

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



DERİN ÖĞRENME TEKNİKLERİ KULLANILARAK
RATLARDA ÖSTRUS DÖNEMLERİNİN YOLOv5 MODELİ
İLE SINIFLANDIRILMASI

Şeyma ÇEÇEN

Yüksek Lisans Tezi

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

Yazılım Bilim Dalı

TEMMUZ 2023

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Bilgisayar Mühendisliği Anabilim Dalı

Yüksek Lisans Tezi

DERİN ÖĞRENME TEKNİKLERİ KULLANILARAK RATLARDA
ÖSTRUS DÖNEMLERİNİN YOLOv5 MODELİ İLE
SINIFLANDIRILMASI

Tez Yazarı
Şeyma ÇEÇEN

Danışman
Prof. Dr. Ahmet Bedri ÖZER

İkinci Danışman
Doç. Dr. Songül ÇERİBAŞI

TEMMUZ 2023
ELAZIĞ

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Bilgisayar Mühendisliği Anabilim Dalı

Yüksek Lisans Tezi

Başlığı:	Derin Öğrenme Teknikleri Kullanılarak Ratlarda Östrus Dönemlerinin YOLOv5 Modeli İle Sınıflandırılması
Yazarı:	Şeyma ÇEÇEN
İlk Teslim Tarihi:	12.06.2023
Savunma Tarihi:	05.07.2023

TEZ ONAYI

Fırat Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına göre hazırlanan bu tez aşağıda imzaları bulunan jüri üyeleri tarafından değerlendirilmiş ve akademik dinleyicilere açık yapılan savunma sonucunda OYBİRLİĞİ ile kabul edilmiştir.

Danışman:	Prof. Dr. Ahmet Bedri ÖZER Fırat Üniversitesi, Mühendislik Fakültesi	<i>İmza</i> Onayladım
Başkan:	Prof. Dr. Taner TUNCER Fırat Üniversitesi, Mühendislik Fakültesi	Onayladım
Üye:	Dr. Öğr. Üyesi Mehmet Şahin AÇIKKAPI Munzur Üniversitesi, Mühendislik Fakültesi	Onayladım

Bu tez, Enstitü Yönetim Kurulunun/...../20..... tarihli toplantısında tescillenmiştir.

İmza

Prof. Dr. Burhan ERGEN
Enstitü Müdürü

BEYAN

Fırat Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına uygun olarak hazırladığım “Derin Öğrenme Teknikleri Kullanılarak Ratlarda Östrus Dönemlerinin YOLOv5 Modeli İle Sınıflandırılması” Başlıklı Yüksek Lisans Tezimin içindeki bütün bilgilerin doğru olduğunu, bilgilerin üretilmesi ve sunulmasında bilimsel etik kurallarına uygun davrandığımı, kullandığım bütün kaynakları atıf yaparak belirttiğimi, maddi ve manevi desteği olan tüm kurum/kuruluş ve kişileri belirttiğimi, burada sunduğum veri ve bilgileri unvan almak amacıyla daha önce hiçbir şekilde kullanmadığımı beyan ederim.

05.07.2023

Şeyma ÇEÇEN



ÖNSÖZ

Ratlar insan hastalıklarını modellemek, keşfetmek ve ilaç geliştirmek amacıyla sıklıkla tercih edilmektedir. Uterus dokusundaki östrus dönemlerindeki değişimlerin izlenmesi ve sınıflandırılması üreme sistemi ile ilgili hastalıkların anlaşılmasını sağlar. Ergenlik dönemine ulaşan dişilerin uterus ve ovaryum dokularında hormonlara bağlı olarak bazı değişiklikler görülmektedir. Üreme sistemindeki hastalıkların nedenleri, gelişimleri ile doku ve hücrelerde meydana getirdiği yapısal değişimleri inceleyen bilim dalı olan Patoloji bilimi ise bu alanda faaliyet göstermektedir. Medikal alanda görüntüleme teknolojinin gelişmesi ile birlikte yapay zeka destekli sistemlerin kullanım alanı da genişlemektedir. Mikroskop altında incelenen numunelerin zaman alması sebebiyle patoloğların iş yükü artmaktadır. Çalışmamız bu anlamda tanı nesnelliğini koruyarak uzman patoloğlara derin öğrenme teknikleri tabanlı ikinci bir görüş desteği sunmayı hedeflemektedir.

Öncelikle çalışmalarım süresince vakit ayırarak sorularımı cevaplayan, bilgi ve deneyimleri ile beni yönlendiren, konu seçimimde yardımcı olan, akademik alanda bakış açımı genişleten danışman hocalarım Sayın Prof. Dr. Ahmet Bedri ÖZER' e ve Doç. Dr. Songül ÇERİBAŞI 'na çok teşekkür ederim.

Son olarak üzerimde büyük emekleri olan her zaman ve her koşulda desteklerini yanımda hissettiğim ve hiçbir zaman haklarını ödeyemeyeceğim çok değerli aileme sonsuz teşekkürlerimi sunarım.

Tezimi aileme ithaf ediyorum.

Şeyma ÇEÇEN
ELAZIĞ, 2023

İÇİNDEKİLER

Sayfa

ÖNSÖZ.....	iv
İÇİNDEKİLER	v
ÖZET	vii
ABSTRACT	viii
ŞEKİLLER LİSTESİ	ix
TABLolar LİSTESİ	x
KISALTMALAR	xi
1. GİRİŞ	1
2. LİTERATÜR TARAMASI	3
3. DERİN ÖĞRENME	7
3.1. Evrişimli Sinir Ağı (ESA)	7
3.1.1. Giriş Katmanı	8
3.1.2. Konvolüsyon Katmanı.....	8
3.1.3. ReLU katmanı	9
3.1.4. Havuzlama Katmanı.....	10
3.1.5. Düzleştirme Katmanı.....	11
3.1.6. Tam Bağlı Katman	11
3.1.7. Dropout Katmanı.....	11
3.1.8. Normalizasyon Katmanı.....	12
3.1.9. Sınıflandırma Katmanı	12
3.2. Derin Öğrenmede Hiperparametreler	12
3.2.1. Veri Setinin Boyutu.....	13
3.2.2. Aktivasyon Fonksiyonları	13
3.2.3. Eğitim Devir (Tur) Sayısı.....	13
3.2.4. Parti Boyutu	13
3.2.5. Öğrenme Oranı.....	14
3.2.6. Optimizasyon Algoritmaları.....	14
4. MATERYAL VE METOT	15
4.1. Veri Seti.....	15
4.1.1. Östrus Dönemleri	16
4.2. Yöntem	17
4.3. Veri Ön İşleme	18
4.3.1. Veri Arttırma Yöntemleri.....	18
4.3.2. Veri Boyutlandırma.....	19
4.3.3. Veri Setinin Eğitime Göre Ayrılması	19
4.4. YOLOv5 Mimarisi ile Sınıflandırma.....	20
4.5. Performans Değerlendirme Metrikleri.....	21
5. BULGULAR VE TARTIŞMA	24
5.1. YOLOv5n Modeli ile Sınıflandırma Sonucu Elde Edilen Bulgular	26
5.2. YOLOv5s Modeli ile Sınıflandırma Sonucu Elde Edilen Bulgular.....	27
5.3. YOLOv5m Modeli ile Sınıflandırma Sonucu Elde Edilen Bulgular	28

6. SONUÇLAR.....	32
KAYNAKLAR.....	33
ÖZGEÇMİŞ	



ÖZET

Derin Öğrenme Teknikleri Kullanılarak Ratlarda Östrus Dönemlerinin YOLOv5 Modeli İle Sınıflandırılması

Şeyma ÇEÇEN

Yüksek Lisans Tezi

FIRAT ÜNİVERSİTESİ
Fen Bilimleri Enstitüsü

Bilgisayar Mühendisliği Anabilim Dalı

Temmuz 2023, Sayfa: xi + 34

Evrişimsel Sinir Ağları tabanlı derin öğrenme teknikleri kullanılarak dişi ratlarda uterus görüntüleri kullanılarak östrus evrelerinin doğru bir şekilde sınıflandırılması amaçlanmıştır. İnsanlarda 28 günlük menstrüel döngünün, ratlarda 4-5 günde bitmesinden dolayı, özellikle kadın üreme sistemi ile ilgili çalışmalar başta olmak üzere; model organizma olarak birçok çalışmada bu hayvan türü deney hayvanı olarak tercih edilmektedir. Çalışmada, dişi ratların uterus dokusuna ait Hematoksilen Eozin ile boyalı kesitlerin, ışık mikroskopunda görüntüleri alınmıştır. Elde edilen görüntüler ile ratlardaki östrus dönemleri histolojik olarak sınıflandırılmıştır. Yapılan incelemenin ardından uterus kesitlerinden elde edilen görüntülerde ratlardaki östrus dönemlerinin sınıflandırılmasında yapay zeka tabanlı bir model önerilmiştir. Çalışmada östrus dönemi proöstrus, östrus, metöstrus ve diöstrus olmak üzere dört faz olarak sınıflandırılmaktadır. Önerilen modelde YOLOv5 algoritmasına ait YOLOv5n, YOLOv5s, YOLOv5m gibi alt modellerin sınıflandırma başarısı histolojik sonuçlar ile karşılaştırılmıştır. YOLOv5m modeli ile sınıflandırmada %98.3 oranında doğruluk, %99 oranında kesinlik, %98 oranında duyarlılık ve %98 oranında F1-puan değerleri elde edilmiştir. Elde edilen sonuçlar önerilen modelin mikroskopik görüntülerin analizinde uzman patoloğlara ikinci bir görüş desteği sağlayacağını göstermektedir.

Anahtar Kelimeler: Derin Öğrenme, Östrus Dönemleri, Sınıflandırma, Uterus, YOLOv5

ABSTRACT

Classification of Oestrus Periods in Rats with the YOLOv5 Model Using Deep Learning Techniques

Şeyma ÇEÇEN

Master's Thesis

FIRAT UNIVERSITY
Graduate School of Natural and Applied Sciences
Department of Computer Engineering

July 2023, Pages: xi + 34

The aim of the present study was to accurately detect estrus phases in female rats using uterine images using deep learning techniques based on Convolutional Neural Networks. Since the 28-day menstrual cycle in humans ends in 4-5 days in rats, this animal species is preferred as a model organism in many studies, especially in studies related to the female reproductive system. In this study, images of Hematoxylin Eosin stained sections of the uterine tissue of female rats were taken under light microscope. With the images obtained, estrus periods in rats were classified histologically. After the examination, an artificial intelligence-based model was proposed for the classification of estrus periods in rats in the images obtained from uterine sections. In the study, the estrous period is classified into four phases: proestrus, estrus, metestrus and diestrus. In the proposed model, the classification success of sub-models of the YOLOv5 algorithm such as YOLOv5n, YOLOv5s, YOLOv5m were compared with histological results. With the YOLOv5m model, 98.3% accuracy, 99% precision, 98% recall and 98% F1-score values were obtained. The results show that the proposed model will provide a second opinion support to expert pathologists in the analysis of microscopic images.

Keywords: Classification, Deep Learning, Estrous Periods, Uterus, YOLOv5

ŞEKİLLER LİSTESİ

	Sayfa
Şekil 3.1. Evrişimli Sinir Ağı Mimarisi	8
Şekil 3.2. Evrişim İşlemi.....	9
Şekil 3.3. Aktivasyon Fonksiyonu [21].....	10
Şekil 3.4. Maksimum ve Ortalama Havuzlama İşlemi.....	10
Şekil 3.5. Düzleştirme (Flatten) Katmanı	11
Şekil 3.6. Normal ve Dropout Katmanı Uygulanan Sinir Ağı Modeli.....	12
Şekil 4.1. Uterus Dokusuna ait Görüntülerin Elde Edilme Süreci	15
Şekil 4.2. Östrus Dönemlerindeki Sınıflara ait Örnekler	16
Şekil 4.3. Önerilen Yöntem Aşamaları	17
Şekil 4.4. Veri Arttırım Yöntemleri Uygulaması.....	18
Şekil 4.5. Arttırılmış Veri Sayıları	19
Şekil 4.6. YOLOv5 Ağı Mimarisi.....	20
Şekil 4.7. İkili Sınıf için Karışıklık Matrisi.....	22
Şekil 5.1. YOLOv5 Modeline Göre Eğitim Doğruluk Grafiği.....	24
Şekil 5.2. YOLOv5 Modeline Göre Eğitim-Test Kayıp Grafikleri.....	25
Şekil 5.3. YOLOv5n Modelinde Eğitilen Diöstrus Sınıfına ait Örnek Görüntüler	26
Şekil 5.4. YOLOv5n Modeli Eğitim Sonuçlarına Göre Karışıklık Matrisleri.....	27
Şekil 5.5. YOLOv5s Modelinde Eğitilen Diöstrus Sınıfına ait Örnek Görüntüler.....	28
Şekil 5.6. YOLOv5s Modeli Eğitim Sonuçlarına Göre Karışıklık Matrisleri	28
Şekil 5.7. YOLOv5m Modelinde Eğitilen Sınıflara ait Örnek Görüntüler	29
Şekil 5.8. YOLOv5m Modeli Eğitim Sonuçlarına Göre Karışıklık Matrisleri	30
Şekil 5.9. Östrus Dönemlerine ait Tahmin Oranı Düşük Sonuçlar	30

TABLÖLAR LİSTESİ

	Sayfa
Tablo 2.1. Patolojik Görüntüler ile Yapılan Derin Öğrenme Çalışmalarına Genel Bakış.....	6
Tablo 5.1. YOLOv5 Alt Modellerinin Uterus Veri Seti'ne Göre Eğitim Metrikleri.....	24
Tablo 5.2. YOLOv5 Modeli Eğitim Parametre Değerleri.....	25
Tablo 5.3. YOLOv5n Modeline Göre Eğitilen Verilerin Test Sonuçları	26
Tablo 5.4. YOLOv5s Modeline Göre Eğitilen Verilerin Test Sonuçları.....	27
Tablo 5.5. YOLOv5m Modeline Göre Eğitilen Verilerin Test Sonuçları	29
Tablo 5.6. Yapılan Çalışma ve Diğer Yöntemlerin Karşılaştırılması.....	31

KISALTMALAR

CBL	: Konvolüsyon + BatchNormalization + ReLU
CONCAT	: Birleştirme İşlevi
CONV	: Evrişim Katmanı
CSP	: Çapraz Aşamalı Kısmi Ağ
DÖ	: Derin Öğrenme
ESA	: Evrişimli Sinir Ağı
FN	: Yanlış Negatif
FP	: Yanlış Pozitif
GPU	: Graphics Processing Unit
R-CNN	: Region-Based Convolutional Neural Networks
ReLU	: Düzleştirilmiş Doğrusal Birim
RGB	: Kırmızı-Yeşil-Mavi
SPP	: Uzamsal Piramit Havuzu
TN	: Doğru Negatif
TP	: Doğru Pozitif
UMT	: Rahim Düz Kas Tümörleri
YOLO	: You Once Look Once

1. GİRİŞ

Bakım ve besleme kolaylığı, yaşam ve gebelik sürelerinin kısalığı, elde edilen verilerin diğer canlılar için model oluşturması gibi sebeplerden dolayı ratlar; deneysel çalışmalarda yaygın olarak kullanılmaktadır. Puberta yani ergenlik dönemine ulaşan bir dişide hormonların kontrolü altında ovaryum ve uterus dokularında bir takım değişiklikler meydana gelir. Memeli hayvanlar, tür ve yaşlarına bağlı olarak farklı aralıklarda östrus gösterirler. Birbirini takiben iki östrus evresinin başlangıcı arasındaki süre östrus siklusu ya da östrus dönemi olarak ifade edilir [1]. İnsanlarda 28 günlük menstrüel döngünün, ratlarda 4-5 günde bitmesinden dolayı, kadın üreme sistemi ile ilgili çalışmalarda; bu hayvan türü model organizma olarak birçok çalışmada tercih edilmektedir. Ratlarda östrus siklusu, proöstrus, östrus, metöstrus ve diöstrus olmak üzere başlıca 4 fazdan oluşmaktadır [2], [3].

Günümüzde yapay sinir ağlarını temel alan, derin öğrenme çalışmaları pek çok farklı alanda olduğu gibi veterinerlik ve tıp alanında da yaygın olarak kullanılmaya başlanmıştır [4]. Bu alanlar geleneksel yaklaşım olarak öncelikle hastalığa tanı konulması ve tanıya yönelik tedavi yöntemlerinin uygulanması esasına dayanmaktadır. İnsanlardaki hücre, doku ve organlarındaki değişimleri ve nedenlerini inceleyen bilim dalı olan Patoloji ise bu alanda faaliyet göstermektedir.

Mikroskobun keşfi ile başlayan süreçte patolojik tanı yöntemi bu alanda kullanılan araçlardan biridir. Doku ve hücre incelemeleri ile patolojik tanı incelemesi ön koşul haline gelmiştir. İlgili dokulardan farklı yöntemlerle alınan kesitler ile laboratuvar incelemesi sonucu tanı konulabilmektedir. Bu anlamda dijital patoloji kavramı ortaya çıkmaktadır. Mikroskoplar ile cam lamalar taranarak elde edilen görüntüler patologlar tarafından yorumlanmaktadır. Dijital ortama aktarımı sayesinde cam halinde hassas ve kırılmaya müsait olan lam şeklindeki verilerin korunarak farklı patologlar tarafından yorumlanmasına imkan sağlanmaktadır.

Dijital ortama aktarılan patolojik görüntülerin sağladığı faydalardan en önemlisi yapay zeka destekli sistemler için girdi verisi olarak kullanılabilmesidir[5].

Özetle bu çalışmanın literatüre katkıları şunlardır :

- Spesifik olarak uterus dokusu üzerinde östrus dönemlerinin incelenmesi için oluşturulan özgün bir veri seti oluşturulmuştur.
- Tıp, veterinerlik ve bilgisayar bilimleri gibi disiplinler arası alanları bir araya getiren ortak bir çalışma ortaya konulmuştur.
- Nesne Tespiti için kullanılan YOLOv5 modeli sınıflandırıcı olarak kullanılmıştır.
- Uterus dokusuna ait östral evrelerin sınıflandırılmasında yüksek doğruluk elde edilmiştir. Bu sonuç modelin uzman patologlara ikinci bir görüş desteği sağlayacağını göstermiştir.

Çalışmada yapısal olarak, ilk bölümde östrus dönemlerinin sınıflandırılmasında dijital patolojik görüntü analizi ve kullanım alanına vurgu yapılarak başlamaktadır. İkinci bölüm olan literatür taraması içerisinde bu alanda yapılan odak noktası sınıflandırma olan literatürdeki çalışmalar ve alınan başarı oranları sunulmuştur. Üçüncü bölümde çalışmada kullanılan yöntemin anlaşılması ve ön bilgi olması amacıyla derin öğrenme başlığı altında evrişimli sinir ağı yapısı, katmanları ve derin öğrenmede kullanılan parametreler açıklanmıştır. Dördüncü bölümde çalışmamızda kullanılan yöntem ve metotlar açıklanarak sırasıyla veri seti ön işlem süreçleri, kullanılan YOLOv5 mimarisi ve performans değerlendirme metrikleri detaylı olarak açıklanmıştır. Beşinci bölüm olan bulgular ve tartışma bölümünde tercih edilen modele ilişkin deneysel sonuçlar değerlendirilmiştir. Altıncı bölüm olan sonuçlar bölümünde ise yöntemin başarısı ve kullanım alanının önemine ilişkin özet şeklinde genel bir değerlendirme ve öneri yapılmıştır.



2. LİTERATÜR TARAMASI

Derin öğrenme teknikleri kullanılarak evrişimli sinir ağları tabanlı literatürde pek çok farklı doku üzerinde yapılan çalışma bulunmaktadır. Çalışma kapsamında bu alanda literatürde yapılan güncel çalışmalar incelenmiştir. Literatürdeki çalışmalar özellikle olarak doku ve yöntem odaklı araştırılmıştır. İncelenen çalışmalar belirli parametrelere göre özet tablo halinde sunulmuştur.

İnik ve ark. [6] tarafından 2019 yılında yapılan çalışmada ESA mimarisi kullanılarak ovaryum dokusuna ait tam slayt görüntüleri üzerinde folikül sayımı için yeni bir yöntem önerilmiştir. Öncelikle çalışmada tam slayt görüntüleri üzerinde filtre uygulanarak segmentasyon işlemi gerçekleştirilmiştir. Segmentasyon işlemi sonrasında sınırları belirlemek için yeni bir yöntem önerilerek sınırları belirlenen foliküller için sınıflandırma işlemi uygulanmıştır. Önerilen yöntem Faster R-CNN modeline göre başarılı olduğu belirtilmektedir. Çalışmada deney hayvanlarından elde edilen ovaryum dokusu kullanılmıştır. OLYMPUS BX51 optik mikroskobu kullanılarak hematoksilin ve eozin boyalı kesitlerden farklı büyütme oranlarına (x10, x20, x40) sahip toplam 1972 görüntü elde edilmiştir. Eğitim için rastgele seçilen 1750 görüntü ve test için 222 görüntü kullanılmıştır. Veri seti görüntüleri $4080 \times 3072 \times 3$ boyutunda olup sonrasında en başarılı modelin çalıştığı $1024 \times 1024 \times 3$ boyutuna düşürülmüştür. 1750 tam slayt eğitim görüntüsünden primordial, primer, preantral, sekonder ve tersiyer foliküllerin görüntüleri 5 sınıflı olarak elde edilmiştir. Ortalama 3280 adet olan her bir folikül dahil olmak üzere toplam 16404 adet görüntü elde edilmiştir. Önerilen yöntemin ortalama doğruluğu %95.35 olarak tespit edilmiştir. Histopatolojik görüntüleri analiz etmek için önerilen yöntemin başarılı olduğu belirtilmektedir.

2019 yılında yapılan endometrium (rahim iç zarı) dokusuna ait bir başka çalışmada histopatolojik görüntüler kullanılarak HIENet adı verilen evrişimsel sinir ağı tabanlı bilgisayar destekli tanı üzerine çalışılmıştır. Bu çalışmada Sun ve ark. [7] tarafından 10x veya 20x büyütmede yakalanan yüksek çözünürlüklü dijital patolojik görüntüler kullanılmıştır. Dokular (normal) endometrium, endometrial polip, endometriyal hiperplazi ve endometrial adenokarsinom olarak sınıflandırılmıştır. Görüntüler mimarinin boyut gereksinimini karşılamak için her giriş görüntüsü 224×224 piksel olarak boyutlandırılmıştır. HIENet modeli dört sınıflı sınıflandırma görevinde %84,50 doğruluk değeri ve %77,97 hassasiyet değeri elde edilmiştir.

Rui ve ark. [8] tarafından 2020 yılında meme kanseri tümör türünü histopatolojik görüntü sınıflandırma işlemi için evrişimli hibrit bir derin sinir ağı modeli önerilmiştir. Başlangıçta 2048×1536 boyutundaki 249 adet patolojik görüntüden oluşan veri seti normal, iyi huylu, in situ carcinoma, invaziv carcinoma olmak üzere 4 sınıf olarak gruplandırılmıştır. Görüntü sayısı daha sonra arttırılarak toplamda 4020 adet görüntü elde edilmiştir. Çalışmada meme kanserine ait histopatolojik görüntüler kullanılarak %91.3 doğrulukla iyi sonuçlar verdiği belirtilmiştir.

2021 yılında yapılan bir çalışmada parazitoz denilen insan vücudunu istila eden parazitlerin neden olduğu hastalıkların tespitinde YOLOv5 modeli kullanılmıştır. Huo ve ark. [9] tarafından yapılan bu çalışmada insan dışkı mikroskopik görüntülerinde parazit yumurtalarının tanınması ve sınıflandırılması amaçlanmıştır. Görüntü elde etme sürecinde Olympus CX31 biyolojik mikroskop ve EXCCD kamera kullanılmıştır. Elde edilen 1360x1024 boyutundaki görüntüler üzerinden 512x512 piksellik kesitler elde edilerek YOLOv5 modeli uygulanmıştır. 8 sınıflı çalışmada görüntülerin 236'sı eğitim için ve 45'i test için olmak üzere toplam 281 örnek görüntü kullanılmıştır. Deneysel sonuçlar neticesinde uygulanan modelin ortalama doğruluğu %99,4 olarak tespit edilmiştir.

YOLOv5 tabanlı bir başka çalışmada ise histopatoloji görüntülerinde meme kanseri tespiti üzerine çalışılmıştır. Drioua ve ark. [10] tarafından 2022 yılında yapılan bu çalışmada veri seti olarak erişime açık histopatolojik görüntülerden oluşan 512x512 boyutundaki veriler kullanılmıştır. Görüntüler üzerinde yeniden boyutlandırma, gri tonlama, otomatik yönlendirme, kontrast vb. işlemler ile veri artırma yöntemleri uygulanmıştır. YOLOv5 modeli kullanılarak kanserli lezyonların erken tespitinde etkili sonuçlar elde edildiği belirtilmiştir.

Prostat kanseri anormal hücrelerinin hızlı tespiti ve tarama etkinliğini arttırmak için Huang ve ark.[11] tarafından 2022 yılında yapılan çalışmada iki aşamalı yöntem kullanılmıştır. Çalışmada anormal hücre görüntülerinin ön taraması ve anormal hücrelerin doğru tanımlanması üzerine yoğunlaşmıştır. Veri seti olarak 2000 piksel x 2000 piksellik 11.550 patolojik hücre görüntüsü üzerinden çalışılmıştır. Sınıflandırma aşamasında kullanılan modellerden genel doğruluk oranı en yüksek ResNet101 modeli olduğu ifade edilmiştir. Diğer bazı modellerin çok sayıda parametreye sahip olduğu, model yapılarının karmaşık olduğu ve eğitimde aşırı uyum durumunun ortaya çıktığı belirtilmiştir. Uygulanan ShuffleNet modelinde ise model parametrelerinin küçük olması , hesaplama maliyetinin küçük olması ve modelin basit yapıda olmasına bağlı olarak muhakeme süresinin az olduğuna değinilmiştir. Ön tarama aşamasında görüntünün anormal hücre kümeleri içerip içermediğini belirlemek için görüntü sınıflandırma ağı olarak ResNet50 modeli uygulanmıştır. Diğer aşamada anormal hücre kümelerini bulmak ve tespit etmek için YOLOv5 modeli kullanılmıştır. Çalışmada çift aşamalı modellerin anormal hücre tespit etkinliğini arttırdığı ve %50 oranında muhakeme süresini kısalttığı belirtilmiştir. Buna göre precision (kesinlik) parametresi %86, recall (Duyarlılık) parametresi doğruluk değeri %77 olarak bulunduğu belirtilmiştir.

Mide kanseri hücrelerinin patolojik tespitinde ise Guo ve ark. [12] tarafından yapılan çalışmada derin öğrenme modeli üzerine çalışıldığı görülmektedir. 2023 yılında yapılan çalışmada YOLOv5 modeli kullanılarak geliştirilen modelin test sonucu F1 score'un 0,616 olduğunu, mAP'nin 0,611 olduğu, precision parametresi 0,581 ve recall parametresinin 0,656 olduğu belirtilmiştir. Bu anlamda klinik muhakeme için karar desteği sağlayabileceği sonucu çıkarılmıştır.

Derin öğrenme tabanlı 2023 yılında yapılan başka bir çalışmada servikal hücre sınıflandırması üzerine çalışılmıştır. Xu ve ark. [13] tarafından yapılan çalışmada servikal hücre yayma görüntülerinin tanıma doğruluğunu artırmak için, ilk olarak, veri özelliği dönüşümünün sağlamlığını artırmak için küresel bir ortalama havuzlama katmanı kullanılmıştır. İkinci olarak, zayıf hücrelerin lokalizasyonunu ve tanınmasını iyileştirmek için yüzeysel bir özellik geliştirme ağı tasarlandığı belirtilmektedir. Son olarak, modelin algılama kabiliyetini geliştirmek için veri arttırma yöntemleri uygulanmıştır. Deneysel sonuçlara göre önerilen model kısa zaman tüketimi, daha yüksek tanıma hassasiyeti ve daha güçlü uyarılma yeteneği gibi bazı yönleriyle CenterNet, YOLOv5 ve Faster R-CNN algoritmalarından üstün olduğu belirtilmektedir. Veri seti olarak kullanılan 4807 örnek içeren SIPaKMeD ve Herlev veri kümeleri içerisindeki hücreler sitopatologlar tarafından hücre özelliklerine göre normal, anormal ve iyi huylu olarak ayrılmıştır. Önerilen model sonucunda kullanılan veri setleri için maksimum doğruluk oranı %99,81 ve genel ortalama kesinlik oranı %89,4 olarak elde edilmiştir.

Rahim düz kas tümörleri (UMT) için literatürde derin öğrenme kullanılarak yapay zeka destekli tespit yöntemi önerilmiştir. Yu ve ark. [14] tarafından 2023 yılında yapılan bu çalışmada hematoksin ve eozin ile boyanmış belirsiz malign potansiyeline sahip 233 adet leiomyosarkomlar, 108 adet leiomyomlar ve 30 adet düz kas tümörlerine ait dijital patolojik tam slayt görüntüleri üzerinde çalışılmıştır. Görüntüler 224x224 boyutlarında küçük bloklar halinde kırılmıştır. ResNet modeli sitolojik atopi ve nekroz için sınıflandırma ağı olarak kullanılırken mitoz sayımında otomatik algılama ağı için YOLOv5 modeli kullanılmıştır. Araştırmacılar kesinlik, geri çağırma ve F1 indeksi gibi parametrelerde %92'nin üzerinde başarı oranı elde edilmiştir.

Çeçen ve Özer [15] tarafından 2023 yılında yapılan çalışmada patolojik meme kanseri görüntülerinin sınıflandırılması üzerine çalışılmıştır. İyi huylu ve kötü huylu olmak üzere iki sınıflı gruplanmış veriler için derin öğrenme modellerinden YOLOv5 tercih edilmiştir. Kaggle üzerinde erişime açık olarak kullanılan veri seti içerisindeki 1693 adet görüntü 224x224 piksel olarak yeniden boyutlandırılmıştır. Verilerin %70'i eğitim, %20'si doğrulama ve %10'u test verisi olarak ayrılmıştır. Deneyler sonucunda doğruluk değeri olarak %95.3 oranında başarı elde edildiği sunulmuştur. Patolojik görüntüler üzerinde tümör türünü sınıflandırmada tercih edilen modelin başarılı olduğu ifade edilmiştir.

Literatürde yapılan çalışmalarda doku türü, görüntü boyutu, kullanılan yöntem, sınıf sayısı, kullanılan model ya da algoritma ve elde edilen doğruluk değeri gibi parametrelere odaklanılmıştır. İncelenen ilgili çalışmalar ve bu çalışmalarda kullanılan parametreler Tablo 2.1 'de literatürde yapılan çalışmalar özet tablo halinde ilgili parametre değerlerine göre sunulmuştur.

Tablo 2.1. Patolojik Görüntüler ile Yapılan Derin Öğrenme Çalışmalarına Genel Bakış

Referans	Doku Türü	Görüntü Boyutu	Yöntem	Sınıf Sayısı	Model	Doğruluk
İnik ve ark. 2019 [6]	Ovaryum	1024x1024	Segmentasyon, Sınıflandırma	6	Faster R-CNN	%95.35
Sun ve ark. 2019 [7]	Rahim İç zarı	224x224	Sınıflandırma	4	HIENet	%84.50
Rui ve ark. 2020 [8]	Meme	2048×1536	Sınıflandırma	4	Inception-V3	%91.3
Huo ve ark. 2021 [9]	Dışkı	512x512	Nesne Tespiti	7	YOLOv5	%99.4
Drioua ve ark. 2022 [10]	Meme	512x512	Nesne Tespiti, Segmentasyon	2	YOLOv5	%89
Huang ve ark. 2022 [11]	Prostat	200x200	Sınıflandırma, Nesne Tespiti	5	ResNet50, YOLOv5	% 71.1
Guo ve ark. 2023 [12]	Mide	640X640	Nesne Tespiti	9	YOLOv5	%61.1
Xu ve ark. 2023 [13]	Servikal Hücre	512x512	Nesne Tespiti	8	GAN	%99.81
Yu ve ark. 2023 [14]	Rahim Düz Kası	224x224	Sınıflandırma, Nesne Tespiti	3	ResNet, YOLOv5	%92
Çeçen ve Ozer 2023 [15]	Meme	224x224	Sınıflandırma	2	YOLOv5	%95.3

Literatürde yapılan çalışmalar incelendiğinde sınıflandırma alanında evrişimli sinir ağları (ESA) tabanlı model ve mimarilerdeki yüksek doğruluk oranı ve düşük kayıp oranları ile başarı sağlandığı görülmektedir. ESA tabanlı katmansal mimarinin kullanımı ile görüntülere ait farklı özelliklerin çıkarımı modelin başarısını ve tahmin gücünü arttırmaktadır.


3. DERİN ÖĞRENME

Derin Öğrenme (DÖ) , bilgisayarların görme ve duyma gibi karmaşık algılama görevlerini insan düzeyinde doğrulukla öğrenmesini sağlayan teknikler geliştirmeyi hedefleyen yapay zekanın bir dalıdır. Derin öğrenme, insan gibi düşünerek karar veren sistemler oluşturmak için makine öğrenmesi algoritmalarından faydalanmaktadır. Derin öğrenme, insan beynine benzer bir yapıyı modelleyerek öğrenme ve karar verme süreçlerini gerçekleştirmeyi amaçlamaktadır. Derin öğrenme yöntemleri, tıp alanında görüntü sınıflandırma, nesne tespiti ve segmentasyon gibi görevler için sık olarak kullanılmaktadır [16]. Görüntü sınıflandırma, nesne algılama, konuşma tanıma, doğal dil işleme, araç ve yaya algılama ve daha pek çok konuda insan düzeyine yakın doğruluk sağlamaktadır. Genel, sağlam ve güvenilir özellikleri belirli nesne türleriyle eşleştirmek zor olduğundan sınıflandırma işlemi için herhangi bir türdeki nesne için doğru özellik kombinasyonunu bulmak önem arz etmektedir. Bu yönüyle görüntüdeki nesnelerin ötelenmesine, döndürülmesine ve ölçeklenmesine dayalı işlevleri tasarlamak gerekmektedir. Tüm bu problemler, çok çeşitli nesneler için yüksek doğrulukta nesne tanıma ve sınıflandırıcılar geliştirmeyi fazlasıyla zorlaştırmaktadır. Öte yandan derin öğrenme yaklaşımı, tanınacak her bir nesne sınıfı için hangi özelliklerin ve özellik kombinasyonlarının ayırt edici olduğunu keşfetmek için çok sayıda gerçek etiketli veriden yararlanır ve birleşik bir özellik çıkarma ve sınıflandırıcı oluşturur. Bu şekilde elde edilen model, yalnızca üzerinde eğitildiği belirli nesneleri sınıflandırmak için değil, aynı zamanda onlara benzer daha önce görülmemiş nesneleri tanımak için de kullanıma sunulabilir [17].

3.1. Evrişimli Sinir Ağı (ESA)

Çok katmanlı algılayıcının özel bir türü olan ve insan görme sisteminin modellemesiyle oluşturulan evrişimli sinir ağları (ESA) ise günümüzde bilgisayarlı görü alanında en başarılı sonuçları elde etmesi nedeniyle yaygın olarak kullanılmaktadır. Nesne tanıma, sınıflandırma, takip etme, doğal dil işlemede anlam ayrıştırma, cümle modelleme, tahmin problemlerinde kullanılan evrişimli sinir ağları, aynı zamanda Google DeepMind şirketinin AlphaGo yazılımında da kullanılmıştır [18]. Evrişimli Sinir Ağları (ESA) derin öğrenmede yüksek başarı sağlanan modellerinden biridir. ESA, en basit tanımıyla bir giriş görüntüsü girdi olarak alınarak, görüntüdeki farklı nesneleri birbirinden ayırt edebilen derin öğrenme modelidir. Evrişimli Sinir Ağı mimarisi, birden fazla katmandan oluşmaktadır. ESA modelinde alınan giriş görüntüsü konvolüsyon işlemi ile aslında her bir görüntüyü matris şeklinde işlemektedir. Matris formundaki görüntü üzerinden özellik çıkarımı sağlanarak belirli bir sınıf içerisine dahil edilmesi sağlanır. Böylece evrişimsel sinir ağı modeli çıkarılmış olur. Genel olarak bir ESA mimarisi Şekil 3.1’de belirtildiği gibi sırasıyla

girdi, konvolüsyon, havuzlama, aktivasyon ve sınıflama katmanlarından oluşmaktadır. Modelin aşamaları ilerleyen bölümde alt başlıklar halinde detaylı olarak açıklanacaktır.



Şekil 3.1. Evrişimli Sinir Ağı Mimarisi

3.1.1. Giriş Katmanı


ESA mimarisinin ilk katmanı olup giriş olarak verilen her bir örneklem ağın eğitimi için kullanılır. Giriş verisi modelin başarımı üzerinde önemli bir etkidir. Kullanılan veri setinin boyutu ağın hızını, test süresini ve bellek ihtiyacı gibi parametrelerini etkilemektedir [19]

3.1.2. Konvolüsyon Katmanı

Konvolüsyon katmanı ESA 'ların temelini oluşturan katmandır. Evrişim katmanı (CONV) evrişim işlemlerini gerçekleştiren filtreleri, giriş verisinin boyutlarına göre tararken kullanır. Hiperparametreleri, F filtre boyutunu ve S adımını içerir. Elde edilen çıktı, öznitelik haritası veya aktivasyon haritası olarak adlandırılır. İki boyutlu bilgiye uygulanacak olan filtrenin x ve y eksenine göre simetrisi alınır. Matristeki tüm değerler eleman eleman çarpılır ve tüm değerlerin toplamı çıkış matrisinin ilgili elemanı olarak kaydedilir. Bu işlem çapraz korelasyon ilişkisi olarak da tanımlanmaktadır. Giriş verisi tek kanallı iken bu işlem basitçe yapılabilir. Ancak giriş verisi farklı formatlarda ve kanal sayısında olabilir [20].

Renkli görüntüler Kırmızı-Yeşil-Mavi (RGB) 3 kanaldan meydana gelmektedir. Bu şartlarda evrişim işlemi 3 kanal için yapılır. Çıkış işaretinin kanal sayısı da uygulanan filtre kanalı/sayısı ile eşit olarak hesaplanır. Bu hesaplama işlemini sinir ağındaki bir katman olarak düşünülebilir. Giriş görüntüsü ve filtre ile sürekli geri yayılımla güncellenen ağırlıklar matrisidir. Aktivasyon fonksiyonuna uygulanan çıkış matrisine en son skaler bir b (bias) değeri eklenir [18]. Örneğin, 128x128 renkli bir görüntü giriş olarak alacak olursak RGB kanalları ile gerçek boyutumuz 128x128x3 olacaktır. 5x5 evrişim filtresi giriş görüntüsü üzerinde piksel piksel

kaydırılarak tüm pikselleri gezecek şekilde, filtre katsayıları ile piksellerdeki renk değerleri çarpılıp bunların toplamı hesaplandığında aktivasyon haritası oluşmaktadır. Şekil 3.2 ‘de evrişim işlemi gösterilmektedir.




Şekil 3.2. Evrişim İşlemi

3.1.3. ReLU katmanı

Konvolüsyon katmanından sonra düzeltilmiş doğrusal birim katmanı olarak adlandırılan **ReLU katmanı**, doğrusal olmayan durumları modele uygulamasıyla bilinen aktivasyon fonksiyonunun gerçekleştiği katmandır. Doğrusal olmamaları ile ağıın öğrenmesi hedeflenir [20]. Bazı kaynaklarda konvolüsyon katmanı ve ReLU katmanı ayrı ayrı değerlendirilse de bütün bir adımı oluşturmaktadır. ReLU katmanına ait [21] matematiksel gösterimi Denklem 3.1 ‘de ifade edilmiştir.

$$f(x) = \begin{cases} 0 & \text{eğer } x < 0 \\ x & \text{eğer } x > 0 \end{cases} \quad (3.1)$$


ReLU katmanına ait aktivasyon fonksiyonu grafiği ise Şekil 3.3’te belirtilmiştir [21].



Şekil 3.3. Aktivasyon Fonksiyonu [21]

3.1.4. Havuzlama Katmanı


Görüntü işleme işleminde havuzlama katmanı uygulanırken önce kenar bulma, adım kaydırma ve son olarak havuzlama işlemi yapılmaktadır. Kenar bulma işlemi ile yoğunluk değişimlerinin olduğu bir yaklaşımı kullanır. Adım kaydırma işlemi ise uygulanan filtrenin giriş görüntüsü üzerinde nasıl hareket edeceğini belirtir [22]. Evrişimli sinir ağı mimarisinde havuzlama katmanı ile sonraki katman için giriş görüntüsünün boyutu azaltılır. Giriş boyutunun azaltılması bilgi kaybını beraberinde getirir. Bu işlem ile hesaplama yükünü azaltsa da aslında sistemin ezberlemesine engel olması amaçlanır [23]. Havuzlama katmanının ortalama, maksimum ve toplamsal havuzlama gibi türleri bulunmaktadır. Şekil 3.4’te ortalama havuzlama ve maksimum havuzlama yöntemi ifade edilmiştir.



Şekil 3.4. Maksimum ve Ortalama Havuzlama İşlemi

3.1.5. Düzleştirme Katmanı

Düzleştirme Katmanı (Flatten Layer) aşamasında tam bağlı katmanın girişindeki verileri hazırlamak amaçlanmaktadır. Sinir Ağları giriş verilerini genellikle tek boyutlu dizilerden almaktadır. Konvolüsyon ve havuzlama katmanı sonucunda elde edilen matrisler düzleştirme katmanı ile Şekilde 3.5 ‘te gösterildiği üzere tek boyutlu dizi haline dönüştürülür.




Şekil 3.5. Düzleştirme (Flatten) Katmanı

3.1.6. Tam Bağlı Katman

Tam Bağlı Katman (Fully Connected Layer) olarak adlandırılması kendinden önceki katmanda bulunan her bir nöronun sonraki katmandaki her bir nörona bağlı olma durumunu ifade etmektedir. Üst düzey özelliklere ait sahip girdi görüntülerini sınıflara ayırarak sınıflandırılmasını sağlayan önemli bir katmandır [16].

3.1.7. Dropout Katmanı

Dropout Katmanı diğer bir ifadeyle seyreltme katmanı ile tam bağlı katmanda oluşturulan bağlantıları sadeleştirerek ağın aşırı öğrenme sonucu ezber yapmasına engel olmak amacıyla uygulanan bir işlemdir [23]. Dropout katmanının kullanılması zorunlu olmayıp, kullanılması durumunda ağ üzerinde gerçekleştirilen sadeleştirme işlemi ile ağın performansını da arttırmaya yardımcı olacaktır. Şekil 3.6’da dropout katmanı uygulanmamış sinir ağı yapısı ile dropout uygulanan sinir ağı yapısı modellenmiştir.



Şekil 3.6. Normal ve Dropout Katmanı Uygulanan Sinir Ağı Modeli

3.1.8. Normalizasyon Katmanı

Normalizasyon (Batch Normalization) katmanı ile sistem performansının önemli olduğu ESA mimarisinde ağı optimize edilmesi amaçlanmaktadır [23].

3.1.9. Sınıflandırma Katmanı

Sınıflandırma (Softmax) katmanı önceki katmandan gelen değerleri alarak sınıflandırma işlemi için olasılıksal değer üretimi gerçekleştirilmesini sağlar. Sınıflandırma yaparken hangi sınıfa daha yakın olduğuna dair her sınıf için ayrı ayrı değerler üretilir [24].

3.2. Derin Öğrenmede Hiperparametreler

Evrişimli Sinir Ağı (ESA) mimarisi yapısını oluşturan katmanların yanında hiperparametrelerin kullanımı da önemli bir yere sahiptir. Modelin performansı, eğitim süresi ve başarı oranı gibi ölçütlerini etkilemektedir. Hiperparametreler kullanım yöntemi ve modeli kullanıcının tercihi bırakılan, veri setinin türü ve boyutuna göre değişkenlik gösteren parametreler olarak adlandırılmaktadır [16]. Model için en başarılı sonuçların alındığı hiperparametrelerden oluşan kombinasyonu bulmak çok önemlidir. Hiperparametreler ağ yapısını belirleyen ve eğitilen ağı belirleyen olmak üzere iki tür olarak tanımlanmaktadır. Ağ yapısını belirleyen; filtre boyutu, filtre türü, adım kaydırma (stride), piksel ekleme (padding), gizli katmanlar ve aktivasyon fonksiyonları gibi parametrelerden oluşmaktadır. Eğitilen ağı belirleyen parametreler ise öğrenme oranı, eğitimde tur sayısı (epoch), parti boyutu (batch size) ve momentum olarak sıralanmaktadır [25]. Bu parametrelerden bazıları ilerleyen başlıklarda açıklanmıştır.

3.2.1. Veri Setinin Boyutu

Veri setinin büyüklüğü ve verinin türü derin öğrenme çalışmalarında önemli bir kriter olarak bilinmektedir. Örnek sayısının fazla olması başarıya olumlu yönde katkı sağlarken ,az sayıda örnek içermesi eğitimi de olumsuz yönde etkilemektedir. Bu sebeple veri arttırım yöntemleri sıkça kullanılmaktadır [26]. Başarı oranı veri setinin büyüklüğü ile orantılı olsa da sadece büyük veri seti ile çalışmak yeterli olmamaktadır. Bunun yanında verinin çeşitliliği, veri seti içerisindeki verilerin sınıfsal olarak birbirine yakın olup olmama durumu ya da gürültülü veri içermesi gibi kriterler modelin başarısını etkilemektedir [27] .

3.2.2. Aktivasyon Fonksiyonları

Evrişimli Sinir Ağı mimari yapısında bulunan aktivasyon fonksiyonlarının doğru seçimi model geliştirmede önemli bir rol oynamaktadır. Sinir ağı içerisinde geriye yayılım yöntemi ile ağırlıkların güncellenerek sonraki katmana iletilmesi sağlanmaktadır [26]. Aktivasyon fonksiyonlarından bazıları ReLU, Sigmoid, TanH, Softmax, Leaky ReLU olarak sıralanmaktadır.

3.2.3. Eğitim Devir (Tur) Sayısı

Eğitimde tur sayısı öğrenme algoritması eğitim boyunca kaç kez çalışacağını tanımlayan hiperparametre olarak adlandırılmaktadır [28]. Eğitim için ilk tur tamamlandıktan sonra modelde geri yayılımla ağırlıkları güncelleme işlemi yapılır. İterasyonlar halinde gerçekleşen bu işlem ile tur sayısı tamamlanmış olur. Tur sayısı arttıkça modelin başarı oranı ve eğitim süresi de artmakla birlikte model başarı oranı sabitlendiğinde doyuma ulaştığı anlamına gelmektedir. Bu durumda eğitim sonlandırılmaktadır [26]. Literatürde 10, 100, 500, 1000 ve daha büyük değerlere ayarlanan tur sayısı (epoch) örnekleri bulunmaktadır. Grafiklerde x eksenini boyunca tur sayısı olarak ifade edilirken y eksenini tur sayısına karşılık gelen hata ya da başarı oranını ifade etmekte kullanılır. Modelin öğrenme oranının aşırı ya da az olup olmadığını yorumlamayı sağlayan bu grafikler modelin öğrenme eğrisi oluşturmaktadır [28].

3.2.4. Parti Boyutu

Öğrenme işleminde her iterasyonda geriye yayılım yapıldığından ağırlıkların güncellenmesi zaman ve bellek maliyeti oluşturmaktadır. Hesaplama maliyetini minimize etmek için veri seti küçük gruplara ayrılmaktadır [27]. Verilerin parti boyutu diğer bir ifadeyle batch size değeri parametre değeri güncellemesinden sonra sinir ağına verilen alt örneklerin sayısı olarak ifade edilmektedir [29]. Veri seti batch değeri olarak verilen değere göre parçalara ayrılarak model eğitimi gerçekleştirilir [16]. Batch size değerinin yüksek veya düşük olması özellik çıkarımında farklılıklara sebep olmaktadır. Yüksek parti boyutu seçiminde ortak özellik daha düşük olacağından

algoritma daha hızlı çalışır ancak detaylı bir çıkarım sağlanamayabilir. Aynı şekilde modelin iyi öğrenmesi için çok düşük parti boyutu seçilmesi de önerilmemektedir [26]. Batch size değeri genellikle GPU belleğine sığması açısından 2'nin katları (2,4,8,16,32,...,512) şeklinde belirlenmektedir [27]. Literatürde yapılan çalışmalarda parti boyutunun genellikle 64-1024 aralığında değerler olarak belirlendiği ifade edilmektedir [30].

3.2.5. Öğrenme Oranı

Öğrenme oranı her parti boyutu (batch size) sonunda ağırlıkların güncellenmesini düzenlemesini sağlayan parametre değeridir [25]. Benzer ifadeyle öğrenme oranı, bir ağırlık parametrelerini ne kadar hızlı güncellediğini tanımlamaktadır. Düşük bir öğrenme oranı, öğrenme sürecini yavaşlatabilmektedir. Yüksek bir öğrenme oranı ise öğrenmeyi hızlandırır ancak yakınsamayabilir [29]. Sinir ağlarında öğrenme oranı için uygun görülen değer 1 ile 10^{-6} aralığı olarak belirtilmektedir [26].

3.2.6. Optimizasyon Algoritmaları


Derin öğrenme optimizasyon yöntemlerini temel aldığından optimizasyon algoritmasının seçimi önemli hale gelmektedir. Stokastik gradyan inişi, mini-toplu gradyan inişi, momentumlu gradyan inişi, Adam, Adagrad, AdaDelta, RMSprop, AdaMax gibi optimizasyon algoritmaları bulunmaktadır. Bu algoritmalarda başarımları ve hız bakımından performans farklılıkları bulunmaktadır [16], [31].

4. MATERYAL VE METOT

Çalışmanın bu bölümünde oluşturulan veri seti ve östrus dönemleri hakkında bilgiler verilmiştir. İlerleyen bölümlerde veri setinin hazırlık süreci, önerilen modelin mimarisi ve yöntem detaylı olarak ele alınarak süreç modellenmiştir.


4.1. Veri Seti

Çalışmada kullanılan veri seti için Gazi Üniversitesi Hayvan Deneyleri Yerel Etik Kurulu tarafından G.Ü.ET-23.038 kod numaralı etik kurul onayı alınmış olup 78 adet Sprague Dawley cinsi sıçanın uterus dokuları kullanılmıştır. Dokular rutin histolojik işlemlerden geçirilerek hazırlanan Hematoksilen Eozin (H&E) yöntemi ile boyanmış kesitlerin Olympus BX 51 ışık mikroskobu ile 4' lük büyütmede fotoğrafları çekilmiştir. Çekilen uterus dokusuna ait görüntüler uzman patolog tarafından ratların hangi östrus (proöstrus, östrus, metöstrus, diöstrus) döneminde olduğuna göre sınıflandırma ve gruplama işlemi gerçekleştirilmiştir. İlgili dokuya ait görüntülerin elde edilme süreci Şekil 4.1'de ifade edilmiştir.



Şekil 4.1. Uterus Dokusuna ait Görüntülerin Elde Edilme Süreci

Elde edilen orijinal görüntüler 5184 x 3456, 3071 x 2126 ve 2040 x 1536 gibi farklı boyutlarda olup, uzman eşliğinde sınıflara göre gruplandırılmıştır. Veri seti proöstrus (37), östrus (59), metöstrus (44) ve diöstrus (55) olmak üzere toplamda 195 adet görüntüden oluşmaktadır. Östrus dönemindeki evrelere ait sınıfların her biri için Şekil 4.2 'de sırasıyla (a) Proöstrus , (b) Östrus ,(c) Metöstrus , (d) Diöstrus olmak üzere patolojik doku örnekleri görülmektedir.



Şekil 4.2. Östrus Dönemlerindeki Sınıflara ait Örnekler

4.1.1. Östrus Dönemleri

Çekilen uterus dokusuna ait görüntüler uzman patolog tarafından ratların hangi östrus (proöstrus, östrus, metöstrus, diöstrus) döneminde olduğunu, endometrium tabakasındaki değişikliklere bakılarak ve aşağıda açıklanan parametreler dikkate alınarak sınıflandırılmıştır.

Proöstrus Dönemi: Tersiyer foliküllerin hızla gelişmesi sonucunda uterusda belirgin değişiklikler gerçekleşir. Bu dönemde gerçekleşen değişiklikler şunlardır [32] :

- Bezlerde ve daha az olmak üzere bez epitelinde hipertofi gerçekleşir.
- Lümen ve bez epitel hücreleri alçaktan yüksek prizmatik hücrelere dönüşür.
- Epitelde mitotik aktivite artarak çok sayıda mitotik figür gözlenir.
- Stromada damarlaşma ve hafif ödem oluşur.
- Östruse kadar yangı hücrelerinin sayısında artış gerçekleşir.
- Uterus lümeni bu fazın sonuna kadar genişlemeye ve berrak bir sıvı ile dolmaya devam eder [32].

Östrus Dönemi: Östrus dönemi dokudaki değişimler aşağıdaki sıralanabilir [32]:

- Östrus fazı boyunca uterusda apoptotik hücrelerde belirginleşme.
- Apoptotik hücreler arasında mitotik figürler hala tespit edilmesine rağmen sayıları hızla azalır.
- Bu fazın başlangıcında uterus lümeni genişlemiştir. Ancak östrusun sonlarında epitel boynuzlarının lümende oluşması ile şekil ve hacim olarak lümen normale döner.
- Yangısal hücrelerin sayısı bu faz boyunca yüksektir [32].

Metöstrus Dönemi: Ovulasyonu takiben yeni korpus luteumun gelişmesi siklustaki metöstrus fazının başlangıcını gösterir. Metöstrus dönemi dokuda oluşan değişimler aşağıdaki gibidir [32]:

- Bu faz apoptotik hücre sayısında azalma ve mitotik aktivitenin artışı ile karakterizedir.

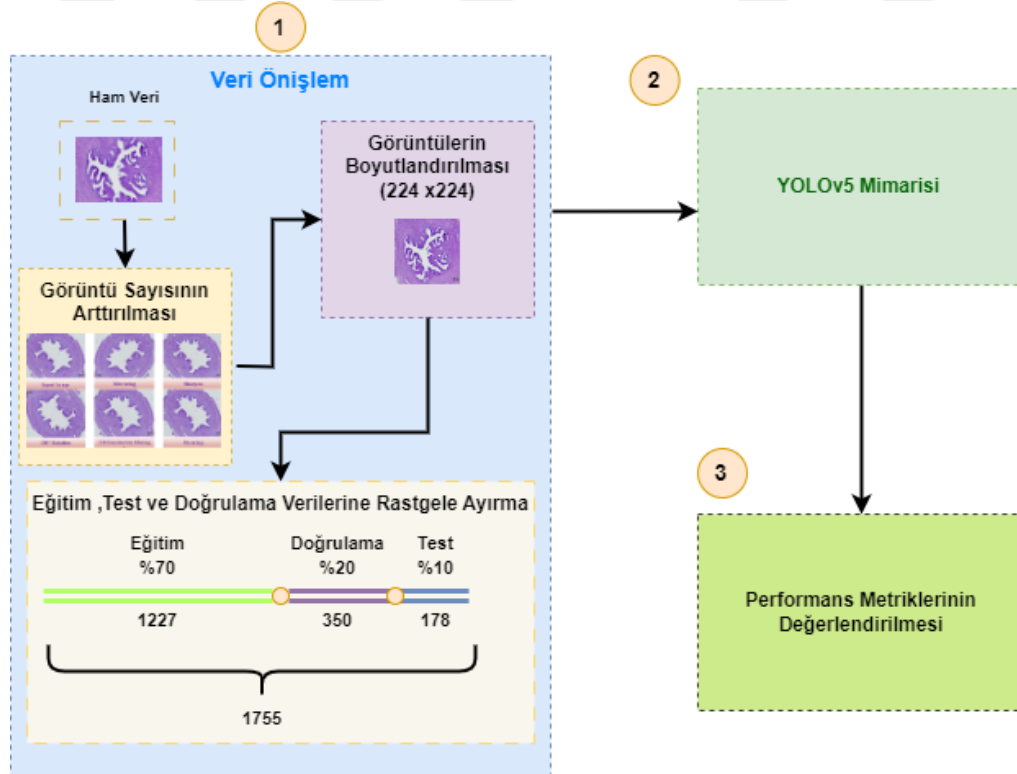
- Genellikle epitel hücreleri değişime uğramaz veya alçak prizmatik epitel şeklinde yenilenir.
- Luminal epitel altındaki bağ doku hücreleri metöstrus sonunda daha belirginleşerek görünür hale gelir.
- Bu faz sonunda stromada birkaç tane eozinofil görülebilir [32].

Diöstrus Dönemi: Bu dönemde dokuda meydana gelen değişiklikler şunlardır [32]:

- Diöstrus fazı boyunca progesteron seviyeleri düşer ve uterus küçülür.
- Endometrial epitel alçak prizmatik epitelden kübik epitele dönüşür.
- Lümendeki boynuzlar yarık gibi veya testere dişi görünümündedir.
- Bu faz boyunca östrojen seviyesi düşük olduğundan mitotik aktivite azdır.
- Stromada birkaç eozinofil bulunabilir [32].

4.2. Yöntem

Çalışmada uterus dokusuna ait görüntüler üzerinden östrus dönemine ait evrelerin doğru sınıflandırılmasını sağlayan bir yapı önerilmiştir. Önerilen yöntem Şekil 4.3'te gösterildiği gibi üç aşamadan oluşmaktadır. Bunlar: veri önileme, özelliklerin çıkarımı için YOLOv5 mimarisi ile sınıflandırma ve performans değerlendirme metrikleri aşamasıdır.




Şekil 4.3. Önerilen Yöntem Aşamaları

4.3. Veri Ön İşleme

Veri ön işleme aşaması ile çalışmada kullanılacak veri setinin işleme hazır hale getirilmesi amaçlanmaktadır. Çalışmada oluşturulan veri seti için sırasıyla görüntü sayısının artırılması, görüntülerin boyutlandırılması, eğitim, test ve doğrulama verilerin ayrılması gibi aşamalı bir dizi işlem uygulanmıştır.

4.3.1. Veri Arttırma Yöntemleri

Görüntü sayısının artırılması işleminde veri setinin hacmi arttırılarak evrişimli sinir ağı yapısını güçlendirmek amaçlanır. Çalışmada aynalama (mirroring), döndürme (rotation), kesme (shearing), keskinlik (sharpen), 2-D Gauss filtreleme (2-D Gaussian blur filtering) gibi veri arttırma yöntemleri uygulanarak toplamda 195 adet bulunan veri sayısı 1755 'e çıkarılmıştır. Şekil 4.4'te belirtilen veri arttırma işlemlerinin çıktılarına ilişkin örnek görüntüler bulunmaktadır.




Şekil 4.4. Veri Arttırma Yöntemleri Uygulaması

Şekil 4.4'te belirtilen veri arttırma işlemlerine ilişkin işlemler açıklamalar aşağıdaki gibidir:

- **Aynalama (Mirroring):** Görüntüyü yatay ve dikey eksene göre piksellerin satır ve sütunlarını tersine çevirme işlemidir. Çalışmadaki görüntülerde iki farklı eksende aynalama işlemi uygulanmıştır.
- **Döndürme(Rotation):** Görüntü merkez noktası etrafında saat yönünün tersi yönünde döndürme işlemidir. Çalışmadaki görüntülerde 180 derece döndürme işlemi uygulanmıştır.

- **Kesme(Shearing):** Görüntülerde sağ ve sol eksen üzerinde 0.1 piksellik kaydırma işlemi uygulanmıştır.
- **Keskinlik (Sharpen):** Görüntüyü keskinleştirerek netliği artırması sağlanmıştır.
- **Gauss filtreleme (2-D Gaussian blur filtering):** Gauss bulanıklaştırma yöntemi ile görüntüdeki ayrıntı ve gürültüyü kaldırmak için kullanılır. Çalışmadaki görüntülerde standart sapması 1 ve 2 olan Gauss filtresi ile filtreleme işlemi uygulanmıştır.

Veri artırma yöntemleri sonrası toplam 1755 adet görüntü içeren veri setinin östrus evrelerine göre sırasıyla veri dağılımı ise Şekil 4.5 'te verilmiştir.



Şekil 4.5. Arttırılmış Veri Sayıları

4.3.2. Veri Boyutlandırma


Veri ön işleme aşamasının ikinci adımı olarak arttırılan veriler eşit ölçüde boyutlandırılmıştır. Modelin etkili çalışması için görüntülerin eşit en-boy oranlarına sahip olması ve sınıf dağılımlarının dengeli olması önemlidir. Bu sebeple veri seti içerisindeki 4 'lük büyütme oranına sahip görüntüler farklı boyutlarda olduğundan her bir görüntü modelin en verimli çalıştığı boyut olan 224×224 piksel olarak boyutlandırılmıştır.

4.3.3. Veri Setinin Eğitime Göre Ayrılması

Veri ön işleme adımının son aşaması olarak çalışmada veri setinin %70'i eğitim %10'u test ve %20'si doğrulama kümesi olacak şekilde ayrılmıştır. Bu durumda veri seti dağılımsal olarak 1227 adet eğitim, 178 adet test ve 350 adet doğrulama kümesi olarak belirlenerek veri hazırlık süreci tamamlanmıştır.

4.4. YOLOv5 Mimarisi ile Sınıflandırma

YOLOv5 model mimarisi, YOLO (You Only Look Once) model ailesinin en yeni sürümü olan nesne tespiti ve sınıflandırma modelidir. YOLOv5, PyTorch kütüphanesi ile geliştirilen hızlı ve doğru bir nesne tespiti modeli olarak öne çıkmaktadır. YOLOv5 yönteminin mimari ağı omurga, boyun ve baş olarak adlandırılan üç ana bölümden meydana gelmektedir. Omurga bölümünün odak noktası giriş görüntülerinden özellik bilgilerinin çıkarılmasına dayanmaktadır. Boyun bölümü, çıkarılan özellik bilgilerini birleştirerek üç ölçekli özellik haritasını oluşturmaktadır. Baş bölümü ise oluşturulan özellik haritasındaki nesneleri sınıflandırmaktadır. Omurga ağı, çoklu evrişim ve havuzlama adımıyla giriş görüntüsünden farklı boyutlarda özellik haritaları çıkaran evrişimli bir sinir ağıdır. Şekil 4.6'da gösterildiği gibi YOLOv5 mimarisi omurga ağına oluşturulan özellik haritasının katmanları bulunmaktadır. Boyun ağı, farklı boyutlardaki özellik haritalarıyla, daha ilişkili bilgi elde etmek ve bilgi kaybını azaltmak için farklı düzeylerdeki özellik haritalarını birleştirmektedir[33].



Mimarinin odak noktası görüntülerin her birini dilimlemek ve alt örnekleme yaparken özellikleri daha iyi çıkarmak üzere birleştirme esasına dayanmaktadır. CBL modülü evrişim, normalizasyon ve Leaky ReLu aktivasyon fonksiyonu olmak üzere üç ana modülden oluşmaktadır. Mimaride iki türü bulunan çapraz aşamalı kısmi ağ (Cross-Stage Partial) olan CSP modülü omurga ve boyun ağında kullanılmaktadır. CSP ağı, model boyutunu küçülterek kesinliği korurken çıkarım hızını artırmayı amaçlamaktadır. Kullanılan CSP ağının iki çeşidinde küçük bir fark bulunmaktadır. Omurgadaki CSP ağı bir veya daha fazla artık birimden oluşurken boyundaki CSP ağı artık birimleri CBL modülleriyle değiştirir. Burada havuzlama adımıyla görüntü özelliklerini daha yüksek bir soyutlama düzeyinde temsil etmek için boyut azaltma işlemleri yapılmaktadır. Temel olarak bu işlem giriş özellik haritasının sıkıştırılması olarak tanımlanmaktadır. Bu işlem ile özellik haritasını küçültülerek ağıın hesaplama karmaşıklığını basite indirgenmektedir. Diğer taraftan, özellik sıkıştırması işlemi ile temel özelliklerin çıkarımı sağlanmaktadır [33]. Concat modülü, birden fazla evrişim katmanından elde edilen özellik haritalarını birleştirerek daha derin ve daha ayrıntılı özellikler elde ederek nesnelerin daha doğru bir şekilde algılanmasına ve sınıflandırılmasına yardımcı olmaktadır. Ayrıca, Concat modülü, ağıın daha az parametreyle daha yüksek doğruluk sağlamasına imkan vermektedir.

Çalışmada uterus dokusuna ait patolojik görüntülerde östrus dönemlerinin sınıflandırılması için YOLOv5 modeli tercih edilmiştir. Çalışma kapsamında YOLOv5n, YOLOv5s, YOLOv5m alt modelleri için sonuçlar elde edilerek performans karşılaştırması yapılmıştır. Genel olarak kullanılan bu modellerin temel özellikleri, parametre sayıları, kullanılan konvolüsyon katman sayısı ve çözünürlükleri birbirinden farklıdır. YOLOv5n, YOLOv5s'den daha hızlıdır ve daha az parametreye sahiptir. Diğer modeller ise farklı boyutlardaki veri setleri için optimize edilmiştir.

4.5. Performans Değerlendirme Metrikleri

Çalışmada östrus evrelerine ait sınıfların tespiti ve uygulanan modelin başarısını ölçmek için performansının belirli ölçütlere göre değerlendirilmesi gerekmektedir. Bunun için doğruluk, kesinlik, duyarlılık, F1 puanı gibi değerlendirme metrikleri kullanılmaktadır. Sınıflandırma algoritmasının başarısının özetlenmesinde ise karışıklık matrisi kullanılan yöntemlerden biridir [34]. İkili sınıflandırmaya ait örnek karışıklık matrisi Şekil 4.7'de verilmiştir.

		Tahmin Sınıfı	
		Pozitif	Negatif
Gerçek Sınıf	Pozitif	TP	FN
	Negatif	FP	TN

Şekil 4.7. İkili Sınıf için Karışıklık Matrisi

TP : Gerçekte pozitif olan bir durumun pozitif olarak tahmin edilmesi durumudur.

FN : Mevcutta pozitif olan bir durumun negatif olarak tahmin edilmesi durumudur.

FP : Mevcutta negatif olan bir durumun pozitif olarak tahmin edilmesi durumudur.

TN : Gerçekte negatif olan bir durumun negatif olarak tahmin edilmesi durumudur.

Karışıklık matrisinde belirtilen değerler doğruluk, kesinlik, duyarlılık, F1 puanı gibi değerlere göre hesaplanmaktadır. Bu ölçütlere ait hesaplamalar aşağıda açıklandığı gibidir:

Doğruluk (Accuracy) parametresi, sınıflandırma işleminde algoritmanın doğruluğunu açıklayan metriklerden biridir [35]. Doğruluk değeri, eşleşen örnek sayısının toplam örnek sayısına oranı olarak ifade edilmektedir. Bu parametre modelin ne kadar iyi performans gösterdiğinin ölçütü olarak kabul edilmektedir. 0-1 aralığında değer almakta olup, ilgili değer 1'e yaklaştıkça başarı oranı yükselmektedir [34]. Denklem 4.1 'de hesaplama formülü verilmiştir.

$$\text{Doğruluk} = \frac{TP+TN}{TP+FN+FP+TN} \quad (4.1)$$

Kesinlik (Precision) parametresi, evrişimli sınır ağındaki pozitif durumların tahmin başarısında kullanılır [30]. Gerçek pozitif tahminlerin, model tarafından yapılan toplam pozitif tahmin sayısına oranı olarak tanımlanmaktadır. Bu değer arttıkça ağın başarısı da o ölçüde yükselmektedir. Denklem 4.2'ye göre hesaplanmaktadır.

$$\text{Kesinlik} = \frac{TP}{TP+FP} \quad (4.2)$$

Duyarlılık (Recall) parametresi pozitif verilen sınıflardan ne kadarının pozitif ya da negatif olarak verilen sınıfların ne kadarının negatif olarak tahmin edildiğini ifade etmektedir. Denklem 4.3 'te verilen formüle göre hesaplanmaktadır.

$$\text{Duyarlılık} = \frac{TP}{TP+FN} \quad (4.3)$$

F1 Puanı (F1 Score) parametresi kesinlik ve duyarlılık metriklerinin harmonik ortalaması olarak ifade edilmektedir. Denklem 4.4'e göre hesaplanmaktadır.

$$F1\ Puanı = \frac{2*(Kesinlik*Duyarlılık)}{(Kesinlik+Duyarlılık)} \quad (4.4)$$




5. BULGULAR VE TARTIŞMA

YOLOv5 modeli kullanılarak gerçekleştirilen örnek uygulamalar incelendiğinde parametre sayısı arttıkça accuracy (doğruluk) değerinin yükseldiği belirtilmektedir [36]. Bu çalışma kapsamında östrus dönemine ait evrelerin sınıflandırılması amacıyla YOLOv5 modelinin YOLOv5n, YOLOv5s ve YOLOv5m modelleri olmak üzere 3 alt modeli üzerinden gerçekleştirilen eğitimler ve sonuçları incelenmiştir. Giriş görüntüsü 224x224 boyutunda alınarak YOLOv5n, YOLOv5s ve YOLOv5m modellerine göre gerçekleştirilen eğitime ilişkin sonuçlar Tablo 5.1 'de ifade edilmiştir. Çalışma Google Colab ortamında Tesla T4 ekran kartına ve 16 GB RAM'e sahip bir sunucu üzerinde gerçekleştirilmiştir. Eğitim için tur sayısı 100 epoch olarak belirlenmiştir. Accuracy parametresine göre %98.3 oranında doğruluk değeri ile YOLOv5m modelinde en yüksek başarı sağlanmıştır. Sonuçlara göre katman sayısının artışına bağlı doğruluk değerinin arttığı gözlemlenmiştir. YOLOv5n, YOLOv5s, YOLOv5m modelleri kullanılarak 100 epoch değerine göre alınan eğitim doğruluk değerleri grafiği Şekil.5.1'de gösterilmektedir.


Tablo 5.1. YOLOv5 Alt Modellerinin Uterus Veri Seti'ne Göre Eğitim Metrikleri

Model	Boyut	Doğruluk Accuracy Top 1	Doğruluk Accuracy Top 5	Eğitim Süresi 100 epoch (devir) (saat)	Eğitim Katman Sayısı	Doğrulama Katman Sayısı
YOLOv5n-cls	224	0.966	1	0.136	149	117
YOLOv5s-cls	224	0.966	1	0.145	149	117
YOLOv5m-cls	224	0.983	1	0.161	212	166



Şekil 5.1. YOLOv5 Modeline Göre Eğitim Doğruluk Grafiği

YOLOv5n, YOLOv5s ve YOLOv5m modellerine göre eğitim ve test verilerine ait kayıp grafikleri Şekil 5.2’de verilmiştir. Eğitimde kullanılan parametre değerleri ise Tablo 5.2’de verilmiştir.



Şekil 5.2. YOLOv5 Modeline Göre Eğitim-Test Kayıp Grafikleri

Tablo 5.2. YOLOv5 Modeli Eğitim Parametre Değerleri

Parametre	Değer
Öğrenme Oranı	0.001
Epoch (Devir) Sayısı	100
Batch Size	64
Görüntü Boyutu	224
Optimizasyon Algoritması	Adam


5.1. YOLOv5n Modeli ile Sınıflandırma Sonucu Elde Edilen Bulgular

YOLOv5n modeline göre eğitilen verilerden elde edilen sonuçların sınıflara göre dağılımları ve değerlendirme metrikleri Tablo 5.3'te verilmiştir. YOLOv5n modeline göre genel doğruluk değerinin %96.63 olduğu görülmüştür. Sınıflara göre dağılımda duyarlılık (recall) metriğine göre en başarılı sınıfın diöstrus sınıfı olduğu görülmektedir.

Tablo 5.3. YOLOv5n Modeline Göre Eğitilen Verilerin Test Sonuçları


Sınıf	Görüntü Sayısı	Doğruluk (Accuracy) (%)	Kesinlik (Precision)	Duyarlılık (Recall)	F1 Puanı (F1 Score)
Tümü	178	96.63	0.96	0.96	0.96
Proöstrus	34	98.31	0.94	0.97	0.96
Östrus	54	98.31	1.0	0.94	0.97
Metöstrus	40	98.88	1.0	0.95	0.97
Diöstrus	50	97.75	0.93	1.0	0.96

YOLOv5n modeline göre eğitilen verilerin sınıflara göre tahmin oranları incelendiğinde diöstrus sınıfına ait 50 adet görüntü verisinden 27 görüntünün %90 ve üstü oranında doğru tahmin oranına sahip olduğu görülmüştür. Rastgele seçilen görüntüler içerisinde en düşük doğruluk oranının %60, modele göre en düşük duyarlılık oranının ise %94 oranıyla östrus sınıfı olduğu belirlenmiştir. Şekil 5.3'te ise diöstrus sınıfına ait tahmin oranları ve rastgele alınan görüntü örnekleri verilmiştir.



Şekil 5.3. YOLOv5n Modelinde Eğitilen Diöstrus Sınıfına ait Örnek Görüntüler

YOLOv5n modelinin performans değerlendirmesi için oluşturulan normalize (b) ve normalize olmayan (a) karışıklık matrisi Şekil 5.4'te verilmiştir.



Şekil 5.4. YOLOv5n Modeli Eğitim Sonuçlarına Göre Karışıklık Matrisleri


5.2. YOLOv5s Modeli ile Sınıflandırma Sonucu Elde Edilen Bulgular

YOLOv5s modeline göre eğitilen verilerden elde edilen sonuçların sınıflara göre dağılımları ve değerlendirme metrikleri Tablo 5.4'te verilmiştir. YOLOv5s modeline göre %96.63 oranında doğruluk elde edilmiştir. En yüksek başarı oranı ile tahmin edilen sınıfın duyarlılık (recall) ölçütüne göre diöstrus sınıfı olduğu görülmüştür.

Tablo 5.4. YOLOv5s Modeline Göre Eğitilen Verilerin Test Sonuçları


Sınıf	Görüntü Sayısı	Doğruluk (Accuracy) (%)	Keskinlik (Precision)	Duyarlılık (Recall)	F1 Puanı (F1 Score)
Tümü	178	96.63	0.97	0.96	0.97
Proöstrus	34	99.44	1.0	0.97	0.99
Östrus	54	98.88	0.98	0.98	0.98
Metöstrus	40	97.75	1.0	0.90	0.95
Diöstrus	50	97.19	0.91	1.0	0.95

YOLOv5s modeline göre eğitilen verilerin sınıflara göre tahmin oranları incelendiğinde diöstrus sınıfına ait rastgele seçilen 50 adet görüntü verisinden 33 görüntünün %90 ve üstü oranında doğru tahmin oranına sahip olduğu görülmüştür. Rastgele seçilen görüntüler içerisinde en düşük doğruluk oranının %60, modelin geneline göre en düşük doğruluk oranının ise %90 oranıyla metöstrus sınıfı olduğu belirlenmiştir. Şekil 5.5'te ise diöstrus sınıfına ait tahmin oranları ve rastgele alınan görüntü örnekleri verilmiştir.



Şekil 5.5.YOLOv5s Modelinde Eğitilen Diöstrus Sınıfına ait Örnek Görüntüler

YOLOv5s modelinin performans değerlendirmesi için oluşturulan normalize ve normalize olmayan karışıklık matrisi Şekil 5.6’da verilmiştir.



Şekil 5.6.YOLOv5s Modeli Eğitim Sonuçlarına Göre Karışıklık Matrisleri


5.3. YOLOv5m Modeli ile Sınıflandırma Sonucu Elde Edilen Bulgular

YOLOv5m modeline göre eğitilen verilerden elde edilen sonuçların sınıflara göre dağılımları ve değerlendirme metrikleri Tablo 5.5’te verilmiştir. Yolov5m modeline göre en yüksek başarı oranı ile tahmin edilen sınıfların duyarlılık (recall) değerlerine göre diöstrus, östrus ve proöstrus sınıfı olduğu görülmüştür.

Tablo 5.5. YOLOv5m Modeline Göre Eğitilen Verilerin Test Sonuçları


Sınıf	Görüntü Sayısı	Doğruluk (Accuracy) (%)	Kesinlik (Precision)	Duyarlılık (Recall)	F1 Puanı (F1 Score)
Tümü	178	98.31	0.99	0.98	0.98
Proöstrus	34	100	1.0	1.0	1.0
Östrus	54	100	1.0	1.0	1.0
Metöstrus	40	98.31	1.0	0.93	0.96
Diöstrus	50	98.31	0.94	1.0	0.97

YOLOv5m modeline göre eğitilen verilerin sınıflara göre tahmin oranları incelendiğinde 4 sınıflı veri setimizde proöstrus, östrus ve diöstrus sınıfına ait görüntü verileri için doğruluk (accuracy) değerlendirme ölçütünde oldukça yüksek başarı elde edilmiştir. YOLOv5n ve YOLOv5s modellerine kıyasla toplam başarı oranı ile birlikte doğru tahmin edilen sınıf sayısının artması YOLOv5m modelinin diğer modellere göre daha başarılı olduğunu kanıtlamaktadır. Bu durum veri setinin uygulanan modeldeki parametre ve katman sayısının artmasına bağlı olarak başarı oranının etkilendiğini göstermektedir. Şekil 5.7 'de tahmin başarısı yüksek olan diöstrus, östrus ve proöstrus sınıflarına ait rastgele alınan örnek görüntüler verilmiştir.




Şekil 5.7. YOLOv5m Modelinde Eğitilen Sınıflara ait Örnek Görüntüler

YOLOv5m modelinin performans değerlendirmesi için oluşturulan normalize (b) ve normalize olmayan (a) karışıklık matrisleri Şekil 5.8'de verilmiştir.



Şekil 5.8.YOLOv5m Modeli Eğitim Sonuçlarına Göre Karışıklık Matrisleri

YOLOv5 modeline göre test verileri kullanılarak elde edilen doğru tahmin oranı düşük bazı görüntü verileri Şekil 5.9’da verilmiştir. Östrus dönemi sırasıyla proöstrus, östrus ,metöstrus ve diöstrus olmak üzere aşamalı olarak 4 ayrı evrede gerçekleşmektedir. Şekil 5.9 ‘da bulunan (a) görüntüsü 1.evre bir görüntü olarak tahmin edilmesi beklenirken 3. evre ile tahmin oranlarının yakın olduğu görülmektedir. Benzer şekilde (b) görüntüsü 3. evre olarak tahmin edilmesi beklenen görüntünün tahmin oranının 2. ve 4. evreye yakın oranlarda çıktığı görülmektedir.



Şekil 5.9. Östrus Dönemlerine ait Tahmin Oranı Düşük Sonuçlar

Yapılan çalışma literatürdeki benzer çalışmalarla Tablo 5.6’da gösterildiği gibi karşılaştırıldığında, örneğin Sun ve ark. [7] tarafından 2019 yılında derin öğrenme teknikleri kullanılarak yapılan sınıflandırma işleminde, çalışmamızdaki gibi 4 sınıflı ve 224x224 boyutundaki rahim iç zarı görüntülerinden oluşan bir veri seti üzerinde çalışılmıştır. Ancak önerilen HIENet modelinin başarısının %84.5 olduğu görülmüştür.YOLOv5 modeli kullanılarak yaptığımız çalışmanın %98.3 oranında yüksek doğruluğa ulaşması modelin benzer çalışmalara göre başarısını

göstermektedir. Benzer şekilde Yu ve ark. [14] tarafından 2023 yılında Rahim düz kas dokusu ile yapılan çalışmada da YOLOv5 modeli tercih edilmiştir. 3 sınıflı 224x224 boyutunda görüntüler üzerinde yapılan çalışmada %92 oranında başarı elde edildiği görülmüştür. Sonuca göre sınıf sayısının model başarısı üzerinde etkili olduğu görülmüştür. Çeçen ve Özer [15] tarafından 2023 yılında yapılan çalışmada ise meme dokusuna ait patolojik biyopsi görüntülerine göre tümör sınıfı için 2 grupta sınıflandırma işlemi yapılmıştır. YOLOv5 modeli tercih edilen çalışmada %95.3 başarı elde edildiği belirtilmiştir. Çalışmamızda kullanılan veri setinin ve modelin benzer çalışmalara kıyasla daha başarılı sonuçlar verdiği görülmektedir.

Tablo 5.6. Yapılan Çalışma ve Diğer Yöntemlerin Karşılaştırılması

Referans	Doku Türü	Görüntü Boyutu	Yöntem	Sınıf Sayısı	Model	Doğruluk
Sun ve ark. 2019 [7]	Rahim İç zarı	224x224	Sınıflandırma	4	HIENet	%84.50
Yu ve ark. 2023 [14]	Rahim Düz Kası	224x224	Sınıflandırma, Nesne Tespiti	3	ResNet, YOLOv5	%92
Çeçen ve Özer 2023 [15]	Meme	224x224	Sınıflandırma	2	YOLOv5	%95.3
Yapılan Çalışma 2023	Uterus	224x224	Sınıflandırma	4	YOLOv5	%98.3

6. SONUÇLAR

Çalışmada patolojik doku analizi ile deney hayvanından alınan kesitler mikroskop altında incelenmiştir. Bu yöntem canlının üreme sistemindeki olası hastalıkların tespiti ya da beklenen durumların takibi açısından önemlidir. Derin öğrenme teknikleri kullanılarak ilgili dokunun sınıflandırılması üzerine yapılan bu çalışmada uzman patoloğlara ikinci bir görüş desteği sunulması amaçlanmıştır. Doku sınıflandırmasında östrus dönemindeki evrelerin tahmini için YOLOv5 modeli kullanılmıştır. YOLOv5 modelinin YOLOv5n, YOLOv5s ve YOLOv5m alt modellerine göre sonuçları değerlendirilerek %98.3 oranında başarı elde edilmiştir.

Çalışma kapsamında östrus evrelerinin sınıflandırılması alanında uterus dokusundan alınan kesitler ile oluşturulan veri setinin özgünlüğü ve bu alanda yapılan az sayıda çalışma olması sebebiyle bu çalışma literatüre katkı sağlayacaktır. Model olarak YOLOv5 mimarisi tercih edilen çalışmaların nesne algılama üzerine yoğunlaştığı görülmektedir. Özellikle tercih edilen mimariyle sınıflandırma alanında az sayıda çalışma olması yaptığımız çalışmayı özgün hale getirmektedir.

Sonuçlar uzman görüşü eşliğinde değerlendirilmiş olup, sonuç olarak önerilen modelin minimum zaman maliyeti, düşük hata oranı ve yüksek doğruluk değeri ile doku sınıflandırmasına imkan sağladığı görülmektedir. Bu yönde patolojik doku sınıflandırılması alanında yapay zeka tekniklerinin tercih edilme potansiyelini arttırmaktadır.

KAYNAKLAR

- [1] H. Bozoğlu, “Deneyisel Hipertiroidi Oluşturulmuş Sıçanlarda Östrus Siklusunun Değişik Evrelerinde Dişi Genital Organlarda (Ovaryum Ve Uterus) Östrojen Ve Progesteron Reseptör Dağılımının İmmünohistokimyasal Olarak İncelenmesi,” Edirne :Trakya Üniversitesi,Yüksek Lisans Tezi, 2013.
- [2] A. A. Yiğit, G. Büyük, and R. Kabakçı, “Dişi Ratlarda Üreme Fizyolojisi,” *Dicle Üniv Vet Fak Derg*, vol. 12, no. 2, pp. 163–167, 2019.
- [3] G. Ekizceli *et al.*, “Sıçanlarda Östrus Döngüsü ile İlişkili Ovaryum ve Uterusların Histolojik Değerlendirmesi,” *Uludağ Üniversitesi Tıp Fakültesi Derg.*, vol. 41, no. 2, pp. 65–72, 2015.
- [4] Z. Aytaç, İ. İşeri, and B. Dandıl, “Derin Öğrenme Kullanarak Tiroid Kanseri Teşhisi,” *Eur. J. Sci. Technol.*, no. 29, pp. 292–298, 2021, doi: 10.31590/ejosat.1011166.
- [5] S. Aksoy and M. N. Gürçan, “Patoloji ve yapay zekâ,” 2022. <https://sarkac.org/2022/02/patoloji-ve-yapay-zeka/> (accessed Apr. 20, 2023).
- [6] Ö. İnik, A. Ceyhan, E. Balcıoğlu, and E. Ülker, “A new method for automatic counting of ovarian follicles on whole slide histological images based on convolutional neural network,” *Comput. Biol. Med.*, vol. 112, no. May, 2019, doi: 10.1016/j.combiomed.2019.103350.
- [7] H. Sun, X. Zeng, T. Xu, G. Peng, and Y. Ma, “Computer-Aided Diagnosis in Histopathological Images of the Endometrium Using a Convolutional Neural Network and Attention Mechanisms,” *IEEE J. Biomed. Heal. Informatics*, vol. 24, no. 6, pp. 1664–1676, 2020, doi: 10.1109/JBHI.2019.2944977.
- [8] R. Yan *et al.*, “Breast cancer histopathological image classification using a hybrid deep neural network,” *Methods*, vol. 173, no. June 2019, pp. 52–60, 2020, doi: 10.1016/j.jymeth.2019.06.014.
- [9] Y. Huo, J. Zhang, X. Du, X. Wang, J. Liu, and L. Liu, “Recognition of parasite eggs in microscopic medical images based on YOLOv5,” *Proc. 2021 5th Asian Conf. Artif. Intell. Technol. ACAIT 2021*, no. 61405028, pp. 123–127, 2021, doi: 10.1109/ACAIT53529.2021.9731120.
- [10] W. R. Drioua, N. Benamrane, and L. Sais, “Breast Cancer Detection from Histopathology Images Based on YOLOv5,” *2022 7th Int. Conf. Front. Signal Process. ICFSP 2022*, pp. 30–34, 2022, doi: 10.1109/ICFSP55781.2022.9924866.
- [11] H. Huang, Z. You, H. Cai, J. Xu, and D. Lin, “Fast detection method for prostate cancer cells based on an integrated ResNet50 and YoloV5 framework,” *Comput. Methods Programs Biomed.*, vol. 226, p. 107184, 2022, doi: 10.1016/j.cmpb.2022.107184.
- [12] Q. Guo *et al.*, “Pathological Detection of Micro and Fuzzy Gastric Cancer Cells Based on Deep Learning,” *Comput. Math. Methods Med.*, vol. 2023, 2023, doi: 10.1155/2023/5147399.
- [13] L. Xu, F. Cai, Y. Fu, and Q. Liu, “Cervical cell classification with deep-learning algorithms,” *Med. Biol. Eng. Comput.*, pp. 821–833, 2023, doi: 10.1007/s11517-022-02745-3.
- [14] H. Yu *et al.*, “A Deep-Learning-Based Artificial Intelligence System for the Pathology Diagnosis of Uterine Smooth Muscle Tumor,” *Life*, vol. 13, no. 1, p. 3, 2022, doi: 10.3390/life13010003.
- [15] Ş. Çeçen and A. B. Özer, “Patolojik Meme Kanseri Görüntülerinin YOLOv5 Algoritması ile Sınıflandırılması,” *1 st Int. Conf. Pioneer Innov. Stud.*, vol. 1, pp. 13–18, 2023.
- [16] E. I. Ünlü, “Derin Öğrenme ile Görüntü Bölütleme,” *Elazığ :Fırat Üniversitesi Yüksek Lisans Tezi*, 2019.
- [17] G. Amato, F. Carrara, F. Falchi, C. Gennaro, C. Meghini, and C. Vairo, “Deep learning for decentralized parking lot occupancy detection,” *Expert Syst. Appl.*, vol. 72, pp. 327–334, 2017, doi: 10.1016/j.eswa.2016.10.055.
- [18] M. A. Kızrak and B. Bolat, “Derin Öğrenme ile Kalabalık Analizi Üzerine Detaylı Bir Araştırma,” *Bilişim Teknol. Derg.*, pp. 263–286, 2018, doi: 10.17671/gazibtd.419205.
- [19] F. Doğan and İ. Türkoğlu, “Derin Öğrenme Modelleri ve Uygulama Alanlarına İlişkin Bir Derleme,” *DÜMF Mühendislik Derg.*, vol. 10, no. 2, pp. 409–445, 2019, doi: 10.24012/dumf.411130.

- [20] A. Amidi and S. A. April, “Evrişimli Sinir Ağları El Kitabı VIP,” pp. 1–6, 2019.
- [21] M. K. ve P. C. Jay Wang , Robert Turko , Omar Shaikh , Haekyu Park , Nilaksh Das , Fred Hohman, “What is a Convolutional Neural Network?” <https://poloclub.github.io/cnn-explainer/>
- [22] H. Çelik, “Knıme Veri Analiz Platformu Kullanarak Derin Öğrenme Algoritmaları İle İmge Sınıflandırma,” Elazığ : Fırat Üniversitesi Yüksek Lisans Tezi, 2021.
- [23] B. Kaya and M. Önal, “COVID-19 Tespiti için Akciğer BT Görüntülerinin Bölütlenmesi,” *Eur. J. Sci. Technol.*, vol. 19, no. 28, pp. 1296–1303, 2021, doi: 10.31590/ejosat.1015061.
- [24] D. Ferdi. and İ. Türkoğlu, “Derin Öğrenme Algoritmalarının Yaprak Sınıflandırma Başarımlarının Karşılaştırılması,” *Sak. Univ. J. Comput. Inf. Sci.*, vol. 1, no. April, pp. 10–21, 2018, [Online]. Available: <https://dergipark.org.tr/tjws%0Ahttp://dergipark.gov.tr/gbad%0Ahttps://dergipark.org.tr/tr/pub/tarbitderg/136983>
- [25] P. D. . Aszemi, Nurshazlyn Mohd ;Dominic, “Hyperparameter Optimization in Convolutional Neural Network using Genetic Algorithms,” *Stud. Comput. Intell.*, vol. 967, no. 6, pp. 37–59, 2019.
- [26] A. Aydın, “Görüntü İşleme Ve Derin Öğrenme Yöntemleri İle Çelik Yüzey Kusurlarının Tespiti Ve Sınıflandırılması,” Elazığ :Fırat Üniversitesi Yüksek Lisans Tezi, 2022.
- [27] N. Çarkıcı, “Derin Öğrenme Uygulamalarında En Sık kullanılan Hiper-parametreler,” 2018. <https://medium.com/deep-learning-turkiye/derin-ogrenme-uygulamalarinda-en-sik-kullanilan-hiper-parametreler-ece8e9125c4> (accessed Jun. 20, 2023).
- [28] J. Brownlee, “What is the Difference Between a Batch and an Epoch in a Neural Network?,” *Mach. Learn. Mastery*, no. July, pp. 3–4, 2018.
- [29] A. Gaspar, D. Oliva, E. Cuevas, D. Zaldivar, and M. Pérez, “Hyperparameter Optimization in a Convolutional Neural Network Using Hyperparameter Optimization in a Convolutional Neural Network Using Metaheuristic Algorithms,” no. July, 2021, doi: 10.1007/978-3-030-70542-8.
- [30] Ö. İnik, “Derin Öğrenme Kullanarak Ovaryum Foliküllerinin Sınıflandırılması,” Konya : Konya Teknik Üniversitesi Doktora Tezi, 2019.
- [31] S. Ruder, “An overview of gradient descent optimization,” pp. 1–14, 2016.
- [32] D. Dixon *et al.*, “Nonproliferative and proliferative lesions of the rat and mouse female reproductive system,” *J. Toxicol. Pathol.*, vol. 27, no. 3–4, 2014, doi: 10.1293/tox.27.1S.
- [33] L. Zhu, X. Geng, Z. Li, and C. Liu, “Improving yolov5 with attention mechanism for detecting boulders from planetary images,” *Remote Sens.*, vol. 13, no. 18, pp. 1–19, 2021, doi: 10.3390/rs13183776.
- [34] A. Çınar, M. Erkuş, and T. Tuncer, “Türk İşaret Dilindeki Harflerin Tespiti İçin Derin Öğrenme Tekniğinin Kullanımı,” *Int. Conf. Sci. Innov. Stud.*, vol. 1, no. 1, pp. 360–365, Apr. 2023, doi: 10.59287/icsis.626.
- [35] A. T. Dang, “Accuracy and Loss: Things to Know about The Top 1 and Top 5 Accuracy,” 2021. <https://towardsdatascience.com/accuracy-and-loss-things-to-know-about-the-top-1-and-top-5-accuracy-1d6beb8f6df3>
- [36] “YOLOv5 Classification,” 2023. <https://github.com/ultralytics/yolov5> (accessed Mar. 10, 2023).

ÖZGEÇMİŞ

Şeyma ÇEÇEN

Downloaded from ascelibrary.org by University of California, San Diego on 06/01/15. Copyright ASCE, For All Rights Reserved, No part of this document may be reproduced without written permission from ASCE.

■ [REDACTED]

■ [REDACTED]

AKADEMİK FAALİYETLER

Bildiriler:

1. Ş. Çeçen and A. B. Özer, "Patolojik Meme Kanseri Görüntülerinin YOLOv5 Algoritması ile Sınıflandırılması," *1 st Int. Conf. Pioneer Innov. Stud.*, vol. 1, pp. 13–18, 2023