



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



**DERİN ÖĞRENME KULLANARAK**  
**OVARYUM FOLLİKÜLLERİNİN**  
**SINIFLANDIRILMASI**

**Özkan İNİK**

**DOKTORA TEZİ**

**Bilgisayar Mühendisliği Anabilim Dalı**

**Kasım-2019**  
**KONYA**  
**Her Hakkı Saklıdır**

## TEZ KABUL VE ONAYI

Özkan İNİK tarafından hazırlanan “*DERİN ÖĞRENME KULLANARAK OVARYUM FOLLİKÜLLERİNİN SINIFLANDIRILMASI*” adlı tez çalışması 27/11/2019 tarihinde aşağıdaki jüri tarafından oy birliği ile Konya Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı’nda DOKTORA TEZİ olarak kabul edilmiştir.

### Jüri Üyeleri

#### Başkan

Dr. Öğr. Üyesi Yusuf UZUN

#### Danışman

Prof. Dr. Erkan ÜLKER

#### Üye

Dr. Öğr. Üyesi Onur İNAN

#### Üye

Doç. Dr. Halife KODAZ

#### Üye

Prof. Dr. Harun UĞUZ

### İmza

  
.....  
  
.....  
  
.....  
  
.....  
  
.....

Yukarıdaki sonucu onaylarım.

Prof. Dr. Saadettin Erhan KESEN  
Enstitü Müdürü

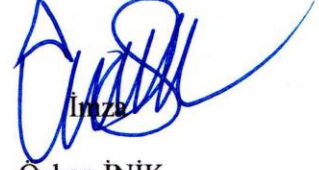
Bu tez çalışması Türkiye Bilimsel ve Teknolojik Araştırma Kurumu (TÜBİTAK-1512) tarafından 2180141 nolu proje ile desteklenmiştir.

## 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.



Özkan İNİK

Tarih: 27.11.2019

# ÖZET

## DOKTORA TEZİ

### DERİN ÖĞRENME KULLANILARAK OVARYUM FOLLİKÜLLERİNİN SINIFLANDIRILMASI

Özkan İNİK

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

**Danışman: Prof. Dr. Erkan ÜLKER**

**2019, 88 Sayfa**

**Jüri**

**Prof. Dr. Erkan ÜLKER  
Prof. Dr. Harun UĞUZ  
Doç. Dr. Halife KODAZ  
Dr. Öğr. Üyesi Onur İNAN  
Dr. Öğr. Üyesi Yusuf UZUN**

Birçok hastalığın teşhisinde ve yapılan bilimsel çalışmalarda mikroskopik görüntüler kullanılmaktadır. Bu görüntüler üzerindeki histolojik analizler, alanında uzman kişiler tarafından yapılmaktadır. Genel anlamda histolojik analiz; hücre, hücre yapıları ve histomorfolojik çalışmaları ifade eder. Histolojik analizlerde görüntü sayısının artması, uzman için hem uzun zaman almakta hem de fazla iş yükü oluşturmaktadır. Ayrıca yapılan analizler her uzmanın bilgi birikimine bağlı olarak çoğu zaman öznel bir şekilde yapılmaktadır. Bu gibi problemler düşünüldüğünde daha az zamanda çok daha fazla görüntü analizini nesnel bir şekilde yapacak akıllı sistemlere ihtiyaç duyulmaktadır.

Literatürde makine öğrenmesi yöntemleri ile medikal görüntülerin analizleri için farklı algoritmalar geliştirilmiştir. Fakat bu yöntemlerde ham verinin işlenmesinde uzmana ihtiyaç duyulmaktadır. Uzmana ihtiyaç duyulmadan ham veri üzerinde özellik keşfinin otomatik olarak yapılması için Derin Öğrenme(DÖ) mimarileri geliştirilmiştir. DÖ yapay zekânın alt dalı olup derin katmanlı ağ mimarilerinin genel bir adı olarak ifade edilmektedir. DÖ modellerinin ortaya çıkmasıyla nesne sınıflandırmadaki hata oranı keskin bir düşüş göstermiştir. DÖ'deki bu başarının temel sebebi, farklı katmanlarda veriye ait farklı özelliklerin keşfedilmesi olarak açıklanabilir. Bu sebeple son yıllarda başta medikal görüntülerin analizi üzere birçok farklı alanla DÖ yöntemleri sıklıkla kullanılmaya başlanmıştır.

Yapılan bu tez kapsamında, ovaryum görüntülerin segmentasyonu ve sınıflandırılması için DÖ tabanlı yeni bir yöntem önerilmiştir. Önerilen yöntemde ovaryum dokusuna ait primordial, primer, preantral, sekonder ve tersiyer olmak üzere toplam beş farklı follikülün otomatik sayılması gerçekleştirilmektedir. Literatürde ovaryum dokusundaki bu beş follikülün otomatik sayılması ilk defa bu tez kapsamında gerçekleştirilmiştir. Önerilen yöntem eğitim ve test olmak üzere iki bölümden oluşmaktadır. Eğitim kısmında farklı Evrişimsel Sinir Ağlarının(ESA) tasarlanması ve eğitilmesi gerçekleştirilmiştir. Test işleminde ise eğitilen ESA modelleri kullanılarak hem segmentasyon hem de sınıflandırma işlemi yapılarak, görüntü içerisinde aranan bir hücre veya hücresel yapının nerede ve ne olduğuna karar verilmektedir. Yöntemin ilk bölümünde toplam 55 farklı ESA modeli tasarlanmıştır. Bu modellerden 43 tanesi segmentasyon için 12 tanesi ise sınıflandırma için tasarlanmıştır. Bu modellerin eğitim ve test aşamalarında kullanılmak üzere ovaryum dokusuna ait 10500 adet görüntüden oluşan özgün bir veri seti oluşturulmuştur. Bu veri setinde her bir görüntüdeki folliküller etiketlenmiştir. Etiketli görüntülerden segmentasyon ve sınıflandırma için tasarlanan ESA modellerinin eğitilmesi için ayrıca

farklı veri setleri de oluşturulmuştur. Segmentasyon için tasarlanan modeller arasında en yüksek doğruluğu elde eden ESA modelinin başarısı %87.1 olarak bulunmuştur. Sınıflandırma işlemi için en yüksek doğruluğa sahip ESA modelinin başarısı ise %96.01 olarak elde edilmiştir. Yöntemin ikinci bölümü olan test bölümünde, öncelikle segmentasyon için eğitilen ESA modeli kullanılarak filtre tabanlı segmentasyon işlemi yapılmaktadır. Bu işlem sonrasında oluşan gürültünün temizlenmesi ve hücresel yapıların sınırlarının belirlenmesi için yeni bir yöntem önerilmiştir. Sınırları belirlenen hücresel yapıların sınıflandırılması için ise önceden eğitilen ESA modeli kullanılmaktadır.

Geliştirilen yöntemin segmentasyon doğruluğunun artırılması için, yöntemde kullanılan Adım Kayma Değeri(AKD), Komşu Sınıf Uzaklığı(KSU) ve Bulanık Sınıf Değeri(BSD) parametrelerinin optimizasyonu gerçekleştirilmiştir. Optimizasyon işlemi için Yapay Arı Kolonisi Algoritması(YAKA) kullanılmıştır. Önerilen yöntem, Ovaryum folliküllerinin otomatik sayılması probleminde, test görüntüleri üzerinde uzman tarafından elde edilen sonuçlar ile karşılaştırılmıştır. Uzman sayım sonuçları referans alındığında, yöntemin elde ettiği doğruluk değeri %96.75 olarak bulunmuştur. Yöntem, ayrıca Faster R-CNN modeli ile karşılaştırılmıştır. Faster R-CNN modeli, literatürde nesne tanımlamada yüksek doğruluğa sahip bir model olarak görülmektedir. Bu modelde katman yapısı olarak farklı ESA modelleri kullanılabilir. Bu sebeple tez kapsamında Faster R-CNN'de katman yapısı olarak AlexNet, Vgg16 ve Vgg19 modelleri kullanılmıştır. Yapılan deneysel çalışmalar sonucunda, önerilen yöntemin Faster R-CNN modelinin bütün katman yapıları ile kullanılmasında elde ettiği değerlerden daha başarılı olduğu gösterilmiştir.

**Anahtar Kelimeler:** Derin Öğrenme, Evrimsel Sinir Ağı, Faster R-CNN, VggNet, AlexNet, Ovaryum, Follikül, Medikal Görüntü, Yapay Arı Kolonisi Algoritması

## **ABSTRACT**

## **PhD THESIS**

# **CLASSIFICATION OF OVARIAN FOLLICLES WITH DEEP LEARNING**

**Özkan İNİK**

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

**Advisor: Prof. Dr. Erkan ÜLKER**

**2019, 88 Pages**

**Jury**

**Prof. Dr. Erkan ÜLKER**

**Prof. Dr. Harun UĞUZ**

**Assoc. Prof. Dr. Halife KODAZ**

**Assist. Prof. Dr. Onur İNAN**

**Assist. Prof. Dr. Yusuf UZUN**

Microscopic images are used in the diagnosis and scientific studies of many diseases. Histological analyses of these images are performed by experts. In general, histological analysis refers to studies on cells, cell structures, and tissue. The increase in the number of images in the histological analysis takes a long time for the expert and also creates an excessive workload. Furthermore, the analyzes are often subjectively based on the knowledge of each specialist. Considering such problems, there is a need for intelligent systems that can perform objectively image analysis in less time.

Different algorithms have been developed for the analysis of medical images with machine learning methods in the literature. However, these methods require the expert to process raw data. Deep Learning (DL) models have been developed for automatic feature discovery on raw data without the need for experts. DL is a sub-branch of artificial intelligence and is referred to as a generic name for deep network architectures. The error rate in object classification has declined sharply using DL models. The main reason for this success in DL can be explained as the discovery of different features of data in different deep layer structures. For this reason, in recent years, DL methods have been used frequently in many different fields, especially the analysis of medical images.

In this thesis, a new method based on DL for segmentation and classification of ovarium images has been proposed. The proposed method was used for automatic counting of five different follicles that primordial, primary, preantral, secondary and tertiary, belonging to ovary tissue. In the literature, the automatic counting of these follicles was performed for the first time within the scope of this thesis. The proposed method consists of two parts: training and testing. In the training section, different Convolutional Neural Networks (CNN) were designed. In the test process, both segmentation and classification process is performed using trained CNN models and it is decided where and what a cell or cellular structure in the image. In the first part of the method, 55 different CNN models were designed. 43 of these models were designed for segmentation and 12 for classification. An original data set consisting of 10500 images of ovarian tissue was created to be used in the training and testing of these models. In this dataset, follicles in each image are labeled. Different data sets have also been created to train CNN models designed for segmentation and classification from labeled images. The success of the CNN model, which achieved the highest accuracy among the models for segmentation was 87.1%. The success rate of the highest accuracy CNN model for the classification process was 96.01%. In the test section of the method, filter-based segmentation is performed using CNN, which is trained primarily for

segmentation. A new method has been proposed to remove the noise generated after this process and to determine the boundaries of cellular structures. Pretrained CNN model is used to classify the cellular structures whose boundaries are defined.

In order to increase the segmentation accuracy of the developed method, General Stride (GS), Neighbor Distance (ND) and Patch Accuracy (PA) parameters used in the method were optimized. The Artificial Bee Colony Algorithm (ABC) was used for optimization. The proposed method is compared with the results obtained by the expert on test images in the problem of automatic counting of ovarian follicles. When the expert results were taken as a reference, the accuracy value of the method was found to be 96.75%. The method was also compared with the Faster R-CNN model. The Faster R-CNN model is accepted as a high accuracy model in object identification in literature. In this model, different CNN models can be used as layers. For this reason, AlexNet, Vgg16, and Vgg19 models are used as layer in Faster R-CNN. As a result of the experimental studies, it has been shown that the proposed method is more successful than the the Faster R-CNN model.

**Keywords:** Deep Learning, Convolutional Neural Networks, Faster R-CNN, VggNet, AlexNet, Ovary, Follicle, Medical images, Artificial Bee Colony



## ÖNSÖZ

Doktora tez çalışmam boyunca teşvik edici fikirleriyle bana rehberlik eden, önerilerini ve katkılarını esirgemeyen tez danışmanım ve çok değerli hocam Sayın Prof. Dr. Erkan ÜLKER hocama en içten teşekkürlerimi sunarım.

Tez izleme komitesinde bulunarak çalışmalarına yön veren ve fikirleriyle beni aydınlatan değerli hocalarım Sayın Doç. Dr. Halife KODAZ ve Sayın Dr. Öğr. Üyesi Onur İNAN hocama teşekkür ederim.

Tez çalışmalarımda yapmış oldukları katkılardan dolayı Sayın Dr. Öğr. Üyesi Esra BALCIOĞLU ve Sayın Öğr. Gör. Ayşe CEYHAN hocama teşekkür ederim.

Tezimi, sonsuz sabır ve anlayışla tez çalışmam boyunca desteklerini esirgemeyen eşim Emine İNİK, konuşmalarıyla motivasyon kaynağım olan kızım Fatma Zehra İNİK ve henüz 50 günlük olan oğlum Muhammed Fatih İNİK'e ithaf ederim.

Özkan İNİK  
KONYA-2019



# İÇİNDEKİLER

<b>ÖZET</b> .....	<b>iv</b>
<b>ABSTRACT</b> .....	<b>vi</b>
<b>ÖNSÖZ</b> .....	<b>viii</b>
<b>İÇİNDEKİLER</b> .....	<b>ix</b>
<b>SİMGELER VE KISALTMALAR</b> .....	<b>xi</b>
<b>1. GİRİŞ</b> .....	<b>1</b>
1.1. Tezin Amacı ve Önemi .....	2
1.2. Tezin Organizasyonu .....	3
<b>2. KAYNAK ARAŞTIRMASI</b> .....	<b>4</b>
<b>3. MATERYALLER VE METOTLAR</b> .....	<b>7</b>
3.1. Derin Öğrenme(DÖ) .....	7
3.1.1. Evrişimsel sinir ağları(ESA).....	10
3.1.2. ESA modelinin eğitimi .....	17
3.1.3. Nesne sınıflandırmada kullanılan derin öğrenme modelleri.....	20
3.1.4. Nesne tanımlamada kullanılan derin öğrenme modelleri .....	25
3.2.Yapay Arı Kolonisi Algoritması(YAKA).....	29
3.3. Ovaryum Follikülleri .....	30
<b>4. ÖNERİLEN YÖNTEM</b> .....	<b>33</b>
4.1. Önerilen Yöntemin Mimarisi.....	33
4.2. Önerilen Yöntemin Eğitim Aşaması.....	35
4.3. Önerilen Yöntemin Test Aşaması.....	36
4.4. Önerilen Yöntemin Parametre Optimizasyonu .....	40
4.5. Önerilen Yöntem İçin Elde Edilen Veri Setleri .....	43
4.5.1. Veri arttırma teknikleri .....	45
4.5.2.Segmentasyon için elde edilen veri setleri.....	47
4.5.3.Sınıflandırma için elde edilen veri setleri .....	48
<b>5. DENEYSEL ÇALIŞMALAR</b> .....	<b>51</b>
5.1.Performans Ölçütleri.....	51
5.2. Segmentasyon İçin Oluşturulan ESA Modelinin Eğitim ve Test Sonuçları.....	53
5.3. Sınıflandırma İçin Oluşturulan ESA Modelinin Eğitim ve Test Sonuçları .....	61
5.4. Önerilen Yöntemin Parametre Optimizasyonu Sonuçları .....	66
5.5. Faster R-CNN Modelinin Eğitim Sonuçları .....	68
5.5.1. Faster R-CNN’de AlexNet modeli kullanılarak elde edilen eğitim sonuçları .....	68
5.5.2. Faster R-CNN’de Vgg16 modeli kullanılarak elde edilen eğitim sonuçları. 70	

5.5.3. Faster R-CNN’de Vgg19 modeli kullanılarak elde edilen eğitim sonuçları.	71
5.6. Önerilen Yöntemin Test Sonuçları ve Diğer Yöntemlerle Karşılaştırılması .....	73

**6. SONUÇLAR VE ÖNERİLER ..... 76**

6.1 Sonuçlar .....	76
6.2 Öneriler .....	78

**KAYNAKLAR ..... 79**

**EKLER ..... 85**

**ÖZGEÇMİŞ ..... 86**



## SİMGELER VE KISALTMALAR

ESA	: Evrişimsel Sinir Ağları (Convolutional Neural Networks-CNN)
YAKA	: Yapay Arı Kolonisi Algoritması
YSA	: Yapay Sinir Ağları
ADALINE	: Adaptive Linear Element
CPU	: Merkezi İşlem Birimi (Central Processing Unit)
GPU	: Grafik İşlem Birimi(Graphic Processing Unit)
ILSVRC	: Büyük Ölçekli Görsel Tanıma Yarışması(ImageNet Large Scale Visual Recognition Challenge)
ReLU	: Düzleştirilmiş Doğrusal Birim Katmanı
RGB	: Kırmızı, Yeşil, Mavi Renk uzayı (Red, Green, Blue)
R-CNN	: Bölge Bazlı Evrişimsel Sinir Ağı(Region-Based Convolutional Neural Networks)
SGD	: Stokastik Gradyan İniş (Stochastic Gradient Descent )
SGDM	: Momentumlu Stokastik Gradyan İniş (Stochastic Gradient Descent with Momentum)
SA	: Seçici Arama (Selective Search)
BÖA	: Bölge Öneri Ağı (Region Proposal Network-RPN)
H&E	: Hematoksilen-Eozin
MT	: Masson's Trikróm
AMH	: Anti Müllerien Hormon
AKD	: Adım Kayma Değeri
KSU	: Komşu Sınıf Uzaklığı
BSD	: Bulanık Sınır Değeri
TP	: Doğru Pozitif(True Positive)
FP	: Yanlış Pozitif(False Positive )
FN	: Yanlış Negatif (False Negative)
TN	: Doğru Negatif(True Negative)
EK	: Evrişim Katmanı
OK	: Ortaklama Katmanı
TBK	: Tam Bağlantılı Katman
RoI	: Bölge Önerisi Ortaklaması ( Region of Interest Pooling)
DÖ	: Derin Öğrenme
FCN	: Tam Evrişimsel Ağlar (Fully Convolutional Networks)
SC-CNN	: Mekansal Kısıtlanmış ESA

## 1. GİRİŞ

Birçok bilim dalında olduğu gibi histolojik olarak elde edilen medikal görüntülerin incelenmesi için de bilgisayar destekli yazılımlar kullanılmaktadır. Histolojik kesitlerin incelenip sonuç çıkarılması karmaşık bir süreci barındırır. Çünkü birçok yapıyı doğru teşhis etmek ve bu yapıların doku içindeki fonksiyonlarını ayrıca diğer dokularla olan ilişkisini saptamak çok zor bir süreçtir. Bu süreç içerisinde yoğun olarak çalışan uzmanın iş yükünün kaldırılması ve nesnel bir yaklaşım sunacak çalışmalar için yapay zekâ alt yapısının kullanılması kaçınılmazdır.

Yapay zekâ tekniğinin bir alt dalı olan makine öğrenmesi yöntemleri, medikal görüntülerde segmentasyon, sınıflama ve kümeleme gibi işlemlerde sıklıkla kullanılır. Geleneksel makine öğrenmesi yöntemleri ile yapılan analizlerde öncelikle verilerin toplanarak sistemin eğitilmesi için bir uzmana ihtiyaç duyulmaktadır. Elde edilen veri çok fazla öznelik içerebilir. Çoğu zaman bu öznelikleri azaltmak için önemli özelliklerin çıkarılması istenebilir. Yapılacak bütün bu aşamalarda uzmanın bilgisine ihtiyaç duyulur ve onayı alınır. Bu süreç yorucu ve zaman almaktadır, ayrıca uzmanı oldukça fazla meşgul etmektedir. Derin öğrenme (DÖ) ile özellik çıkarma işleminde uzmana ihtiyaç duymadan veri içindeki bilgiye erişilebilir ve sınıflandırma yapılabilir. DÖ ile görüntülerin sınıflandırılmasının geleneksel yöntemlere göre çok daha başarılı olduğu ve kısa zaman aldığı görülmektedir. Evrişimsel Sinir Ağları (ESA)(Krizhevsky ve ark., 2012) derin öğrenmenin temel mimarisi olarak kabul edilmektedir. Bu ağlar özellikle görüntü sınıflandırma ve kümeleme, ses işleme, sinyal işleme ve doğal dil işleme gibi alanlarda sıklıkla kullanılır(İnik ve Ülker, 2017).

Yapılan bu tez kapsamında histolojik kesitlerden elde edilen medikal görüntülerin segmentasyonu, tanımlama ve sınıflandırılması için DÖ tabanlı yeni bir yöntem geliştirilmiştir. Geliştirilen yöntem, ovaryum dokusuna ait folliküllerin segmentasyonu ve sınıflandırılmasında kullanılarak folliküllerin otomatik sayılması gerçekleştirilmiştir. Bu kapsamda ovaryum dokusuna ait yeni bir veri seti oluşturulmuştur.

Önerilen yöntem iki bölümden oluşmaktadır. Birinci bölümde segmentasyon ve sınıflandırma işlemi için farklı ESA modelleri tasarlanmıştır. Bu ESA modelleri, oluşturulan veri setleri ile eğitilmiştir. İkinci bölümde ise test işlemi gerçekleştirilmiştir. Bu bölümde ilk olarak birinci bölümünde segmentasyon için eğitilen ESA modeli ile segmentasyon işlemi yapılmıştır. Segmentasyon işleminden sonra gürültü temizleme

işlemi uygulanmıştır. Bu işlemlerden sonra sınır değerleri belirlenen nesnelere, ön eğitilmiş ESA modeli ile sınıflandırma işlemi yapıp sayısal değerleri hesaplanmıştır. Önerilen yöntem hakkında detaylı bilgiler Bölüm 4'te sunulmuştur.

### 1.1. Tezin Amacı ve Önemi

Bilgisayarlı görü sistemlerindeki gelişmeler farklı alanlardaki birçok problemin çözülmesinde büyük katkılar sağlamaktadır. Özellikle medikal görüntülerin analizinde yapay zekâ destekli akıllı sistemler kullanılmaktadır. Bu analizler bazen kanserli yapıların teşhisi olabileceği gibi bazen de hücrelerin tanımlanması, sayılması ve sınıflandırılması gibi işlemlerde olabilir. Görüntü analizinde temel olarak sınıflandırma, segmentasyon ve nesne sınır değerleri belirleme ve nesne tanımlama gibi problemlerin çözülmesi için farklı algoritmalar geliştirilmektedir. Bu algoritmalar ile medikal görüntüler üzerinde yapılan analizlerde incelenecek dokunun tanımlanması için öncelikle görüntü içerisindeki yapının arka plandan ayrılması gerekmektedir. Daha sonra arka plandan ayrılan yapının görüntünün neresinde ve ne olduğu belirlenmelidir. Analizi yapılacak dokunun farklılığı veya görüntü alma kaynağının değişkenliğine göre farklı segmentasyon, tanımlama ve sınıflandırma yöntemleri geliştirilmektedir. Karmaşık yapıya sahip histolojik görüntülerin analiz işlemleri için yüksek doğrulukta ve kısa sürede sonuç verecek yöntemlerin geliştirilmesi gerekmektedir.

Bu sebeple yapılan bu tezde amaç, histolojik görüntülerde bulunan çeşitli hücre veya hücrelerin oluşturduğu yapıların segmentasyon, sınır değerlerinin belirlenmesi ve sınıflandırılması için ESA temelli yeni bir yöntemin geliştirilmesidir. Geliştirilen yöntemin, histolojik olarak elde edilen ovaryum dokusuna ait görüntülerdeki folliküllerin otomatik sayılması için kullanımı sergilenmiştir.

Medikal alanda farklı görüntü alma teknolojilerinin artmasıyla elde edilen görüntü sayısı da artmıştır. Bu görüntülerin değerlendirilmesi uzman tarafında uzun zaman almaktadır. Ayrıca uzman için yoğun bir iş yükü oluşturmaktadır. Görüntülerin değerlendirilmesindeki en büyük problem ise her bir uzmanın bilgi seviyesine göre bazen öznel bir çıkarım yapabilmesidir. Bu gibi problemler düşünüldüğünde daha az zamanda daha fazla görüntü analizini nesnel bir şekilde yapacak akıllı sistemlere ihtiyaç duyulmaktadır. Bu tezde geliştirilen yöntem ile histolojik kesitlerdeki hücre veya hücre yapılarının, daha kısa sürede ve nesnel olarak analizlerinin yapılması gerçekleştirilmiştir. Ayrıca tez kapsamında, ovaryum dokusuna ait yaklaşık 10500 adet

görüntüden oluşan özgün bir veri seti oluşturulmuş olup literatüre büyük bir katkı sağlanmıştır.

## 1.2. Tezin Organizasyonu

Sunulan bu tez çalışmasında Bölüm 1’de tezin amacı ve önemi açıklanmıştır. Bölüm 2’deki kaynak araştırması kısmında medikal görüntü analizlerinde kullanılan DÖ yöntemleri hakkında literatürde yapılan çalışmalar belirtilmiştir. Bölüm 3’te tezde kullanılan materyal hakkında bilgilendirmeler yapılmıştır. Bu bölümde DÖ, ESA, nesne sınıflandırma ve tanımlamada kullanılan DÖ modelleri hakkında detaylı bilgiler verilmiştir. Bu bölümde ayrıca, Yapay Arı Kolonisi Algoritması(YAKA) hakkında gerekli açıklamalar yapılmıştır. Son olarak ovaryum dokusundaki follüküller hakkında bilgilendirmeler yapılmıştır. Bölüm 4’te önerilen yöntemin mimarisi, yöntemin eğitim ve test aşaması, yöntemin parametre optimizasyonu gibi yöntem hakkında bilgilendirmeler yapılmıştır. Bu bölümde ayrıca tez kapsamında elde edilen veri setleri hakkında bilgiler sunulmuştur. Bölüm 5’te deneysel çalışmalar anlatılmıştır. Bu bölümde öncelikle performans ölçütleri hakkında gerekli açıklamalar yapılmıştır. Ayrıca segmentasyon ve sınıflandırma için oluşturulan modellerin mimarileri, parametre değerleri ve elde ettikleri performans değerleri verilmiştir. Son olarak önerilen yöntemin diğer yöntemlerle test sonuçları karşılaştırılıp gerekli tartışmalar yapılmıştır. Bölüm 6’da, tez kapsamında elde edilen sonuçlar ve öneriler anlatılmıştır.

## 2. KAYNAK ARAŞTIRMASI

Görüntü segmentasyonu, sınıflama ve tanımlama gibi alanlarda farklı yapay zekâ tabanlı yöntemler geliştirilmiştir(Niu ve Suen, 2012; Sun ve ark., 2014; Tao ve ark., 2016; Chen ve ark., 2018; Vogado ve ark., 2018; Dabeer ve ark., 2019; Guo ve ark., 2019; Jiang ve ark., 2019; Rehman ve ark., 2019; Wang ve ark., 2019). Geliştirilen bu yöntemler içerisinde DÖ temelli yöntemler, birçok problemin çözümünde diğer yöntemlerden daha yüksek performans sergilemiştir.

DÖ modelleri, başarılarından dolayı medikal görüntülerin analizinde kullanılmaya başlanmıştır(İnik ve ark., 2019). Özellikle histolojik veya histopatolojik kesitlerden elde edilen görüntülerin analizleri için yeni ESA modelleri (Cruz-Roa ve ark., 2013; Ronneberger ve ark., 2015; Albarqouni ve ark., 2016) tasarlanmıştır. O. Ronneberger ve ark. biyomedikal görüntü segmentasyonu için U-NET (Ronneberger ve ark., 2015) adında yeni bir DÖ modeli önermişlerdir. Bu model ile elektron mikroskobu ile elde edilen görüntülerde nöronal yapıların segmentasyonu gerçekleştirilmiştir. A. Cruz-Roa ve ark. görüntü gösterimi, görsel yorumlanabilirlik ve bazal hücre karsinomu kanseri tespiti için bir DÖ mimarisi önermişlerdir (Cruz-Roa ve ark., 2013). Önermiş oldukları yöntemde öncelikle özellik öğrenme danışmansız yöntemle yapılmaktadır. Akabinde görüntü temsili için evrişimsel oto-kodlayıcı kullanılmaktadır. Daha sonra softmax sınıflandırıcı ile bazal hücre karsinomu kanseri tanımlanmaktadır. En sonunda görsel yorumlanabilirlik tahmini için görüntü oluşturulmaktadır. S. Albarqouni ve ark. ESA modelinin Crowdsourcing ( web temelli görüntü etiketleme topluluğu) tarafından medikal görüntülerin etiketlenmesi ile eğitim için AggNet (Albarqouni ve ark., 2016) adında yeni bir derin öğrenme modeli önermişlerdir. Yapılan çalışmada temelde önceden eğitilen ESA modeline etiketlenmesi gereken bir test görüntüsü verilmekte, AggNet ile Crowdsourcing'ge etiketleme için bir öneri sunulmakta ve yapılan etiketleme ile ESA tekrar güncellenerek eğitim işlemi gerçekleştirilmektedir.

Bu modellere ek olarak ESA tabanlı birçok yöntem geliştirilmiştir. John A. Quinny ve ark. kan lekelerinden sıtma tanısı, balgam örneklerinde tüberküloz ve dışkı örneklerinde bağırsak parazitinin tespiti için ESA modeli kullanılmıştır (Quinn ve ark., 2016). Yapılan çalışma sonucunda her üç problem için ESA ile elde edilen performansın geleneksel makine öğrenmesi yöntemlerinden daha başarılı olduğu gösterilmiştir. Korsuk Sirinukunwattana ve ark. tarafından kolon kanseri histolojisi görüntülerinde çekirdeklerin tespiti için ESA temelli bir yöntem önerilmiştir

(Sirinukunwattana ve ark., 2016). Yapılan çalışmada segmentasyon işlemi yapılmadan çekirdek yerinin tespiti ve sınıflandırılması gerçekleştirilmektedir. Deneysel çalışmalar, kolorektal adenokarsinom görüntülerinden oluşan 20000 etiketli görüntüler üzerinde yapılmıştır. Elde edilen test sonuçları son zamanlarda yapılan çalışmalarla karşılaştırıldığında daha iyi sonuçların elde edildiği ifade edilmiştir. Weidi Xie ve ark. tarafından mikroskobik görüntülerde hücrelerin otomatik tanımlanması ve sayılması için ESA temelli bir yaklaşım önerilmiştir (Xie ve ark., 2018). Yapılan çalışma özellikle geleneksel tek hücreli segmentasyon tabanlı yöntemlerin, hücre kümelenmesi veya çakışma nedeniyle iyi çalışmadığı durumlar için geliştirilmiştir. Çalışmada sentetik olarak üretilen veri setleri kullanılmıştır. Sentetik verilerle eğitilen yöntemin test aşamasında gerçek veriler üzerinde test edilmiş olup yüksek performans gösterdiği ifade edilmiştir. Yuanpu Xie ve ark. tarafından özgün bir ESA temelli yapısal regresyon modeli önerilmiştir (Xie ve ark., 2015). Bu model ile birbirine yapışmış hücrelerin, homojen olmayan arka plan gürültülerin temizlenmesi ve çeşitli şekillerde ve büyüklükte hücrelerin tanımlanması gerçekleştirilmiştir. Önerilen yöntemin eğitiminde sadece çok az etiketlenmiş görüntülere ihtiyaç duyulmaktadır. Test aşamasında test görüntüsü(yama) verildiğinde, bu görüntünün tek bir sınıf değeri belirtmesinin yerine, algoritma yapılandırılmış çıktılar(yakınlık yamaları) üretmektedir. Hücre merkezlerine yakın pikseller için daha yüksek değerler sergileyen bu yakınlık yamaları, daha sonra tüm test görüntü yamalarından toplanıp ve maksimum konumların hücre merkezlerini gösterdiği son yakınlık haritasını elde etmek için birleştirilmektedir. Algoritma, farklı boyama türlerine göre elde edilen üç veri seti kullanılarak test edilmiştir. Yapılan deneysel çalışmalar sonucunda yöntemin mevcut en son yöntemlere kıyasla üstün performans gösterdiği söylenmiştir. Zhimin Gao ve ark. Epitel-2 hücrelerinin sınıflandırılması için ESA temelli bir mimari önermişlerdir (Gao ve ark., 2017). Yapılan çalışmada ayrıca veri arttırma tekniklerinden döndürme yönteminin(9-18-36 derecelik döndürme) etkisi de incelenmiştir. Çalışma sonucunda önerilen yöntemin, farklı veri setlerinde hücre sınıflandırma problemlerinde bile sonuçlar üretildiği görülmüştür. Ayrıca bu yöntem ICPR 2014'ün düzenlemiş olduğu hücre sınıflandırma iyi bir performans göstermiş olup yarışmada üst sıralarda yer almıştır. Muhammad Nasim Kashif ve ark. tarafından Mekansal Kısıtlanmış ESA(SC-CNN) modelini geliştirerek yeni bir yöntem önerilmiştir (Kashif ve ark., 2016). Geliştirilen yöntem kanser histolojisi görüntülerinde tümör çekirdeğinin tespiti için kullanılmıştır. Önerilen yöntemde, ESA tarafından keşfedilen özellikler ile manuel belirlenen özelliklerin ortak



kullanımı ile yöntemin klasik ESA modeline göre daha iyi performans sergilediği görülmüştür. N. Bayramoglu ve J. Heikkilä tarafından transfer öğrenme kullanılarak hücre çekirdeği sınıflandırılması üzerine bir çalışma yapılmıştır (Bayramoglu ve Heikkilä, 2016). Yapılan çalışmada temel hedef farklı veri setleri ile eğitilen ESA ağlarının, transfer öğrenme kullanılarak medikal verilerde kullanılması amaçlanmıştır. Bu amaçla 4 farklı ESA modeli kullanılmıştır. Yapılan çalışma sonucunda ön eğitilmiş ağların daha iyi performans gösterdiği belirlenmiştir. Haibo Wang ve ark. tarafından önerilen yöntem ile meme kanseri patolojisi görüntülerinde mitoz tespiti için manuel olarak belirlenen özellikler ile ESA tarafından keşfedilen özelliklerinin birleşimiyle mitoz tespiti yapan bir yöntem önerilmiştir (Wang ve ark., 2014). Deneysel çalışmalar, ICPR12 mitoz veri kümesi üzerinde yapılmış olup 0.7345 F-ölçüsü değeri elde edilmiştir. Önerilen yöntem doğru, hızlı ve mevcut yöntemlerle karşılaştırıldığında daha az bilgi işlem kaynağı gerektirmesinden dolayı klinik kullanım için uygun olduğu ifade edilmiştir. Philipp Kainz ve ark. iyi ve kötü huylu kolon bezleri kanserinin segmentasyonu için derin öğrenme temelli bir yöntem önermişlerdir (Kainz ve ark., 2015). Çalışmada görüntüler Hematoksilen-Eosin(H&E) boyama protokolüne göre elde edilmiştir. Çalışmada öncelikle iki farklı ESA modeli piksel sınıflandırıcı olarak eğitilmiştir. ESA modellerinin tahminleri daha sonra nihai segmentasyon sonucunu üretmek için ağırlıklı toplam varyasyona dayanan bir rakam temelli segmentasyon kullanılarak düzenlenmiştir. Yapılan çalışma sonucunda 2 farklı veri seti üzerinde %98 ve %94 sınıflandırma başarısı elde edilmiştir. Jiazhuo Wang ve ark. tarafından farklı doku bölgelerinin tanımlanması için Tam Evrişimsel Ağlar( Fully Convolutional Networks-FCN) temelli özgün bir yöntem önerilmiştir (Wang ve ark., 2016). Önerilen yöntem farklı ölçek ve boyutlardaki şekillerin segmentasyonu için çok ölçekli bilgileri ve yapısal bilgileri keşfetmektedir. Önerilen yöntemin, klinik görüntüler üzerinde yapılan deneysel sonuçlarda, kas ve dağınık bölgelerin semantik segmentasyonu için son teknoloji FCN'den daha iyi performans gösterdiği belirtilmiştir.

Ayrıca medikal görüntülerin analizinde kullanılan derin öğrenme yöntemleri ile ilgili derleme çalışmalarda yapılmıştır (Angermueller ve ark., 2016; Litjens ve ark., 2017; Razzak ve ark., 2018).

### 3. MATERYALLER VE METOTLAR

Bu bölümde, öncelikle önerilen yöntemin temelini oluşturan DÖ ve DÖ'nün temel mimarisi olan ESA hakkında detaylı bilgilendirme yapılmıştır. ESA mimarisindeki her bir katman hakkında gerekli açıklamalar yapılmıştır. DÖ'de nesne sınıflandırma ve tanımlama alanında kullanılan modeller hakkında bilgiler verilmiştir. Devamında, YAKA ve ovaryum follikülleri hakkında açıklamalarda bulunulmuştur.

#### 3.1. Derin Öğrenme(DÖ)

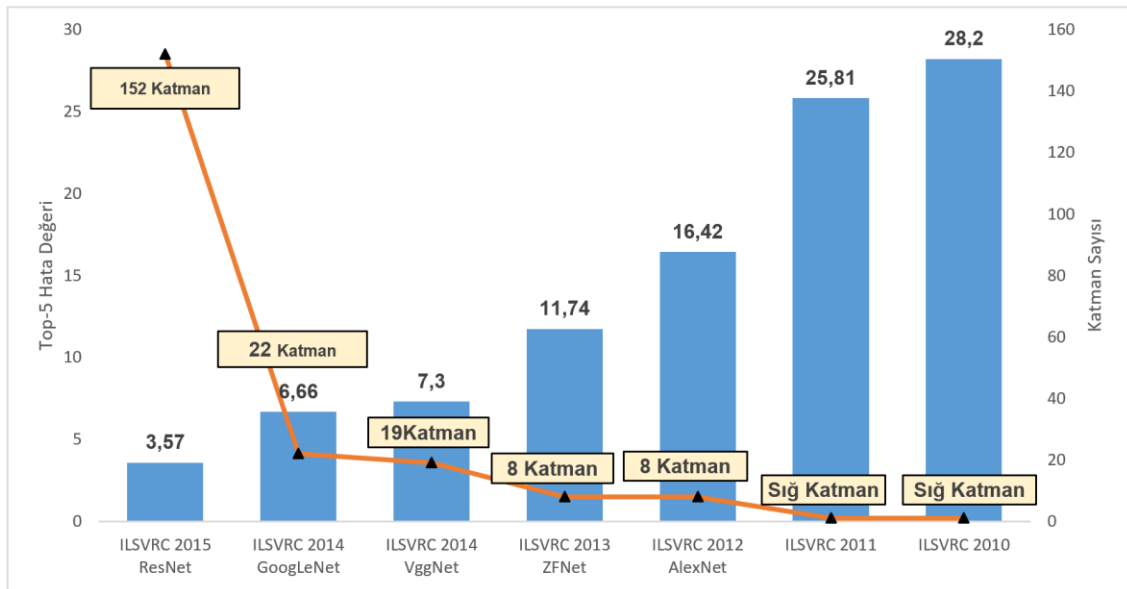
Yapay zekâ ve alt dalları ile ilgilenen araştırmacılar her zaman daha zeki sistemlerin tasarlanmasını hedeflemektedirler. İnsan düşünce yapısını ve karar verme yetisini modellemek, kuşkusuz bu hedeflerin en önemlisidir. Bu amaçla ilk defa McCulloch-Pitts tarafından insan sinir sisteminden esinlenerek beyin fonksiyonlarının işleyişinin mantıksal olarak hesaplayan bir model ortaya konulmuştur (McCulloch ve Pitts, 1943). Bu aynı zamanda insan sinir sisteminin bir taklidi olan Yapay Sinir Ağlarının(YSA) temelini oluşturmuştur. Daha sonraki süreçlerde Perseptron (Rosenblatt, 1958; Rosenblatt, 1962), Adaptive lineer element (ADALINE) (Widrow ve Hoff, 1960) gibi modeller ortaya konulmuştur. Oluşturulan bu doğrusal modellerin en büyük dezavantajı, XOR gibi doğrusal olmayan problemleri çözememeleridir (Minsky, 1969). Bu yüzden o yıllarda YSA temelli yöntemlere ilgi azalmıştır. 1980'lerde, sinir ağı araştırmaları yeniden paralel dağıtık işlem (Rumelhart ve ark., 1986b; McClelland ve ark., 1995) olarak ortaya çıkmış ve bugünün derin öğrenme (LeCun ve ark., 2015) temeli de o yıllarda ortaya atılmıştır. O yıllarda YSA'ı eğitmek için geri yayılım algoritması (Rumelhart ve ark., 1986a; LeCun, 1987) başarıyla kullanılmış ve bu kullanım yaygınlaştırılmıştır. 2006 yılında Geoffrey Hinton, derin inanç ağlarının etkili bir şekilde eğitilebileceğini göstermiştir (Hinton ve ark., 2006). Diğer araştırma grupları, aynı stratejiyi birçok başka derin ağı eğitmek için kullanmıştır(Bengio ve ark., 2007; Ranzato ve ark., 2007). Daha iyi performans sergileyen sinir ağlarını tasarlamının yolunun daha derin ağların kurulması olduğu anlaşılmıştır. Derinlik kavramına dikkat çekilmesi için “**Derin Öğrenme**” teriminin kullanılması yaygınlaştırılmıştır (Bengio ve LeCun, 2007; Delalleau ve Bengio, 2011; Montufar, 2014; Pascanu ve ark., 2014).

DÖ ile ilgili ilk çalışmalar çok geçmişe dayanmasına rağmen son yıllarda başarılı bir şekilde kullanılmasının başlıca iki sebebi bulunmaktadır. Bunlar, yeteri kadar verinin ve bu veriyi işleyecek donanımsal kaynakların geliştirilmesi olarak sıralanabilir. Bu kaynakların ilkinin oluşturduğu veri, toplumun dijitalleşmesinin gittikçe artması ile sağlanmaktadır. Bilgisayarlarda gerçekleştirilen faaliyetlerin artmasıyla yapılan işlemler daha çok kaydedilmektedir. Bilgisayarlar daha fazla ağa bağlandığından, bu kayıtları merkezileştirmek ve bunları makine öğrenmesi uygulamaları için uygun bir veri kümesi haline getirmek daha kolay hale gelmiştir. Artan veri yapısı son yıllarda "**Büyük Veri (Big Data)**" adı altında yeni bir alan oluşturmuştur. Büyük veri ile makine öğrenimi çok daha kolay hale gelmiştir.

DÖ'nün günümüzde uygulanabilirliğine sebep olan bir diğer nedeni ise, ihtiyaç duyulan hesaplama kaynaklarının var olmasıdır. DÖ'nün temel mimarisi olan ESA'lardaki parametreler için kullanılan bellek hafızası ve hesaplama için işlemci kapasitesi artmıştır. Özelliklerin keşfi için katman sayısının artırılmasıyla derinleştirilen ağ, daha büyük belleklere sahip ve daha yüksek hesaplama kapasitesine sahip hızlı bilgisayar ihtiyacını meydana getirmiştir. Bazı veri setlerinin milyon satırlar seviyesinde olduğu düşünülürse kullanılacak bellek hafızasının önemi ortaya çıkmaktadır. Aynı şekilde derin katman sayısına sahip bir ağın eğitilmesi esnasında geriye yayılım algoritmasının kullanılması için yapılan hesaplamalar paralel işlemciler ile daha hızlı gerçekleştirilebilir. Bu sebeple derin ağların eğitimi için Merkezi İşlem Birimi (Central Processing Unit-CPU) yerine genel amaçlı kullanılmak üzere ortaya çıkan Grafik İşlem Birimi (Graphic Processing Unit-GPU) kullanılmaktadır. DÖ modellerinin geliştirilmesi, ihtiyaç duyulan verinin ve bu verinin işlenmesi için gerekli GPU'ların varlığıyla mümkün olduğu görülmüştür. Fakat DÖ modellerinin yoğun bir şekilde kullanılmasının en önemli sebebi farklı problemlerde elde ettikleri başarı oranıdır.

DÖ, ilk defa 2012 yılında büyük etki oluşturmuştur. Bu etkinin temel sebebi, 2012 yılında yapılan ILSVRC( ImageNet Büyük Ölçekli Görsel Tanıma Yarışması) (Competition, 2012) yarışmasının, DÖ'nün temel mimarisi olan ESA ile yüksek doğrulukta kazanılması olmuştur. ESA modelinin yarışmada Top-5 hata oranı %16.42 olarak elde etmiştir. Yıllara göre ILSVRC yarışmasında elde edilen hata oranları Şekil 3.1'de verilmiştir. Şekil 3.1'e bakıldığında 2012 yılında keskin bir düşüşün olduğu görülmektedir. Bu oran bir önceki yıldaki %25.81 olan oranlar karşılaştırıldığında sınıflandırmadaki başarı oranının performansı daha iyi anlaşılmaktadır. 2012 yılından

İtibaren yapılan bütün ILSVRC yarışmalarındaki katılımcılar DÖ mimarileri kullanmıştır. Kullanılan farklı modeller yarışmadaki Top-5 hata oranını %3.57'ye kadar düşürmüştür. DÖ modellerinin elde ettiği bu başarı farklı katmanlardaki farklı özelliklerin keşfi olarak açıklanabilir.



Şekil 3.1. Yıllara göre ILSVRC yarışmasının Top-5 hata oranları (Julia, 2016).

Klasik Makine öğrenme teknikleri ile bir model tanımlama veya makine öğrenimi sistemi kurmak için öncelikle özellik vektörünün çıkarılması gerekmektedir. Özellik vektörünün çıkarılması için alanında uzman kişilere ihtiyaç duyulmaktadır. Bu işlemler hem çok zaman almakta hem de uzmanı çok meşgul etmektedir. Bu sebeple bu teknikler, ham bir veriyi ön işlem yapmadan ve uzman yardımı olmadan işleyemezler. DÖ makine öğrenimi alanında çalışanların uzun yıllar boyunca uğraştığı bu sorunu ortadan kaldırarak büyük ilerleme sağlamıştır. Çünkü derin ağlar geleneksel makine öğrenmesi ve görüntü işleme tekniklerinin aksine öğrenme işlemi ham veri üzerinde yapılmaktadır. Ham veriyi işlerken gerekli bilgiyi farklı katmanlarda oluşturmuş olduğu temsillerle elde etmektedir. Tasarlanan bu modeller, kullanıcı tarafından belirlenen özellikler olmadan öğrenme işlemi giriş verisinden kendisi yapmaktadır (Bengio ve ark., 2013).

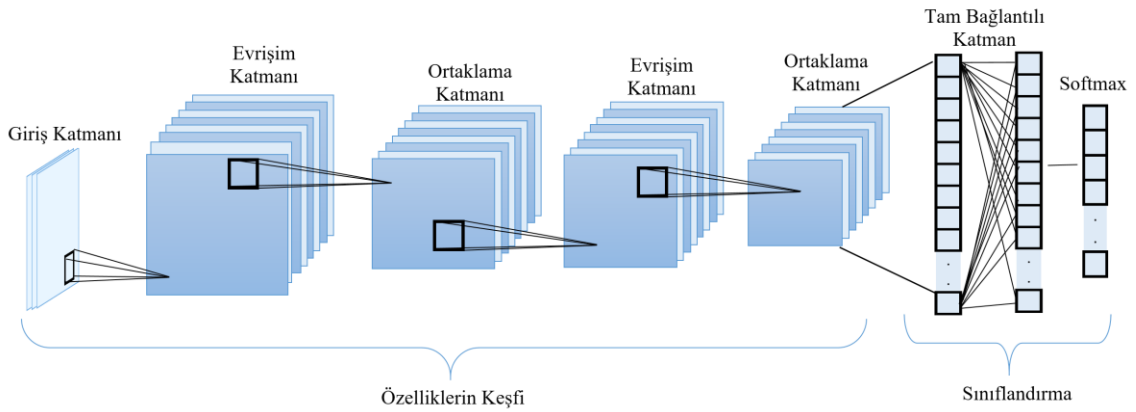
DÖ modelleri arasında literatürde temel olarak kabul edilen bazı modeller mevcuttur. Bu modeller genellikle ILSVRC yarışmasının ilgili yıllarda kazanan modeller olarak geçmektedir. Bu modellerden AlexNet (Krizhevsky ve ark., 2012) ILSVRC yarışmasının 2012 yılında kazanan modeli olmuştur. Bu modelin en önemli

özelliği eğitim esnasında GPU işlemcilerini kullanması, ReLu ve DropOut katmanının kullanılması olarak sıralanabilir. ILSVRC yarışmasının 2013 yılında kazanan modeli ise ZFNet (Zeiler ve Fergus, 2014a) modeli olmuştur. ZFNet modeli AlexNet modelinin çok küçük değişikliklerle değiştirilmesi ile elde edilmiştir. Daha küçük filtreler ile daha derin ağların tasarlanması fikri ile VggNet (Simonyan ve Zisserman, 2014) tasarlanmıştır. Bu sayede bu modelin elde ettiği başarı hem AlexNet hem de ZFNet'ten yüksek olmuştur. 2014 yılında ILSVRC yarışmasının kazanan modeli GoogLeNet (Szegedy ve ark., 2015a) olmuştur. Bu modelin en büyük özelliği yapısında bulunan Başlangıç(Inseption) modülleridir. Bu modüller sayesinde ağ daha az parametre kullanımına ihtiyaç duyar. Daha iyi performansın sergilenmesi için daha derin ağların tasarlanması fikriyle Microsoft ResNet (He ve ark., 2016a) modeli tasarlanmıştır. Bu model 152 katmandan oluşmaktadır ve ILSVRC yarışmasının 2015 yılında kazanan modeli olmuştur. Bu modellerle ilgili detaylı bilgiler Bölüm 3.1.3'te verilmiştir.

### 3.1.1. Evrimsel sinir ağları(ESA)

ESA, DÖ'nün temel mimarisi olarak kabul edilir. ESA'lar görüntü sınıflandırma, nesne tanımlama, görüntü segmentasyon v.b. problemlerde başarılı bir şekilde uygulanmaktadır. Genel bir ESA yapısı Şekil 3.2'de gösterildiği gibidir. Şekil 3.2'ye bakıldığında ESA yapısı temelde iki bölüme ayrılabilir. Birinci bölümde evrişim, ReLu ve ortaklama katmanlarından oluşan bloklarda özelliklerin keşfi gerçekleştirilmektedir. İkinci bölümde ise tam bağlantılı, ReLu, düğüm seyreltme(Dropout) katmanlarından oluşan bloklarda sınıflandırma işlemi yapılmaktadır. Birinci bölümde ilk olarak belli bir boyutta ağa giriş görüntüsü verilir. Bu katmana giriş katmanı denir. Görüntüler giriş katmanında 3 kanallı RGB olarak veya tek kanallı olarak verilebilir. Giriş katmanından sonra evrişim katmanı gelir. Evrişim katmanı özellik keşfinde en önemli katman olarak bilinir. Bu katmanda özellik keşfi tanımlanan filtreler aracılığıyla yapılır. Filtreler genellikle 2x2, 3x3, 5x5, veya 7x7 şeklinde seçilir. Her bir filtre giriş görüntüsü üzerinde belli bir adım kayma değerine göre dolaştırılarak çıkış görüntüsü oluşturulur. Böylelikle evrişim katmanından sonra filtre sayısı kadar görüntü oluşur. Bu görüntülere özellik haritası denir. Evrişim katmanından sonra ReLu katmanı gelir. Bu katman giriş görüntüsündeki negatif değerleri sıfıra eşitler, diğer değerleri aynı bırakır. ReLu katmanından sonra ortaklama(pooling) katmanı gelir. Bu katmanın temel amacı giriş görüntü boyutunu

düşürerek hesaplama maliyetini azaltmaktır. Ayrıca eğitim esnasında ağın ezberlemesini önler. Birinci bölümdeki bu katmanlar farklı sayıda ve farklı parametreler kullanılarak değişik ESA modelleri tasarlanabilir. Bu katmanlardan sonra sınıflandırmanın yapıldığı ikinci bölüm gelir. Bu bölümde ilk olarak tam bağlantılı katman gelir. Bu katman kendinden önceki katmanın tüm alanlarına bağlıdır. Bu katmandan sonra ağın ezberlemesini önleyen düğüm seyreltme katmanı gelir. Düğüm seyreltmede her iterasyonda gelişigüzel olarak ağın bazı düğümleri ve bağlantıları pasifleştirilir. Böylelikle her seferinde farklı düğümler aktif veya pasifleştirilerek ezberlemenin önüne geçilir. Bu katmandan sonra softmax katmanı gelir. Softmax katmanında her bir nesnenin 0-1 aralığında olasılıksal değeri hesaplanarak ait olduğu sınıfa dahil edilir. Bu katmanda farklı sınıflandırma algoritmaları da kullanılabilir.



Şekil 3.2. Derin öğrenmede ESA mimarilerinin temel yapısı

### 3.1.1.1 Giriş katmanı


Bu katman isminden de anlaşılacağı üzere modelin ilk katmanını oluşturmaktadır. Bu katmanda veri ham olarak ağına verilmektedir. Tasarlanacak modelin başarımı için bu katmandaki verinin boyutu önem kazanmaktadır. Giriş görüntü boyutunun yüksek seçilmesi hem yüksek bellek ihtiyacını hem eğitim süresini hem de görüntü başına düşen test süresini uzatabilir. Bunun yanında ağı başarısını arttırabilir. Giriş görüntü boyutunun düşük seçilmesi bellek ihtiyacını azaltır ve eğitim süresini kısaltır. Fakat kurulacak ağın performansı düşük olabilir. Görüntü analizinde hem ağı derinliği hem donanımsal hesaplama maliyeti hem de ağı başarısı için uygun bir giriş görüntü boyutu seçilmelidir (İnik ve Ülker, 2017).

### 3.1.1.2 Evrişim katmanı

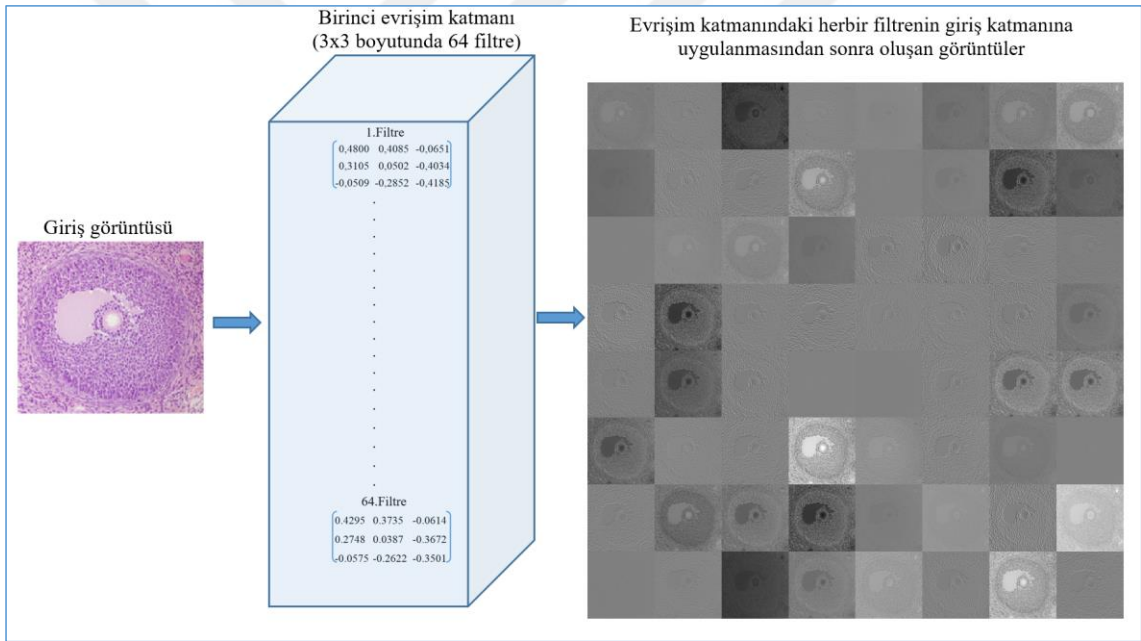
ESA modelinin temelini oluşturan bu katman dönüşüm katmanı olarak da bilinir. Bu dönüşüm işlemi belirli bir filtrenin tüm görüntü üzerinde dolaştırılması işlemine dayanmaktadır. Bu sebeple filtreler katmanlı mimarinin ayrılmaz bir bileşenidir. Filtreler, bir önceki katmandan gelen görüntülere evrişim işlemi uygulayarak çıkış verisini oluştururlar. Bu evrişim işlemi sonucu aktivasyon haritası (Özellik haritası) oluşur. Aktivasyon haritası, her bir filtreye özgü özelliklerin keşfedildiği bölgelerdir. Modelin eğitimi esnasında bu filtrelerin katsayıları, eğitim kümesindeki her öğrenme yinelemesiyle değişir. Böylelikle ağ, özelliklerin belirlenmesi için, verinin hangi bölgelerinin önem taşıdığını belirler.

Bir filtrenin görüntü üzerine uygulanması Şekil 3.3'te gösterilmiştir. Şekil 3.3'te giriş görüntüsü olarak ovaryum dokusundaki sekonder follikülüne ait bir görüntü ele alınmıştır. Bu görüntü renkli (RGB) yani 3 kanaldan oluşmaktadır. Bu görüntüye ait her bir kanal matris formunda ifade edilmiştir. Evrişim katmanında farklı boyutta ve farklı sayıda filtreler bulunmaktadır. Şekil 3.3'te örnek olması açısından 3x3 boyutunda bir filtre tanımlanmıştır. Evrişim katmanındaki bu filtre kendisinden önce giriş kanalındaki her bir görüntüye ayrı ayrı uygulanır. Yapılan uygulama işleminde filtre matrisi görüntünün ilgili piksel değerleriyle çarpılıp toplamları elde edilir. Bu işlem her bir görüntü için yapıldıktan sonra elde edilen değerlerin ortalaması alınır. Elde edilen ortalama değer evrişim katmanından sonra elde edilen görüntünün ilgili pikseline yazılır. Bu işlem belirli bir adım(stride) değerine göre giriş görüntüsü üzerine uygulanır. Her bir giriş kanalı matrisine uygulanan filtrenin katsayıları farklı olabilir. Bu filtre katsayılarındaki değişimler tasarımcılar tarafından modellerine uygun olacak şekilde seçilir. Filtrelerin uygulanmasından sonra oluşan çıkış görüntülerin tümüne aktivasyon haritası veya özellik haritası denir. Aktivasyon haritasındaki değerler, giriş ve çıkış boyutu arasında aynı yoğunluk aralığını sağlamak için normalize edilir.

Örnek olması açısından birinci evrişim katmanı 64 filtreden oluşan örnek bir ESA modeli tasarlanmıştır. Filtre boyutu ise 3x3 olarak belirlenmiştir. Evrişim katmanından sonra oluşan aktivasyon haritasına örnek bir gösterim Şekil 3.4'te verilmiştir. Her bir filtrenin giriş görüntüsüne uygulanması sonucu evrişim katmanından sonra oluşan görüntüler elde edilir. Şekil 3.4'e bakıldığında her bir filtrenin giriş görüntüsüne etkisi farklı olduğu görülmektedir.



Şekil 3.3. Evrişim katmanındaki bir filtrenin evrişim işlemi




Şekil 3.4. Evrişim katmanındaki filtrelerin giriş katmanına uygulanması

Evrişim katmanında filtrelerin görüntüye uygulandıktan sonra oluşan görüntünün boyut hesabı Eşitlik 3.1'e göre yapılır. Eşitlik 3.1'deki değişkenler Şekil 3.5'te gösterilmiştir.

$$\zeta = \frac{G - F + 2 * E}{A} + 1 \quad (3.1)$$





Şekil 3.5. Evrişim katmanında boyut hesabında kullanılan değişkenlerin gösterilmesi


Şekil 3.5'teki G giriş görüntüsünün ve Ç evrişim katmanından sonra çıkan görüntünün boyutunu ifade eder. E giriş görüntüsünü ifade eden matrise eklenecek satır ve sütun değerini gösterir. Eklenen satır ve sütun değerleri 0 rakamı ile doldurulur. Buradaki amaç giriş görüntüsünün kenar noktaları üzerinde de evrişim işlemi yapıp bu değerlerin hesaplamaya katılmasını sağlamaktır. F filtre boyutunu ifade etmektedir. A değişkeni ise giriş görüntüsü üzerinde dolaştırılacak filtrenin adım kayma değerini ifade eder. Örneğin giriş görüntüsü 32x32, filtre boyutu 3x3, ekleme 0 ve adım kayma sayısı 1 ise çıkış görüntü boyutu Eşitlik 3.2.'de hesaplandığı gibi 30x30 olur. Eğer ekleme değeri 1 olursa çıkış boyutu 32x32 olur.

$$\zeta = \frac{32 - 3 + 2 * 0}{1} + 1 = 30 \quad (3.2)$$

### 3.1.1.3. Düzleştirilmiş doğrusal birim katmanı(ReLU)


ESA modellerinde her evrişim katmanından ve tam bağlantılı katmandan sonra ReLu katmanı kullanılmıştır. ReLu matematiksel olarak Eşitlik 3.3.'deki gibi tanımlanır ve Şekil 3.6'da gösterilmiştir. Bu katmanın giriş verisine yapmış olduğu etki negatif değerleri sıfıra çekmesidir. Bu katmandan önce kullanılan evrişim katmanında belirli matematiksel işlemler yapıldığı için ağ doğrusal bir yapıdadır. Ağın doğrusal olmayan bir yapıya sokulması için bu katman uygulanır. Bu katman aynı zamanda aktifleştirme katmanı olarak ta bilinir.

$$f(x) = \begin{cases} 0 & \text{eğer } x < 0 \\ x & \text{eğer } x \geq 0 \end{cases} \quad (3.3)$$



Şekil 3.6. Düzleştirilmiş doğrusal birim katmanı çıkış verisine etkisi.

ReLU katmanının giriş görüntüsü üzerine yaptığı etki Şekil 3.7’de gösterilmiştir. Şekil 3.7 (a) giriş görüntüsü, (b) evrişim katmanında 3x3’lük bir filtre uygulanması sonucu oluşan görüntü ve (c) ise ReLu katmanından çıkan görüntüyü göstermektedir.




Şekil 3.7. (a) Giriş görüntüsü, (b) birinci evrişim katmanında 3x3’lük bir filtrenin giriş görüntüsüne uygulandıktan sonra çıkan görüntü, (c) evrişim katmanından sonra gelen ReLu katmanından çıkan görüntü.

#### 3.1.1.4. Ortaklama(Pooling) katmanı

DÖ modellerinde ortaklama işlemi evrişim işleminde olduğu gibi tanımlanan filtrelerin görüntü üzerinde dolaştırılması ile gerçekleştirilir. Bu filtreler görüntü üzerinde belli bir adım atma değerine göre gezdirilerek görüntüdeki piksellerin maksimum değerlerini veya değerlerin ortalamasını alarak işlem yapar. Bu katman sonucu boyuttaki azalmadan dolayı bilgi kaybı oluşur. Fakat böyle bir kayıp ağ için iki nedenden dolayı faydalıdır. Birincisi, bir sonraki ağ katmanları için daha az hesaplama yükü oluşturur. İkincisi ise ağın ezberlemesini önler. Ortaklama işleminde boyut düşürme işlemi adım kayma sayısına göre yapılmaktadır. Adım kayma sayısından

dolayı, sonraki evrişim katmanı için giriş boyutu (Genişlik x Yükseklik) azalmaktadır. Bu işlem veride derinlik boyutunu etkilemez.

Ortaklama katmanının giriş görüntüsü üzerine yaptığı etki Şekil 3.8’de gösterilmiştir. Örnek olarak kullanılan ESA modelinin ortaklama katmanındaki filtre boyutu 2x2 ve adım kayma sayısı 2 olarak belirlenmiştir. Ortaklama yöntemi için max-ortaklama yapılmıştır. Şekil 3.8’de görüldüğü gibi veri boyutundaki değişimden dolayı şekil daha az piksel içermektedir.



**Şekil 3.8.** (a)Giriş görüntüsü, (b) evrişim katmanında 3x3'lük bir filtre uygulanması sonucu oluşan görüntü, (c)ReLu katmanından çıkan görüntü ve (d) ortaklama katmanından sonra çıkan görüntü.


### 3.1.1.5. Tam bağlantılı katman

ESA modellerinde art arda gelen evrişim, ReLu ve ortaklama katmanından sonra tam bağlantılı katman gelmektedir. Farklı mimarilerde bu katmanın sayısı değişebilir. Katman sayısının yanında çıkış değeri de uzman bilgisine göre seçilir. Bu katman kendinden önceki katmanın tüm alanlarına bağlıdır. ESA’da özellik keşfi bölümünün en sonundaki katman 2 boyutludur. Bu katmandan tam bağlantılı katmana geçerken düzleştirme işlemi gerçekleştirilir. Tam bağlantılı katmana geçiş alanı, ESA modellerinde evrişim katmanı ile beraber en fazla parametrelerin kullanıldığı alanlar olarakda bilinir. Yani tasarlanacak bir ESA modelinin hesaplama karmaşıklığı düşünüldüğünde bu alanda kullanılan parametre sayıları uygun seçilmelidir.

### 3.1.1.6. Düğüm seyreltme (DropOut) katmanı

Danışmanlı öğrenme metodunda büyük problemlerin biriside eğitilen sistemin ezberleme problemidir. Bu durum ESA modellerinde de söz konusu olmuştur. ESA modellerinde ezberlemenin önüne geçilmesi için düğüm seyreltme(Srivastava ve ark., 2014) katmanı kullanılır. Bu katmanda uygulanan temel mantık ağın bazı düğümlerinin

gelişigüzel kaldırılmasıdır. Şekil 3.9.a'da ağın orijinal yapısı gösterilirken, Şekil 3.9.b'de ise düğüm seyreltme katmanından sonraki hali gösterilmiştir.



Şekil 3.9. Standart bir ESA ağına düğüm seyreltme katmanının uygulanması

### 3.1.1.7. Sınıflandırma katmanı

Bu katman tam bağlantılı katmandan sonra gelir ve bu katmanda sınıflandırma işlemi yapılmaktadır. Bu katmanın çıkış değeri, sınıflandırması yapılacak nesne sayısına eşittir. Örneğin 10 farklı nesnenin sınıflandırılması isteniyorsa bu katmanın çıkış değeri 10 olarak seçilir. Bu katmanda farklı sınıflandırıcılar kullanılmaktadır. Çoğunlukla başarısından dolayı softmax sınıflandırıcı tercih edilir. Bu sınıflandırıcıda her bir nesne sınıfı için  $[0,1]$  aralığında çıkış üretilir. En yüksek değer hangi çıkışta üretilmişse sınıflandırılması yapılan nesne o sınıfa dâhil edilir.

### 3.1.2. ESA modelinin eğitimi

Tasarlanan derin ağlarda en zor kısım bu ağların eğitilmesidir. Derin ağların eğitilmesi kısaca şu şekilde açıklanabilir;

Oluşturulan modele giriş verisi olarak eğitim setinden görüntü verilir. Görüntüdeki piksel değerleri ile her bir katmandaki filtrelerin ağırlıkları çarpılıp bunların toplamı alınarak bir sonraki katmana aktarılır. Bu aşamaya ileri besleme denir. İleri besleme ile ağın üretmiş olduğu sonuçlar ile hedef sonuçların farkı alınarak toplam hata değeri hesaplanır (Eşitlik 3.4). Buradaki  $n$  görüntü sayısını temsil eder.

$$\text{Toplam Hata} = \sum_{i=1}^n \frac{1}{2} (\text{Hedef}_i - \text{Tahmin Edilen}_i)^2 \quad 3.4$$

Elde edilen toplam hata değeri geriye doğru ağıdaki bütün ağırlıklara dağıtılır. Eğitim kümesindeki bütün veriler devir(epoch) sayısı kadar model üzerinde ileri ve geri besleme yapılarak eğitim işlemi bitirilir.

Eğitim işlemindeki en önemli kısım ağın geriye yayılım esnasında kullanılmış olduğu gradyan tabanlı optimizasyon algoritmalarıdır. Bu algoritmaların birbirlerine göre avantaj ve dezavantajları (Ruder, 2016)'de detaylı bir şekilde anlatılmıştır. Bu tez kapsamında tasarlanan ESA modellerinin eğitim aşamasında optimizasyon için Momentumlu Stokastik Gradyan İniş (Stochastic Gradient Descent with Momentum(SGDM) ) algoritması kullanılmıştır.

### 3.1.2.1. Momentumlu stokastik gradyan iniş (SGDM)

Standart gradyan iniş algoritması parametreleri Eşitlik 3.5'e göre günceller.

$$\theta = \theta - \alpha \nabla_{\theta} J(\theta) \quad (3.5)$$

Burada  $J(\theta)$  amaç fonksiyonunu,  $\theta$  amaç fonksiyonundaki parametreleri,  $\nabla_{\theta}$  gradienti ve  $\alpha$  öğrenme oranını belirtir. Standart gradyan iniş yönteminde tek bir güncelleme gerçekleştirmek için tüm veri kümesinin gradyanları hesaplanması gerekir. Bu yüzden eğitim hem çok yavaş hem de büyük veri setlerinde kullanılacak bellek boyutu yüksek olur. Bu dezavantajlarından dolayı Stokastik Gradyan İniş (Stochastic Gradient Descent-SGD) algoritması geliştirilmiştir. SGD, Gradyan inişin aksine yalnızca bir veya birkaç eğitim örneği kullanılarak parametrelerin değişim derecesini hesaplar(Eşitlik 3.6). Eşitlik 3.6'daki  $(x^{(i)}; y^i)$  parametre çifti olup  $x^{(i)}$  eğitim örneğini  $y^i$  ise eğitim örneğinin etiketini temsil eder.

$$\theta = \theta - \alpha \nabla_{\theta} J(\theta; x^{(i)}; y^i) \quad (3.6)$$

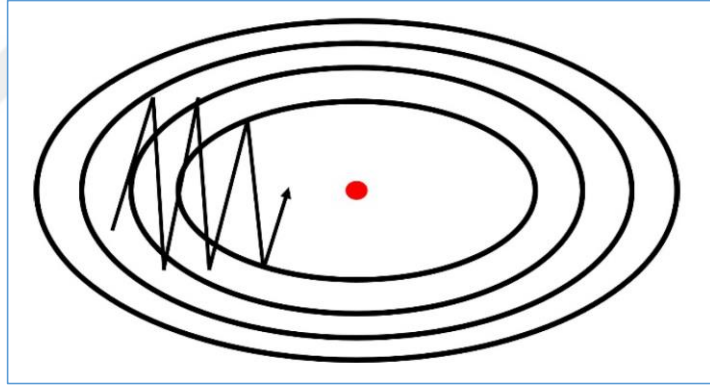
Amaç fonksiyonun optimumu, uzun ve sığ bir vadi ve kenarları dik duvar biçimindeyse SGD bu dar koridor boyunca sık salınım göstermektedir(Şekil 3.10). Çünkü negatif gradyan, optimuma doğru koridor boyunca değil de dik taraflardan birini

aşağı doğru gösterecektir. Derin ağların hedefleri yerel optimum yakınında bu şekle sahiptir ve bu nedenle standart SGD özellikle ilk dik kazançlardan sonra çok yavaş bir yakınsama sağlayabilir. Momentum, bu yapıdaki bir optimizasyon probleminde amaç fonksiyonunun istenilen optimum değere daha hızlı erişmesini sağlamaktadır(Şekil 3.11). Momentum güncelleme işlemi Eşitlik 3.7'deki gibi yapılır(Tutorial, 2017).


$$v = v\gamma - \alpha \nabla_{\theta} J(\theta; x^{(i)}; y^i) \quad (3.7)$$

$$\theta = \theta - v \quad (3.8)$$

Burada  $v$ , mevcut hızlanma vektörüdür ve parametre vektörü  $\theta$  ile aynı boyuttadır.  $\gamma$  momentum terimidir ve önceki gradientlerde kaç tane iterasyonun mevcut güncellemeye dahil edileceğini belirler. Değer olarak  $\gamma < 1$ 'dir ve genellikle öğrenme oranı stabilize olana kadar 0.5 daha sonra ise 0.9'yükseltilir.



**Şekil 3.10.** Derin ağların eğitiminde kullanılan SGD'nin momentum olmadan sergilediği yakınsama davranışı(Ruder, 2016).



**Şekil 3.11.** Derin ağların eğitiminde momentum ile kullanılan SGD'nin yakınsama davranışı(Ruder, 2016)

SGDM’de kullanılan bazı temel parametre tanımları aşağıda açıklanmıştır.

**Öğrenme Oranı(Learning Rate):** Öğrenme oranı tasarlanan modelin performansını etkileyen en önemli parametredir. Ağın hızlı öğrenilmesi için bu değer yüksek seçilmelidir. Fakat eğer ön eğitilmiş bir ağın tekrar eğitilmesi gerekiyorsa bu değer çok düşük seçilmesi gerekir. Başlangıç öğrenme oranı genellikle 0.001 olarak seçilir. Eğitilen ESA ağı her bir devirden sonra biraz daha öğrendiği için, genellikle belli bir devir sayısından sonra öğrenme oranı düşürülür. Öğrenme oranının sıklıkla düşürülme periyodu 8 devirde bir ve değeri ise 0.1 ile çarpılarak belirlenir. Örneğin ilk 8 devirde öğrenme oranı 0.001 iken 8-16 devir arası 0.0001 olarak ayarlanır

**Momentum:** ESA modelinde ağın optimum değere daha hızlı ulaşması için kullanılan parametredir. Genellikle 0.9 olarak seçilmiştir.


**Paket Boyutu( Mini-Batch Size):** Paket boyutu her bir devirde kaç tane görüntünün kullanılacağını belirtir. Paket boyutu yüksek seçilmesi kullanılan bellek miktarını artırır. Literatürde genellikle 64-1024 arasında farklı değerler kullanılmaktadır.

**Devir Sayısı(Epoch Number) :** ESA modellerinin eğitimi esnasında kaç defa ileri ve geri besleme yapılacağını belirtir. Bir diğer deyişle ESA modelindeki ağırlıkların kaç defa güncelleneceğini ifade eder.

### 3.1.3. Nesne sınıflandırmada kullanılan derin öğrenme modelleri

#### 3.1.3.1. AlexNet


DÖ mimarisinin kullanımı ilk olarak 1998 yılında Yann LeCun’nun yaptığı çalışmada(Lecun ve ark., 1998) elle yazılan yazıların tanımlanmasında kullanılmıştır. Fakat en büyük etkisini 2012 yılında yapılan ILSVRC yarışması ile göstermiştir. 2012 yılında yapılan imageNet yarışmasını, DÖ mimarisi ile tasarlanan AlexNet (Krizhevsky ve ark., 2012) modeli kazanmıştır. AlexNet modeli nesne tanımlamadaki hata oranını çok keskin bir düşüşle aşağıya indirmiştir. Bu mimari ile bilgisayarlı nesne tanımlama hata oranı %25,81’den %16,42’ye düşürülmüştür. Şekil 3.12’de verilen mimari 5 evrişim katmanı, 3 ortaklama katmanı ve 3 tam bağlantılı katmandan oluşmaktadır. AlexNet modeli 1000 nesneyi sınıflandıracak şekilde tasarlanmıştır. Filtreler 11x11 boyutunda ve adım kayma sayısı 4 olarak belirlenmiştir.



Şekil 3.12. AlexNet mimarisi(Krizhevsky ve ark., 2012)

### 3.1.3.2. ZF Net

2012 yılında AlexNet'in ILSVRC yarışmasını kazanmasının akabinde yapılan yarışmalarda DÖ modelleri kullanılmaya başlanmıştır. Matthew Zeiler ve Rob Fergus tasarlamış olduğu ZFNet (Zeiler ve Fergus, 2014b) 2013 yılında ImageNet yarışmasının kazanan modeli olmuştur. Bu model ile nesne tanımda hata oranı %11,74'ye indirilmiştir. Bu mimari AlexNet mimarisinin geliştirilmiş halidir ve Şekil 3.13'te verilmiştir.



Şekil 3.13. ZF Net mimarisi(Zeiler ve Fergus, 2014b)


ZF Net modelinde, ilk katmanda AlexNet'in uyguladığı 11x11 boyutlu filtreler kullanmak yerine, 7x7 boyutundaki filtreler ve ortaklama katmanında 2 adım kayma miktarı kullanılmıştır. Bu değişikliğin arkasındaki mantık, birinci evrişim katmanındaki daha küçük bir filtre boyutunun, giriş boyutundaki birçok orijinal piksel bilgisinin korunmasına yardımcı olmasıdır. Aktivasyon fonksiyonu için ReLu ve eğitim için SGDM optimizasyon algoritması kullanılmıştır.

### 3.1.3.3. VggNet

Bu ağ mimarisi Basitlik ve Derinlik ile ifade edilebilir. 2014'te oluşturulan bu model ILSVRC yarışmasında % 7.3 hata oranını elde etmiştir. Oxford Üniversitesi'nden



Karen Simonyan ve Andrew Zisserman tarafından tasarlanmıştır. VggNet modelinin mimarisi Şekil 3.14’de verilmiştir. Şekil 3.15’ gösterildiği gibi farklı katman sayısına göre çeşitli VggNet modelleri tasarlanmıştır. Bu modeller arasında en yüksek doğruluğa sahip Vgg16(Şekil 3.15’ D modeli) ve Vgg19(Şekil 3.15’de E modeli) modelleri olmuştur. VggNet modeli, derin öğrenme ağlarının, görsel verilerin bu hiyerarşik temsilinin çalışması için derin bir katman ağına sahip olması gerektiği fikrini güçlendirmiştir.



Şekil 3.14. VGG Net ağ mimarisi(Hassan, 2019).

ConvNet Configuration					
A	A-LRN	B	C	D	E
11 weight layers	11 weight layers	13 weight layers	16 weight layers	16 weight layers	19 weight layers
input (224 × 224 RGB image)					
conv3-64	conv3-64 LRN	conv3-64 conv3-64	conv3-64 conv3-64	conv3-64 conv3-64	conv3-64 conv3-64
maxpool					
conv3-128	conv3-128	conv3-128 conv3-128	conv3-128 conv3-128	conv3-128 conv3-128	conv3-128 conv3-128
maxpool					
conv3-256 conv3-256	conv3-256 conv3-256	conv3-256 conv3-256	conv3-256 conv3-256 conv1-256	conv3-256 conv3-256 conv3-256	conv3-256 conv3-256 conv3-256 conv3-256
maxpool					
conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512 conv1-512	conv3-512 conv3-512 conv3-512	conv3-512 conv3-512 conv3-512 conv3-512
maxpool					
conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512 conv1-512	conv3-512 conv3-512 conv3-512	conv3-512 conv3-512 conv3-512 conv3-512
maxpool					
FC-4096					
FC-4096					
FC-1000					
soft-max					

Şekil 3.15. VggNet için birden fazla mimari tasarlanmıştır. Bunlar içerisinde en iyi sonuç D (Vgg16) ve E(Vgg19) ile elde edilmiştir(Hassan, 2019).

VggNet, 3x3 boyutlu filtrelerin kullanımından dolayı AlexNet(11x11) ve ZFNet (7x7) filtrelerinden oldukça farklıdır. Bu yapı, daha küçük filtre boyutlarının faydalarını korurken, daha büyük bir filtre simüle eder. VggNet, özellikle önceki modellerle karşılaştırıldığında daha az parametre kullanılarak daha yüksek performans sergilediği görülmüştür. Ayrıca, iki evrişim katmanı için tek ReLU katmanı yerine iki tane ReLU katmanı kullanılmıştır. Her katmandaki girdi hacimlerinin mekânsal boyutu azaldığından (evrişim ve ortaklama katmanlarının sonucu), filtre sayısının artması nedeniyle hacimlerin derinliği artar. Hem nesne sınıflandırma hem de kenar belirleme problemlerinde iyi çalışmaktadır.

### 3.1.3.4. GoogLeNet

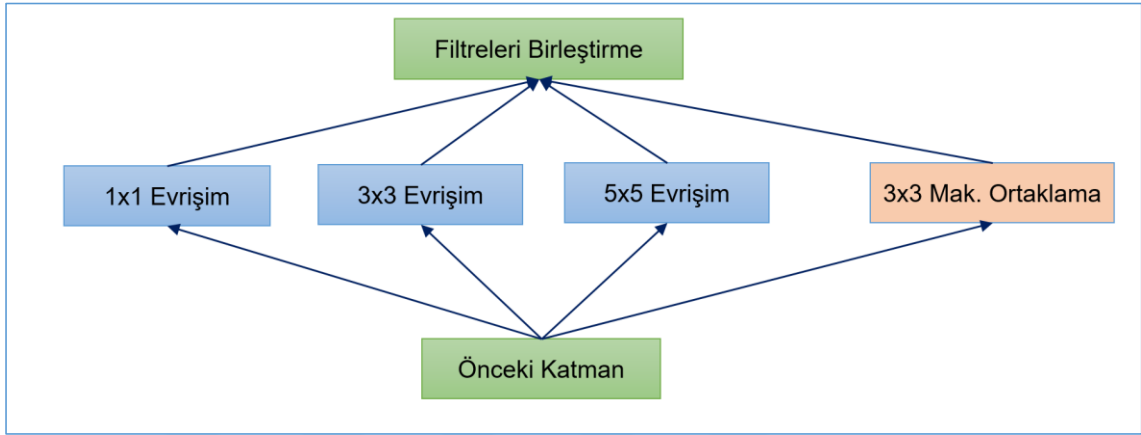
GoogLeNet (Szegedy ve ark., 2015b) 22 katmanlı ve %6.66 hata oranı ile ILSVRC yarışmasının 2014 yılındaki kazanan modeli olmuştur. Modelin mimarisi Şekil 3.16'da verilmiştir. Bu model genel olarak, ardışık bir yapıda evrişim ve ortaklama katmanlarını üst üste istiflemekten uzaklaşan ilk ESA mimarilerinden birisidir. Ayrıca bu yeni model bellek ve güç kullanımı üzerinde önemli bir yere sahiptir. Çünkü katmanların hepsini yığınlamak ve çok sayıda filtre eklemek, bir hesaplama ve bellek maliyeti getirir ve ezberleme olasılığını artırır. GoogLeNet mimarisinde bu durumun üstesinden gelmek için paralel olarak birbirine bağlı modüller kullanılmıştır. Bu modüllere **Başlangıç(Inception)** modülleri denilmiştir. Bu modüllerden dolayı model karmaşık bir mimariye sahiptir.



Şekil 3.16. GoogLeNet ağ mimarisi(Szegedy ve ark., 2015b)

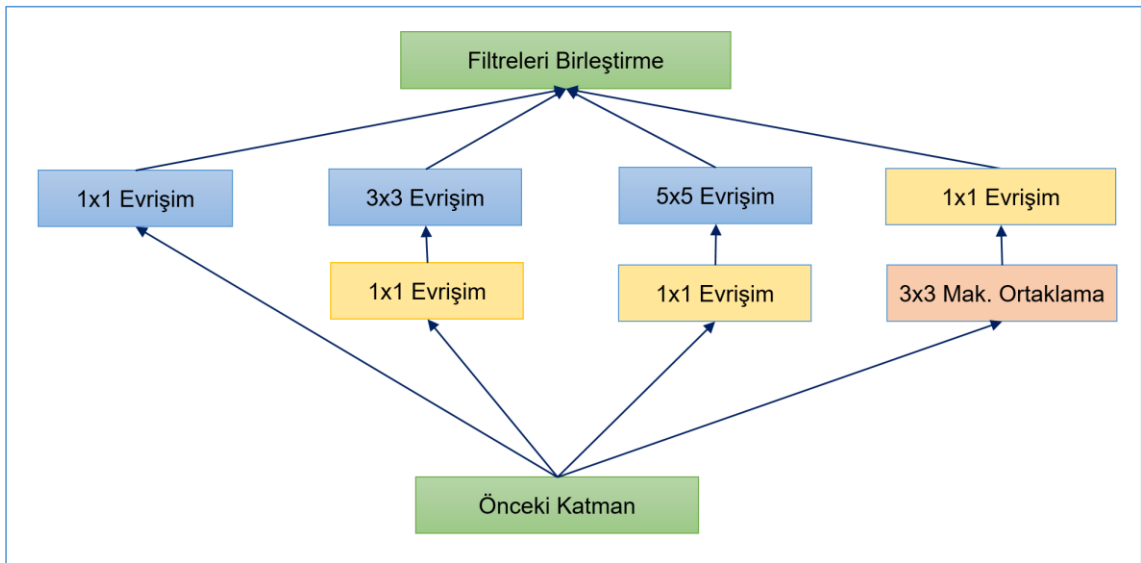
Başlangıç modülleri Şekil 3.17'de gösterildiği gibi 3x3 maksimum ortaklama ve 1x1, 3x3, 5x5 evrişim katmanlarından oluşmaktadır. Ağ bir önceki katmandan gelen

veri üzerinde bu insepction katmanını uyguladıktan sonra çıkışta filtreleri toplayarak bir sonraki katmana aktarmaktadır. Bu modül sayesinde bir nesneye ait hem genel hem de spesifik özellikler keşfedilmeye çalışılır. Şekil 3.17’de alt yeşil kutu Giriş kısmı ve en üstteki ise modelin çıktısıdır. Bu resmi 90 derece sağa çevirirsek Şekil 3.16’da verilen ağ mimarisinin bir parçası elde edilir.



Şekil 3.17. GoogLeNet mimarisinde kullanılan Başlangıç modül yapısı


Şekil 3.17’deki Başlangıç yapısında evrişim işlemi esnasında fazla parametre olacağı için hesaplama maliyeti artmaktadır. Bu problemin üstesinden gelmek için Şekil 3.18’de gösterildiği gibi 1x1 evrişim uygulanarak boyut düşürme işlemi gerçekleştirilmiştir.



Şekil 3.18. GoogLeNet’teki Başlangıç modülünde boyut düşürme işlemleri için 1x1 evrişim işleminin uygulanması


### 3.1.3.5. Microsoft RestNet

ResNet (He ve ark., 2016b) kendisinden önce tasarlanan bütün mimarilerden daha derin olarak tasarlanan bir mimariye sahiptir. Model 152 katmandan oluşmaktadır. Aynı zamanda %3.6 hata oranı ile ILSVRC 2015 yarışmasının kazananı olmuştur. Microsoft RestNet ilk 34 katmanlı ağ mimarisi Şekil 3.19'da gösterilmiştir.



Şekil 3.19. Microsoft RestNet ilk 34 katmanının ağ mimarisi(He ve ark., 2016b)

Bu mimari Şekil 3.20'de gösterilen kalıntı bloklardan oluşmaktadır. Kalıntı bloкта,  $x$  girişinin evrişim-ReLu-evrişim serisinden sonra bir  $F(x)$  sonucu vermektedir. Bu sonuç daha sonra orijinal  $x$  girişine eklenir ve  $H(x) = F(x) + x$  olarak ifade edilir.




Şekil 3.20. Residual blok(He ve ark., 2016b)

### 3.1.4. Nesne tanımlamada kullanılan derin öğrenme modelleri

ESA modelleri ilk olarak sınıflandırma işlemi için kullanılmıştır. ESA modellerinde Şekil 3.21.a'da olduğu gibi sınıflandırmada, ağa verilen bir resmin bir bütün olarak neyi temsil ettiği tahmin edilmeye çalışılır. Fakat gerçek hayatta Şekil 3.21.b'de gösterildiği gibi bir görüntü içerisinde birden fazla nesne bulunabilir. Bu gibi durumlarda görüntü içerisindeki her bir nesnenin tespiti için zamanla farklı mimariler geliştirilmiştir. Bu mimarilerden hem nesne tanımlama başarısı hem de test süresi olarak Faster R-CNN (Ren ve ark., 2017) modeli ön plana çıkmaktadır. Faster R-CNN modeli


kendisinden önce geliştirilen Region-based CNN (R-CNN) (Girshick ve ark., 2014), Fast R-CNN (Girshick, 2015) modellerinin dezavantajlarının ortadan kaldırılmasına yönelik geliştirilmiştir.




Şekil 3.21. (a) Sınıflandırma için bir resimdeki nesnenin tahmini yapılırken (b) tanımlamada görüntüdeki bütün nesnelerin yerleri ve ne olduğu tespit edilmeye çalışılır (Liang ve ark., 2019).

### 3.1.4.1. R-CNN

R-CNN mimarisi şekil 3.22’de verilmiştir. Bu mimari başlıca 4 bölümden oluşmaktadır. Birinci bölümde görüntüler alınır. İkinci bölümde ise şekil 3.23’te gösterildiği gibi Seçici Arama(SA) ile bölge önerileri yapılır. SA, bir nesneyi ihtimali yüksek olan 2000 farklı bölge üretme işlevini gerçekleştirir. Üçüncü bölümde her bir bölge önerisi AlexNet modeline benzer şekilde tasarlanmış ESA modeline verilir. Son olarak ESA çıktısı eğer bir nesne ise SA ile belirlenen bölge üzerinde bir düzenleme yapılarak nihai sonuç üretilir.



Şekil 3.22. R-CNN mimarisi



Şekil 3.23. R-CNN mimarisinin ikinci aşamasında seçici arama ile farklı ölçeklerde elde edilen alanları temsil eden farklı iki resim


R-CNN bazı dezavantajları vardır. Bunlar;

1. Öncelikle her bir görüntü için seçici arama algoritması ile önerilen 2000 bölge önerisinin ESA ile sınıflandırılması gerekmektedir. Bu yüzden modelin eğitim ve test süreleri yüksek olur.
2. Test aşamasında her görüntünün işlenmesi yaklaşık 47 saniye sürdüğü için model gerçek zamanlı olarak uygulanamaz.
3. Bölge önerileri için kullanılan seçici arama algoritması sabit bir algoritmadır. Bu nedenle, bölge önerisi aşamasında hiçbir öğrenme gerçekleşmez. Bu sebeple uygun olmayan bölge önerisi teklifleri oluşturulabilir.
4. Mimari üç farklı modeli ayrı ayrı eğitmek zorundadır. Bunlar; görüntü özelliklerini oluşturmak için ESA, nesnenin sınıfını tahmin eden sınıflandırıcı ve sınırlayıcı çerçeveleri sıkıştırmak için regresyon modelidir. Bu sebeple R CNN'i eğitmek son derece zordur.

Yukarıda bahsedilen sorunların üstesinden gelmek için Fast R-CNN modeli geliştirilmiştir.

#### **3.1.4.2. Fast R-CNN**

Bu mimari R-CNN modelindeki dezavantajların üstesinden gelmek için tasarlanmıştır. Bu mimaride öncelikle her bir görüntü için yaklaşık 2000 kez ESA çalıştırmak yerine tek bir kez ESA çalıştırıp 2000 öneri arasında bu hesaplamanın paylaşımı yapılmaktadır. Böylelikle eğitim ve test süresi kısaltılmıştır. Bu modelin yapısı Şekil 3.24'ta verilmiştir. Şekil 3.24'te giriş görüntüsü bir bütün olarak ESA modeline verilir. ESA modelinin son evrişim katmanından sonra özellik haritası elde edilir. Son evrişim katmanından sonra bölge önerileri üzerinde ortaklama işlemi uygulanır ve bu işlem Bölge önerileri ortaklama (Region of Interest Pooling-RoI) olarak adlandırılır. Bu katmandan sonra TBK katmanları kullanılır. TBK katmanlarından sonra RoI Özellik vektörü elde edilir. Bu özellik vektörüne göre nesnenin sınırlayıcı kutu değerleri ve sınıf değeri belirlenir.




Şekil 3.24. Fast R-CNN mimarisi

### 3.1.4.3. Faster R-CNN

Bu model, hem R-CNN hem de Fast R-CNN'nin sergilediği karmaşık eğitim hattını iyileştirmek için tasarlanmıştır. Son evrişim katmanından sonra bir Bölge Öneri Ağı (BÖA (Region Proposal Network-RPN)) eklenmiştir. Bu ağ sadece son evrişim katmanındaki özellik haritasına bakarak bölge önerileri üretmektedir. Bu aşamada, R-CNN ile aynı hat kullanılır. Şekil 3.25'te hem bölge önerileri hem de sınıflandırma yapmak için tek bir ESA'nın nasıl kullanıldığı görülmektedir. Bu şekilde, yalnızca bir ESA eğitilerek bölge önerileri alınmaktadır. R-CNN, Fast R-CNN ve Faster R-CNN modelleri PASCAL VOC(Everingham ve ark., 2010) veri seti üzerinde denenmiş ve sonuçları Tablo 3.1'de verilmiştir.

Tablo 3.1. Nesne tanımlama için kullanılan modellerin karşılaştırılması

	R-CNN	Fast R-CNN	Faster R-CNN
Görüntü başına test süreleri	50sn	2sn	0.2sn
Hızlanma	1x	25x	250x
Ortalama tahmin(%)	66	66.9	66.9



Şekil 3.25. Faster R.CNN mimarisi

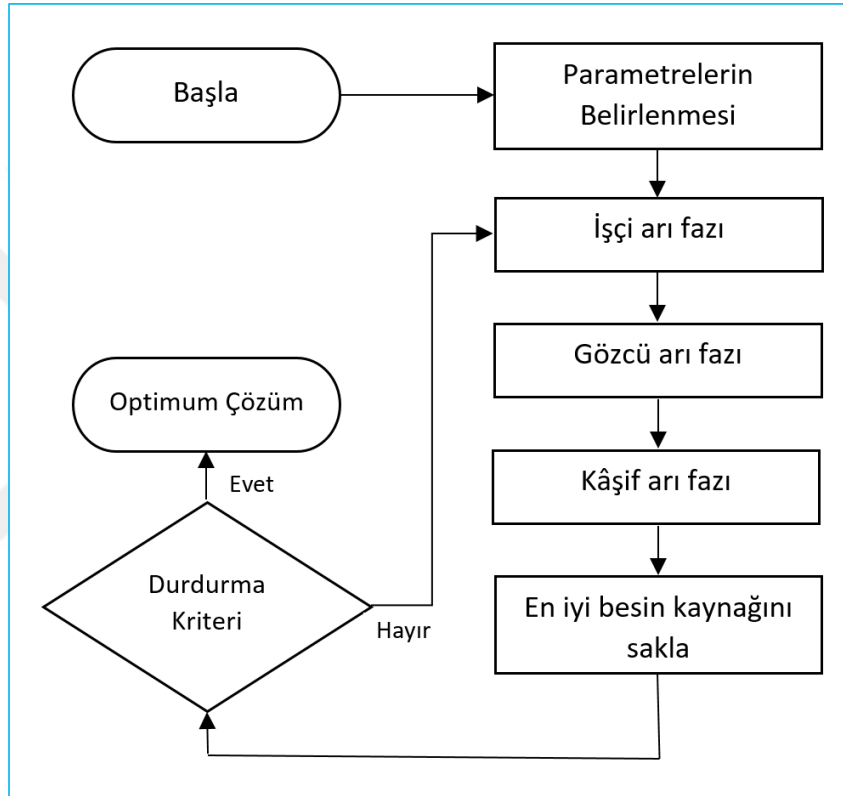
### 3.2.Yapay Arı Kolonisi Algoritması(YAKA)

YAKA, Karaboğa(Karaboga, 2005) tarafından önerilen, bal arılarının çiçeklerden nektar toplamak için yaptığı çalışmalarından ilham alan, popülasyon tabanlı, sezgisel bir optimizasyon algoritmasıdır. Arıların yiyecek aradığı kaynaklar, çözülecek sorunun olası çözümlerini ifade eder. Kaynaktaki nektar miktarı, çözümlerin kalitesini ifade eder. YAKA, optimum noktayı bulmak için en fazla nektarlı besin kaynağını bulmaya çalışır (Karaboga ve Akay, 2009). Algoritmada, ilk olarak, çözüm alanında rastgele dağıtılmış gıda kaynakları oluşturulur. Algoritmada üç tür arı kullanılmaktadır. Bunlar işçi, gözcü ve kaşif arılardır. Her bir nektarın çıkarılmasından sadece bir işçi arı sorumlu olduğundan dolayı algoritmada yer alan besin sayısı ile işçi arı sayısı birbirine eşittir. İşçi arılar mevcut besin kaynaklarının komşuluğunda yeni yiyecek kaynağı araması yapmaktadırlar. Yeni besin kaynağındaki nektar miktarı eski besin kaynağındaki nektar miktarından daha iyiyse, yeni besin kaynağını hafızasına alır ve eski besin kaynağı bilgisini siler. Gözcü arılar, işçi arılar tarafından elde edilen bilgileri toplayarak nektar miktarıyla orantılı olasılıkta bir gıda kaynağı seçerler. Bu olasılık rastgele oluşturulmuş bir sayıdan büyükse, gözcü arılar, ilgili gıda kaynağının



komşuluğunu da dikkate alarak yeni bir çözüm üretir. Yeni çözüm eski çözümden daha iyiye, yeni çözüm saklanır ve eski çözüm bellekten silinir. Bir besin kaynağındaki nektar tüketildiğinde, bu besin kaynağından sorumlu olan işçi arı, kaşif arı olur. Bu kaşif arı, yeni kaynakları keşfetmek için rastgele aramalar yapar.

Algoritmanın kullanılan işçi, gözcü ve kaşif arı aşamaları önceden tanımlanmış bir kritere veya maksimum döngü sayısına ulaşıncaya kadar devam eder. Yapay arı kolonisi algoritmasının akış diyagramı, Şekil 3.26'da gösterilmiştir.




Şekil 3.26. YAKA akış şeması

### 3.3. Ovaryum Follikülleri


Ovaryum, dişi üreme sisteminde tekrarlayan döngülere göre önemli yapısal ve işlevsel değişiklikler gösteren karmaşık bir endokrin organdır. Ovaryumda beş farklı follikül mevcuttur. Bunlar sırasıyla Primordial, Primer, Preantral, Sekonder ve Tersiyerdir. Bu folliküller gelişerek birbirine dönüşürler(Şekil 3.27). Gelişmekte olan follikül sayısının belirlenmesi üreme sisteminin tekrarlayan döngülerinde önem arz eder. Primordial follikül sayısında meydana gelen azalma ovaryum rezervinin tükenmesinin bir işaretiyken, gelişmekte olan oositi taşıyan tersiyer folliküllerin

gözlenebilmesi infertilite ile sonuçlanabilir (Inik ve ark., 2019). Özellikle tüp bebek teknolojisinde ovaryum dokusundaki folliküller üzerinde yapılan çalışmalar çok büyük öneme sahiptir. Bunun yanında ilaçların geliştirme aşamasında ovaryum dokusuna olan etkisi ile ilgili çalışmalarda folliküllerin tespiti önem arz etmektedir. Bu önemden dolayı literatürde sıklıkla ovaryumdaki folliküllerin sayısı, hacim ve yüzey alanlarının değerlendirilmesi yapılmıştır. Yapılan değerlendirmeler stereolojik yöntemler kullanılarak yapılmıştır (Miller ve ark., 1997; Coward ve Bromage, 2002; Myers ve ark., 2004; Charleston ve ark., 2007; Smith ve ark., 2009; Aragon ve ark., 2010; Chand ve Legge, 2011; Hansen ve ark., 2012; Karbalay-Doust ve Noorafshan, 2012; Medigovic ve ark., 2012; Skodras ve Marcelli, 2015).

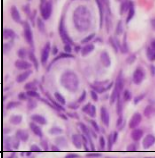
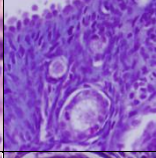
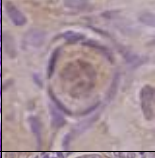
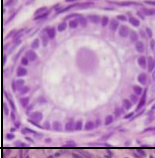
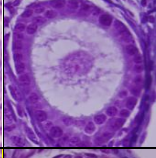
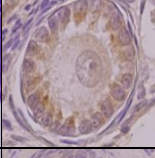
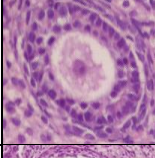
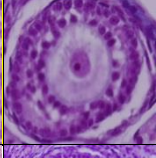
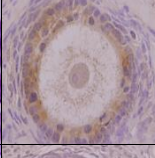
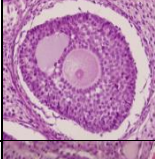
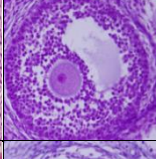
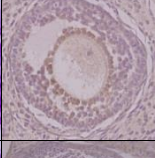

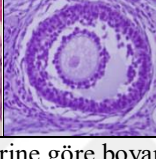
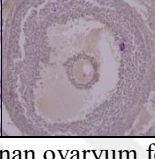


**Şekil 3.27.** Ovaryum dokusuna ait folliküllerin birbirine dönüşüm periyotları (Araújo ve ark., 2014)

Ovaryum dokusuna ait histolojik olarak alınan bir kesit Şekil 3.28’de verilmiştir. Alınan kesitler farklı boyama türlerine göre boyanmaktadır. Yoğun olarak kullanılan boyama türleri Hematoksilen-Eozin (H&E), Masson’s Trikrom (MT) ve Anti Mülleriin Hormon (AMH) olarak sıralanabilir. Ovaryum dokusuna ait folliküllerin boyama türüne göre gösterimi Şekil 3.29’da verilmiştir.



**Şekil 3.28.** Ovaryum dokusuna ait bir kesitten elde edilen genel bir görüntü

Foliküller	Boyama Türleri		
	H&E	MT	AMH
Primordial			
Primer			
Preantral			
Sekonder			
Tersiyer			

Şekil 3.29. Farklı boyama tekniklerine göre boyanan ovaryum follikülleri

## 4. ÖNERİLEN YÖNTEM

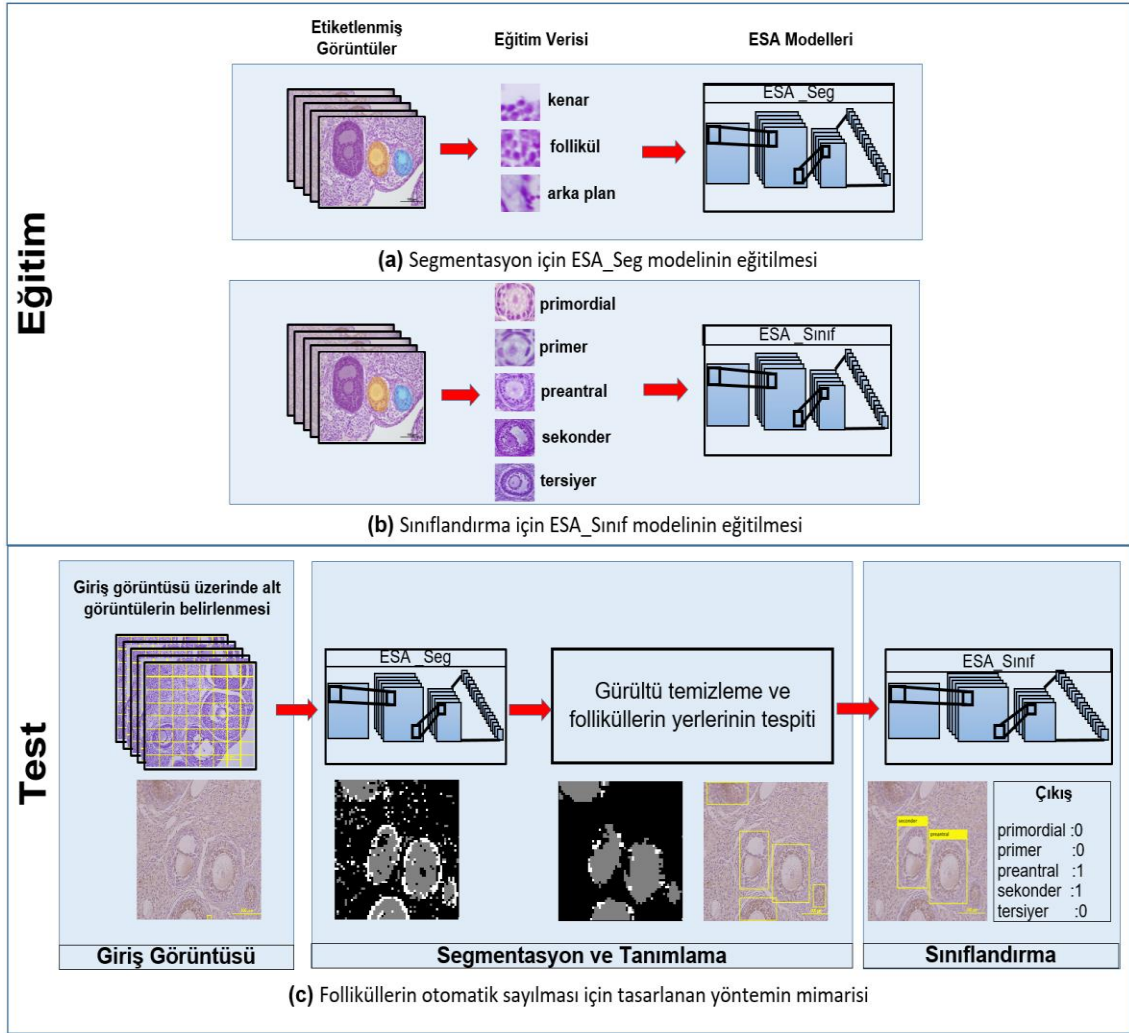
Bilgisayarlı görü sistemlerinde medikal görüntülerin analizi görüntülerdeki gürültü etkenlerinin fazla olmasından dolayı zor bir süreçtir. Görüntülerdeki yapıların birbirine benzerliği veya tespit edilecek nesnelerin farklı boyutlarda olması segmentasyon, tanımlama veya sınıflandırma işlemini zorlaştırmaktadır. Tez çalışmasında geliştirilen yöntemin uygulandığı ovaryum dokusundaki follüküllerin tespiti aşağıdaki sebeplerden dolayı zor bir problemdir (İnik ve ark., 2019).

1. Her bir follükül bir önceki follükülün gelişimi ile meydana gelmektedir (bakınız Bölüm 3.3 Şekil 3.27). Bu gelişim esnasında ara formlar oluşmaktadır. Bu ara formların hangi sınıfa dâhil edileceği büyük bir zorluğu oluşturur. Bu problem uzmanların bile öznel olarak karar vermesine sebep olmaktadır.
2. Bazı durumlarda tek bir kesitte farklı follüküller farklı boyutlarda bulunabilir. Örneğin seconder follükülü 300x300 piksel boyutunda iken primordial follükülü 40x40 piksel boyutunda olabilir. Bu iki farklı boyuttaki follükülün tanımlanması zor bir problemdir.
3. Görüntüler mikroskop ile elde edilirken sabit bir büyütme oranına göre elde edilmezler. Farklı büyütme oranlarına göre elde edilen görüntülerdeki follüküllerin görünüşleri de farklı olmaktadır. Bu sebeple bazen tekbir follükül farklı büyütme oranlarında farklı görünüşe sahip olabilir.
4. Son olarak görüntüler farklı boyama tekniklerine göre elde edilirler. Bu boyama tekniklerinin farklılıkları follükül görünüşündeki farklılıklara sebep olur ve follükül tanımlanması zorlaşır.

Bu tez kapsamında, bahsedilen problemler düşünülerek hepsine çözüm üretecek bir yöntem geliştirilmiştir.


### 4.1. Önerilen Yöntemin Mimarisi

Önerilen yöntemin mimarisi Şekil 4.1'de ve yöntemin uygulanması için akış şeması Şekil 4.2'de verilmiştir.



Şekil 4.1. Tez kapsamında önerilen yöntemin mimarisi

Şekil 4.1'e bakıldığında yöntem temel olarak iki bölüme ayrılmıştır. Birinci bölümde ESA modellerin eğitilmesi gerçekleştirilir. Eğitim aşamasında, hem segmentasyon için hem de sınıflandırma için farklı ESA modelleri tasarlanıp eğitilmiştir. İkinci bölümde ise eğitilen ESA modelleri kullanılarak test işlemi gerçekleştirilir. Test işleminde, giriş görüntüsünden alınan alt görüntüler, öncelikle segmentasyon için eğitilen ESA modelinden geçirilir. Segmentasyon işleminden sonra oluşan gürültülerin temizlenmesi yapılarak nesnelere (folliküllerin) yerleri tespit edilmektedir. Yerleri tespit edilen nesnelere (folliküllerin) sınıflandırması daha önce eğitilen ESA modeli kullanılarak gerçekleştirilir. Sonuç olarak test aşamasında bir bütün olarak verilen görüntüdeki nesnelere (folliküllerin) segmentasyonu ve sınıflandırılması yapılarak sayım işlemi gerçekleştirilmektedir.



Şekil 4.2. Önerilen yöntemin uygulanması için gerekli akış şeması

#### 4.2. Önerilen Yöntemin Eğitim Aşaması

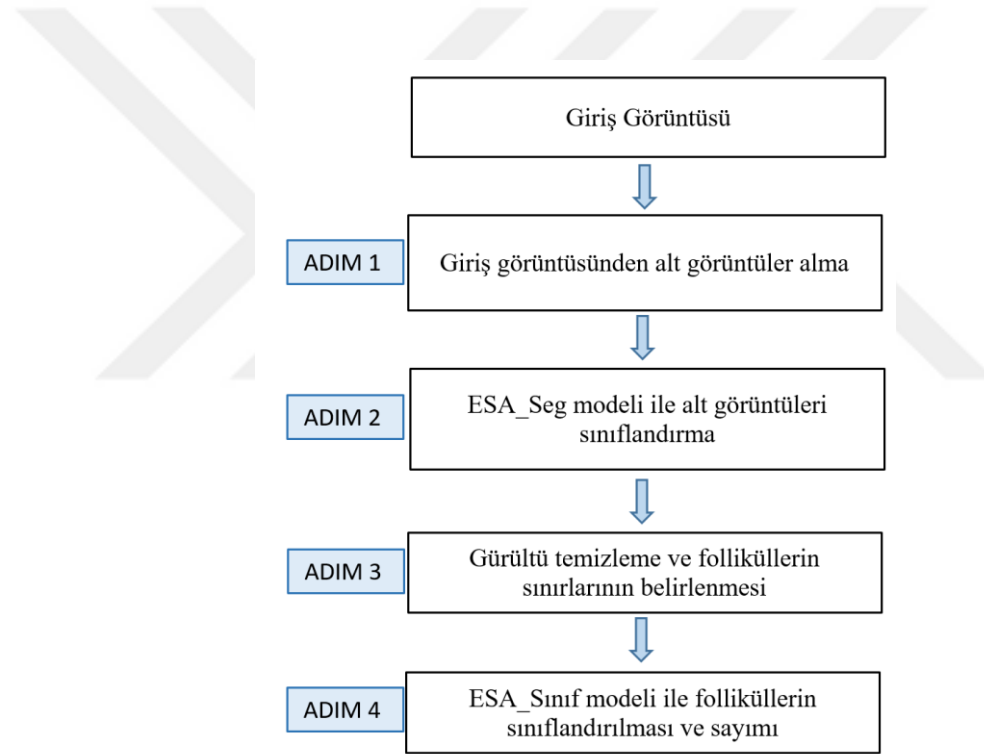
Tez kapsamında önerilen yöntemin temel yapısını bu bölüm oluşturmaktadır. Bu bölümde Segmentasyon ve sınıflandırma işlemlerinin başarılı olması için farklı ESA modellerinin eğitimi gerçekleştirilir.

Şekil 4.1.a ve Şekil 4.1.b’de gösterildiği gibi önerilen yöntemin eğitim aşamasında segmentasyon ve sınıflandırma için farklı ESA modelleri tasarlanmıştır. İlk etapta segmentasyon için en uygun ESA modelinin bulunması için farklı özellikte toplam 43 adet ESA modeli tasarlanmıştır. Bu 43 arasında en iyi performans sergileyen ESA modeli yöntemin bir sonraki adımı olan test aşamasında kullanılmıştır.

Segmentasyon için tasarlanan ESA modelleri 3 gruba ayrılmış olup her gruptaki en iyi ESA modeli hakkında detaylı bilgiler Bölüm 5’te verilmiştir. Ayrıca bu modellerin mimari özellikleri ve performans değerleride Bölüm 5’te verilmiştir. Şekil 4.1.(b)’de gösterildiği gibi sınıflandırma işlemi için 12 farklı ESA modelleri tasarlanmış olup eğitim ve test işlemleri yapılmıştır. Tasarlanan bu modeller hakkındaki parametre bilgileri ve performans değerleri yine Bölüm 5’te verilmiştir.

### 4.3. Önerilen Yöntemin Test Aşaması

Yöntemin eğitim aşamasında ESA modellerinin eğitimi bittikten sonra test aşamasına geçilmektedir. Test aşamasındaki akış şeması Şekil 4.3’de verilmiştir.




Şekil 4.3. Önerilen yöntemin test aşamasındaki akış şeması

**ADIM 1:** Eğitim aşamasında hem segmentasyon hem de sınıflandırma işlemi için oluşturulan veri setlerine benzer olarak bu adımda da giriş görüntüsü alt parçalara bölünmektedir. Bu alt parçaların görüntü boyutu, segmentasyon için tasarlanan ESA modelinin giriş görüntü boyutuna eşittir.

**ADIM 2:** Bu adım yöntemin en önemli adımıdır. Bu bölümde ADIM 1’de alınan alt görüntüler, segmentasyon için eğitilen ESA modeli tarafından sınıflandırılır. Bu adımda giriş görüntüsü boyutunda yeni bir matris oluşturulur. Giriş görüntüsünden alınan alt

görüntünün sınıflandırılmasına göre oluşturulan matrisin değerleri 0,128,255 değerleri ile doldurulur. Burada 0 arka planı, 128 follükülü ve 255 kenar sınıfını temsil etmektedir. Örneğin giriş görüntüsü üzerinde 16x16 boyutlarında alt görüntüler alındığında sınıflandırma sonucu bu alt görüntü kenar sınıfı ise ilgili matris alanı(16x16 alan) 255 değerleri ile doldurulur. Bu şekilde giriş görüntüsü RGB olan bir görüntü segmentasyon sonucu 3 değerden oluşan bir görüntü olur. Şekil 4.4.'te yapılan işleme örnek bir görüntü verilmiştir.




Şekil 4.4. Segmentasyon sonucu oluşan görüntü.

**ADIM 3:** ADIM 2’de ESA\_Seg modeli kullanılarak yapılan segmentasyon sonucu çıkış görüntüsünde gürültülerin oluştuğu görülmektedir. Örneğin Şekil 4.4’te bakıldığında kenar olarak sınıflandırılması gereken bazı alt görüntüler arka plan veya follükül olarak sınıflandırılmıştır. Aynı şekilde follükül olarak sınıflandırılması gereken bazı alt görüntülerde arka plan veya kenar olarak sınıflandırılmıştır. Şekil 4.5’e bakıldığında, bu gürültü kaynağının düşük olasılıkla sınıflandırılan alt görüntülerden kaynaklandığı anlaşılmıştır. Buradaki düşük olasılıktan kasıt kullanıcı tarafından girilen sınır değerinin altında olan sınıflandırma işlemi için kullanılan terimdir. Örneğin sınır değeri 0.6 seçilirse, 0.6’dan küçük olasılıkla sınıflandırılan bütün alt görüntüler düşük olasılıklı olarak ifade edilir.

Şekil 4.5.b’de gösterilen 3 farklı renk gurubundaki kutular ESA\_Seg tarafından düşük olasılıkla değerlendirilen alt görüntüleri ifade etmektedir. Kenar sınıfına dahil edilen düşük olasılıklı alt görüntüler siyah renkle, follükül sınıfına dahil edilen düşük olasılıklı alt görüntüler kırmızı renkle ve arka plan sınıfına dahil edilen düşük olasılıklı alt görüntüler sarı renkle gösterilmiştir. Şekil 4.5.b ile Şekil 4.5. c’nin karşılaştırılması ile yapılan değerlendirmede, oluşan gürültülerin düşük olasılık değeri ile sınıflandırılan alt görüntüler olduğu anlaşılmıştır. Bu gibi alt görüntülere bulanık görüntüler denilmiştir. Örneğin Tablo 4.1’e bakıldığında 3 farklı alt görüntünün ESA\_Seg tarafından sınıflandırma değerleri verilmiştir. Alt görüntü 1’in en yüksek tahmin değeri 0.4917 ile arka plan ve Alt görüntü 2’nin en yüksek tahmin değeri 0.5376 ile follükül



olarak bulunmuştur. Bu yüzden Alt görüntü 1 ve Alt görüntü 2 bulanık görüntüler kategorisindedir. Alt görüntü 3'e bakıldığında ise en yüksek tahmin değeri 0.9115 ile arka plan olarak bulunmuştur. Bu görüntünün tahmin değeri yüksek olduğu için bu görüntü kesin görüntü kategorisindedir.



**Şekil 4.5.** Gürültü temizleme yöntemi. (a) Segmentasyon için tasarlanan ESA giriş görüntüsü, (b) Düşük olasılıkla elde edilen sınıfların gösterilmesi (Siyah: Kenar, Kırmızı:Folikül, Sarı: Arka plan), (c) tasarlanan ESA ile segmentasyonu yapılan görüntü.

**Tablo 4.1.** Segmentasyonda kullanılan CNN modelinin düşük ihtimal ve yüksek ihtimalle yapmış olduğu sınıflandırma örneği


ESA_Seg için giriş görüntüsü	ESA_Seg tarafından yapılan sınıflandırma sonucu			Durum
	Kenar	Folikül	Arka plan	
Alt görüntü 1	0.4426	0.0658	0.4917	Bulanık (Arka plan)
Alt görüntü 2	0.2492	0.5376	0.2132	Bulanık (Folikül)
Alt görüntü 3	0.0836	0.0049	0.9115	Kesin (Arka plan)

Bulanık görüntülerin tekrar değerlendirilmesi için 8 yönlü komşu görüntülerinin değerlerine bakılmaktadır. 8 komşu ve kendisiyle beraber 9 görüntüden en fazla değeri alan sınıf hangisi ise bulanık görüntü o sınıfa dâhil edilir. Böylelikle anlamsal olarak görüntü üzerindeki birbirine yakın alanlar aynı kategoriye konulmuş olup gürültü temizlenmiş olur. Örneğin Şekil 4.6'da 0.537 olasılık ile follikül olarak sınıflandırılmış bir alt görüntü olduğu düşünülün. Bulanık görüntü kategorisi için ise sınır değeri 0.7 olsun. Bu durumda bu alt görüntü bulanık görüntü kategorisine girmektedir. Bu alt görüntünün tekrar değerlendirilmesi için komşu sınıflarına bakılmalıdır. Komşu

sınıflarına bakıldığında 5 adet kenar, 2 adet follikül ve 1 adet arka plan sınıfı mevcut. Bu durumda bulanık olarak kategorize edilen alt görüntü kenar sınıfına dâhil edilir. Bu şekilde bütün bulanık görüntüler, komşu sınıflarına bakılarak yeniden değerlendirilir. Şekil 4.7’de gösterildiği gibi, yapılan bu değerlendirme sonucu gürültüsü temizlenmiş görüntü elde edilir.

Kenar	Kenar	Follikül		Kenar	Kenar	Follikül
Follikül	Follikül (0.537 olasılıkla bulanık kategoride)	Kenar	→	Follikül	Kenar	Kenar
Arka plan	Kenar	Kenar		Arka plan	Kenar	Kenar

**Şekil 4.6.** Bulanık kategorisindeki alt görüntülerin komşu sınıf değerlerine göre tekrar değerlendirilmesi ile segmentasyon sonrası oluşan gürültünün temizlenmesi



**Şekil 4.7.** Gürültü temizleme yöntemi ile oluşan çıkış görüntüsü

Gürültünün temizlenme işleminden sonra çıkış görüntüsünde oluşan görüntüde 255 ve 128 değerlerine sahip piksel değerleri 1 yapılarak ikili bir görüntü elde edilmektedir. Oluşan ikili görüntüde 1’ler nesneyi(follikülleri) 0’lar ise arka planı ifade etmektedir. Böylelikle nesnelerin(folliküllerin) sınırları belirlenmiş olur.


**ADIM 4:** Sınır bölgeleri belirlenen follikülleri görüntü üzerinden kırılır, sınıflandırma işlemi için daha önce eğitilen ESA\_Sınıf modeli ile sınıflandırılarak sayım işlemi gerçekleştirilir.

#### 4.4. Önerilen Yöntemin Parametre Optimizasyonu

Tez kapsamında geliştirilen yöntemin ayarlanması gereken parametreler temel olarak 2 gruba ayrılmıştır. Bunlardan ilki ESA modellerine ait parametrelerdir. ESA modellerine ait parametreler ise temel olarak 3 gruba ayrılır. Bunlar; tasarım parametreleri, model parametreleri ve hiperparametreler. Tasarım parametreleri, modelde kullanılacak giriş katmanı görüntü boyutu, evrişimsel, ortaklama ve tam bağlantılı katmanların sayısı ve bu katmanların diziliş sırası, optimizasyon için kullanılacak yöntem gibi değişkenleri ifade eder. Model parametreleri, evrişimsel veya ortaklama katmanlarındaki filtrelerin boyutu, filtrelerin sayısı, adım kayma değerleri, tam bağlantılı katmanların çıkış değerleri gibi değişkenleri ifade eder. Hiperparametreler ise kullanılan optimizasyon algoritmasının değişkenlerini ifade eder. örneğin öğrenme oranı, momentum değeri gibi. Bu değerlerin optimizasyonu bu tez kapsamı dışında tutulmuştur. Bu değişkenlerin optimizasyonu için literatürde farklı çalışmalar yapılmıştır (Bergstra ve Bengio, 2012; Cai ve ark., 2019; Cui ve Bai, 2019; Junior ve Yen, 2019; Yoo, 2019).


Diğer ikinci gruba ait parametreler ise tez kapsamında önerilen yöntemin test aşamasında ayarlanması gereken parametrelerdir. Yöntemin test başarısını etkileyen 3 temel parametre bulunmaktadır. Bu parametreler Adım Kayma Değeri (AKD), Komşu Sınıf Uzaklığı (KSU) ve Bulanık Sınır Değeri (BSD)'dir.

AKD, yöntemin test aşamasında, giriş görüntüsü üzerinden alınacak alt görüntülerin yatayda ve düşeyde ne kadarlık bir kayma değerine göre alınacağını ifade eder. Bu parametre aynı zamanda segmentasyonu yapılacak görüntüde kaç adet alt görüntünün alınacağını belirlemektedir. Şekil 4.8'de 512x512x3 boyutunda bir giriş görüntüsü bulunmaktadır. Bu görüntü için AKD değeri 32 seçildiğinde toplam 256 alt görüntü (Şekil 4.8.a), 22 seçildiğinde toplam 529 alt görüntü (Şekil 4.8.b) ve 18 seçildiğinde ise toplam 784 alt görüntü (Şekil 4.8.c) elde edilmektedir.



Şekil 4.8. Farklı AKD değerlerinde alınan alt görüntüler. (a) AKD=32, (b) AKD=22, (c) AKD=18.


BSD, yöntemin test aşamasında gürültü temizleme yönteminde bulanık görüntülerin sınır değerini ifade etmektedir. BSD değerinin altındaki olasılıkla sınıflandırılan görüntüler, bulanık görüntü kategorisine konulmakta ve bu görüntüler tekrar komşu sınıf değerlerine bakılarak sınıflandırılmaktadır. Şekil 4.9.a'ya bakıldığında ilk görüntüdeki BSD değeri 0.7 seçilmiştir. Bu değere göre tekrar değerlendirilecek alt görüntü sayısı 93'tür. Şekil 4.9.b'de BSD değeri 0.8 ve tekrar değerlendirilecek alt görüntü sayısı 143'tür. Şekil 4.9.c'de BSD değeri 0.85 ve tekrar değerlendirilecek alt görüntü sayısı 190'dır.



**Şekil 4.9.** Farklı BSD değerlerine göre tekrar değerlendirilecek alt görüntüler. (a) BSD =0.7, (b) BSD=0.8, (c) BSD =0.85.

KSU, belirlenen BSD değerine göre elde edilen her bir alt görüntünün değerlendirilmesi için ne kadar uzaklıktaki komşularına bakılması gerektiğini ifade eder. Örneğin KSU değeri 12 seçilirse, tekrar değerlendirilecek alt görüntünün 12 piksel uzaklığındaki 8 komşusunun sınıf değerlerine bakılır. Bu sınıf değerlerine göre bulanık görüntünün sınıf değeri yeniden belirlenir.

Bu 3 değişkenin birbiriyle olan ilişkisi Şekil 4.10'da verilmiştir. Şekil 4.10'a bakıldığında sol eksen değişkenlerin aralığını gösterilmektedir. BSD değeri 0.34-0.9 yerine 3-9 aralığına normalize edilerek grafikte gösterilmiştir. Sağ eksen ise hata değerini gösterir. 3 parametrenin değişimi sonucu elde edilen hata değeri 30 farklı deneme için yapılmıştır. Yöntemin segmentasyon hata değeri azalırken diğer parametrelerin birbiriyle doğrusal olmayan bir ilişkisi olduğu görülmektedir. Bu yüzden bu parametrelerin, optimizasyon yöntemiyle en optimum şekilde seçilmesi düşünülmüştür.



Şekil 4.10. AKD, BSD ve KSU değerlerinin segmentasyon hata değerine göre birbiriyle olan ilişkisi


Tez kapsamında geliştirilen yöntemde kullanılan AKD, KSU ve BSD parametrelerin en uygun değerleri için optimizasyon algoritması kullanılmıştır. Optimizasyon algoritmasının yönteme uygulanmasının akış şeması Şekil 4.11’de verilmiştir. Şekil 4.11’e bakıldığında öncelikle kullanılacak optimizasyon algoritmasının başlangıç değerleri belirlenir. Başlangıç değerlerine göre geçici AKD, KSU ve BSD değerleri oluşturulur. Belirlenen bu parametre değerlerine göre yöntem test görüntüleri üzerinde çalıştırılır. Yöntemin test görüntüler üzerinde segmentasyon hata değeri elde edilir. Elde edilen segmentasyon hatasına göre optimizasyon algoritması yeni AKD, KSU ve BSD değerleri önerir. Her bir iterasyonda en düşük segmentasyon hata değerini elde etmek için parametreler optimize edilir. Segmentasyon hatası Eşitlik 4.1’e göre hesaplanır.

$$Segmentasyon\ hatası = \left( 1 - \frac{1}{k} \sum_{i=1}^k \frac{1}{m} \sum_{j=1}^m (IoUs)_j \right) \quad (4.1)$$

Burada, m değeri görüntüdeki follikül sayısını ifade eder. k değeri ise toplam test görüntüsü sayısını ifade eder. IoUs (Intersection over Union), gerçek follikül sınırları ile tahmin edilen follikül sınırlarının kesiştiği piksel sayısının, toplam piksel sayısına olan oranını ifade eder ve Eşitlik 4.2’ye göre hesaplanır.

$$IoUs = \frac{TPs}{TPs + FPs + FNs} \quad (4.2)$$


Burada TPs tahmin edilen follükülün doğru sınıflandırılmış piksel sayısını. FPs, follükül olmayan piksellerin follükül olarak tahmin edilen piksel sayısını ifade eder. FNs ise yanlış olarak tahmin edilen follükül piksel sayısıdır.



**Şekil 4.11.** ESA tabanlı yöntemin AKD, KSU ve BSD değerlerinin optimizasyon algoritması ile optimize etmek için akış şeması.

#### 4.5. Önerilen Yöntem İçin Elde Edilen Veri Setleri

Yapılan çalışmada ovaryum dokusuna ait görüntüler deney hayvanlarından elde edilmiştir. Deney hayvanları için gerekli etik kurulu raporu Tokat Gaziosmanpaşa Üniversitesi Deney hayvanları merkezinden alınmıştır. Etik kurulu raporu Ek-1’de verilmiştir. Histolojik kesitlerin alınmasında takip edilen iş akışı Şekil 4.12.’de verilmiştir. Şekil 4.12’ye bakıldığında deney hayvanlarından ovaryum dokusu alınıp doku tespiti, kesit alma ve boyama işleminden sonra görüntü alma işlemine geçilmiştir. Kesitler 3 farklı boyama tekniği ile boyama işlemi yapılarak elde edilmiştir. Boyama çeşitleri sırasıyla Hematoksilen-Eozin (H&E), Masson’s Trikrom (MT) ve Anti Mülleriien Hormon (AMH) dir.




řekil 4.12. Ovaryum dokusuna ait grntlerin elde edilmesi iin akıř diyagramı.

Grnt alma iřlemi OLYMPUS BX51 marka ıřık mikroskobu ile gerekleřtirilmiřtir. Alınan grntlerin bytme oranları ařađıda verilmiřtir.


- 4'lk objektif x10 okler bytme (40)
- 10'lk objektif x10 okler bytme (100)
- 20'lik objektif x10 okler bytme (200)
- 40'lk objektif x10 okler bytme (400)
- 100'lk objektif x10 okler bytme (1000)

Yukarıda belirtilen bytme oranlarına gre eđitim iřlemleri iin 4080x3072x3 boyutunda toplam 1972 grnt ve test iřlemleri iin 887 grnt elde edilmiřtir. Eđitim iin elde edilen grntler bir sonraki blmde belirtilen veri arttırma yntemleri ile arttırılmıř olup toplam 10500 adet eđitim grnts elde edilmiřtir. Elde edilen grntlerin hepsi Matlab Image Labeler yazılımı ile 2 farklı yntemle etiketlenmiřtir. Birinci yntemde řekil 4.13'te gsterildiđi gibi follikller dikdrtgen bir ereveye alınacak řekilde etiketlenmiřtir. Bu etiketleme yntemi ile elde edilen veri seti Faster R-CNN modelinin eđitim ve test iřlemlerinde kullanılmıřtır. Bir diđer etiketleme yntemi ise řekil 4.14'te gsterilen piksel bazlı yapılan etiketlemedir. Bu etiketleme yntemi ile oluřturulan veri seti nerilen yntemdeki ESA modellerinin eđitim iřlemlerinde kullanılmıřtır.

ESA modellerinin eđitilmesi iin 10500 adet grnt zerinden elde edilen veri setleri ve adetleri Blm 4.5.2 ve Blm 4.5.3'te anlatılmıřtır.



**Şekil 4.13.** Faster R-CNN modelinde kullanılmak üzere dikdörtgen çerçeve şeklinde görüntülerin etiketlenmesi



**Şekil 4.14.** Önerilen yöntemde kullanılmak üzere piksel bazlı görüntülerin etiketlenmesi

#### 4.5.1. Veri artırma teknikleri

DÖ modellerinin eğitimi için büyük verilere ihtiyaç duyulmaktadır. Milyonlar seviyesinde bu büyük verilerin normal olarak toplanması çok zordur. İhtiyaç duyulan verilerin artırılması için veri artırma (Data Augmentation) yöntemleri kullanılmaktadır. Veri arttırmanın derin ağlar için gerekli verilerin arttırılmasının yanında ayrıca bu ağların performansı üzerinde olumlu yönde önemli etkisi vardır (Wang ve Perez; Wong ve ark., 2016; Xu ve ark., 2016). Ayrıca eğitim esnasında derin ağların ezberlemesini önlemek için var olan yöntemlere (Srivastava ve ark., 2014; Ma ve Klabjan, 2017; Wang ve Klabjan, 2017) ek olarak veri arttırma yöntemide kullanılmaktadır. Genel olarak döndürme (rotation), öteleme (translated), aynalama (reflection), yeniden ölçekleme (rescaling), histogram eşikleme (histogram equalization)




ve gürültü ekleme (adding noise) v.b. gibi veri artırma yöntemleri mevcuttur. Tez çalışmasında verilerin artırılması için döndürme, öteleme, aynalama ve parlaklık ayarlama yöntemleri uygulanmıştır.

**Döndürme(Rotation):** Bu işlemde, görüntü belli bir açıya göre döndürülmektedir. Mikroskop ile görüntü alma esnasında preparat sağa veya sola belli bir açıyla çevrilmiş bir şekilde konumlanabilir ve görüntü alma işlemi gerçekleştirilebilir. Bu yüzden Döndürme yönteminin kullanılması gerçek verilerin elde edilmesi gibi düşünülebilir. Yöntemin kullanımı örnek bir görüntü üzerinde gösterilmesi Şekil 4.15'te verilmiştir. Bu çalışmada 90 ve 270 derecelik açılarla döndürme işlemi gerçekleştirilmiştir.




Şekil 4.15. 90 ve 270 derecelik döndürme işlemleri ile veri artırma

**Öteleme(Translation):** Bu yöntemde orijinal görüntü x eksenini, y eksenini ve hem x hemde y ekseninde olmak üzere 3 farklı şekilde öteleme işlemi uygulanmaktadır. Öteleme işlemi sonucunda oluşan siyah piksellerin ESA mimarilerinde bir etki oluşturamadıkları söylenebilir. Çünkü sıfır rakamı ile doldurulan alanlar evrişim katmanında etkisiz eleman konumunda kalmaktadır. Öteleme işlemi döndürme işleminde olduğu gibi gerçek görüntü alma işleminde gerçekleşen durumlara benzerlik gösterdiği için kullanılmıştır. Dikey, yatay ve hem dikey hem yatay ekseninde 25 piksellik öteleme sonucunda oluşan görüntüler Şekil 4.16'da verilmiştir.




Şekil 4.16. Farklı eksenlerde öteleme işlemi ile veri artırma

**Aynalama(Flipping):** Bu yöntemde görüntü yataya göre, düşeye göre ve hem yatay hem de düşeye göre çevrilir. Aynı zamanda çevirme olarakta bilinir. Yöntemin orijinal bir görüntüye uygulanması Şekil 4.17’de gösterilmiştir.



**Şekil 4.17.** Farklı eksenlerde çevirme işlemi ile veri arttırma

**Parlaklık Ayarlama:** Bu yöntemde görüntü üzerinde aydınlatma ve karartma işlemleri yapılmaktadır. Gerçek görüntülerin elde edilmesinde ışık ayarına göre farklılıklar oluşabilmektedir. Bu yüzden bu yöntemin uygulanması gerçek görüntülere benzer görüntülerin elde edilmesi hedeflenmiştir. Orijinal bir görüntü üzerinde aydınlatma ve karartma işleminin uygulanması Şekil 4.18’de gösterilmiştir




**Şekil 4.18.** Görüntüde parlaklık ayarları ile veri arttırma işlemi

#### 4.5.2.Segmentasyon için elde edilen veri setleri

Önerilen yöntemde segmentasyon işlemindeki temel yaklaşım, bir bütün olarak verilen görüntünün daha küçük parçalara bölünüp bu parçaların ESA ile sınıflandırılmasına dayanmaktadır. Sınıflandırılan bu parçalar birleştirildiğinde bir bütün olan görüntünün segmentasyon işlemi gerçekleştirilmiş olur. Bu kapsamda giriş görüntüsü 3 farklı sınıftan oluşan alt görüntülere bölünmüştür. Bu sınıflar daha öncede

belirtildiği gibi nesne sınır bölgeleri, nesnenin kendisi ve arka plan görüntülerinden oluşmaktadır. Bu yapının ovaryum dokusuna ait bir görüntü üzerinde örnek gösterimi Şekil 4.19'da verilmiştir. Bölüm 4.5'te belirtildiği gibi görüntülerin orijinal boyutu 4080x3072x3'tir. Şekil 4.19.a'daki görüntüler orijinal boyuttan daha düşük boyutlara indirgenmiş görüntüleri temsil etmektedir. Şekil 4.19.b'de etiketlenmiş bu görüntüler üzerinde 16x16, 32x32, 64x64 gibi alt boyutlarda görüntüler elde edilerek segmentasyon için veri setleri oluşturulmuştur. Bu şekilde elde edilen veri setleri ile ilgili sayısal bilgiler Tablo 4.2'de verilmiştir.



**Şekil 4.19.** Yöntemin segmentasyon işlemi için kullanılacak veri setlerinin oluşturulması. (a) Etiketlenmiş orijinal görüntü boyutunun düşük boyutlara indirgenmiş veri seti, (b) boyutu indirgenen görüntüler üzerinden alt görüntülerin elde edilmesi ile oluşturulan veri seti


**Tablo 4.2.** Giriş görüntü boyutuna göre farklı alt boyutlarda alınan görüntülerden oluşturulan veri setleri

Giriş görüntü Boyutu	Kırılan Görüntü Boyutu	Sınıflar			Toplam
		Kenar	Follikül	Arka plan	
500x500x3	16x16	51308	162488	581872	795668
500x500x3	32x32	18536	19081	113358	150975
1024x1024x3	32x32	42722	323414	1357433	1723569
2048x2048x3	64x64	111720	314544	1168651	1594915
4080x3072x3	64x64	61540	268877	1411631	1742048

#### 4.5.3.Sınıflandırma için elde edilen veri setleri


Önerilen yöntemde sınıflandırma aşamasında veri setinde sınıflandırılması istenen nesnelere kırılarak bir veri seti oluşturulmaktadır. Bu tez kapsamında yöntem

ovaryum dokusuna ait görüntüler üzerinde test edildiği için ovaryuma ait follüküller ayrı ayrı kırılarak yeni bir veri seti oluşturulmuştur. Bölüm 3.3'te bahsedildiği gibi ovaryum dokusuna ait 5 farklı follükül olduğu için sınıf değeri ilk etapta 5 olarak seçilmiştir. Fakat veri seti incelendiğinde görüntüler üzerinde bazı yapıların bu sınıflara ait olduğu fakat tam olarak hangi sınıfta olduğu bilinmediği için "Belirsiz" adında yeni bir sınıf daha tanımlanmıştır. Örneğin Şekil 4.20'ye bakıldığında bir adet sekonder follükülü rahatlıkla tanımlanabilmektedir. Fakat diğer follükülün tam olarak ne olduğu bilinmediği için belirsiz olarak etiketlenmiştir. Bu belirsiz olarak etiketlenen follüküller dokulardan kesit alma esnasında kesim yönü ve kalınlığı ile ilgili oluşan yapılardır.



Şekil 4.20. Ovaryum dokusuna ait veri setinde "Belirsiz" olarak etiketlenen follükül.

Sınıflandırma için Şekil 4.21'de gösterildiği gibi daha önce etiketlenen görüntülerden follüküller kırılarak veri setleri oluşturulmuştur. Oluşturulan veri setleri ile ilgili sayısal bilgiler Tablo 4.3'te verilmiştir.



**Şekil 4.21.** Yöntemde sınıflandırma işlemi için kullanılacak veri setinin oluşturulması. (a) Etiketlenmiş orijinal görüntü boyutunun düşük boyutlara indirgenmiş veri seti, (b) folliküllerin kırılarak 6 sınıftan oluşan veri setinin oluşturulması.

**Tablo 4.3.** Sınıflandırma için oluşturulan veri setleri

Veri Seti Kategorisi	Sınıflar						Toplam
	Primordial	Primer	Preantral	Sekonder	Tersiyer	Belirsiz	
32x32x3_1	6555	12920	24789	33903	3849	10738	92754
48x48x3_1	1311	2584	4958	6781	770	2148	18552
64x64x3	18282	36289	74349	101541	10773	59290	300524
32x32x3_2	18282	36289	74349	101541	10773	59290	300524
48x48x3_2	18282	36289	74349	101541	10773	59290	300524

## 5. DENEYSEL ÇALIŞMALAR

Bu bölümde, önerilen yöntemin deneysel çalışmaları hakkında bilgiler verilmiştir. İlk olarak, deneysel çalışmalarda kullanılan performans ölçütleri için gerekli bilgiler sunulmuştur. Daha sonra, yöntemde segmentasyon işlemi için tasarlanan ESA modellerinin tasarım özellikleri ve eğitim/test sonuçları ile ilgili bilgiler verilmiştir. Devamında, yöntemde sınıflandırma işlemi için kullanılan ESA modelinin özellikleri ve eğitim/test sonuçları hakkında bilgiler verilmiştir. Bir sonraki başlıkta, önerilen yöntemin parametre optimizasyonu için yapılan çalışmaların sonuçları verilmiştir. Son aşamada ise önerilen yöntemin elde ettiği test sonuçları ile diğer yöntemlerin elde ettiği sonuçlar sunulmuştur.

Tez kapsamında yapılan deneysel çalışmalar, Intel® Core™ i9-7900X CPU @ 3.30GHz×20 işlemci, 64 GB Ram ve 2 x GeForce RTX2080Ti ekran kartına sahip bir bilgisayarda yapılmıştır. Yazılım platformu olarak Matlab R2019a 64bit(win64) kullanılmıştır.

### 5.1. Performans Ölçütleri

Makine öğrenmesi yöntemlerinde sınıflandırma başarısının ölçülmesi için sınıflandırma matrisi (confusion matrix) kullanılır. İkili sınıflandırma sonucunda kullanılan sınıflandırma matrisi Şekil 5.1’de verilmiştir.

		GERÇEK	
		Pozitif	Negatif
TAHMİN	Pozitif	Doğru Pozitif (TP)	Yanlış Pozitif (FP)
	Negatif	Yanlış Negatif (FN)	Doğru Negatif (TN)

Şekil 5.1. ikili sınıflandırma için sınıflandırma matrisi

Şekil 5.1’deki matrise göre Doğruluk, Hassaslık, Duyarlılık ve F-Ölçüsü ölçütleri hesaplanmaktadır. Bu performans ölçütlerinin doğru anlaşılması için ESA tarafından yapılan sınıflandırmada görüntünün nesne veya arka plan durumu düşünülerek aşağıdaki tanımlamalar yapılmıştır.

TP: ESA tarafından, nesne olan görüntülere nesne olarak etiketleme sayısı

FP: ESA tarafından, arka plan olan görüntülere nesne olarak etiketleme sayısı

FN: ESA tarafından, nesne olan görüntülere arka plan olarak etiketleme sayısı

TN: ESA tarafından, arka plan olan görüntüye arka plan olarak etiketleme sayısı

**Doğruluk(Accuracy):** Sınıflandırmada yapılan doğru tahminlerin bütün tahminlere olan oranını ifade eder ve Eşitlik 5.1'deki gibi hesaplanır. Yani nesne ve arka plan olarak tahmin edilen görüntülerin sayısının bütün görüntülere oranını ifade eder.

$$\text{Doğruluk} = \frac{TP + TN}{TP + FP + FN + TN} \quad (5.1)$$

**Hassaslık(Precision):** Bu metrikteki amaç ESA'nın gerçekten pozitif durumları doğru tahmin etmedeki başarısını ölçmektir. Yani ESA'nın doğru olarak sınıflandırdığı nesnelerin ne kadar doğru olduğunu ölçer. Bir diğer ifadeyle pozitiflik durumun doğruluk hassaslığını ifade eder. Bu değer ne kadar yüksekse ESA modelinin başarısı o nispette yüksektir denilebilir. Hassaslık değeri Eşitlik 5.2'ye göre hesaplanmaktadır.

$$\text{Hassaslık} = \frac{TP}{TP + FP} \quad (5.2)$$

**Duyarlılık(Recall):** Sınıflandırmada pozitif veya negatif olan sınıflardan ne kadarının doğru olarak tahmin edildiğini ifade eder ve Eşitlik 5.3'teki gibi hesaplanır. Yani ESA'nın gerçekte nesne olan görüntülerin ne kadarını doğru tahmin ettiğini ifade eder. Daha açık bir ifadeyle doğru tahmin edilen nesne sayısının gerçekteki nesne sayısına oranıdır.

$$\text{Duyarlılık} = \frac{TP}{TP + FN} \quad (5.3)$$

**F-ölçüsü (F-measure):** Duyarlılık veya Hassaslık ölçütlerinin harmonik ortalamasını ifade eder ve Eşitlik 5.4'teki gibi hesaplanır.


$$F - \text{Ölçüsü} = \frac{2 * \text{Duyarlılık} * \text{Hassaslık}}{\text{Duyarlılık} + \text{Hassaslık}} \quad (5.4)$$

## 5.2. Segmentasyon İçin Oluşturulan ESA Modelinin Eğitim ve Test Sonuçları

Segmentasyon için kullanılan 43 farklı ESA modeli 3 grup halinde tasarlanıp eğitilmiştir. Bu gruplar, sırasıyla 500x500x3, 1024x1024x3 ve 2048x2048x3 olmak üzere test görüntü boyutuna göre kategorize edilmiştir. Eğitim aşamasında bütün gruplar için kullanılan veri setlerindeki (Bakınız Bölüm 4.5.2) görüntülerin %80'ni eğitim, %10'u doğrulama ve kalan %10'u ise test için kullanılmıştır. Eğitim, doğrulama ve test görüntülerin seçilmesi tamamen rastgele yapılmıştır.

Bölüm 3.3'te belirtildiği üzere, veri setinde orijinal görüntü boyutları 4080x3072x3'tür. Bu boyuttaki görüntüler üzerinde çalışmak hem donanımsal kaynak hem de zaman açısından dezavantaj oluşturduğu için daha düşük boyuttaki görüntüler üzerinde çalışmaların yapılması planlanmıştır. Bu yüzden ilk etapta en düşük boyut olarak 500x500x3 seçilmiştir. Daha sonra 1024x1024 ve son olarak 2048x2048 boyutlarında çalışmalar yapılmıştır. Yapılan çalışmalar sonucunda test doğruluğu ve zaman açısından en ideal görüntü çözünürlüğün 1024x1024x3 olduğu anlaşılmıştır.

**Birinci grup(500x500x3):** İlk olarak 500x500x3 görüntü boyutunda toplam 17 farklı ESA modeli tasarlanmıştır. Bu ESA modellerinin arasında en yüksek test doğruluğuna sahip modelin mimarisi Şekil 5.2'de verilmiştir. Model tasarımındaki katmanlar ve katmanlarda kullanılan parametre değerleri Tablo 5.1'de verilmiştir. Model eğitiminde kullanılan optimizasyon algoritmasına ait hiperparametreler Tablo 5.2'de verilmiştir. Modelin eğitim aşamasında devir sayısına göre elde ettiği doğruluk grafiği Şekil 5.3'te verilmiştir. Aynı şekilde modelin devir sayısına göre kayıp değeri Şekil 5.4'te verilmiştir.



**Şekil 5.2.** Test görüntü boyutu 500x500x3 olan kategori için tasarlanan 17 farklı model içinde en yüksek doğrulukta çalışan ESA modelinin mimarisi

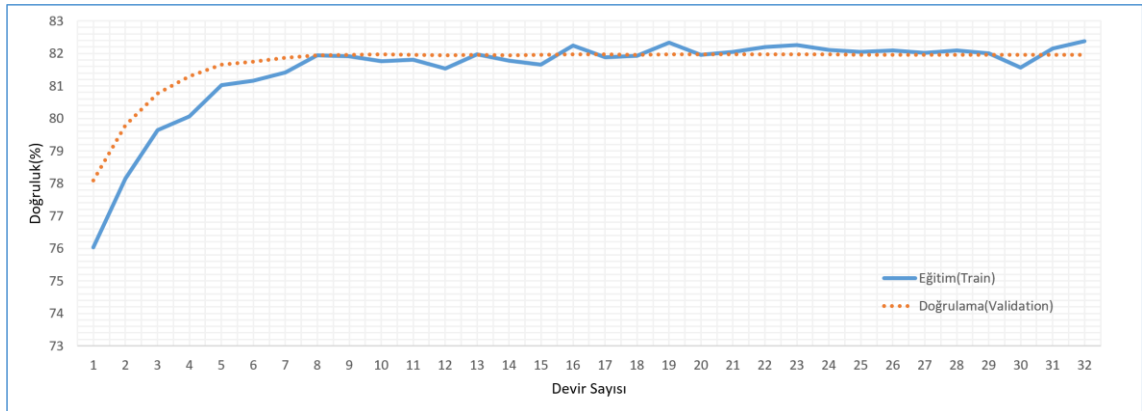


**Tablo 5.1.** Test görüntü boyutu 500x500x3 olan kategori için tasarlanan 17 farklı model içinde en yüksek doğrulukta çalışan ESA modelinin tasarım özellikleri


Katman Sayısı	Katman Adı	Katman Özellikleri		
1	Giriş Katmanı	Boyut: 16x16x3		
2	Evrişim Katmanı 1 (EK-1)	Filtre Sayısı: 128	Filtre Boyutu: 3x3	Adım Kayma Sayısı: 1x1
3	ReLU	-		
4	Normalizasyon Katmanı	-		
5	Evrişim Katmanı 2 (EK-2)	Filtre Sayısı: 128	Filtre Boyutu: 3x3	Adım Kayma Sayısı: 1x1
6	ReLU	-		
7	Normalizasyon Katmanı	-		
8	Ortaklama Katmanı 1 (OK-1)	Maksimum ortalama	Filtre Boyutu: 2x2	Adım Kayma Sayısı: 2x2
9	Tam Bağlantılı Katman 1 (TBK-1)	Çıkış kanal sayısı: 512		
10	ReLU	-		
11	Düğüm Seyreltme Katmanı	Seyreltme olasılığı: 0.5		
12	Tam Bağlantılı Katman 2 (TBK-2)	Çıkış kanal sayısı: 3		
13	Sınıflandırma Katmanı	Sınıf Sayısı: 3		

**Tablo 5.2.** Test görüntü boyutu 500x500x3 olan kategori için tasarlanan 17 farklı model içinde en yüksek doğrulukta çalışan ESA modelinin hiperparametre değerleri

Hiperparametre	Değer
Başlangıç öğrenme oranı	0.001
Öğrenme oranı düşürme periyodu	0.2
Öğrenme oranı düşürme periyodu oranı	8
Devir Sayısı	32
Bir devirde kullanılacak görüntü sayısı (Mini Batch Size)	1024
Optimizasyon algoritması	SGDM
Momentum	0.9



**Şekil 5.3.** Test görüntü boyutu 500x500x3 olan kategori için tasarlanan 17 farklı model içinde en yüksek doğrulukta çalışan ESA modelinin eğitim esnasındaki başarı ve doğrulama grafiği



**Şekil 5.4.** Test görüntü boyutu 500x500x3 olan kategori için en yüksek doğrulukta çalışan ESA modelinin eğitim esnasındaki eğitim ve doğrulama hatası grafiği

Modelin elde ettiği sınıflandırma matrisi Tablo 5.3'te verilmiştir. Bu kategorideki modelin doğruluk başarıları %82.9 olarak elde edilmiştir. Modelin her bir sınıf için elde ettiği performans değerleri Tablo 5.4'te verilmiştir.

**Tablo 5.3.** Test görüntü boyutu 500x500x3 olan kategori için tasarlanan 17 farklı model içinde en yüksek doğrulukta çalışan ESA modelinin elde ettiği sınıflandırma matrisi


	GERÇEK		
	Arka Plan	Follikül	Kenar
Arka Plan	139150	18508	7645
TAHMİN Follikül	2410	13618	3035
Kenar	8	6	85

**Tablo 5.4.** Test görüntü boyutu 500x500x3 olan kategori için tasarlanan 17 farklı model içinde en yüksek doğrulukta çalışan ESA modelinin her bir sınıf için elde ettiği performans değerleri(%)

Sınıf	Hassaslık	Duyarlılık	F-Ölçüsü
Arka Plan	84.18	98.29	90.69
Follikül	71.44	42.38	53.20
Kenar	85.86	0.79	1.56

**İkinci grup(1024x1024x3):** Bu kategoride toplam 14 farklı ESA modeli tasarlanmıştır. Bu modeller arasında doğruluğu en yüksek modelin mimarisi Şekil 5.5'te verilmiştir. Şekil 5.5'te verilen modelin katmanlarında kullanılan parametre değerleri Tablo 5.5'te

verilmiştir. Modelin eğitimi için kullanılan hiperparametreler Tablo 5.6’da verilmiştir. Yapılan eğitim işlemi modelin elde ettiği doğruluk grafiği Şekil 5.6’da ve hata grafiği Şekil 5.7’de verilmiştir.




**Şekil 5.5.** Test görüntü boyutu 1024x1024x3 olan kategori için tasarlanan 14 farklı model içinde en yüksek doğrulukta çalışan ESA modelinin mimarisi

**Tablo 5.5.** Test görüntü boyutu 1024x1024x3 olan kategori için tasarlanan 14 farklı model içinde en yüksek doğrulukta çalışan ESA modelinin tasarım özellikleri


Katman Sayısı	Katman Adı	Katman Özellikleri		
1	Giriş Katmanı		Boyut: 16x16x3	
2	Evrişim Katmanı 1 (EK-1)	Filtre Sayısı: 128	Filtre Boyutu: 3x3	Adım Kayma Sayısı: 1x1
3	ReLU		-	
4	Normalizasyon Katmanı		-	
5	Evrişim Katmanı 2 (EK-2)	Filtre Sayısı: 128	Filtre Boyutu: 3x3	Adım Kayma Sayısı: 1x1
6	ReLU		-	
7	Normalizasyon Katmanı		-	
8	Evrişim Katmanı 3 (EK-3)	Filtre Sayısı: 128	Filtre Boyutu: 3x3	Adım Kayma Sayısı: 1x1
9	ReLU		-	
10	Normalizasyon Katmanı		-	
11	Ortaklama Katmanı 1 (OK-1)	Maksimum ortaklama	Filtre Boyutu: 2x2	Adım Kayma Sayısı: 2x2
12	Evrişim Katmanı 4 (EK-4)	Filtre Sayısı: 256	Filtre Boyutu: 3x3	Adım Kayma Sayısı: 1x1
13	ReLU		-	
14	Normalizasyon Katmanı		-	
15	Evrişim Katmanı 5 (EK-5)	Filtre Sayısı: 256	Filtre Boyutu: 3x3	Adım Kayma Sayısı: 1x1
16	ReLU		-	
17	Normalizasyon Katmanı		-	
18	Evrişim Katmanı 6 (EK-6)	Filtre Sayısı: 256	Filtre Boyutu: 3x3	Adım Kayma Sayısı: 1x1
19	ReLU		-	
20	Normalizasyon Katmanı		-	
21	Tam Bağlantılı Katman 1 (TBK-1)		Çıkış kanal sayısı: 512	
22	ReLU		-	
23	Düğüm Seyreltme Katmanı		Seyreltme olasılığı: 0.5	
24	Tam Bağlantılı Katman 2 (TBK-2)		Çıkış kanal sayısı: 512	
25	ReLU		-	
26	Düğüm Seyreltme Katmanı		Seyreltme olasılığı: 0.5	
27	Tam Bağlantılı Katman 3 (TBK-3)		Çıkış kanal sayısı: 3	
28	Sınıflandırma Katmanı		Sınıf Sayısı: 3	

**Tablo 5.6.** Test görüntü boyutu 1024x1024x3 olan kategori için tasarlanan 14 farklı model içinde en yüksek doğrulukta çalışan ESA modelinin hiperparametre değerleri

Hiperparametre	Değer
Başlangıç öğrenme oranı	0.001
Öğrenme oranı düşürme periyodu	0.2
Öğrenme oranı düşürme periyodu oranı	8
Devir Sayısı	32
Bir devirde kullanılacak görüntü sayısı (Mini Batch Size)	256
Optimizasyon algoritması	SGDM
Momentum	0.9



**Şekil 5.6.** Test görüntü boyutu 1024x1024x3 olan kategori için tasarlanan 14 farklı model içinde en yüksek doğrulukta çalışan ESA modelinin eğitim esnasındaki eğitim ve doğrulama grafiği



**Şekil 5.7.** Test görüntü boyutu 1024x1024x3 olan kategori için tasarlanan 14 farklı model içinde en yüksek doğrulukta çalışan ESA modelinin eğitim esnasındaki eğitim ve doğrulama hatası grafiği

Modelin test aşamasında elde ettiği sınıflandırma matrisi Tablo 5.7'de verilmiştir. Modelin sınıflandırma doğruluğu %87.1 olarak elde edilmiştir. Her bir sınıf için elde edilen performans değerleri Tablo 5.8'da verilmiştir.


**Tablo 5.7.** Test görüntü boyutu 1024x1024x3 olan kategori için tasarlanan 14 farklı model içinde en yüksek doğrulukta çalışan ESA modelinin elde ettiği sınıflandırma matrisi

	GERÇEK			
	Arka Plan	Follikül	Kenar	
TAHMİN	Arka Plan	139080	11082	6285
	Follikül	2896	20155	3171
	Kenar	193	248	1336

**Tablo 5.8.** Test görüntü boyutu 1024x1024x3 olan kategori için tasarlanan 14 farklı model içinde en yüksek doğrulukta çalışan ESA modelinin elde ettiği performans ölçütleri

Sınıf	Hassaslık	Duyarlılık	F-Ölçüsü
Arka Plan	88.90	97.83	93.15
Follikül	76.86	64.01	69.85
Kenar	75.18	12.38	21.26

**Üçüncü grup (2048x2048x3):** Bu kategoride toplam 12 farklı ESA modeli tasarlanmıştır. Bu modeller arasında doğruluğu en yüksek modelin mimarisi Şekil 5.8’de verilmiştir. Şekil 5.8’de verilen modelin katmanlarında kullanılan parametre değerleri Tablo 5.9’da verilmiştir. Modelin eğitimi için kullanılan hiperparametreler Tablo 5.10’da verilmiştir. Yapılan eğitim işleminde modelin elde ettiği doğruluk grafiği Şekil 5.9’da ve hata grafiği Şekil 5.10’da verilmiştir.




**Şekil 5.8.** Test görüntü boyutu 2048x2048x3 olan kategori için tasarlanan 12 farklı model içinde en yüksek doğrulukta çalışan ESA modelinin mimarisi

**Tablo 5.9.** Test görüntü boyutu 20048x2048x3 olan kategori için tasarlanan 12 farklı model içinde en yüksek doğrulukta çalışan ESA modelinin tasarım özellikleri


Katman Sayısı	Katman Adı	Katman Özellikleri		
1	Giriş Katmanı	Boyut: 64x64x3		
2	Evrişim Katmanı 1 (EK-1)	Filtre Sayısı: 64	Filtre Boyutu: 3x3	Adım Kayma Sayısı: 1x1
3	ReLU	-	-	-
4	Normalizasyon Katmanı	-	-	-
5	Evrişim Katmanı 2 (EK-2)	Filtre Sayısı: 64	Filtre Boyutu: 3x3	Adım Kayma Sayısı: 1x1
6	ReLU	-	-	-
7	Normalizasyon Katmanı	-	-	-
8	Ortaklama Katmanı 1(OK-1)	Maksimum Ortaklama	Adım Kayma Sayısı: 2x2	Ortaklama Katmanı 1(OK-1)
9	Evrişim Katmanı 3 (EK-3)	Filtre Sayısı: 128	Filtre Boyutu: 3x3	Adım Kayma Sayısı: 1x1
10	ReLU	-	-	-
11	Normalizasyon Katmanı	-	-	-
12	Evrişim Katmanı 4 (EK-4)	Filtre Sayısı: 128	Filtre Boyutu: 3x3	Adım Kayma Sayısı: 1x1
13	ReLU	-	-	-
14	Normalizasyon Katmanı	-	-	-
15	Ortaklama Katmanı 2(OK-2)	Maksimum Ortaklama	Adım Kayma Sayısı: 2x2	Ortaklama Katmanı 1(OK-1)
16	Evrişim Katmanı 5 (EK-5)	Filtre Sayısı: 128	Filtre Boyutu: 3x3	Adım Kayma Sayısı: 1x1
17	ReLU	-	-	-
18	Normalizasyon Katmanı	-	-	-
19	Evrişim Katmanı 6 (EK-6)	Filtre Sayısı: 128	Filtre Boyutu: 3x3	Adım Kayma Sayısı: 1x1
20	ReLU	-	-	-
21	Normalizasyon Katmanı	-	-	-
21	Tam Bağlantılı Katman 1(TBK-1)	-	Çıkış kanal sayısı:512	-
22	ReLU	-	-	-
23	Düğüm Seyreltme Katmanı	-	Seyreltme olasılığı: 0.5	-
24	Tam Bağlantılı Katman 2(TBK-2)	-	Çıkış kanal sayısı:512	-
25	ReLU	-	-	-
26	Düğüm Seyreltme Katmanı	-	Seyreltme olasılığı: 0.5	-
27	Tam Bağlantılı Katman 3(TBK-3)	-	Çıkış kanal sayısı:3	-
28	Sınıflandırma Katmanı	-	Sınıf Sayısı:3	-

**Tablo 5.10.** Test görüntü boyutu 2048x2048x3 olan kategori için tasarlanan 12 farklı model içinde en yüksek doğrulukta çalışan ESA modelinin hiperparametre değerleri

Hiperparametre	Değer
Başlangıç öğrenme oranı	0.001
Öğrenme oranı düşürme periyodu	0.2
Öğrenme oranı düşürme periyodu oranı	8
Devir Sayısı	32
Bir devirde kullanılacak görüntü sayısı (Mini Batch Size)	512
Optimizasyon algoritması	SGDM
Momentum	0.9



Şekil 5.9. Test görüntü boyutu 2048x2048x3 olan kategori için tasarlanan 12 farklı model içinde en yüksek doğrulukta çalışan ESA modelinin eğitim esnasındaki eğitim ve doğrulama grafiği



Şekil 5.10. Test görüntü boyutu 2048x2048x3 olan kategori için tasarlanan 12 farklı model içinde en yüksek doğrulukta çalışan ESA modelinin eğitim esnasındaki eğitim ve doğrulama hatası grafiği

Modelin test aşamasında elde ettiği sınıflandırma matrisi Tablo 5.11’de verilmiştir. Modelin sınıflandırma doğruluğu %85.9 olarak elde edilmiştir. Her bir sınıf için elde edilen performans değerleri Tablo 5.12’de verilmiştir.

Tablo 5.11. Test görüntü boyutu 2048x2048x3 olan kategori için tasarlanan 12 farklı model içinde en yüksek doğrulukta çalışan ESA modelinin elde ettiği sınıflandırma matrisi

		GERÇEK		
		Arka Plan	Follikül	Kenar
TAHMİN	Arka Plan	139939	12244	6691
	Follikül	2874	18441	4060
	Kenar	37	16	80

Tablo 5.12. Test görüntü boyutu 2048x2048x3 olan kategori için tasarlanan 12 farklı model içinde en yüksek doğrulukta çalışan ESA modelinin elde ettiği sınıflandırma matrisi

Sınıf	Hassaslık	Duyarlılık	F-Ölçüsü
Arka Plan	88.08	97.96	92.76
Follikül	72.67	60.07	65.77
Kenar	60.15	0.74	1.46

Segmentasyon için 3 farklı kategoride eğitilen farklı ESA modellerinin performans değerlerinin karşılaştırılması Şekil 5.11’de verilmiştir. Şekil 5.11’e bakıldığında 500x500x3, 1024x1024x3 ve 2048x2048x3 kategorilerindeki modellerin doğruluk, ortalama hassaslık, ortalama duyarlılık ve ortalama F-ölçüsü değerleri verilmiştir. Turuncu rengi(ikinci kolon) ile gösterilen 1024x1024x3 kategorisinde eğitilen ESA modelinin doğruluk duyarlılık ve F-ölçüsünde diğer diğer kategorilerdeki modellerden daha üstün performans gösterdiği görülmüştür. Bu sebeple segmentasyon için kullanılacak ESA modelinin 1024x1024x3 kategorisindeki modelin olmasına karar verilmiştir.




Şekil 5.11. Üç farklı kategoride eğitilen ESA modellerinin performans değerlerinin karşılaştırılması

### 5.3. Sınıflandırma İçin Oluşturulan ESA Modelinin Eğitim ve Test Sonuçları

Önerilen yöntemde, segmentasyon sonucu sınır değerleri bulunan nesnelere sınıflandırılması için toplam 12 farklı ESA modeli tasarlanmıştır. Bu modellerin eğitimi için hazırlanan veri setlerindeki(Bakınız Bölüm 4.5.3) görüntülerin %90’ını eğitim, %10’nu doğrulama ve kalan %10’u ise test için kullanılmıştır. Eğitim, doğrulama ve test işlemi için kullanılan görüntüler rastgele seçilmiştir. Bu modeller arasında en yüksek doğruluk oranında çalışan modelin(ESA\_Sınıf) tasarımı Şekil 5.12’de verilmiştir. ESA\_Sınıf modeli toplam 36 katmandan oluşmaktadır. Modelin eğitimi için



kullanılan hiperparametreler Tablo 5.13’de verilmiştir. Modelin katmanlarında kullanılan parametre bilgileri Tablo 5.14’te verilmiştir. ESA\_Sınıf modelinin eğitim esnasında elde ettiği eğitim ve doğrulama grafikleri Şekil 5.13’te verilmiştir. Aynı şekilde eğitim esnasında eğitim hatası ve doğrulama hatası grafikleri Şekil 5.14’te verilmiştir. ESA\_Sınıf modelinin eğitimi yaklaşık 10 saat sürmüştür.




Şekil 5.12. Sınıflandırma için tasarlanan ESA\_Sınıf modelinin mimarisi

Tablo 5.13. Sınıflandırma için tasarlanan ESA\_Sınıf modelinin hiperparametre değerleri

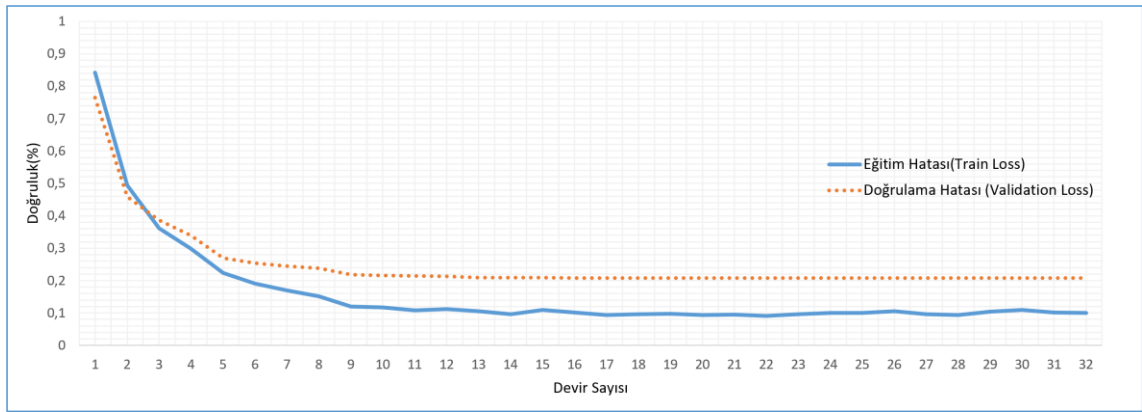
Hiperparametre	Değer
Başlangıç öğrenme oranı	0.001
Öğrenme oranı düşürme periyodu	0.2
Öğrenme oranı düşürme periyodu oranı	8
Devir Sayısı	32
Bir devirde kullanılacak görüntü sayısı (Mini Batch Size)	64
Optimizasyon algoritması	SGDM
Momentum	0.9

**Tablo 5.14.** Sınıflandırma için tasarlanan ESA\_Sınıf modelinin tasarım özellikleri

Katman Sayısı	Katman Adı	Katman Özellikleri		
1	Giriş Katmanı		Boyut: 64x64x3	
2	Evrişim Katmanı 1 (EK-1)	Filtre Sayısı: 256	Filtre Boyutu: 3x3	Adım Kayma Sayısı: 1x1
3	ReLU		-	
4	Normalizasyon Katmanı		-	
5	Evrişim Katmanı 2 (EK-2)	Filtre Sayısı: 256	Filtre Boyutu: 3x3	Adım Kayma Sayısı: 1x1
6	ReLU		-	
7	Normalizasyon Katmanı		-	
8	Ortaklama Katmanı 1(OK-1)	Maksimum Ortaklama	Filtre Boyutu: 2x2	Adım Kayma Sayısı: 2x2
9				
10	Evrişim Katmanı 3 (EK-3)	Filtre Sayısı: 256	Filtre Boyutu: 3x3	Adım Kayma Sayısı: 1x1
11	ReLU		-	
12	Normalizasyon Katmanı		-	
13	Evrişim Katmanı 4 (EK-4)	Filtre Sayısı: 256	Filtre Boyutu: 3x3	Adım Kayma Sayısı: 1x1
14	ReLU		-	
15	Normalizasyon Katmanı		-	
16	Evrişim Katmanı 5 (EK-5)	Filtre Sayısı: 256	Filtre Boyutu: 3x3	Adım Kayma Sayısı: 1x1
17	ReLU		-	
18	Normalizasyon Katmanı		-	
19	Evrişim Katmanı 6 (EK-6)	Filtre Sayısı: 256	Filtre Boyutu: 3x3	Adım Kayma Sayısı: 1x1
20	ReLU		-	
21	Normalizasyon Katmanı		-	
22	Ortaklama Katmanı 1(OK-2)	Maksimum Ortaklama	Filtre Boyutu: 2x2	Adım Kayma Sayısı: 2x2
23	Evrişim Katmanı 7 (EK-7)	Filtre Sayısı: 512	Filtre Boyutu: 3x3	Adım Kayma Sayısı: 1x1
24	ReLU		-	
25	Normalizasyon Katmanı		-	
26	Evrişim Katmanı 8 (EK-8)	Filtre Sayısı: 512	Filtre Boyutu: 3x3	Adım Kayma Sayısı: 1x1
27	ReLU		-	
28	Normalizasyon Katmanı		-	
29	Tam Bağlantılı Katman 1(TBK-1)		Çıkış kanal sayısı:1024	
30	ReLU		-	
31	Düğüm Seyreltme Katmanı		Seyreltme olasılığı: 0.5	
32	Tam Bağlantılı Katman 2(TBK-2)		Çıkış kanal sayısı:1024	
33	ReLU		-	
34	Düğüm Seyreltme Katmanı		Seyreltme olasılığı: 0.5	
35	Tam Bağlantılı Katman 3(TBK-3)		Çıkış kanal sayısı:6	
36	Sınıflandırma Katmanı		Sınıf Sayısı:3	



Şekil 5.13. Sınıflandırma için tasarlanan ESA\_Sınıf modelinin eğitim esnasındaki eğitim ve doğrulama grafiği



Şekil 5.14. Sınıflandırma için tasarlanan ESA\_Sınıf modelinin eğitim esnasındaki eğitim ve doğrulama hatası grafiği

ESA\_Sınıf modelinin eğitim sonucunda elde ettiği sınıflandırma matrisi Tablo 5.15'te verilmiştir. Modelin sınıflandırma doğruluk oranı %95.96 olarak elde edilmiştir. Modelin her bir sınıf için elde ettiği performans değerleri Tablo 5.16'da verilmiştir.

Tablo 5.15. Sınıflandırma için tasarlanan ESA\_Sınıf modelinin test verileri üzerinde elde ettiği sınıflandırma matrisi

		GERÇEK					
		Primordial	Primer	Preantral	Sekonder	Tersiyer	Belirsiz
TAHMİN	Primordial	1749	120	1	3	0	0
	Primer	65	3436	75	1	0	11
	Preantral	3	54	6958	190	0	39
	Sekonder	11	0	281	9822	36	28
	Tersiyer	0	0	0	104	1032	11
	Belirsiz	0	19	120	34	9	5840

**Tablo 5.16.** Sınıflandırma için tasarlanan ESA\_Sınıf modelinin test verileri üzerinde elde ettiği performans değerleri(%)

Sınıf	Hassaslık	Duyarlılık	F-Ölçüsü
Primordial	93.38	95.68	94.51
Primer	95.76	94.68	95.22
Preantral	96.05	93.58	94.80
Sekonder	96.50	96.73	96.62
Tersiyer	89.97	95.82	92.81
Belirsiz	96.98	98.50	97.73

Tablo 5.16'daki sınıfların hassaslık değerlerine bakıldığında, primordial %93.38, primer %95.76, preantral %96.05, sekonder %96.50, tersiyer %89.97 ve belirsiz %96.98 olarak hesaplanmıştır. Diğer taraftan sınıfların duyarlılık değerlerine bakıldığında primordial %95.68, primer %94.68, preantral %93.58, sekonder %96.73, tersiyer %95.82 ve belirsiz %98.50 olduğu görülmektedir.

Bölüm 4'te problemin zorluğundan bahsedilirken, folliküllerin birbirine dönüşümü ile oluştuğu ve dönüşüm esnasında ara formlardaki ilgili folliküllerin hangi sınıfa dâhil edilmesi gerektiğini belirlemenin zor olduğu belirtilmiştir. Tablo 5.15'teki sınıflandırma matrisine bakıldığında bu zorluk görülmektedir. Çünkü en fazla birbirine karıştırılan sınıfların birbirine dönüşüm sırasında olan folliküllerin olduğu sınıflar olarak tespit edilmiştir. Örneğin, ilk olarak primordial follikülü akabinde primer follikülü oluşur. Sınıflandırma matrisine bakıldığında primordial en fazla primer follikülü ile karıştırılmıştır. ESA\_Sınıf modeli, 120 adet primer follikülünü primordial olarak sınıflandırmıştır. Primer follikülü, primordial'dan sonra ve preantral'den önce oluştuğu için Tablo 5.15'te bu follikülün en fazla bu iki follikül ile karıştırıldığı görülmektedir (65 adet primordial ile 75 adet preantral, primer olarak sınıflandırılmıştır). Diğer bir örnek ise preantral sınıfı olarak verilebilir. Bilindiği gibi preantral follikülü, primer follikülünden sonra oluşur ve daha sonra sekonder follikülüne dönüşür. Sınıflandırma matrisine bakıldığında bu sınıfın en fazla primer ve sekonder ile karıştırıldığı görülmektedir. Diğer folliküllerin sınıflandırma değerlerine bakıldığında aynı sonuçlar görülmektedir. Bu sebepten dolayı uzmanların bile bazen kararsız kaldığı folliküllerin sınıflandırılması, ESA\_Sınıf modeli ile %95.96 doğruluk başarısı ile gerçekleştirilmiştir.


#### 5.4. Önerilen Yöntemin Parametre Optimizasyonu Sonuçları

Tez kapsamında geliştirilen yöntemin test aşamasında Bölüm 4.4'te anlatıldığı gibi sistemin başarısını etkileyen AKD, KSU ve BSD parametreleri mevcuttur. Bu parametrelerin, yöntemin çalışma sistemine göre farklı etkileri olduğu söylenebilir. Örneğin, eğer görüntülerdeki nesnelere birbirine yakın konumda ise KSU değeri daha düşük seçilebilir. Böylelikle nesnelere birbirinden ayrılması için yakın komşu değerlerine bakılarak birbirinden ayrılabilir. Yöntemde segmentasyon için kullanılan ESA modelinin sınıflandırma doğruluğu yüksek ise AKD değeri büyük seçilebilir. Bunun sonucunda az bir alan üzerinde dolaşarak hem zamansal olarak daha kısa hem de doğruluk olarak daha yüksek değerler elde edilebilir. Eğer yöntemde sınıflandırma için kullanılan ESA modelinin sınıflandırma doğruluğu düşük ise BSD değeri yüksek tutularak daha fazla alt görüntü tekrar kontrol edilerek yöntemin doğruluk oranı arttırılmaya çalışılır. Bu bilgiler ışığında, parametre değerleri her ne kadar uzman bilgisiyse belli bir aralığa indirgenmiş olsa da, parametrelerin en optimum değerlerinin bulunması için optimizasyon algoritmaları kullanılmalıdır. Bu tez kapsamında yöntemin parametre optimizasyonu için YAKA kullanılmıştır.


Yöntemdeki AKD, KSU ve BSD parametrelerinin optimizasyonu için; test görüntüsünü temsil edecek görüntüler seçilip, sadece o görüntüler üzerinde parametrelerin en optimum değerleri bulunur. Çünkü yöntemde kullanılan modellerin görüntüler üzerindeki davranışlarını etkileyen başlıca etkenler, görüntülerin mikroskop ile hangi büyütme oranı ile elde edildiği ve görüntülerde kullanılan boyama tekniği olarak sıralanabilir. Yani H&E ile boyanan bütün görüntüler içerisinden sadece bir görüntü alınıp yöntemin parametreleri optimize edilse, diğer H&E ile boyanan görüntülerin analizinde aynı etkiyi gösterecektir. Bu bilgiler ışığında farklı boyama ve farklı büyütme oranlarına göre 4 görüntü kullanılarak yöntemdeki parametreler optimize edilmiştir. Kullanılan görüntüler ve segmente edilmiş halleri Şekil 5.15'de verilmiştir.

Yöntemin optimize edilmesi için oluşturulan algoritma akış diyagramı Şekil 4.11'de verilmiştir. Optimizasyon amacıyla kullanılan YAKA için toplam 10 bireyden oluşan bir popülasyon oluşturulmuştur. İterasyon sayısı 50 olarak seçilmiştir. Optimizasyon sonucu en düşük segmentasyon hatasının elde edildiği yakınsama grafiği Şekil 5.16'da verilmiştir. Yapılan deneysel çalışmalarda yöntemin test aşamasında kullanılmak üzere en yüksek doğruluk değerini veren ilk 10 parametre değerleri YAKA ile hesaplanmış olup, bu değerler Tablo 5.17'de verilmiştir. Tablo 5.17'e bakıldığında

en yüksek segmentasyon doğruluğunu veren parametre değerleri sırasıyla AKD 30, KSU 28 ve BSD 0,85 olarak bulunmuştur.



Şekil 5.15. Önerilen yöntemdeki parametrelerin optimizasyonu için kullanılan görüntüler(üstte), görüntülerdeki foliküllerin segmentasyonu(altta)



Şekil 5.16. AKD, KSU ve BSD değerlerinin YAKA algoritması ile optimizasyonda yakınsama grafiği

**Tablo 5.17.** Optimizasyon esnasında en iyi değere doğru giderken 10 farklı parametre değerinin elde ettiği segmentasyon performans değerleri ve görüntülerin segmentasyon çıktısı

Durum	AKD	KSU	BSD	Ortalama Doğruluk	Ortalama IoUs
1	25	29	0,79	0.89824	0.83500
2	28	16	0,78	0.90997	0.84245
3	16	16	0,78	0.89810	0.84487
4	25	32	0,79	0.90918	0.85031
5	30	32	0,69	0.90834	0.85067
6	32	32	0,83	0.90602	0.85673
7	30	24	0,84	0.91114	0.85963
8	32	14	0,62	0.91805	0.85742
9	30	30	0,79	0.91128	0.86005
<b>10</b>	<b>30</b>	<b>28</b>	<b>0,85</b>	<b>0.91290</b>	<b>0.86099</b>


## 5.5. Faster R-CNN Modelinin Eğitim Sonuçları

Tez kapsamında önerilen yöntemin performans başarısının değerlendirilmesi için Faster R-CNN modeli kullanılmıştır. Faster R-CNN modelinde katman yapısı olarak AlexNet, Vgg16 ve Vgg19 modelleri kullanılmıştır. Her bir modelin kullanılması ile elde edilen eğitim grafikleri bu bölümde verilmiştir. Faster R-CNN modelinin mimari yapısından dolayı eğitim işlemi Matlab derin öğrenme kütüphanesinde 4 aşamadan oluşmaktadır. Bu aşamalar sırasıyla;


- Bölgesel Öneri Ağının(BÖA) eğitilmesi
- Eğitilen BÖA ağı ile Fast R-CNN modelinin eğitilmesi
- Fast R-CNN ağırlıklarının kullanılmasıyla BÖA ağının tekrar eğitilmesi
- Güncellenen BÖA ağını kullanarak Fast R-CNN modelinin tekrar eğitilmesi

### 5.5.1. Faster R-CNN’de AlexNet modeli kullanılarak elde edilen eğitim sonuçları


Faster R-CNN’de AlexNet modeli kullanılarak yapılan eğitimde ilk olarak BÖA ağının eğitilme esnasındaki iterasyon sayısına göre hata ve doğruluk değeri Şekil 5.17’de verilmiştir. Eğitilen BÖA ağı kullanılarak Fast R-CNN ağının eğitilmesi esnasında hata ve doğruluk değeri Şekil 5.18’de verilmiştir. Eğitilmiş Fast R-CNN modelinin ağırlıkları kullanılarak BÖA ağının tekrar eğitilmesi esnasında elde edilen hata ve doğruluk değeri Şekil 5.19’da verilmiştir. Son olarak güncellenen BÖA ile Fast R-CNN modelinin tekrar eğitilmesi esnasındaki hata ve doğruluk değeri Şekil 5.20’de verilmiştir.




Şekil 5.17. Faster R-CNN’de AlexNet modelinin kullanılmasıyla, BÖA ağının eğitimi esnasındaki iterasyon sayısına göre hata ve doğruluğun yakınsama grafikleri



**Şekil 5.18.** FASTER R-CNN'de AlexNet modelinin kullanılmasıyla eğitilmiş BÖA ağı kullanılarak Fast R-CNN modelinin eğitimi esnasındaki iterasyon sayısına göre hata ve doğruluğun yakınsama grafikleri



**Şekil 5.19.** FASTER R-CNN'de AlexNet modelinin kullanılmasıyla, eğitilmiş Fast R-CNN modelinin ağırlıklarını kullanarak BÖA ağına tekrar eğitimi esnasındaki iterasyon sayısına göre hata ve doğruluğun yakınsama grafikleri




**Şekil 5.20.** FASTER R-CNN'de AlexNet modelinin kullanılmasıyla, güncellenen BÖA ağı kullanılarak Fast R-CNN modelinin tekrar eğitimi esnasındaki iterasyon sayısına göre hata ve doğruluğun yakınsama grafiği




### 5.5.2. Faster R-CNN'de Vgg16 modeli kullanılarak elde edilen eğitim sonuçları


Faster R-CNN'de Vgg16 modeli kullanılarak yapılan eğitimde ilk olarak BÖA ağının eğitilme esnasındaki iterasyon sayısına göre hata ve doğruluk değeri Şekil 5.21'de verilmiştir. Eğitilen BÖA ağı kullanılarak Fast R-CNN ağının eğitilmesi esnasında hata ve doğruluk değeri Şekil 5.22'de verilmiştir. Eğitilmiş Fast R-CNN modelinin ağırlıkları kullanılarak BÖA ağının tekrar eğitilmesi esnasında elde edilen hata ve doğruluk değeri Şekil 5.23'te verilmiştir. Son olarak güncellenen BÖA ile Fast R-CNN modelinin tekrar eğitilmesi esnasındaki hata ve doğruluk değeri Şekil 5.24'te verilmiştir.




Şekil 5.21. Faster R-CNN'de Vgg16 modelinin kullanılmasıyla, BÖA ağının eğitimi esnasındaki iterasyon sayısına göre hata ve doğruluğun yakınsama grafikleri



Şekil 5.22. Faster R-CNN'de Vgg16 modelinin kullanılmasıyla eğitilmiş BÖA ağı kullanılarak Fast R-CNN modelinin eğitimi esnasındaki iterasyon sayısına göre hata ve doğruluğun yakınsama grafikleri




**Şekil 5.23.** FASTER R-CNN'de Vgg16 modelinin kullanılmasıyla, eğitilmiş Fast R-CNN modelinin ağırlıklarını kullanarak BÖA ağına tekrar eğitimi esnasındaki iterasyon sayısına göre hata ve doğruluğun yakınsama grafikleri




**Şekil 5.24.** FASTER R-CNN'de Vgg16 modelinin kullanılmasıyla, güncellenen BÖA ağı kullanılarak Fast R-CNN modelinin tekrar eğitimi esnasındaki iterasyon sayısına göre hata ve doğruluğun yakınsama grafiği

### 5.5.3. FASTER R-CNN'de Vgg19 modeli kullanılarak elde edilen eğitim sonuçları


FASTER R-CNN'de Vgg19 modeli kullanılarak yapılan eğitimde ilk olarak BÖA ağına eğitilme esnasındaki iterasyona göre hata ve doğruluk değeri Şekil 5.25'de verilmiştir. Eğitilen BÖA ağı kullanılarak Fast R-CNN ağına eğitilmesi esnasında hata ve doğruluk değeri Şekil 5.26'da verilmiştir. Eğitilmiş Fast R-CNN modelinin ağırlıkları kullanılarak BÖA ağına tekrar eğitilmesi esnasında elde edilen hata ve doğruluk değeri Şekil 5.27'de verilmiştir. Son olarak güncellenen BÖA ile Fast R-CNN modelinin tekrar eğitilmesi esnasındaki hata ve doğruluk değeri Şekil 5.28'de verilmiştir.




Şekil 5.25. Fast R-CNN'de Vgg19 modelinin kullanılmasıyla, BÖA ağının eğitimi esnasındaki iterasyon sayısına göre hata ve doğruluğun yakınsama grafikleri



Şekil 5.26. Fast R-CNN'de Vgg19 modelinin kullanılmasıyla eğitilmiş BÖA ağı kullanılarak Fast R-CNN modelinin eğitimi esnasındaki iterasyon sayısına göre hata ve doğruluğun yakınsama grafikleri



Şekil 5.27. Fast R-CNN'de Vgg19 modelinin kullanılmasıyla, eğitilmiş Fast R-CNN modelinin ağırlıklarını kullanarak BÖA ağının tekrar eğitimi esnasındaki iterasyon sayısına göre hata ve doğruluğun yakınsama grafikleri



**Şekil 5.28.** Faster R-CNN'de Vgg19 modelinin kullanılmasıyla, güncellenen BÖA ağı kullanılarak Fast R-CNN modelinin tekrar eğitimi esnasındaki iterasyon sayısına göre hata doğruluğunun yakınsama grafiği

## 5.6. Önerilen Yöntemin Test Sonuçları ve Diğer Yöntemlerle Karşılaştırılması


Yapılan eğitim işlemlerinden sonra önerilen yöntem 887 adet görüntü ile test edilmiştir. Test işleminde görüntülerdeki toplam follüküllerin (primordial, primer, preantral, sekonder, tersiyer) sayısı elde edilmiştir. Sistemin doğruluğunu ölçmek için test görüntüleri üzerindeki bütün follüküller öncelikle bir uzman tarafından manuel olarak sayılmıştır. Daha sonra görüntüdeki follüküller yöntem tarafından sayılmıştır. Önerilen yöntem ile uzman tarafından sayılan follüküllerin sayısal değerleri Tablo 5.18'de verilmiştir.

Tablo 5.18'e bakıldığında, geliştirilen yöntemin tersiyer follükülün sayısını uzman sayımıyla aynı değer olarak elde etmiştir. Primordial'de 5 adet eksik, primer'de 18 adet fazla, preantral'de 1 adet eksik ve sekonder'de 11 adet eksik saymıştır. Bu farklılıklara bakıldığında follükülün sayımında elde edilen değerlerin manuel olarak uzman tarafından yapılan sayıya çok yakın olduğu görülmektedir.

**Tablo 5.18.** Önerilen yöntem ile uzmanın 887 görüntü üzerinde saymış olduğu follükül değerlerinin karşılaştırılması

Follükül	Önerilen Yöntem	Uzman Sayımı	Sayım Farkı
Primordial	103	108	-5
Primer	188	170	+18
Preantral	305	306	-1
Sekonder	570	581	-11
Tersiyer	51	51	0


Aynı test verisi üzerinde follikül sayımı Faster R-CNN modeli ile de gerçekleştirilmiştir. Faster R-CNN modelinde ESA modeli olarak AlexNet, Vgg16 ve Vgg19 modelleri kullanılmıştır. Uzman sayımı, önerilen yöntem ve Faster R-CNN ile elde edilen sonuçlar Şekil 5.29’da verilmiştir. Şekil 5.29’a bakıldığında her bir follikül değeri altta, grafiksel gösterimi ise üstte gösterilmiştir. Örneğin 887 adet test görüntüsü üzerinde uzman tarafından yapılan sayımda primordial folliküllerinden toplam 108 adet sayılmış olup sarı renk(birinci kolon) ile gösterilmiştir. Bu follikülün önerilen yöntem ile yapılan sayımda ise 103 adet sayılmış olup yeşil renkle(ikinci kolon) gösterilmiştir. Bu follikül, Faster R-CNN’nin AlexNet ile kullanılarak yapılan sayımda 4 adet bulunmuş olup kırmızı renkle(dördüncü kolon) ifade edilmiştir. Faster R-CNN’nin Vgg16 modeliyle kullanılarak 64 adet primordial sayımı yapmış olup mor renkle (üçüncü kolon) gösterilmiştir. Son olarak, bu follikül Faster R-CNN’nin Vgg19 ile kullanılarak 53 adet olarak sayılmış olup gri renkle(beşinci kolon) gösterilmiştir.



Şekil 5.29. Test verisi üzerinde yöntemlerin elde ettiği follikül sayısının karşılaştırılması

Şekil 5.30’da folliküllerin uzman tarafından elde ettiği sayım değerleri referans alınarak diğer yöntemlerin yüzde olarak başarı değerleri hesaplanıp kıyaslanmıştır. Örneğin önerilen sistem ile primer folliküllerinin sayısı 103 olarak bulunmuştur. Uzman ise bu değeri 108 olarak elde etmiştir.  $\pm 5$  bir hata ile %96.37 başarı değeri elde edilmiştir. Diğer folliküller için benzer hesaplama yapılmıştır. Şekil 5.30’a bakıldığında follikül sayımının ortama başarısı önerilen yöntem ile %96.72, Faster R-CNN’de AlexNet modeli kullanılarak %56.66, Faster R-CNN’de Vgg16 modeli kullanılarak

%70,09 ve Faster R-CNN’de Vgg19 modeli kullanılarak %75,51 olarak hesaplanmıştır. Folliküllerin özelinde ise 5 follikülün 4 ünde önerilen yöntem diğerlerine nazaran daha başarılı sonuç elde etmiştir. Sadece primer follikülünde Faster R-CNN’nin Vgg19 ile kullanılmasıyla daha başarılı olmuştur.



Şekil 5.30. Uzman sayım değerine göre test verisi üzerinde yöntemlerin her bir follikül sayımında elde ettiği başarı değeri ve ortalama başarı değerinin karşılaştırılması

## 6. SONUÇLAR VE ÖNERİLER

Bilgisayarlı görü sistemlerinde, bir görüntü üzerindeki nesnelerin yerlerinin belirlenmesi, nesnelerin sınıflandırılması ve bu nesnelerin segmentasyonu en önemli problemler olarak düşünülmektedir. Özellikle medikal görüntülerdeki sınıflandırma ve segmentasyon işlemi zor problemlerdir. Çünkü incelenecek ilgili dokudaki hücre veya hücrelerin oluşturduğu yapılar, arka plan dokusuyla çok benzer özellikler sergileyebilir. Bu sebeple görüntü işleme veya makine öğrenmesi yöntemlerin en fazla zorlandığı veri setlerinin medikal görüntülerden elde edilen veri setleri olduğu söylenebilir. DÖ modellerinin geliştirilmesiyle, medikal görüntülerin sınıflandırılmasında yüksek doğruluklar elde edilmiştir. Bu görüntülerdeki tanımlama ve segmentasyon problemlerinde ise sınıflandırma kadar yüksek başarılar elde edilememiştir. Bu sebeple özellikle histolojik olarak elde edilen görüntülerin sınıflandırılması, segmentasyonu ve nesne sınır değerlerinin tespiti için yeni yöntemlere ihtiyaç duyulmaktadır.

Yapılan bu tez çalışmasında DÖ tabanlı yeni bir yöntem geliştirilmiştir. Geliştirilen yöntem görüntülerdeki nesnelerin yerlerinin tespiti ve bu nesnelerin sınıflandırmasını yapmaktadır. Geliştirilen yöntem histolojik olarak elde edilen ovaryum dokusuna ait görüntüler üzerinde test edilmiştir. Yapılan deneysel çalışmalarda, önerilen yöntemin tatmin edici sonuçlar elde ettiği görülmüştür.

### 6.1 Sonuçlar

Tez kapsamında geliştirilen yöntem, histolojik olarak elde edilen ovaryum dokusuna ait beş farklı follikülün otomatik sayılması için kullanılmıştır. Bu sebeple histolojik olarak ovaryum dokusundan toplam 10500 adet görüntü elde edilerek, bu görüntülerdeki folliküllerin uzman tarafından etiketlendiği özgün bir veri seti oluşturulmuştur. Önerilen yöntemin mimarisi, eğitim ve test bölümü olmak üzere iki bölüme ayrılmıştır.

Eğitim işleminde hem sınıflandırma hem de segmentasyon için tasarlanan farklı ESA modellerinin eğitim işlemi gerçekleştirilmiştir. Bu bölümde, segmentasyon ve sınıflandırmada kullanılmak üzere toplam 55 farklı ESA modeli tasarlanmış ve bu modellerin eğitimi, oluşturulan veri seti ile gerçekleştirilmiştir. Segmentasyon işleminde kullanılan ESA modelleri, giriş görüntü boyutuna göre 3 farklı gruba ayrılmıştır. Birinci

gruptaki ESA modelleri için kullanılan görüntü boyutu  $500 \times 500 \times 3$ , ikinci gruptaki ESA modelleri için kullanılan görüntü boyutu  $1024 \times 1024 \times 3$  ve son olarak üçüncü gruptaki ESA modelleri için kullanılan görüntü boyutu  $2048 \times 2048 \times 3$  olarak belirlenmiştir. Birinci gruptaki ESA modelleri arasında en yüksek doğruluk % 82.9 olarak elde edilmiştir. İkinci gruptaki ESA modelleri arasında en yüksek doğruluk %87.1 olarak elde edilmiştir. Üçüncü gruptaki ESA modelleri arasında en yüksek doğruluk % 85.9 olarak elde edilmiştir. Elde edilen bu veriler sonucunda önerilen yöntemde segmentasyon için kullanılacak model, en yüksek doğruluk değerini elde eden ikinci gruptaki ESA modeli olmuştur. Bu model *ESA\_Seg* olarak isimlendirilmiştir. Sınıflandırma işlemi için toplam 12 farklı ESA modeli tasarlanmıştır. Bu modeller içerisinde en yüksek doğruluk değeri olarak %95.96 değeri elde edilmiştir. Bu değeri elde eden model *ESA\_Sınıf* olarak isimlendirilmiş ve yöntemde sınıflandırma işlemi için kullanılmıştır.

Yöntemin test aşamasında segmentasyon doğruluğunun en yüksek doğrulukta yapılması için, yöntemde kullanılan AKD, KSU ve BSD parametrelerinin optimizasyonu gerçekleştirilmiştir. Optimizasyon işlemi için YAKA algoritması kullanılmıştır. Yapılan optimizasyon sonucunda bu parametrelerin en uygun AKD değeri 30, KSU değeri 28 ve BSD değeri 0.85 olarak bulunmuştur.

Tez kapsamında, literatürde nesne tanımlamada en fazla kullanılan Faster R-CNN modeli yöntem karşılaştırılması için kullanılmıştır. Faster R-CNN modelinin katman yapısı için AlexNet, Vgg16 ve Vgg19 modeli kullanılmıştır.

Yöntemin test işlemi için, hazırlanan veri setinden toplam 887 adet görüntü kullanılmıştır. Bu 887 adet görüntü üzerinde uzman sayımına göre primordial follikülünden 108, primer follikülünden 170, preantral follikülünden 306, sekonder follikülünden 581 ve tersiyer follikülünden 51 adet sayılmıştır. Önerilen yöntem ile primordial follikülünden 103, primer follikülünden 188, preantral follikülünden 305, sekonder follikülünden 570 ve tersiyer follikülünden 51 adet sayılmıştır. Sonuçlar karşılaştırıldığında önerilen yöntemin uzmana göre  $\pm 18$  aralığında çalıştığı görülmüştür. Yöntemin test başarısı nesne tanımlamada yüksek performans gösteren Faster R-CNN modeli ile karşılaştırılmıştır. Deneysel çalışmalarda Faster R-CNN'nin model olarak Alexnet'i kullanmasıyla elde ettiği ortalama doğruluk değeri %56.66, Faster R-CNN'nin Vgg16 ile elde ettiği ortalama doğruluk değeri %70.09 ve Faster R-CNN'nin Vgg19 modelini kullanarak elde ettiği ortalama doğruluk değeri ise %75.51'dir. Önerilen yöntem ile %96.72 doğruluk elde edilmiştir. Elde edilen sonuçlara



bakıldığında önerilen yöntemin diğer 3 yöntemden başarılı olduğu görülmüştür. Faster R-CNN modeli ise Vgg19 ağını kullanarak en yüksek ortalama doğruluk değerini elde etmiştir.

## 6.2 Öneriler

Bu tez kapsamında önerilen yöntemin, histolojik görüntülerde segmentasyon, hücresel yapıların sınır değerlerinin bulunması ve bu hücresel yapıların sınıflandırma problemlerinde kullanılması amaçlanmıştır. Segmentasyon, tanımlama ve sınıflandırma problemlerinin tek bir yöntemle çözülmesinden dolayı önerilen yöntemde ayarlanması gereken parametre sayısının da fazla olduğu görülmektedir. Yöntem için hiperparametreler olarak ifade edilebilecek bu parametrelerin başında, kullanılan ESA modelleri gelmektedir. Bu parametrelerin en uygun değerlerinin optimizasyon teknikleriyle elde edilebileceği düşünülmektedir. Örneğin yöntemin eğitim kısmında segmentasyon için 43 farklı ESA modeli tasarlanmış ve içlerinde en yüksek doğruluk değerine sahip olan model yöntemde kullanılmıştır. Fakat seçilen bu ESA modelinden daha yüksek doğruluk değerlerini verebilecek ESA modellerinin olması mümkündür. Aynı şekilde sınıflandırma için 12 farklı ESA modeli tasarlanmış ve içlerinde en yüksek doğrulukta çalışan ESA modeli kullanılmıştır. Bu modelden yüksek başarılar elde edecek modeller optimizasyon algoritmaları ile bulunabilir. Bu optimizasyon işlemi için yüksek hesaplama kapasitelerine sahip donanımlara ihtiyaç duyulmaktadır. Gerekli donanımsal kaynakların temin edilmesiyle, önerilen yöntemde hiperparametrelerin optimizasyonu önerilmektedir.

Bu tez kapsamındaki histolojik görüntüler üzerinde kullanılan yöntemin, farklı veri setlerinde kullanılması önerilebilir. Nesne tanımlama/segmentasyon/sınıflandırma gibi problemler için hazırlanan farklı veri setlerinde önerilen yöntemin kullanılmasıyla yüksek doğruluk elde edileceği beklenmektedir. Çünkü farklı yapıların iç içe geçtiği histolojik kesitlerden elde edilen veri setinde yüksek bir başarı değeri elde etmesi diğer veri setlerinde de başarılı olacağı tezini kuvvetlendirmektedir.

Önerilen yöntem ile bir tane görüntünün analizi ortalama 12 saniyede yapılmaktadır. Gerçek zamanlı görüntü analizinde veya video analizinde yöntemin kullanılması için, optimize edilerek hızlandırılması önerilmektedir.

## KAYNAKLAR

- Albarqouni, S., Baur, C., Achilles, F., Belagiannis, V., Demirci, S. ve Navab, N., 2016, Aggnet: deep learning from crowds for mitosis detection in breast cancer histology images, *IEEE transactions on medical imaging*, 35 (5), 1313-1321.
- Angermueller, C., Pärnamaa, T., Parts, L. ve Stegle, O., 2016, Deep learning for computational biology, *Molecular systems biology*, 12 (7), 878.
- Aragon, L., Aranda, G., Santos, A. ve Medina, A., 2010, Quantification of ovarian follicles in bluefin tuna *Thunnus thynnus* by two stereological methods, *Journal of Fish Biology*, 77 (3), 719-730.
- Araújo, V. R., Gastal, M. O., Figueiredo, J. R. ve Gastal, E. L., 2014, In vitro culture of bovine preantral follicles: a review, *Reproductive biology and endocrinology*, 12 (1), 78.
- Bayramoglu, N. ve Heikkilä, J., 2016, Transfer learning for cell nuclei classification in histopathology images, *European Conference on Computer Vision*, 532-539.
- Bengio, Y., Lamblin, P., Popovici, D. ve Larochelle, H., 2007, Greedy layer-wise training of deep networks, *In NIPS'2006* . 14, 19, 200, 323, 324, 530, 532.
- Bengio, Y. ve LeCun, Y., 2007, Scaling learning algorithms towards AI., *In Large Scale Kernel Machines* . 19.
- Bengio, Y., Courville, A. ve Vincent, P., 2013, Representation Learning: A Review and New Perspectives, *Ieee Transactions on Pattern Analysis and Machine Intelligence*, 35 (8), 1798-1828.
- Bergstra, J. ve Bengio, Y., 2012, Random search for hyper-parameter optimization, *Journal of Machine Learning Research*, 13 (Feb), 281-305.
- Cai, Z., Long, Y. ve Shao, L., 2019, Classification complexity assessment for hyper-parameter optimization, *Pattern Recognition Letters*.
- Chand, A. ve Legge, M., 2011, Stereological Assessment of Developing Mouse Ovarian Follicles in an In Vitro Culture System, *Anatomical Record-Advances in Integrative Anatomy and Evolutionary Biology*, 294 (3), 379-383.
- Charleston, J. S., Hansen, K. R., Thyer, A. C., Charleston, L. B., Gougeon, A., Siebert, J. R., Soules, M. R. ve Klein, N. A., 2007, Estimating human ovarian non-growing follicle number: the application of modern stereology techniques to an old problem, *Human Reproduction*, 22 (8), 2103-2110.
- Chen, Y., Tao, G., Ren, H., Lin, X. ve Zhang, L., 2018, Accurate seat belt detection in road surveillance images based on CNN and SVM, *Neurocomputing*, 274, 80-87.
- Competition, I. L. S. V. R., 2012, Available online: <http://www.image-net.org/challenges>, *LSVRC/(accessed on 27 December 2016)*.
- Coward, K. ve Bromage, N. R., 2002, Stereological point-counting; an accurate method for assessing ovarian function in tilapia, *Aquaculture*, 212 (1-4), 383-401.
- Cruz-Roa, A. A., Ovalle, J. E. A., Madabhushi, A. ve Osorio, F. A. G., 2013, A deep learning architecture for image representation, visual interpretability and automated basal-cell carcinoma cancer detection, *International Conference on Medical Image Computing and Computer-Assisted Intervention*, 403-410.
- Cui, H. ve Bai, J., 2019, A new hyperparameters optimization method for convolutional neural networks, *Pattern Recognition Letters*.
- Dabeer, S., Khan, M. M. ve Islam, S., 2019, Cancer diagnosis in histopathological image: CNN based approach, *Informatics in Medicine Unlocked*, 16, 100231.

- Delalleau, O. ve Bengio, Y., 2011, Shallow vs. deep sum-product networks, *In NIPS*, 19, 556.
- Everingham, M., Van Gool, L., Williams, C. K., Winn, J. ve Zisserman, A., 2010, The pascal visual object classes (voc) challenge, *International journal of computer vision*, 88 (2), 303-338.
- Gao, Z., Wang, L., Zhou, L. ve Zhang, J., 2017, HEp-2 cell image classification with deep convolutional neural networks, *IEEE journal of biomedical and health informatics*, 21 (2), 416-428.
- Girshick, R., Donahue, J., Darrell, T. ve Malik, J., 2014, Rich feature hierarchies for accurate object detection and semantic segmentation, *Proceedings of the IEEE conference on computer vision and pattern recognition*, 580-587.
- Girshick, R., 2015, Fast r-cnn, *Proceedings of the IEEE international conference on computer vision*, 1440-1448.
- Guo, G., Wang, H., Yan, Y., Zheng, J. ve Li, B., 2019, A fast face detection method via convolutional neural network, *Neurocomputing*.
- Hansen, K. R., Craig, L. B., Zavy, M. T., Klein, N. A. ve Soules, M. R., 2012, Ovarian primordial and non-growing follicle counts according to the stages of reproductive aging workshop (STRAW) staging system, *Menopause (New York, NY)*, 19 (2), 164.
- Hassan, M. u., 2019, Popular networks, <https://neurohive.io/en/popular-networks/vgg16/>: [30.10.2019 18:57].
- He, K., Zhang, X., Ren, S. ve Sun, J., 2016a, Deep residual learning for image recognition, *Proceedings of the IEEE conference on computer vision and pattern recognition*, 770-778.
- He, K. M., Zhang, X. Y., Ren, S. Q. ve Sun, J., 2016b, Deep Residual Learning for Image Recognition, *2016 Ieee Conference on Computer Vision and Pattern Recognition (Cpvr)*, 770-778.
- Hinton, G. E., Osindero, S. ve Teh, Y.-W., 2006, A fast learning algorithm for deep belief nets, *Neural computation*, 18 (7), 1527-1554.
- 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., Ceyhan, A., Balcıoğlu, E. ve Ülker, E., 2019, A new method for automatic counting of ovarian follicles on whole slide histological images based on convolutional neural network, *Computers in Biology and Medicine*, 112, 103350.
- Jiang, B., He, J., Yang, S., Fu, H., Li, T., Song, H. ve He, D., 2019, Fusion of machine vision technology and AlexNet-CNNs deep learning network for the detection of postharvest apple pesticide residues, *Artificial Intelligence in Agriculture*, 1, 1-8.
- Julia, D. L. f., 2016, [devblogs.nvidia.com, https://devblogs.nvidia.com/parallelforall/mocha-jl-deep-learning-julia/](https://devblogs.nvidia.com/devblogs.nvidia.com/parallelforall/mocha-jl-deep-learning-julia/):
- Junior, F. E. F. ve Yen, G. G., 2019, Particle swarm optimization of deep neural networks architectures for Image classification, *Swarm and Evolutionary Computation*.
- Kainz, P., Pfeiffer, M. ve Urschler, M., 2015, Semantic segmentation of colon glands with deep convolutional neural networks and total variation segmentation, *arXiv preprint arXiv:1511.06919*.
- Karaboga, D., 2005, An idea based on honey bee swarm for numerical optimization, *Technical report-tr06, Erciyes university, engineering faculty, computer ....*
- Karaboga, D. ve Akay, B., 2009, A comparative study of artificial bee colony algorithm, *Applied mathematics and computation*, 214 (1), 108-132.

- Karbalay-Doust, S. ve Noorafshan, A., 2012, Stereological estimation of ovarian oocyte volume, surface area and number: application on mice treated with nandrolone decanoate, *Folia Histochemica Et Cytophysiologica*, 50 (2), 275-279.
- Kashif, M. N., Raza, S. E. A., Sirinukunwattana, K., Arif, M. ve Rajpoot, N., 2016, Handcrafted features with convolutional neural networks for detection of tumor cells in histology images, *Biomedical Imaging (ISBI), 2016 IEEE 13th International Symposium on*, 1029-1032.
- Krizhevsky, A., Sutskever, I. ve Hinton, G. E., 2012, Imagenet classification with deep convolutional neural networks, *Advances in neural information processing systems*, 1097-1105.
- LeCun, Y., 1987, Modèles connexionistes de l'apprentissage, *Université de Paris VI*, 18, 504, 517.
- Lecun, Y., Bottou, L., Bengio, Y. ve Haffner, P., 1998, Gradient-based learning applied to document recognition, *Proceedings of the IEEE*, 86 (11), 2278–2324.
- LeCun, Y., Bengio, Y. ve Hinton, G., 2015, Deep learning, *Nature*, 521 (7553), 436-444.
- Liang, S., Lu, J. ve Perkins, K., 2019, Object Detection, [http://slazebni.cs.illinois.edu/spring17/lec07\\_detection.pdf](http://slazebni.cs.illinois.edu/spring17/lec07_detection.pdf): [30.10.2019].
- Litjens, G., Kooi, T., Bejnordi, B. E., Setio, A. A. A., Ciompi, F., Ghafoorian, M., Van Der Laak, J. A., Van Ginneken, B. ve Sánchez, C. I., 2017, A survey on deep learning in medical image analysis, *Medical image analysis*, 42, 60-88.
- Ma, Y. ve Klabjan, D., 2017, Convergence analysis of batch normalization for deep neural nets, *arXiv preprint arXiv:1705.08011*.
- McClelland, J., Rumelhart, D. ve Hinton, G., 1995, The appeal of parallel distributed processing . In *Computation & intelligence*, American Association for Artificial Intelligence. 17, p. 305–341. .
- 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.
- Medigovic, I., Ristic, N., Trifunovic, S., Manojlovic-Stojanoski, M., Milosevic, V., Zikic, D. ve Nestorovic, N., 2012, Genistein affects ovarian folliculogenesis: A stereological study, *Microscopy Research and Technique*, 75 (12), 1691-1699.
- Miller, P. B., Charleston, J. S., Battaglia, D. E., Klein, N. A. ve Soules, M. R., 1997, An accurate, simple method for unbiased determination of primordial follicle number in the primate ovary, *Biology of Reproduction*, 56 (4), 909-915.
- Minsky, M. L. a. P., S. A. , 1969, Perceptrons, *MIT Press, Cambridge*. 15.
- Montufar, G. F., 2014, Universal approximation depth and errors of narrow belief networks with discrete units, *Neural computation*, 26 (7), 1386–1407.
- Myers, M., Britt, K. L., Wreford, N. G. M., Ebling, F. J. P. ve Kerr, J. B., 2004, Methods for quantifying follicular numbers within the mouse ovary, *Reproduction*, 127 (5), 569-580.
- Niu, X.-X. ve Suen, C. Y., 2012, A novel hybrid CNN–SVM classifier for recognizing handwritten digits, *Pattern Recognition*, 45 (4), 1318-1325.
- Pascanu, R., Gülçehre, Ç., Cho, K. ve Bengio, Y., 2014, How to construct deep recurrent neural networks., *In ICLR'2014 . 19*, 199, 265, 398, 399, 400, 412, 462.
- Quinn, J. A., Nakasi, R., Mugagga, P. K., Byanyima, P., Lubega, W. ve Andama, A., 2016, Deep convolutional neural networks for microscopy-based point of care diagnostics, *Machine Learning for Healthcare Conference*, 271-281.

- Ranzato, M., Poultney, C., Chopra, S. ve LeCun, Y., 2007, Efficient learning of sparse representations with an energy-based model, *In NIPS'2006* . 14, 19, 509, 530, 532.
- Razzak, M. I., Naz, S. ve Zaib, A., 2018, Deep Learning for Medical Image Processing: Overview, Challenges and the Future, In: *Classification in BioApps*, Eds: Springer, p. 323-350.
- Rehman, Y. A. U., Po, L.-M., Liu, M., Zou, Z., Ou, W. ve Zhao, Y., 2019, Face liveness detection using convolutional-features fusion of real and deep network generated face images, *Journal of Visual Communication and Image Representation*, 59, 574-582.
- Ren, S., He, K., Girshick, R. ve Sun, J., 2017, Faster R-CNN: towards real-time object detection with region proposal networks, *IEEE Transactions on Pattern Analysis & Machine Intelligence* (6), 1137-1149.
- Ronneberger, O., Fischer, P. ve Brox, T., 2015, U-net: Convolutional networks for biomedical image segmentation, *International Conference on Medical image computing and computer-assisted intervention*, 234-241.
- Rosenblatt, F., 1958, The perceptron: A probabilistic model for information storage and organization in the brain, *Psychological review*, 65 (6), 386-408.
- Rosenblatt, F., 1962, Principles of Neurodynamics, *Spartan, New York*. 15, 27, p.
- Ruder, S., 2016, An overview of gradient descent optimization algorithms, *arXiv preprint arXiv:1609.04747*.
- Rumelhart, D. E., Hinton, G. E. ve Williams, R. J., 1986a, Learning representations by back-propagating errors, *Nature*, 323 (6088), 533-536.
- Rumelhart, D. E., McClelland, J. L. ve Group, T. P. R., 1986b, *Parallel Distributed Processing: Explorations in the Microstructure of Cognition*, MIT Press, Cambridge. 17, p.
- Simonyan, K. ve Zisserman, A., 2014, Very deep convolutional networks for large-scale image recognition, *arXiv preprint arXiv:1409.1556*.
- Sirinukunwattana, K., Raza, S. E. A., Tsang, Y.-W., Snead, D. R., Cree, I. A. ve Rajpoot, N. M., 2016, Locality sensitive deep learning for detection and classification of nuclei in routine colon cancer histology images, *IEEE transactions on medical imaging*, 35 (5), 1196-1206.
- Skodras, A. ve Marcelli, G., 2015, Computer-generated ovaries to assist follicle counting experiments, *PloS one*, 10 (3), e0120242.
- Smith, P., Steckler, T. L., Veiga-Lopez, A. ve Padmanabhan, V., 2009, Developmental Programming: Differential Effects of Prenatal Testosterone and Dihydrotestosterone on Follicular Recruitment, Depletion of Follicular Reserve, and Ovarian Morphology in Sheep, *Biology of Reproduction*, 80 (4), 726-736.
- Srivastava, N., Hinton, G. E., Krizhevsky, A., Sutskever, I. ve Salakhutdinov, R., 2014, Dropout: a simple way to prevent neural networks from overfitting, *Journal of Machine Learning Research*, 15 (1), 1929-1958.
- Sun, Y., Wang, X. ve Tang, X., 2014, Deep learning face representation from predicting 10,000 classes, *Proceedings of the IEEE conference on computer vision and pattern recognition*, 1891-1898.
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V. ve Rabinovich, A., 2015a, Going deeper with convolutions, *Proceedings of the IEEE conference on computer vision and pattern recognition*, 1-9.

- Szegedy, C., Liu, W., Jia, Y. Q., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V. ve Rabinovich, A., 2015b, Going Deeper with Convolutions, *2015 Ieee Conference on Computer Vision and Pattern Recognition (Cvpr)*, 1-9.
- Tao, Q.-Q., Zhan, S., Li, X.-H. ve Kurihara, T., 2016, Robust face detection using local CNN and SVM based on kernel combination, *Neurocomputing*, 211, 98-105.
- Tutorial, U., 2017, <http://ufldl.stanford.edu/tutorial/supervised/OptimizationStochasticGradientDescent/>.
- Vogado, L. H., Veras, R. M., Araujo, F. H., Silva, R. R. ve Aires, K. R., 2018, Leukemia diagnosis in blood slides using transfer learning in CNNs and SVM for classification, *Engineering Applications of Artificial Intelligence*, 72, 415-422.
- Wang, B. ve Klabjan, D., 2017, Regularization for Unsupervised Deep Neural Nets, *AAAI*, 2681-2687.
- Wang, H., Roa, A. C., Basavanhally, A. N., Gilmore, H. L., Shih, N., Feldman, M., Tomaszewski, J., Gonzalez, F. ve Madabhushi, A., 2014, Mitosis detection in breast cancer pathology images by combining handcrafted and convolutional neural network features, *Journal of Medical Imaging*, 1 (3), 034003.
- Wang, J. ve Perez, L., The Effectiveness of Data Augmentation in Image Classification using Deep Learning.
- Wang, J., MacKenzie, J. D., Ramachandran, R. ve Chen, D. Z., 2016, A deep learning approach for semantic segmentation in histology tissue images, *International Conference on Medical Image Computing and Computer-Assisted Intervention*, 176-184.
- Wang, Y., Chen, Y., Yang, N., Zheng, L., Dey, N., Ashour, A. S., Rajinikanth, V., Tavares, J. M. R. ve Shi, F., 2019, Classification of mice hepatic granuloma microscopic images based on a deep convolutional neural network, *Applied Soft Computing*, 74, 40-50.
- Widrow, B. ve Hoff, M. E., 1960, Adaptive switching circuits, *Adaptive switching circuits. In 1960 IRE WESCON Convention Record, volume 4, pages 96–104. IRE, New York. 15, 21, 24, 27.*
- Wong, S. C., Gatt, A., Stamatescu, V. ve McDonnell, M. D., 2016, Understanding data augmentation for classification: when to warp?, *Digital Image Computing: Techniques and Applications (DICTA), 2016 International Conference on*, 1-6.
- Xie, W., Noble, J. A. ve Zisserman, A., 2018, Microscopy cell counting and detection with fully convolutional regression networks, *Computer methods in biomechanics and biomedical engineering: Imaging & Visualization*, 6 (3), 283-292.
- Xie, Y., Xing, F., Kong, X., Su, H. ve Yang, L., 2015, Beyond classification: structured regression for robust cell detection using convolutional neural network, *International Conference on Medical Image Computing and Computer-Assisted Intervention*, 358-365.
- Xu, Y., Jia, R., Mou, L., Li, G., Chen, Y., Lu, Y. ve Jin, Z., 2016, Improved relation classification by deep recurrent neural networks with data augmentation, *arXiv preprint arXiv:1601.03651*.
- Yoo, Y., 2019, Hyperparameter optimization of deep neural network using univariate dynamic encoding algorithm for searches, *Knowledge-Based Systems*, 178, 74-83.
- Zeiler, M. D. ve Fergus, R., 2014a, Visualizing and understanding convolutional networks, *European conference on computer vision*, 818-833.

Zeiler, M. D. ve Fergus, R., 2014b, Visualizing and Understanding Convolutional Networks, *Computer Vision - Eccv 2014, Pt I*, 8689, 818-833.



**EKLER****EK-1:** Etik kurulu raporu

**T.C**  
**GAZİOSMANPAŞA ÜNİVERSİTESİ**  
**REKTÖRLÜĞÜ**  
**HAYVAN DENEYLERİ YEREL ETİK KURULU**

Sayı : 51879863- **118**  
 Konu : Karar

09.05.2018

Sayın: Arş. Gör. Özkan İNİK

HADYEK'na değerlendirilmek üzere sunmuş olduğunuz "Farklı Dokulardaki Hücrelerin Derin Öğrenme ile Otomatik Analizlerinin Yapılması" başlıklı 2018 HADYEK-19 nolu projeniz kurulumuz tarafından değerlendirilerek etik açıdan uygun bulunmuştur.

Bilgilerinize rica ederim.

  
 Prof. Dr. Semiha Gülsüm KURT  
 HADYEK Bşk.

Prof. Dr. Ataç ÇELİK (Başkan Yrd.)  
 ÜYE

Doç. Dr. Arda YILDIRIM  
 ÜYE (Katılmadı)

Dr. Öğretim Üyesi Mehmet TOKATLI  
 ÜYE

Dr. Öğretim Üyesi Adem SOYDAN  
 ÜYE

Dr. Öğretim Üyesi Serbüfent YİĞİT  
 ÜYE

Dr. Öğretim Üyesi İbrahim ERDİM  
 ÜYE

Atilla BULDUK  
 SİVİL ÜYE

Eczacı Osman Atif ÖZMEN  
 ÜYE (Katılmadı)



## ÖZGEÇMİŞ

### KİŞİSEL BİLGİLER

**Adı Soyadı** : Özkan İNİK  
**Uyruğu** : Türkiye Cumhuriyeti  
**Doğum Yeri ve Tarihi** : Kars 1984  
**Telefon** : 0537 664 8042  
**Faks** :  
**E-Posta** : ozkaninik@hotmail.com

### EĞİTİM

Derece	Adı	İlçe	İl	Bitirme Yılı
Lise	: İncirtepe Lisesi	Esenyurt	İSTANBUL	2003
Üniversite	: Selçuk Üniversitesi	Selçuklu	KONYA	2010
Yüksek Lisans	: Selçuk Üniversitesi	Selçuklu	KONYA	2013
Doktora	: Konya Teknik Üniversitesi	Selçuklu	KONYA	2019

### İŞ DENEYİMLERİ

Yıl	Kurum	Görevi
2014-...	Tokat Gaziosmanpaşa Üniversitesi	Araştırma Görevlisi
2012-2014	Şırnak Üniversitesi	Araştırma Görevlisi
2012-2012	Kombassan MPG Acar Vinç	Yazılım Uzmanı
2010-2012	UKDE Mühendislik	Yazılım Uzmanı
2008-2010	UKDE Mühendislik	Yarı zamanlı proje geliştirici

### UZMANLIK ALANI

Derin Öğrenme, Makine Öğrenmesi, Bilgisayarlı Görü, Görüntü İşleme

### YABANCI DİLLER

İngilizce  
YDS: 63.75, YÖK DİL: 68.75

### PROJELER

1. "Derin Öğrenme ile Nesne Tanımlama", Yükseköğretim Kurumları tarafından destekli bilimsel araştırma projesi, Araştırmacı, 02.05.2017-26.12.2017 (Tamamlandı) (ULUSAL)
2. "Farklı Dokulardaki Hücrelerin Derin Öğrenme ile Otomatik Analizlerinin Yapılması", TÜBİTAK-1512 Projesi, Proje no:2180141, Yürütücü, 01.09.2018 (Devam Ediyor) (ULUSAL)

## YAYINLAR

1. İnik Ö., Ceyhan A., Balcıoğlu E. ve Ülker E., (2019). "A New Method For Automatic Counting Of Ovarian Follicles On Whole Slide Histological Images Based On Convolutional Neural Network.", Computers In Biology And Medicine, (Doktora tezinden yapılmıştır)
2. inik, Ö., Balcıoğlu, E., Ceyhan, A. ve Ülker, E. (2019). "Using Convolution Neural Network For Classification of Different Tissue Images in Histological Sections." Annals of the Faculty of Engineering Hunedoara, 17(1), 101-104.(Doktora tezinden yapılmıştır)
3. İnik, Ö., Uyar, K., ve Ülker, E. (2018). Gender Classification with A Novel Convolutional Neural Network (CNN) Model and Comparison with other Machine Learning and Deep Learning CNN Models. Journal Of Industrial Engineering Research, 4(4), 57-63. (Doktora tezinden yapılmıştır)
4. İnik Ö ve Ülker E (2018). "The Effect Size and Number of Filter on Deep Learning Models." 6th International Conference of Applied Science (Özet Bildiri) (Doktora tezinden yapılmıştır)
5. İnik Ö. ve Turan B., (2018). "Classification Of Animals With Different Deep Learning Models", Journal Of New Results İn Science, 7(1), 11-18.
6. İnik Ö. ve Turan B., (2018). "Classification of Different Age Groups of People by Using Deep Learning." Journal of New Results in Science, 7(3), 9-16.
7. Koç, İ. ve İnik, Ö. (2018). "B-Spline Eğri Uydurmada Optimum Serbest Düğüm Noktalarının Seçilmesi için Guguk Kuşu Arama Algoritması." Bilge International Journal of Science and Technology Research, 2(2), 120-127.
8. inik Ö. ve Koç İ, (2017). "Gray Wolf Optimizer For Knot Placement İn B-Spline Curve Fitting", Gaziosmanpasa Journal Of Scientific Research, Gbad, 97-109.
9. İnik Ö. ve Ülker E., (2017). "Derin Öğrenme Ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri", Gaziosmanpasa Journal Of Scientific Research, Gbad, 85-104. (Doktora tezinden yapılmıştır)
10. İnik Ö. ve Ülker E (2017). "Data Sets and Software Libraries Used for Deep Learning." 1st International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT2017) ( Doktora tezinden yapılmıştır)

11. İnik Ö., (2016). “B Spline Eğri Tahmininde Yerçekimsel Arama Algoritmasının Kullanılması.” International Conference on Computer Science and Engineering (UBMK 2016) (Tam Metin Bildiri)
12. Önder M. ve İnik Ö., (2016). “Özilinti ve Yapay Sinir Ağı ile Tek Sesli Müzik Notalarının Bulunması.” International Conference on Computer Science and Engineering (UBMK 2016) (Tam Metin Bildiri)
13. Önder M. ve İnik Ö., (2016). “Note Recognition from Monophonic Musical Signals By Using Neural Network.” 3rd International Conference on Advanced Technology Sciences (ICAT16) (Tam Metin Bildiri)
14. İnik Ö. ve Önder M., (2016). “Yapay Sinir Ağı ile Kırma Bomlu Vinçlerin Bomlarını Çekme Anındaki Yük Tahmini.” International academic research congress (Tam Metin Bildiri)
15. İnik Ö., Özkan İ. ve Ünal E.,(2014). “Development of computer software based on RMR Q and M RMR Classification Systems Used for Rock Mass Characterization ROCKMASS V2 0.” 14th International Conference of the International Association for Computer Methods and Advances in Geomechanics(IACMAG) (Tam Metin Bildiri)(Yüksek Lisans Tezinden yapılmıştır)