


**EK-2** Test Görüntüsü (Görüntü No.: 1)

**EK-3** Test Görüntüsü (Görüntü No.: 15)

**EK-4** Test Görüntüsü (Görüntü No.: 18)

**EK-5** Test Görüntüsü (Görüntü No.: 55)

**EK-6** Test Görüntüsü (Görüntü No.: 78)

## EK-7 Bant Kombinasyonları İçin Hata Matrisleri (Eşik=0.1)

Bant Kombinasyonu	Görüntü No.	Hata Matrisi	
7,5,4	1	63809	532
		206	989
	15	46220	4636
		68	14612
	18	15298	2638
		140	47460
	55	65536	
	78	52852	909
		78	11697

Bant Kombinasyonu	Görüntü No.	Hata Matrisi	
5,3,7	1	63298	1043
		250	945
	15	46860	3996
		433	14247
	18	15303	2633
		739	46861
	55	64530	1006
		0	0
	78	52812	949
		147	11628

Bant Kombinasyonu	Görüntü No.	Hata Matrisi	
5,4,3	1	63924	417
		830	365
	15	46594	4262
		58	14622
	18	15376	2560
		2166	45434
	55	65536	
	78	53219	542
		544	11231

Bant Kombinasyonu	Görüntü No.	Hata Matrisi	
4,3,2	1	63400	941
		678	517
	15	40062	10794
		160	14520
	18	13796	4140
		925	46675
	55	65393	143
		0	0
	78	42863	10898
		346	11429

Bant Kombinasyonu	Görüntü No.	Hata Matrisi	
4,3,2,5	1	62788	1553
		235	960
	15	37127	13729
		1	14679
	18	14732	3204
		113	47487
	55	59914	5622
		0	0
	78	51015	2746
		154	11621

Bant Kombinasyonu	Görüntü No.	Hata Matrisi	
2,3,4,5,6,7	1	64297	44
		792	403
	15	49339	1517
		1438	13242
	18	15093	2843
		390	47210
	55	65535	1
		0	0
	78	53169	592
		186	11589

## EK-8 Bant Kombinasyonları İçin Hata Matrisleri (Eşik=0.5)

Bant Kombinasyonu	Görüntü No.	Hata Matrisi	
7,5,4	1	64277	64
		492	703
	15	49206	1650
		561	14119
	18	16802	1134
		1102	46498
	55	65536	
	78	53562	199
		420	11355

Bant Kombinasyonu	Görüntü No.	Hata Matrisi	
5,3,7	1	64007	334
		530	665
	15	49393	1463
		1668	13012
	18	16609	1327
		1520	46080
	55	65060	476
		0	0
	78	53471	290
		457	11318

Bant Kombinasyonu	Görüntü No.	Hata Matrisi	
5,4,3	1	64244	97
		1037	158
	15	49102	1754
		481	14199
	18	16737	1199
		3040	44560
	55	65536	
	78	53562	199
		1221	10554

Bant Kombinasyonu	Görüntü No.	Hata Matrisi	
4,3,2	1	64220	121
		1016	179
	15	47117	3739
		1300	13380
	18	16330	1606
		4186	43414
	55	65536	
	78	47238	6523
		1689	10086

Bant Kombinasyonu	Görüntü No.	Hata Matrisi	
4,3,2,5	1	63941	400
		600	595
	15	45805	5051
		133	14547
	18	16665	1271
		1500	46100
	55	64639	897
		0	0
	78	53289	472
		1550	10225

Bant Kombinasyonu	Görüntü No.	Hata Matrisi	
2,3,4,5,6,7	1	64340	1
		1121	74
	15	50671	185
		3466	11214
	18	16878	1058
		3074	44526
	55	65536	
	78	53666	95
		1120	10655



## EK-9 Bant Kombinasyonları İçin Hata Matrisleri (Eşik=0.9)

Bant Kombinasyonu	Görüntü No.	Hata Matrisi	
7,5,4	1	64340	1
		815	380
	15	50566	290
		2468	12212
	18	17549	387
		4407	43193
	55	65536	
	78	53703	58
		1028	10747

Bant Kombinasyonu	Görüntü No.	Hata Matrisi	
5,3,7	1	64264	77
		863	332
	15	50589	267
		4414	10266
	18	17474	462
		4101	43499
	55	65344	192
		0	0
	78	53710	51
		1099	10676

Bant Kombinasyonu	Görüntü No.	Hata Matrisi	
5,4,3	1	64325	16
		1144	51
	15	50371	485
		1722	12958
	18	17439	497
		4612	42988
	55	65536	
	78	53695	66
		2086	9689

Bant Kombinasyonu	Görüntü No.	Hata Matrisi	
4,3,2	1	64341	0
		1195	0
	15	50266	590
		5829	8851
	18	17730	206
		14471	33129
	55	65536	
	78	51914	1847
		4527	7248

Bant Kombinasyonu	Görüntü No.	Hata Matrisi	
4,3,2,5	1	64288	53
		1073	122
	15	50348	508
		2304	12376
	18	17652	284
		7459	40141
	55	65533	3
		0	0
	78	53750	11
		4382	7393

Bant Kombinasyonu	Görüntü No.	Hata Matrisi	
2,3,4,5,6,7	1	64341	0
		1186	9
	15	50854	2
		9458	5222
	18	17818	118
		11030	36570
	55	65536	
	78	53748	13
		2674	9101

## EK-10 Optimizasyon Algoritmaları İçin Hata Matrisleri

AdaGrad Algoritması (Eşik = 0.1)			
Bant Kombinasyonu	Görüntü No.	Hata Matrisi	
7,5,4	1	61812	2529
		133	1062
	15	38959	11897
		44	14636
	18	13128	4808
		19	47581
	55	63397	2139
		0	0
	78	50450	3311
		18	11757

AdaMax Algoritması (Eşik = 0.1)			
Bant Kombinasyonu	Görüntü No.	Hata Matrisi	
7,5,4	1	63232	1109
		159	1036
	15	46303	4553
		279	14401
	18	15048	2888
		105	47495
	55	65533	236
		0	0
	78	52564	1197
		74	11701

AdaGrad Algoritması (Eşik = 0.5)			
Bant Kombinasyonu	Görüntü No.	Hata Matrisi	
7,5,4	1	63843	498
		536	659
	15	48750	2106
		802	13878
	18	16196	1740
		859	46741
	55	65515	21
		0	0
	78	53337	424
		167	11608

AdaMax Algoritması (Eşik = 0.5)			
Bant Kombinasyonu	Görüntü No.	Hata Matrisi	
7,5,4	1	64111	230
		348	847
	15	48894	1962
		771	13909
	18	16528	1408
		553	47047
	55	65536	
		78	53345
	379		11396

AdaGrad Algoritması (Eşik = 0.9)			
Bant Kombinasyonu	Görüntü No.	Hata Matrisi	
7,5,4	1	64319	22
		1007	188
	15	50855	1
		10926	3754
	18	17697	239
		6491	41109
	55	65536	
		78	53695
	1215		10560

AdaMax Algoritması (Eşik = 0.9)			
Bant Kombinasyonu	Görüntü No.	Hata Matrisi	
7,5,4	1	64322	19
		647	548
	15	50239	617
		2157	12523
	18	17439	497
		2019	45581
	55	65536	
		78	53651
	870		10905

## EK-10'un devamı

AdaGrad Algoritması (Eşik = 0.1)			
Bant Kombinasyonu	Görüntü No.	Hata Matrisi	
4,3,2	1	12355	51986
		11	1184
	15	0	50856
		0	14680
	18	132	17804
		1	47599
	55	40172	25364
		0	0
	78	7254	46507
		30	11745

AdaMax Algoritması (Eşik = 0.1)			
Bant Kombinasyonu	Görüntü No.	Hata Matrisi	
4,3,2	1	64296	45
		1195	0
	15	33642	17214
		158	14522
	18	12477	5459
		680	46920
	55	36098	29438
		0	0
	78	43436	10325
		894	10881

AdaGrad Algoritması (Eşik = 0.5)			
Bant Kombinasyonu	Görüntü No.	Hata Matrisi	
4,3,2	1	64341	0
		1195	0
	15	50856	0
		14680	0
	18	17936	0
		47600	0
	55	65536	
	78	53761	0
		11775	0

AdaMax Algoritması (Eşik = 0.5)			
Bant Kombinasyonu	Görüntü No.	Hata Matrisi	
4,3,2	1	64341	0
		1195	0
	15	49146	1710
		3440	11240
	18	16992	944
		13464	34136
	55	62014	3522
		0	0
	78	47743	6018
		2493	9282

AdaGrad Algoritması (Eşik = 0.9)			
Bant Kombinasyonu	Görüntü No.	Hata Matrisi	
4,3,2	1	64341	0
		1195	0
	15	50856	0
		14680	0
	18	17936	0
		47600	0
	55	65536	
	78	53761	0
		11775	0

AdaMax Algoritması (Eşik = 0.9)			
Bant Kombinasyonu	Görüntü No.	Hata Matrisi	
4,3,2	1	64341	0
		1195	0
	15	50856	0
		14680	0
	18	17936	0
		47600	0
	55	65536	
	78	53761	0
		11775	0

## EK-11 Nihai Model İçin Hata Matrisleri (AdaMax Algoritması)

Nihai Model (Eşik =0.1)			
Bant Kombinasyonu	Görüntü No.	Hata Matrisi	
7,5,4	1	63982	359
		160	1035
	15	46640	4216
		169	14511
	18	14981	2955
		30	47570
	55	65536	
	78	53233	528
		75	11700

Nihai Model (Eşik =0.5)			
Bant Kombinasyonu	Görüntü No.	Hata Matrisi	
7,5,4	1	64297	44
		483	712
	15	48932	1924
		499	14181
	18	16606	1330
		506	47094
	55	65536	
	78	53573	188
		337	11438

Nihai Model (Eşik =0.9)			
Bant Kombinasyonu	Görüntü No.	Hata Matrisi	
7,5,4	1	64341	0
		800	395
	15	50250	606
		1440	13240
	18	17594	342
		2929	44671
	55	65536	
	78	53697	64
		843	10932