ÇANKIRI KARATEKİN ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

FETÜS CİNSİYETİNİN ULTRASON GÖRÜNTÜLERİNDEN DERİN ÖĞRENME TEKNİKLERİNE DAYALI TESPİTİ VE SINIFLANDIRILMASI

ESRA SİVARİ

ELEKTRİK – ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

ÇANKIRI
2021

Her hakkı saklıdır

TEZ ONAYI

Esra SİVARİ tarafından hazırlanan "Fetüs Cinsiyetinin Ultrason Görüntülerinden Derin Öğrenme Tekniklerine Dayalı Tespiti ve Sınıflandırılması" adlı tez çalışması aşağıdaki jüri tarafından oy birliği / oy çokluğu ile Çankırı Karatekin Üniversitesi Fen Bilimleri Enstitüsü Elektrik – Elektronik Mühendisliği Anabilim Dalı'nda Yüksek Lisans Tezi olarak kabul edilmiştir.

Danışman **:** Dr. Öğr. Üyesi Zafer CİVELEK

Eş Danışman **:** Dr. Öğr. Üyesi Seda ŞAHİN

Jüri Üyeleri :

Başkan **:** Dr. Öğr. Üyesi Zafer CİVELEK

Çankırı Karatekin Üniversitesi

Üye **:** Dr. Öğr. Üyesi Mehmet GÜÇYETMEZ

Kırşehir Ahi Evran Üniversitesi

Üye **:** Dr. Öğr. Üyesi Mustafa TEKE

Çankırı Karatekin Üniversitesi

Yukarıdaki sonucu onaylarım

Prof. Dr. İbrahim ÇİFTÇİ

Enstitü Müdürü

ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ

Çankırı Karatekin Üniversitesi Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliğine göre hazırlamış olduğum "Fetüs Cinsiyetinin Ultrason Görüntülerinden Derin Öğrenme Tekniklerine Dayalı Tespiti ve Sınıflandırılması" konulu tezin bana ait, özgün bir çalışma olduğunu; çalışmamın hazırlık, veri toplama, analiz ve bilgilerin sunumu olmak üzere tüm aşamalarında bilimsel etik ilke ve kurallara uygun davrandığımı, tezin içerdiği yenilik ve sonuçları başka bir yerden almadığımı, tezde kullandığım eserleri usulüne göre kaynak olarak gösterdiğimi, tezin Çankırı Karatekin Üniversitesi Fen Bilimleri Enstitüsü'nden başka bir bilim kuruluna akademik amaç ve unvan almak amacıyla vermediğimi ve bu çalışmanın Çankırı Karatekin Üniversitesi tarafından kullanılan "Bilimsel İntihal Tespit Programı"yla tarandığını, "intihal içermediğini" beyan ederim. Çalışmamla ilgili yaptığım bu beyana aykırı bir durumun saptanması halinde ortaya çıkacak tüm ahlaki ve hukuki sonuçlara razı olduğumu bildiririm. Çankırı Karatekin Üniversitesi Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliğinin ilgili maddeleri uyarınca gereğinin yapılmasını arz ederim.

Esra SİVARİ

ÖZET

Yüksek Lisans Tezi

FETÜS CİNSİYETİNİN ULTRASON GÖRÜNTÜLERİNDEN DERİN ÖĞRENME TEKNİKLERİNE DAYALI TESPİTİ VE SINIFLANDIRILMASI

Esra SİVARİ

Çankırı Karatekin Üniversitesi

Fen Bilimleri Enstitüsü

Elektrik – Elektronik Mühendisliği Anabilim Dalı

Danışman: Dr. Öğr. Üyesi Zafer CİVELEK

Eş Danışman: Dr. Öğr. Üyesi Seda ŞAHİN

Fetüs cinsiyetinin tespitinde kullanılan tıbbi yöntemlerin tamamı uzman müdahalesi gerektirmektedir. Bu çalışmada, fetüs cinsiyetinin uzmandan bağımsız teşhis edilebildiği, derin transfer öğrenme algoritmalarına dayalı yeni bir yöntem önerilmiştir. Çalışma için uzmanlarla birlikte, 2200' ü kız, 2200' ü erkek cinsiyetli olmak üzere 4400 adet fetüs cinsiyeti içeren 2-D, B-Mod obstetrik ultrasonografi görüntülerinden oluşan veri seti oluşturulmuştur. Çalışmanın ilk aşamasında, veri setiyle en uyumlu özellik çıkarıcı ağın bulunması hedeflenmiştir. VGG16, InceptionV3, ResNet152V2, DenseNet201 ve Xception ağlarına derin transfer öğrenme teknikleri uygulanarak, hassas ayarlı yeni modeller elde edilmiştir. Bu modeller ile sınıflandırma yapılarak, 0.9627 doğruluk ile en başarılı sınıflandırıcı olan ft-DenseNet201 ağı en iyi özellik çıkarıcı seçilmiştir. İkinci aşamada, en iyi sınıflandırıcının bulunması hedeflenmiştir. Bu aşamanın gerçekleştirilmesinde, ft-DenseNet201 ağının evrişim tabanı ile özellik çıkarma işlemi yapılmıştır ve bu özellikler, Lojistik Regresyon (LR), Doğrusal Destek Vektör Makinesi (LSVM), K-En Yakın-Komşu (KNN), Karar Ağacı (DT), Rastgele Orman (RF) ve AdaBoost (AB) algoritmaları ile sınıflandırılmıştır. Kullanılan 11 farklı sınıflandırıcı algoritma içinde en başarılı model, 0.9782 test doğruluğu ile ft-DenseNet201 + LSVM' dir. Önerilen yöntem, ev tipi ultrason cihazlarına entegre edilebilir ve böylece, ebeveynler doktor muayenesi olmadan fetüs cinsiyetini öğrenebilirler. Aynı zamanda önerilen sistem, cinsiyet teşhisinde en sık başvurulan, invaziv olmayan obstetrik ultrasonografi yöntemine alternatif, yeni bir teşhis yöntemi olarak değerlendirilebilir ve doktorların iş yükünü hafifleten olanaklar sağlayabilir.

2021, 86 Sayfa

ANAHTAR KELİMELER: Derin Öğrenme, Evrişimli Sinir Ağları, Makine Öğrenmesi, Fetüs Cinsiyeti Teşhisi ve Sınıflandırılması

ABSTRACT

Master of Science Thesis

DETECTION AND CLASSIFICATION OF FETAL GENDER FROM ULTRASOUND IMAGES BASED ON DEEP LEARNING TECHNIQUES

Esra SİVARİ

Çankırı Karatekin University

Graduate School Of Natural And Applied Sciences

Department of Electrical Engineering

Supervisor: Dr. Öğr. Üyesi Zafer CİVELEK

Co- Supervisor: Dr. Öğr. Üyesi Seda ŞAHİN

All of the medical methods used in determining the sex of the fetus require expert intervention. In this study, a new method based on deep transfer learning algorithms is proposed by which fetal gender can be diagnosed independently from an expert. For the study, a data set consisting of 2-D, B-Mode obstetric ultrasonography images containing 4400 fetuses, 2200 female and 2200 male gender, was created together with the experts. In the first phase of the study, it is aimed to find the most compatible feature extractor network with the data set. By applying deep transfer learning techniques to VGG16, InceptionV3, ResNet152V2, DenseNet201 and Xception networks, new precision tuned models have been obtained. By classifying these models, the most successful classifier with an accuracy of 0.9627, ft-DenseNet201 network was chosen as the best feature extractor. In the second stage, it is aimed to find the best classifier. In the realization of this stage, feature extraction process has been performed with the convolution base of ft-DenseNet201 network and these features are classified with the algorithms of Logistic Regression (LR), Linear Support Vector Machine (LSVM), K-Nearest-Neighbor (KNN), Decision Tree (DT), Random Forest (RF) and AdaBoost (AB). Among the 11 different classifier algorithms used, the most successful model is ft-DenseNet201 + LSVM with 0.9782 test accuracy. The proposed method can be integrated into household ultrasound devices so that parents can find out the sex of the fetus without a doctor's consultation. At the same time, the proposed system can be considered as a new diagnostic method, an alternative to the non-invasive obstetric ultrasonography method, which is the most commonly used method in gender diagnosis, and can provide opportunities that alleviate the workload of doctors.

2021, 86 Pages

KEY WORDS: Deep Learning, Convolutional Neural Networks, Machine Learning, Diagnosis and Classification of Fetus Gender

ÖNSÖZ VE TEŞEKKÜR

“Fetüs Cinsiyetinin Ultrason Görüntülerinden Derin Öğrenme Tekniklerine Dayalı Tespiti ve Sınıflandırılması” isimli bu çalışma 2019 – 2021 yılları arasında hazırlanarak Çankırı Fen Bilimleri Enstitüsü Elektrik – Elektronik Mühendisliği Anabilim Dalı’na Yüksek Lisans Tezi olarak sunulmuştur. Bu çalışmada, fetüs cinsiyetinin tespiti için kullanılan yöntemlere ek olarak, uzmandan bağımsız teşhis yapabilen yenilikçi bir teşhis yöntemi önerilmiştir.

Yüksek lisans eğitimim boyunca birçok şey öğrendiğim ve sayesinde ilk akademik deneyimlerimi kazandığım, destek ve yardımını benden hiçbir zaman esirgemeyen danışman hocam, Sayın Dr. Öğr. Üyesi Zafer CİVELEK’ e, hem deneyim ve bilgisiyle hem de güler yüzüyle yanımda olarak, benden bilgi ve manevi desteğini hiçbir zaman esirgemeyen değerli eş danışman hocam, Sayın Dr. Öğr. Üyesi Seda ŞAHİN’ e, çalışma süresince karşılaştığım problemlerin çözümünde yardımlarını esirgemeyen, tez çalışmasında kullandığım metodolojiye hakim tecrübesi ile beni her zaman aydınlatan ve teşvik eden değerli hocam, Sayın Dr. Öğr. Üyesi Serkan SAVAŞ’ a, teşekkürlerimi sunarım.

Bu çalışma, tüm dünyanın yaşam koşullarını kötü etkileyen Covid-19 salgını sürecinde gerçekleştirilmiştir. Bu sürece rağmen, zamanını esirgemeden çalışmanın gerçekleşmesi için veri temini sağlayan, verileri etiketleyerek çalışmaya büyük destek sağlayan Çankırı Karatekin Hastanesi Kadın Hastalıkları ve Doğum Uzmanı, Sayın Op. Dr. İlhan ARSLANPENÇE’ ye, veri temin izni sağlayan Çankırı Karatekin Hastanesi Yönetim Kurulu’ na ve Kalite Yönetim Direktörü, Sayın Önder İZMİRLİOĞLU’ na ve yardımlarını esirgemeyen tüm sağlık çalışanlarına sonsuz teşekkürlerimi sunarım.

Hayatımın her döneminde yanımda olan ve bana her türlü desteği sağlayan sevgili aileme, özellikle de stresli zamanlarımda en zor hallerime katlanan biricik kardeşim Gözde Nur SİVARİ’ ye teşekkür ve şükranlarımı sunarım.

Esra SİVARİ

Çankırı, Mayıs 2021

İÇİNDEKİLER

ÖZET ..... **i**
ABSTRACT ..... **ii**
ÖNSÖZ VE TEŞEKKÜR ..... **iii**
İÇİNDEKİLER ..... **iv**
SİMGELER VE KISALTMALAR DİZİNİ ..... **v**
ŞEKİLLER DİZİNİ ..... **vi**
ÇİZELGELER DİZİNİ ..... **vii**
1. GİRİŞ **1**
1.1. Tıpta Fetüs Cinsiyetinin Tespitinde Kullanılan Yöntemler **5**
1.1.1. Amniyosentez **6**
1.1.2. Fetoskopi **7**
1.1.3. Koryon Villus Örneklemesi (CVS) **7**
1.1.4. Meternal Serumunda Serbest Fetüs DNA İncelemesi **7**
1.1.5. Obstetrik Ultrasonografi (OUSG) **7**
2. KAYNAK ÖZETİ **10**
3. MATERYAL VE YÖNTEM **13**
3.1. Makine Öğrenmesi ve Derin Öğrenme **13**
3.2. Evrişimli (Konvolüsyonel) Sinir Ağları (ESA) **13**
3.2.1. ESA Mimarisi ve Katmanları **15**
3.2.1.1. Evrişim (konvolüsyon) katmanı **16**
3.2.1.2. Aktivasyon katmanı **20**
3.2.1.3. Havuzlama (alt örnekleme) katmanı **21**
3.2.1.4. Yığın (batch) normalizasyonu katmanı **22**
3.2.1.5. İletim sönümü (dropout) katmanı **23**
3.2.1.6. Düzleştirme (flatten) katmanı **23**
3.2.1.7. Tam bağlı (fully connected) katman **24**
3.2.2. Ön-eğitilmiş ESA Modelleri **24**
3.2.2.1. VGGNet **24**
3.2.2.2. ResNet **25**
3.2.2.3. GoogLeNet (Inception) **26**
3.2.2.4. DenseNet **27**
3.2.3. ESA' ların Eğitim Süreci ve Hiperparametreleri **29**
3.3. Derin Transfer Öğrenme (DTÖ) **33**
3.3.1. Transfer Öğrenmenin ESA Problemlerine Uygulanması **37**
3.4. Metodoloji ve Materyal **41**
3.4.1. Görüntü Elde Etme ve Ön-işleme **44**
3.4.2. Birinci Aşama: En İyi Özellik Çıkarıcının Bulunması **46**
3.4.3. İkinci Aşama: En İyi Sınıflandırıcının Bulunması **51**
4. BULGULAR **58**
5. SONUÇ VE TARTIŞMA **64**
KAYNAKLAR **69**
ÖZGEÇMİŞ **76**

SİMGELER VE KISALTMALAR DİZİNİ

AB	AdaBoost
avgpool	Ortalama Havuzlama
B	Boyut
Conv	Konvolüsyon
ÇKA	Çok Katmanlı Algılayıcı
DN	Doğru Negatif
DÖ	Derin Öğrenme
DP	Doğru Pozitif
DT	Karar Ağacı
DTÖ	Derin Transfer Öğrenme
ESA	Evrişimli Sinir Ağı
ft-	Hassas Ayarlı
GPU	Grafik İşlemci Birimi
ILSVRC	Büyük Ölçekli Görsel Tanıma Yarışması
KNN	K-En Yakın Komşu
LR	Lojistik Regresyon
LSVM	Doğrusal Destek Vektör Makinesi
maxpool	Maksimum Havuzlama
MÖ	Makine Öğrenmesi
OUSG	Obstetrik Ultrasonografi
RF	Rastgele Orman
SGD	Stokastik Gradyan İnişi
SVM	Destek Vektör Makinesi
USG	Ultrasonografi
YN	Yanlış Negatif
YP	Yanlış Pozitif

ŞEKİLLER DİZİNİ

Şekil 1.1 Fetal Genital Organları İçeren USG Görüntüleri 9
Şekil 3.1. ESA Mimarisi ve Katmanları 15
Şekil 3.2. Bir Girdiye (7×7×3), Bir Adet Filtrenin (3×3) Uygulandığı Evrişim İşlemi .. 18
Şekil 3.3. Havuzlama İşlemi 22
Şekil 3.4. VGG16 Mimarisi 25
Şekil 3.5. Artık (Residual) Blokların Yapısı 26
Şekil 3.6. Naif Inception Modülü 27
Şekil 3.7. 5 Katmanlı Yoğun Blok Yapısı (k = 4) 29
Şekil 3.8. Makine Öğrenmesi ve Transfer Öğrenmenin Öğrenme Süreçleri 34
Şekil 3.9. ESA' ların Genel Yapısı 38
Şekil 3.10. Boyut-Benzerlik Matrisi 40
Şekil 3.11. Önerilen Modele Genel Bakış 42
Şekil 3.12. Kullanılan Ön-eğitilmiş ESA' larda Hassas Ayar Detayları 48
Şekil 3.13. Uygulamada Kullanılan Hassas Ayarlı ESA' ların Öğrenim Eğrileri 50
Şekil 3.14. Doğrusal Olmayan Ayrılabilir Sınıflandırmada Esnek Değişken Durumu .. 54
Şekil 3.15. Uygulamada Kullanılan MÖ Sınıflandırıcılarının Öğrenme Eğrileri 57
Şekil 4.1. Uygulamada Kullanılan Hassas Ayarlı ESA' ların Kıyaslama Matrisleri 59
Şekil 4.2. Uygulamada Kullanılan MÖ Sınıflandırıcılarının Kıyaslama Matrisleri 60
Şekil 4.3. Uygulamada Kullanılan MÖ Sınıflandırıcılarının ROC Eğrileri 63
Şekil 5.1. Uygulamada Kullanılan Tüm Algoritmaların Test Doğruluğu Sıralaması 64

ÇİZELGELER DİZİNİ

Çizelge 3.1. ESA' larda Sık Kullanılan Aktivasyon Fonksiyonları 21
Çizelge 3.2. Yığın Normalleştirme Dönüşümleri 23
Çizelge 3.3. DenseNet201 Mimarisi 28
Çizelge 3.4. Makine Öğrenmesi ve Transfer Öğrenmede Kaynak ve Hedef Etki Alanları ile Görevleri Arasındaki Durumlar 35
Çizelge 3.5. Transfer Öğrenme Çeşitlerine Göre Kaynak ve Hedef Etki Alanlarındaki Etiketler Arasındaki Durumlar 35
Çizelge 3.6. Önerilen Yöntemde Kullanılan Veri Setlerindeki Veri Dağılımı 45
Çizelge 3.7. Uygulamada Kullanılan Veri Çoğaltma Yöntemleri 46
Çizelge 3.8. ft-DenseNet201' in Evrişim Tabanı 52
Çizelge 4.1. Performans Metrikleri 61
Çizelge 4.2. Birinci Aşamada Kullanılan DÖ Algoritmalarının Performans Metriklerine Göre Test Sonuçları 62
Çizelge 4.3. Uygulamada Kullanılan Tüm Algoritmaların Performans Metriklerine Göre Test Sonuçları 62
Çizelge 5.1. Fetal Genital Organ Sınıflandırması İçeren Makalelere Genel Bakış ve Karşılaştırma 67

1. GİRİŞ

Prenatal dönem, gebeliğin döllenme ile başlayıp doğum ile son bulduğu, 40±2 haftalık doğum öncesi dönemidir (Açar ve Karaoğlu 2018). Bu dönem kendi içinde 2 alt döneme ayrılmıştır, bunlar; organların farklılaştığı embriyonik dönem (3. haftanın başından 8. haftanın sonuna kadar), organ sistemlerinin oluşumunun tamamlandığı fetal dönemdir (9. Haftanın başından doğuma kadar) (Dudek 2016). Anne karnındaki bebeğe, embriyonik dönemde embriyo, fetal dönemdeki embriyoya fetüs denir (Moore et al. 2016).

Prenatal tanı, embriyo ve fetüse yapılan bütün teşhis ve tespit çalışmalarını oluşturmaktadır. Fetüs cinsiyetinin tespiti için çeşitli prenatal tanı yöntemleri kullanılmaktadır. Bu yöntemler invaziv ve invaziv olmayan yöntemler olarak sınıflandırılmıştır. İnvaziv yöntemler, hastanın vücut bütünlüğüne en az zarar verilecek şekilde yapılan cerrahi müdahalelerdir (Yüreğir vd. 2012). Fetüs cinsiyeti tespitinde kullanılan en bilindik invaziv yöntemler; Fetoskopi, Amniyosentez ve Kronik Villus Örneklemesi (CVS) uygulamalarıdır. İnvaziv olmayan yöntemler; Obstetrik Ultrasonografik değerlendirme (OUSG), meternal kan örneğinden fetal hücrelerin analizi gibi, hastaya herhangi bir cerrahi müdahale gerektirmeyen yöntemlerdir. Fetüs cinsiyetinin tespitinde kullanılan tıbbi yöntemlerin tamamı uzman müdahalesi gerektirmektedir.

Prenatal dönemde, prenatal tanı tekniklerini kullanarak uzman sağlık personelleri tarafından yapılan muayenelere, takip ve kontrollere prenatal bakım denir. Prenatal bakım almak, teşhis ve tedavide gebe kadınlar için hayati önem taşımaktadır. Türkiye Nüfus ve Sağlık Araştırması (TNSA) 2018 verilerine göre, Türkiye' de kadınların %4' ü prenatal bakım hiç almamıştır. En az 4 kez bakım alan kadınların yüzdesi, 2013 ve 2018 yılları arasında %89' dan %90' a, yalnızca %1 artış göstermiştir (TNSA 2018).

Prenatal tanının bilimsel anlamının yanı sıra, geçmişten geleceğe toplum temelinde anlamları da vardır. Yüzyıllardır her toplumda, bebek bekleyen ebeveynlerin en çok merak ettiği şeylerden biri bebeğinin cinsiyetidir. Bebeğin cinsiyetini tahmin etmek için halk içinde yaygınlaşmış ve günümüze kadar ulaşmış bazı yöntem ve işaretlerin kullanılıyor olması (Erbil ve Sağlam 2010), ebeveynlerin bu konudaki merak ve sabırsızlığına en büyük kanıtı oluşturmaktadır. Ancak, ebeveynlerin bilimsel olarak bebeklerinin cinsiyetini öğrenebilmesi için alanında uzman bir kadın doğum uzmanına muayene olmaları gerekmektedir.

Tüm dünyayı etkileyen COVID-19 salgınının gebeler üzerindeki etkilerini araştıran çalışmalar mevcuttur fakat bulunan sonuçlar yeterli değildir (Aydın vd. 2020). Bu bilinmezlikle birlikte daha önce geçirilmiş pandemi dönemleri incelendiğinde, gebelik döneminde yaşanılacağı düşünülen kötü etkiler, ruhsal ve psikolojik olarak gebeleri her zaman etkilemiştir. Örneğin, Lee vd.' nin 2006' da yaptıkları bir araştırmaya göre SARS pandemisinde gebelerin kaygı ve depresyon düzeyleri, normal yaşam koşullarına göre daha yüksek çıkmıştır (Lee et al. 2006). Bir başka örnek; Linde ve Siqueira'ın 2018' de yaptığı bir araştırmaya göre, Zika salgınında gebelerin üzüntü, korku ve çaresizlik içinde olduğu belirtilmiştir (Linde and Siqueira 2018). Tüm bu bilgiler değerlendirildiğinde pandemi dönemindeki gebe kadınların, prenatal bakım almak istemedikleri ve doktor muayenesine gitmekten kaçındıkları bilinen bir gerçektir. Bu süreç, uzmanların, gebelik ve doğum yönetiminde, önleyici bazı tedbirler almalarını zorunlu hale getirmiştir. Bu önlemlerden birisi, prenatal kontrollerin olabildiğince sınırlandırılması ve evden hasta takibi yapılmasıdır (Çağlar ve Oskay 2020). Uluslararası bir kuruluş olan Kraliyet Obstetrik ve Jinekoloji Derneği (Royal College of Obstetricians and Gynaecologists), pandemi sürecinde alınan güvenlik tedbirleri içinde, hastane muayenesinin 6 kontrol ile sınırlandırılmasının yeterli olacağını bildirmiştir (RCOG 2020) .

Pandeminin hastalara etkilerinin yanı sıra, en fazla sağlık çalışanları olumsuz etkilenmiştir ve iş yükleri inanılmaz seviyelerde artmıştır. Bu süreçte, sağlık

çalışanlarına yardım sağlayan, uzmanlara teşhis ve tedavide güvenilir destek veren, sağlık sistemimizi geliştiren akıllı sistemler, uygulamalar ve biyomedikal cihazlara ihtiyaç artmıştır.

İnsan kulağının duyamayacağı frekanstaki ses dalgalarını dokular arasına göndererek gelen yankıları görüntüleyen cihazlara Ultrasonografi (USG) denir. Günümüzde USG teknolojileri, yüksek frekanslı, görüntü kalitesi yüksek cihazlarla birlikte gelişmiştir. Hastane tipi USG cihazları dışında, taşınabilir, çalışma sahası dışında kullanılabilir ve akıllı telefonlarla kullanılabilir, android uyumlu USG cihazları da mevcuttur. Bu USG cihazlarına yapay zeka destekli mobil uygulamalar geliştirilip entegre edilmesi, biyomedikal cihaz teknolojileri alanında, üzerinde oldukça çalışılan bir konudur. Örneğin, Yüksel ve Ertuğrul' un yaptığı bir çalışmada, fetüsün evde toplanan verilerini hastane ortamına aktarabilen ve doktorların uzaktan bağlantı sağlayabildiği Mobile Entegre Fetal Doppler (mDoppler) cihazı geliştirilmiştir (Yüksel ve Ertuğrul 2017).

USG sistemlerinde gözlemciler arası yüksek değişkenlik gibi benzersiz zorluklar da bulunmaktadır. Fetal USG taramasının duyarlılığı değişkendir ve sonografi uzmanının deneyimine bağlıdır. Örneğin, USG görüntüleri kullanılarak malformasyonların doğum öncesi tespiti üzerine yapılan bir çalışma, farklı tıp kurumları arasında duyarlılığın %27.5 ile %96 arasında değiştiğini göstermiştir (Salomon et al. 2008). Bir başka çalışmada, deneyimli sonografi uzmanları ile deneyimsiz sonografi uzmanlarının ikinci üç aylık dönemde (ikinci trimester) fetal muayenede konjenital kalp kusurlarının tespit oranları gözlenmiştir. Deneyimli sonografi uzmanı / ebeler, hem dört oda görüntüsünü hem de büyük arterleri %75 oranında elde etmişlerdir; daha az deneyimli sonografi uzmanı / ebeler için ise rakam %36 idi ($p < 0.001$). (Tegnander and Eik-Nes 2006)

USG teknolojileri her geçen gün gelişmesine rağmen, günümüz teknolojisinde uzmandan bağımsız veri değerlendirmesi ya da teşhis yapabilen akıllı USG cihazları

bulunmamaktadır. Görüntü analizi perspektifinden, USG teşhisine yardımcı olmak ve / veya bu tür bir değerlendirmeyi daha objektif ve doğru hale getirmek için gelişmiş otomatik USG görüntü analizi yöntemleri geliştirmek oldukça önemlidir.

Bu nedenlerle, özellikle bu salgın sürecinde, insanları hastane ve uzman bağımlılığından kurtarabilecek ve uzmanların da iş yükünü hafifletebilecek, güvenilir, otonom sistemlerin geliştirilmesi önem arz etmektedir. Son yıllarda tüm disiplinlerde olduğu gibi sağlık alanında da yapay zeka çalışmaları hız kazanmış, makine öğrenmesi (MÖ) algoritmaları ve derin öğrenme (DÖ) teknikleriyle birlikte akıllı sistemler geliştirilmeye başlanmıştır.

Bu tez çalışmasında, fetüs cinsiyetinin doktor muayenesinden bağımsız teşhisi ve sınıflandırılması için DÖ tekniklerine dayalı hibrit bir yöntem önerilmiştir. Çalışmada, cinsiyet tespiti için önce, ön-eğitilmiş Evrişimli Sinir Ağı (ESA) modelleri kullanılarak sınıflandırma yapılmış daha sonra, bu modeller içinden en yüksek doğruluk değerini veren model özellik çıkarıcı olarak kullanılarak sınıflandırma aşamasında MÖ algoritmaları kullanılmıştır. Çalışma için, ön-eğitilmiş ESA modellerinden; VGG16, InceptionV3, ResNet152V2, DenseNet201, Xception ağları Derin Transfer Öğrenme (DTÖ) teknikleri ile birlikte kullanılmıştır. MÖ sınıflandırma algoritmalarından; Lojistik Regresyon (Logistic Regression-LR), Doğrusal Destek Vektör Makinesi (Linear Support Vector Machine-LSVM), K-En Yakın Komşu (K-Nearest-Neighbor-KNN), Karar Ağacı (Decision Tree-DT), Rastgele Orman (Random Forest-RF) ve, AdaBoost (AB) olmak üzere, toplam 11 algoritma probleme uygulanmıştır.

Önerilen yöntem, taşınabilir ev tipi USG cihazlarına entegre edilebilir. Böylece ebeveynler doktor muayenesi olmadan fetüs cinsiyetini öğrenebilirler ve prenatal bakım için gebenin evde kontrolü sağlanarak kontrol sınırlandırmasına destek sağlanabilir. Aynı zamanda önerilen sistem, hastane tipi USG cihazlarına entegre edilerek, cinsiyet teşhisinde invaziv olmayan OUSG yönteminin farklı bir seçeneği olarak

değerlendirilebilir, uzman doktorlara yardımcı bir sistem olarak kullanılabilir ve doktorun iş yükünü hafifleten olanaklar sağlayabilir. Gelecekteki otomatik, verileri yorumlayabilen ve teşhis yapabilen akıllı USG cihazlarındaki sistemlerin veya e-sağlık uygulamalarının bir parçasını oluşturabilir.

Bu çalışma, uzmanlar tarafından yorumlama gerektiren, toplanması zaman alan, zor bir veri seti içermesi, DÖ tekniklerinin bu tür problemlere uygulanmasının oldukça yeni olması, ultrason görüntüleriyle çalışılmasının getirdiği zorluklar, DÖ tekniklerinin donanım bağımlılıkları gibi nedenler ve çalışmanın şimdiye kadar yapılmamış olmasından dolayı önem arz etmektedir.

1.1. Tıpta Fetüs Cinsiyetinin Tespitinde Kullanılan Yöntemler

Fetüs cinsiyetinin tam olarak oluşumu için dört evrenin tamamlanması gerekir; genetik cinsiyet (XX, XY kromozomları), Gonadal cinsiyet (yumurtalık, testis organları), iç genital organlar, dış genital organlar. Genetik cinsiyet, döllenme sırasında Y kromozomu etkenine göre belirlenir. Y kromozomunun varlığı erkek cinsiyetini belirler. Gonadal cinsiyet, üreme hücreleri olan gametleri oluşturan organlarda değişimin meydana gelmesiyle oluşur. Değişim testis yönündeyse erkek, yumurtalık (over) yönündeyse kızdır (Makiyan 2016). Gebeliğin 7. haftasına kadarki süreye tam farklılaşmamış evre denir ve gonadal değişim gerçekleşmediği için her iki cinste de cinsiyet kavramı aynıdır (Sadler 2012). 7. haftadan sonra gonadal değişimle birlikte iç genital organlar oluşur. 11. haftaya kadar embriyolojik dış genital organlar cinsiyet farkını göstermez (Speroff et al. 1994). Dış genital organlar arasında, 14. haftadan sonra fark görülür (Feldman and Smith 1975). Uterus, 18. haftaya kadar oluşur. Testisler 20. haftaya kadar oluşarak 28 ve 32. haftalar arasında skrotuma (içinde testislerin bulunduğu organ) iner (Bertrand et al. 1993).

Fetüs cinsiyetinin tespitinde kullanılan teknikler, fetüsteki anomalilikleri ve genetik bozuklukları tespit etmeye yönelik yapılan prenatal tanı tekniklerinin bir kısmıdır. Bu tekniklerden, Amniyosentez, Fetoskopi ve Koryon Villüs Örneklemesi (CVS) invazivken, Meternal (Anne) kan örneğinden fetal DNA incelemesi ve Obstetrik Ultrasonografi (OUSG) teknikleri invaziv değildir. Bu tekniklere ek olarak embriyo cinsiyetinin teşhisinde kullanılan prenatal teknikler de mevcuttur. Örneğin; Preimplantasyon Genetik Tanı (PGT) (Handyside et al. 1990). İnvaziv teknikler ile cinsiyetin erken gebelik dönemlerinde teşhisi mümkündür fakat, Obstetrik muayene bulguları bir tehlikenin varlığına dair kanıtlar içermiyorsa, uzmanlar tarafından invaziv yöntemlerin en aza indirilmesi veya kullanılmaması tercih edilmektedir. USG görüntüleme, göreceli güvenliği, düşük maliyeti, noninvaziv yapısı, gerçek zamanlı görüntüsü, operatör konforu ve operatör deneyimi nedeniyle dünyanın çoğunda doğum öncesi taramada yaygın olarak kullanılmaktadır (Reddy et al. 2008).

1.1.1. Amniyosentez

Bebeğin, anne karnında içinde bulunduğu sıvıdan (amniyon sıvısı) örnek alınarak yapılmaktadır. 100 yılı aşkın süredir prenatal tanı tekniği olarak kullanılmaktadır (Cunningham et al. 2014). İlk olarak, Fuschs ve Riis, 1956 yılında amniyotik sıvıda Barr cisimciğinin varlığına bakarak fetüs cinsiyetinin tespit edilebileceğini savunmuştur (Fuchs and Riis 1956). Amniyon hücrelerinden 2. tip hücrelerdeki kromatin incelemesi ile fetal cinsiyet tespit edilir. Genellikle, 15 ila 20. haftalar arasında yapılmaktadır ve 15 haftanın altında genetik inceleme ve cinsiyet tespitinde kullanılması kısıtlanmaktadır (Enzensberger et al. 2012). Blumberg vd. yaptıkları çalışmalarda, Amniyosentez sonrası annelerde uzun süreli depresyon ve psikolojik bozukluk keşfetmiştir (Blumberg et al. 1975). Buna rağmen fetüs ölüm riskinin (%0.5-1) çok düşük olduğu bir tekniktir (Tabor et al. 2009).

1.1.2. Fetoskopi

Bir endoskopi yardımıyla fetüsün dış genital organlarının görüntülenmesi tekniğidir. Genellikle, 15 ila 21. haftalar arasında yapılmaktadır. Enfeksiyon, metarnal kanama, su kesesinin yırtılması, fetal travma ve fetüs ölümü (%2) gibi riskleri vardır (Woo 2001).

1.1.3. Koryon Villus Örneklemesi (CVS)

Fetal doku örneğinden genetik tanı koymayı hedefleyen invaziv bir yöntemdir (Klages et al. 2017). Amniyosentezde olduğu gibi gebelerde anksiyete gibi psikolojik etkiler bırakabilmektedir. Amniyosenteze göre avantajı erken tanı konulabilmesidir (Colmant et al. 2013). Genellikle 11 ila 14. haftalar arasında yapılmaktadır. Fetüs ölüm riski %1' in altındadır (Akolekar et al. 2011).

1.1.4. Meternal Serumunda Serbest Fetüs DNA İncelemesi

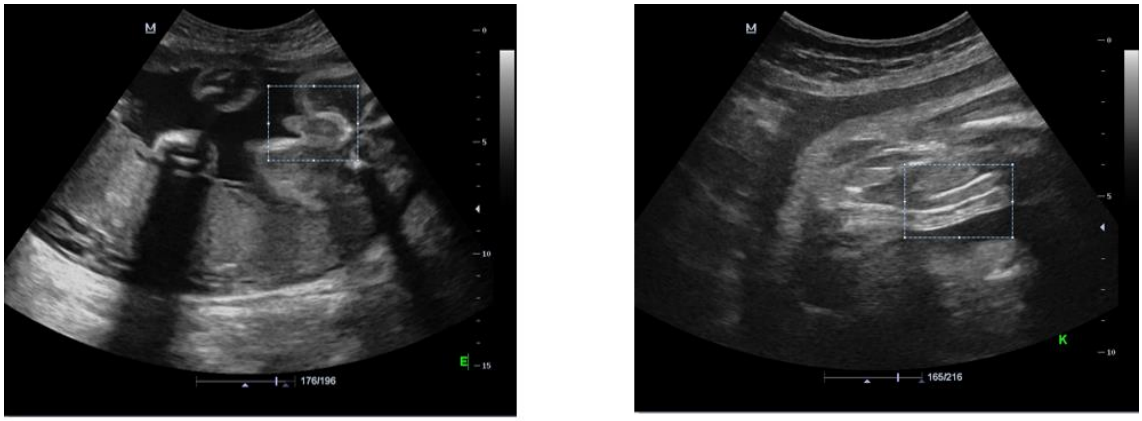
Lo vd. tarafından 1997 yılında yapılan bir çalışmayla anne kanında gezen serbest fetal hücrelerin ayrıştırılmasıyla cinsiyet tespitinin yapılabileceği savunulmuştur (Dennis Lo et al. 1997). 8. haftadan sonra yapılan testlerde başarı oranı yüksektir (Colmant et al. 2013). Fetal hücrede Y kromozomuna ait DNA tespit edilirse cinsiyet erkek, edilmezse kızdır.

1.1.5. Obstetrik Ultrasonografi (OUSG)

OUSG, cinsiyet tespitinde en sık kullanılan yöntemdir ve bilimsel araştırma olarak cinsiyetin OUSG ile teşhisinde yeni yöntemlerin önerileri tıp literatüründe önemli yer tutmaktadır. OUSG' de gerçek zamanlı (real-time), gri skala, B-Mod (Brightness

Mode), iki boyutlu (2D) kesitsel görüntüleme yöntemi kullanılmaktadır. Gri skala USG' de yansımaların (ekolar) dönüş süresi ve genliği ile görüntü oluşur. B-mod görüntülemede, anne rahmine, çok kısa atımlar şeklinde ultrases gönderilir ve dönen yansımalar, parlaklığı farklı noktalar şeklinde siyah bir zemin üzerinde görüntü oluşturur. Güçlü yansıyan ekolar parlak gri, yansımayan ekolar ise siyah rengindedir.

OUSG ile en klasik kullanılan cinsiyet teşhis tekniği, gebeliğin ikinci veya üçüncü trimesterında (üç aylık dönemi) yapılan, Scholly vd. tarafından 1980' de önerilen yöntemdir. Bu yönteme göre cinsiyet, erkek fetüslerde penis veya skrotum görselleştirilerek, dişi fetüslerde ise, labia görselleştirilerek tanımlanabilir ve bir erkek fetüsün aksine, başka hiçbir ilgili yapı görselleştirilemez (Şekil 1.1) (Scholly et al. 1980). Labia, genellikle "üç çizgi işareti" olarak adlandırılan ventral perine üzerinde üç paralel çizgi olarak görselleştirilebilir (Şekil 1.1-(b)) (Ammini et al. 1994). 14 haftalık gebelikte cinsiyet tam olarak ayırt edilemeyebilir, penis ve klitoris görseli karıştırılabilir. 14 haftalık bir fetüsün genital görüntüsüne ilk bakıldığında erkek gibi görünebilir fakat uretral açıklığın varlığı ile asıl cinsiyet ayırt edilebilir. Bu nedenle, bu yöntemle cinsiyet belirlenirken, 16 haftalık gebelik döneminden görüntü yakalayarak teşhis yapmak en doğrusudur (Harrington et al. 1996).



(a) (b)

Şekil 1.1 Fetal Genital Organları İçeren USG Görüntüleri
(a) Erkek Fetüs; (b) Dişi Fetüs

Bu yöntemin dışında, cinsiyetin oluştuğu bölgedeki genital çıkıntı veya yumrunun (tüberkül) yaptığı açı yorumlanarak fetüs cinsiyetinin tespit edilebileceğini savunan çalışmalar da mevcuttur. Erken gebelik haftalarında (12. haftadan itibaren), fetüsün uzunlamasına görüntüsünde USG cihazı tarafından ya da uzman eliyle açı ölçümleri yapılır (Altunyurt vd. 2010) (Efrat et al. 2006).

OUSG tekniği iyonizan radyasyon içermemesi, hastaya hiç rahatsızlık vermemesi, invaziv olmayan zararsız bir teknik olmasıyla avantajlıdır. Bununla birlikte, incelemenin uzmana bağımlı olması bu yöntemin önemli bir dezavantajıdır (Odeh et al. 2009).

2. KAYNAK ÖZETİ

Makine öğreniminin (MÖ) bir dalı olan Derin Öğrenme (DÖ), ham verilerden elde edilen orta düzey ve üst düzey soyut özellikleri doğrudan işleyebilen ve otomatik olarak öğrenebilen bir temsil öğrenme yaklaşımıdır. Derin bir Evrişimli Sinir Ağı (ESA) ve DÖ yönteminin bir temsilcisi olan AlexNet (Krizhevsky et al. 2012), 2012 ImageNet Büyük Ölçekli Görsel Tanıma Yarışması' nı (ILSVRC) kazandığında, DÖ, MÖ alanında dikkat çekmeye başlamıştır. Bir yıl sonra, DÖ, çeşitli araştırma alanlarında ve özellikle genel görüntüleme analizinde, lider MÖ aracı olarak konumunu daha da pekiştiren ilk on çığır açan teknolojiden biri olarak seçilmiştir (Wang 2016).

Son yıllarda tüm disiplinlerde olduğu gibi sağlık alanında da yapay zeka çalışmaları hız kazanmış, MÖ algoritmaları ve DÖ teknikleriyle birlikte akıllı sistemler geliştirilmeye başlanmıştır. DÖ, çeşitli otomatik USG görüntü analizi görevleri için de büyük bir potansiyel göstermektedir. USG görüntüleri ile yapılan çalışmalarda önerilen yöntemler arasında DÖ tekniklerinin yüksek başarım oranları elde ettikleri görülmektedir (Brattain et al 2018, Liu et al. 2019). Bu çalışmaların bazılarında, ön-eğitilmiş ESA' lar hem özellik çıkarıcı hem sınıflandırıcı olarak kullanılırken (Liu and Li 2018), bazılarında ise sadece özellik çıkarıcı olarak kullanılmış ve sınıflandırma aşamasında MÖ algoritmaları kullanılmıştır (Huynh et al. 2016). Bu teknikler medikal USG görüntülerine uygulanarak hastalık teşhisi (Liangmet al. 2020), sınıflandırma (Savaş vd. 2019) ve lokalizasyon (Hemalatha et al. 2019) gibi birçok tıbbi probleme çözüm ve yeni yöntemler sunmuştur.

Fetal USG görüntüleri kullanılarak gerçekleştirilen çalışmalara baktığımızda; serbest el ultrasonunda fetal standart tarama düzlemlerinin saptanması ve lokalizasyonu (Baumgartner et al. 2017), fetal yapıların sınıflandırılması (Kumar et al. 2016), fetal hastalıkların tespiti (Bindiya et al. 2018) gibi problemlere de DÖ ve MÖ algoritmaları sıklıkla uygulanmıştır.

Mühendislikte fetal genital organ sınıflandırması ve lokalizasyonu çalışmalarında, doğrudan cinsiyet tespiti ve sınıflandırılması yapılmamıştır. Ancak, fetal USG görüntülerinden oluşan veri setlerinde, cinsiyet tanımlayan özellikleri içeren görüntüler tespit edilmiştir.

Tang ve Chen tarafından yapılmış bir çalışmada, Asya ülkelerindeki cinsiyet seçici kürtajları ve ultrason teknisyenlerinin fetüsün cinsiyetini etik olmayan bir şekilde tanımlamasını önlemek için fetal genital organları otomatik tanıma ve konumlama algoritması önerilmiştir. USG görüntülerinde fetal genital organların mevcut olup olmadığı konusunda bir karar oluşturmak için sınıflandırma yapılmıştır. Çalışmada 658 adet fetal genital organ içeren görüntü, 500 adet de fetal genital organ içermeyen görüntü kullanılmıştır. Özellik çıkarma işleminde görüntü işleme teknikleri, sınıflandırma aşamasında ise, Radyal Temelli Fonksiyon Ağı (Radial Basis Function Network), Geri Yayılım Ağı (Backpropagation Network) ve Karar Destek Makinesi (Support Vector Machine-SVM) algoritmaları kullanılmıştır. SVM algoritması 89.01 ile en yüksek geometrik ortalama sonucunu vermiştir (Tang and Chen 2009).

Kumar ve ekibinin yaptıkları bir çalışmada, fetal yapıların analizi ve yorumlanması için 13 fetal anatomik yapı, 3 yapısal olmayan anlık görüntü sınıflandırması yapılmıştır. Sınıflandırılan anatomik yapıların içinde genital organ sınıfı da vardır. Çalışma için 7568 adet fetal USG görüntüsü kullanılmıştır. Özellik çıkarma aşamasında ESA (hassas ayarlı AlexNet – fine-tuned AlexNet), sınıflandırma aşamasında ise SVM algoritması kullanılmıştır. Genital organ sınıfı, %23.8 accuracy vermiştir (Kumar et al. 2016). Aynı yazarların 2019 yılında yaptıkları bir çalışma ile, bu çalışma geliştirilmiş, fetal yapıların analizi ve yorumlanması için 14 farklı fetal yapının sınıflandırılması yapılmıştır. Sınıflandırılan anatomik yapıların içinde genital organ sınıfı da vardır. 4074 Fetal USG görüntüsünden 52 adeti fetal genital organ sınıfına aittir. Kırpılmış ve bütün görüntülerden çıkarılan özellikler karar füzyonu ile birleştirilmiştir. Özellik çıkarıcı olarak ESA (hassas ayarlı AlexNet), sınıflandırıcı olarak SVM kullanılmıştır. 14 fetal

yapı, %97.05 ortalama doğruluk (mean accuracy) ile sınıflandırılmıştır. Genital organ sınıfı % 99 doğruluk (accuracy) vermiştir (Sridar et al. 2019).

Lakra ve arkadaşları tarafından 2019' da yapılan bir çalışmada, Hindistan'da cinsiyet seçici kürtajları önlemek ve gizliliğin korunması için fetal USG görüntüleri, genital organ içeren görüntü, genital organ içermeyen görüntü şeklinde sınıflandırılmıştır. Böylece, cinsiyet tanımlayan özellikleri içeren görüntüler tespit edilmiştir. Çalışma için 6027 adet fetal genital organ içeren görüntü, 15585 adet fetal genital organ içermeyen görüntü kullanılmıştır. Özellik çıkarıcı ve sınıflandırıcı olarak ESA (ResNet-18 ve ResNet-34) kullanılmıştır. Çalışma sonucunda, beş kat çapraz doğrulama ile %83.63 doğruluk (accuracy) elde edilmiştir (Lakra et al. 2019).

3. MATERYAL VE YÖNTEM

3.1. Makine Öğrenmesi ve Derin Öğrenme

Derin öğrenme, temsil öğrenmeli, yüksek seviyeli özellikleri çıkarmak için birden çok katman kullanan yapay sinir ağlarına dayalı makine öğreniminin teknik bir sınıfıdır. Geleneksel makine öğrenimi teknikleri, ham verileri işleme açısından sınırlıdır. Derin öğrenme, bir makinenin ham verilerle beslenmesini ve algılama veya sınıflandırma için gereken temsilleri otomatik olarak keşfetmesini sağlamaktadır. Derin öğrenmedeki "derin" sıfatı, ağdaki birden çok katmanın kullanımından gelmektedir. Derin katmanlar, her seviye girdi verilerini biraz daha soyut ve bileşik bir temsile dönüştürmeyi öğrenmektedir. Derin katmanlı modeller, sığ katmanlı modellerden daha iyi özellikler çıkarabilir ve bu nedenle ekstra katmanlar, özelliklerin etkili bir şekilde öğrenilmesini sağlar.

3.2. Evrişimli (Konvolüsyonel) Sinir Ağları (ESA)

ESA, görsel görüntüleri analiz etmek için uygulanan derin, ileri beslemeli (tekrarlayan değil), katmanlarından en az birinde matris çarpımı yerine konvolüsyon (evrişim) işlemi içeren yapay sinir ağları sınıfıdır. Günümüzde ESA' lar, görüntü verilerini sınıflandırmak için en verimli derin modellerdir. Çok aşamalı mimarileri canlıların optik sisteminin mekanizmasından esinlenmiştir (Hubel and Wiesel 1968). Bu modeller aracılığıyla, değişmeyen özellikler hiyerarşik ve otomatik olarak öğrenilir. Derin ESA' ların güçlü öğrenme yeteneği, büyük ölçüde veriden temsilleri otomatik olarak öğrenebilen çoklu özellik çıkarma aşamalarının (gizli katmanlar) kullanımından kaynaklanmaktadır. ESA' lar, önce düşük seviyeli özellikleri tanımlarlar ve ardından daha karmaşık kalıpları öğrenmek için bu özellikleri tanımayı ve birleştirmeyi öğrenirler. Bu farklı özellik düzeyleri, ağın farklı katmanlarından gelmektedir. Her

katmanın belirli sayıda, yükseklik, genişlik, derinlik olmak üzere üç boyutta sunulan nöronları vardır.

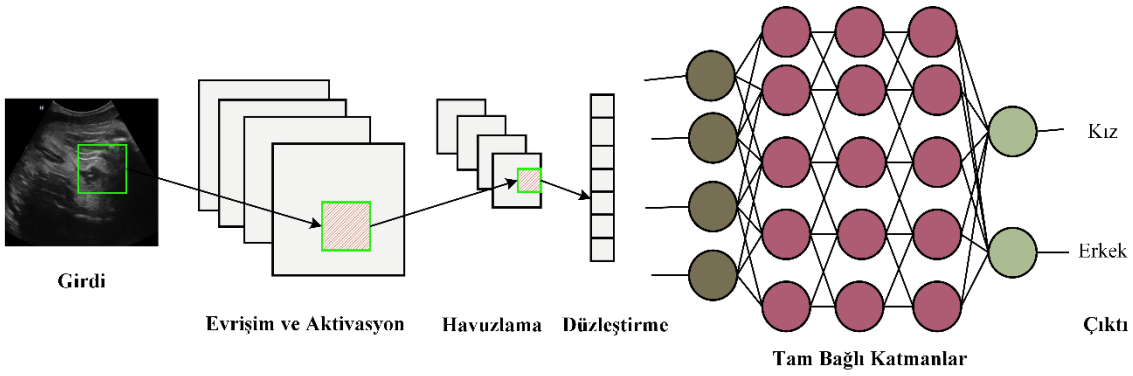
ESA' ların en faydalı yönü, yapay sinir ağlarının parametre sayısını azaltmaktır. ESA parametreleri, görüntüde nesnenin konumuna bağımlı olan özelliklere sahip değildir. ESA, verilen resimlerdeki nesneleri konumlarından bağımsız olarak tespit etmektedir. ESA' ların bir başka önemli yönü, giriş daha derin katmanlara doğru yayıldığında soyut özellikler elde etmektir. ESA mimarisinde, ilk katmanlar çok genel özellikler (köşeler, kenarlar, renkler, dokular vb.) çıkarırken son katmanlara ilerledikçe soyut kavramlar ve sınıfa özel özellikler (göz, kulak vb.) çıkarmaktadır. Bu özelliği sayesinde ESA' ların evrişim katmanları, görüntüden özellik çıkarma ve tekrar kullanma açısından geleneksel algoritmalara üstünlük sağlar. Geleneksel sınıflandırıcı algoritmalarında özellik çıkarma işlemi için görüntü işleme yöntemleri kullanılırken, ESA ise ham verilerden konvolüsyon yöntemiyle özellik çıkarmakta ve sınıflandırıcısı ile sınıflandırmaktadır. Tüm bu avantajlarının yanında, veri setinin büyüklüğü ve işlem çokluğu ile birlikte, ESA' ların eğitim aşaması donanımsal olarak oldukça maliyetlidir. Ancak, günümüz yüksek performanslı GPU' lar ile bu dezavantajın üstesinden kolaylıkla gelinmektedir.

Geleneksel Çok Katmanlı Algılayıcı (ÇKA) modelleri, başarıyla görüntü tanıma işlemleri için kullanılmıştır. Ancak, birbiri ile tamamen bağlantısı nedeniyle yüksek boyutlu ortamlarda boyutluluk laneti (Bellman 2010) sorununun üstesinden gelememiştir. Boyutluluk laneti, verileri analiz ve organize ederken ortaya çıkan çeşitli olaylara atıfta bulunulan bir terimdir ve düşük boyutlu ortamlarda meydana gelmemektedir. ESA' ları, ÇKA' lardan ayıran üstün özellikler mevcuttur. Bu özelliklerden biri ESA' ların üç boyutlu nöronlara sahip olmasıdır. ESA' lar katmanlar halinde düzenlenmiş genişliği, yüksekliği ve derinliği olan üç boyutlu nöronlara sahiptir. Hem yerel hem de tamamen bağlı katmanların ayrı tipi ESA mimarisini oluşturmak için bir araya gelmektedir. Bir diğer ayırt edici üstünlüğü ise, ESA' ların yerel bağlantılara sahip olmasıdır. Doğrusal olmayan filtreler daha büyük alanların temsillerini bir araya getirdikten sonra ilk girişin küçük parçalarının temsilleri

oluşturulur. Böylece, piksel alanı giderek daha büyük bir bölgeye duyarlı olmaktadır. Diğer ayırt edici üstünlüğü ise ESA' ların ortak ağırlıklara sahip olmasıdır. ESA' ların her bir filtresi görme alanını çoğalttıktan sonra, bu çoğaltılmış üniteler, aynı ağırlık ve önyargı vektörlerini paylaşarak özellik çıkarmaktadırlar. Bu ayırt edici özellikler, ESA' ların iyi genelleme yaparak bilgisayarlı görme problemlerinin üstesinden başarıyla gelmesini sağlar.

3.2.1. ESA Mimarisi ve Katmanları

Genel olarak bir ESA' nın, evrişim katmanı, havuzlama katmanı ve tam bağlı katman olmak üzere üç ana katmanı vardır (Şekil 3.1). Bu ana katmanlara ek olarak, ana katmanların arasında konumlanan aktivasyon katmanı, yığın (batch) normalizasyonu katmanı, iletim sönümü (dropout) katmanı, düzleştirme (flatten) katmanı gibi ara katmanlara sahiptir.



Şekil 3.1. ESA Mimarisi ve Katmanları

3.2.1.1. Evrişim (konvolüsyon) katmanı

ESA' lar ham verilerle çalışmaktadır. Giriş (girdi) katmanından çıkan ham resim verileri evrişim katmanına gönderilir. Evrişim katmanı, ESA' lara ismini veren en önemli katmandır. Evrişim katmanının genel amacı, görüntülerden özellik çıkarmaktır. Çıkarılan özellikler genelleştirme özelliği ile tekrar kullanılabilirdir. ESA' ların ilk evrişim katmanlarında genel özellikler çıkarılırken (kenar, köşe vb.), üst katmanlara doğru daha özel ve nesneyi tanımlayan özellikler çıkarılır.

Tensörler, veriler için taşıyıcı görevinde olan matrislerin herhangi bir boyuttaki halidir. Matrisleri bir dizide birleştirerek üç veya daha fazla boyutlu tensörler (3B, 4B vb.) elde edilmektedir. Evrişim katmanına giriş katmanından gelen ham resim verisi, boyutları genişlik, yükseklik, derinlik (kanal) olmak üzere 3B tensörlerdir ve bu tensörler nitelik haritası diye isimlendirilir. Evrişim katmanının görevi, nitelik haritasından çekilen küçük parçalara, evrişim işlemi uygulayarak çıktı oluşturmak, diğer adıyla, öznitelik (aktivasyon) haritası elde etmektir. Denklem (3.1)' de formüle edilen iki boyutlu evrişim işlemi, nitelik haritası (p×r boyutlu x) ve filtreler (m×n boyutlu w) arasında gerçekleşmektedir. Evrişim işlemi sonucu oluşan yeni matrisin boyutu M×N olmak üzere i = 0, 1, …, M-1 ve j = 0, 1, …, N-1' dir.

$$(w * x)[i,j] = \sum_{a=0}^{m-1} \sum_{b=0}^{n-1} w[a,b]x[i-a, j-b] \tag{3.1}$$

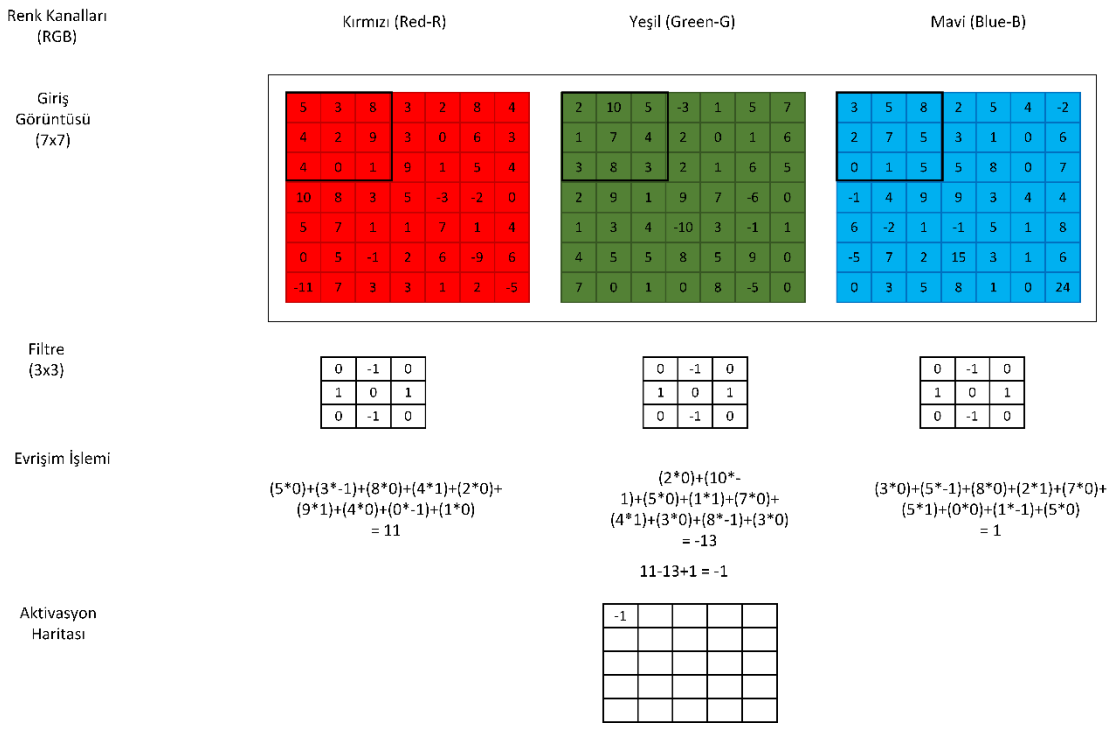
3B tensörlerde derinlik kavramı renk kanalını temsil etmektedir. Renkli resimlerde kanal sayısı RGB olmak üzere 3 iken, gri seviye resimlerde 1' dir. İlk evrişimden geçen çıktı da 3B tensördür fakat, derinlik kavramı, evrişim katmanının bir parametresine dönüşür ve resmin kanallarından değil, filtre (kernel, maske) yapılarından oluşur.

Örneğin; ilk evrişim katmanı 28×28×1 boyutunda girdi (nitelik haritası) alır ve 26×26×32 çıktı oluşturursa, bu, 32 farklı filtre (filtre sayısı) ve çıktı oluştuğunu göstermektedir. Filtre sayısı, çıktı haritasının derinliğidir. Filtre resim üzerinde kayarak evrişim işlemini gerçekleştirir bu nedenle, girdiden çıkarılacak parçaların boyutu filtre boyutunu (3×3, 5×5, 7×7 vb.) oluşturmaktadır. Büyük filtre boyutu seçimi maliyetlidir, bu nedenle evrişim katmanının bir parametresi olarak filtre boyutunun seçimi önemlidir. Örneğin, 32×32×3 boyutundaki bir girdiye 3×3 boyutlu bir filtre uygulandığında filtre başına 27 tane ağırlık düşerken, 5×5 boyutunda bir filtre seçilirse, filtre başına 75 tane ağırlık düşmektedir. Bu durum 5×5 boyutlu bir filtrenin, 3×3 boyutlu filtreden yaklaşık 2.8 kat daha maliyetli olduğunu göstermektedir (Szegedy et al. 2016).

Filtrenin nitelik haritası üzerinde kaydırılma sayısına adım sayısı denir. Genel ayar olarak, giriş görüntüsünün genişliği ve yüksekliği eşit boyutlarda, adım sayısı 1 alınan ve kenar doldurma işlemi yapılmayan evrişim katmanının çıktı haritasının genişliği ve yüksekliği (3.2)' de verildiği gibi hesaplanmaktadır. (3.2)' de kullanılan parametreler, G: girdinin genişliği ve yüksekliği, D1: girdinin derinliği (ilk evrişim katmanı için renk kanalı sayısı), G×G×D1: girdi boyutu, F: filtre genişliği ve yüksekliği, N: filtre sayısı, F×F×N: filtre boyutu, S: adım sayısı, Ç: çıktı genişliği ve yüksekliği olmak üzere çıktı boyutu: Ç×Ç×N şeklindedir. Örneğin, bir evrişim katmanında 7×7×3' lük bir girdiye 3×3×32' lik filtre uygulandığında (7-3)/1+1 = 5×5'lik 32 tane çıktı haritası oluşmaktadır.

$$Ç = (G - F)/S + 1 \tag{3.2}$$

Şekil 3.2 'de, 7×7×3'lük bir girdiye 3×3'lük bir adet filtrenin uygulandığı evrişim (konvolüsyon) işlemi gösterilmektedir. Evrişim işlemine göre, giriş görüntüsünü oluşturan nitelik haritasındaki her bir değer, eşleştiği filtre değeriyle çarpılarak elde edilen çarpım değerleri toplanır böylece vektör şekline dönüştürülür. Tüm bu vektörler yan yana getirilerek 3B tensör olan çıktı yani aktivasyon haritası oluşturulur.



Şekil 3.2. Bir Girdiye (7×7×3), Bir Adet Filtrenin (3×3) Uygulandığı Evrişim İşlemi

Çıktı boyutuna kenar doldurma ve adım sayısı olmak üzere iki faktör etki etmektedir. Bir nitelik haritasının üzerine filtrenin merkezi yerleştirildiğinde oluşan çıktının boyutu, girdi boyutu ile aynı olmayabilir, bu durumda kenar etkisi meydana gelmektedir. Örneğin 5×5'lik bir girdi 25 döşemeye sahiptir. Bu döşemeler üzerinde 3×3' lük bir filtrenin kaydığını düşünürsek 9 tanesinin üzerine filtrenin merkezi denk gelir ve 3×3' lük, 9 çıktı oluşur. Bu durumda çıktı oluşurken, girdi boyutu her yönden 2 eksilir. Girdi boyutu ile çıktı boyutunun eşit olması için girdiye her yönden satır ve sütunlar eklenerek kenar doldurma işlemi uygulanır. En sık kullanılan sıfır doldurma (zero padding) işleminde girdiye her yönden satır ve sütun olarak sıfır eklenmektedir. Örneğin, 5×5'lik bir girdiye kenar doldurma işlemi uygulandığında boyutu 7×7 haline gelir. 7×7' lik yeni girdi üzerinde 3×3' lük filtre kaydırıldığında 5×5' lik, 25 adet çıktı oluşur böylece girdi ve çıktı boyutları eşitlenmektedir.

Çıktı boyutunu etkileyen ikinci faktör adım sayısını arttırmaktır. Adım sayısı 1 alındığında girdi üzerinde kayan filtrenin merkezleri bitişik noktalara denk gelmektedir. Adım aralığı 1' den büyükse evrişim işlemi, aralıklı evrişim ismini almaktadır. Adım aralığı 2 alınırsa nitelik haritası ½ oranında küçülmektedir. Adım sayısı arttırma, her bir katmanın çıktısı ardından gelen katmanın girdisi olduğu için girdi küçültme işleminde kullanılmaktadır. Genel olarak, girdinin küçültülmesi için adım aralığı arttırma yerine havuzlama (alt örnekleme) işlemi tercih edilmektedir. Adım sayısının artırılması çıktının küçülmesi anlamına gelmektedir. Örneğin, adım sayısı 1 alındığında, 5×5' lik bir girdi ve 3×3' lük bir filtre çıkışı 3×3' lük iken adım sayısı 2 alındığında, aynı girdi ve filtre için 2×2' lik çıktı oluşmaktadır.

Giriş görüntüsünün genişliği ve yüksekliği eşitsiz boyutlarda, adım sayısı 1 veya 1'den büyük alınan ve kenar doldurma işlemi yapılan evrişim katmanının çıktısının genişliği ve yüksekliği, Eşitlik (3.3) ve (3.4)' te verildiği gibi hesaplanmaktadır. Bu eşitliklerde kullanılan parametreler, GG: girdinin genişliği, GY: girdinin yüksekliği, GD: girdinin derinliği (ilk evrişim katmanı için renk kanalı sayısı), GG×GY×GD: girdi boyutu, F: filtre genişliği ve yüksekliği, N: filtre sayısı, F×F×N: filtre boyutu, S: adım sayısı, P: sıfır doldurma miktarı, ÇG: çıktı genişliği, ÇY: çıktı yüksekliği olmak üzere çıktı boyutu: ÇG×ÇY×N şeklindedir. Çıktı derinliği (ÇD) filtre sayısına eşittir. Filtre başına düşen ağırlık sayısı F*F*GD, katmanın sahip olduğu filtrelerin toplam ağırlık sayısı (F*F*GD)*N şeklinde hesaplanır ve katman N tane de önyargı nöronuna sahiptir. Örneğin, bir evrişim katmanında 28×25×3 boyutundaki girdiye, 1 adım kaydırmalı, sıfır doldurma miktarı 2 olan, 10 adet 5×5 filtre uygulandığında çıktı boyutu, eşitlik (3.3) ve (3.4)' ten, 28×25×10 olarak hesaplanır. Filtre başına düşen ağırlık sayısı 5*5*3 = 75, toplam filtrelerin ağırlık sayısı 75*10 = 750, önyargı nöronlarının ağırlık sayısı 10 olmak üzere, katman toplam 760 tane parametreye sahiptir.

$$ÇG = (GG - F + 2P)/S + 1 \quad (3.3)$$

$$ÇY = (GY - F + 2P)/S + 1 \quad (3.4)$$

3.2.1.2. Aktivasyon katmanı

Bu katman genelde evrişim katmanlarının sonuna ya da sınıflandırma katmanının sonuna eklenir ve doğrultucu katman görevindedir. Bu katman doğrusal olmayan bir dönüşümle hangi nöronun aktif olacağını belirler. ESA' larda evrişim katmanından sonra genellikle ReLU aktivasyon fonksiyonu kullanılmaktadır. Bunun sebebi, ReLU' nun negatif girdileri sıfıra çevirmesi böylece tüm nöronları aktif etmemesi ve ağın çok hızlı birleşmesini sağlayarak maliyeti azaltmasıdır. ReLU doğrusal bir işlem gibi gözükse de türevi alınabilir ve geri yayılımı etkinleştirir. ReLU negatif bölgede gradyanı sıfır yapar yani, geri yayılım sırasında tüm ağırlıklar güncellenmez. Bu sorunun üstesinden zayıf ReLU (Leaky ReLU) fonksiyonu gelmektedir. Zayıf ReLU' nun negatif bölgede küçük bir pozitif eğimi vardır, bu nedenle negatif giriş değerleri için bile geri yayılımı etkinleştirir. Bu avantajına rağmen, zayıf ReLU negatif girdi değerleri için tutarlı tahminleme yapamayabilir.

ESA' larda sınıflandırma görevi için, sigmoid ve softmax aktivasyon fonksiyonları tam bağlı katmanın ardından kullanılmaktadır. Sigmoid fonksiyonu çıkış değerlerini 0 ila 1 arasında sınırlandırılarak her bir nöronun çıktısını normalleştirir ve ikili sınıflandırma problemlerinde kullanılır. Dezavantajları, tahminde neredeyse hiç değişiklik olmayabilir ve bu da kaybolan gradyan sorununa neden olabilir. Bu, ağın daha fazla öğrenmeyi reddetmesine veya doğru bir tahmine ulaşmak için çok yavaş olmasına neden olabilir. Softmax fonksiyonu çoklu sınıflandırma için kullanılmaktadır. Her sınıf için çıktıları 0 ile 1 arasında normalleştirir ve toplamlarına bölerek girdi değerinin belirli bir sınıfta olma olasılığını verir. Çizelge 3.1' de ReLU, zayıf ReLU, softmax ve sigmoid fonksiyonlarının matematiksel formülleri verilmiştir (Sharma et al. 2020).

Çizelge 3.1. ESA' larda Sık Kullanılan Aktivasyon Fonksiyonları

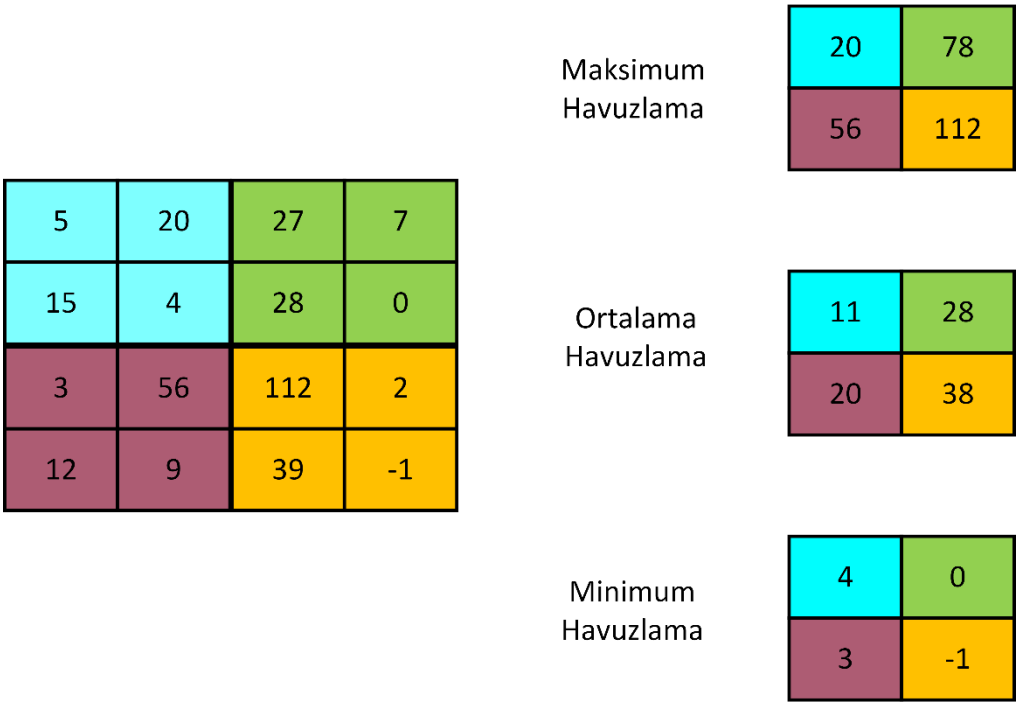
Aktivasyon Fonksiyonu	**Formülü**
ReLU	$f(x) = \max(0, x)$ (3.5)
Leaky ReLU	$f(x) = 0.01x, x < 0$ $f(x) = x, x \geq 0$ (3.6)
Softmax	$f(x_i) = \frac{e^{xi}}{\sum_j e^{xj}}$ (3.7)
Sigmoid	$f(x) = \frac{1}{1+e^{-x}}$ (3.8)

3.2.1.3. Havuzlama (alt örnekleme) katmanı

Evrişim ve aktivasyon katmanının ardından gelen katmandır ve görevi kendisinden sonra gelecek olan katmanın giriş görüntüsünü küçültmektir. Bir katmandan çıkan görüntü sonraki katmanının girişi olacağı için küçültme işlemi ağın maliyetini azaltır ve ezber yapmasını önler. ESA' larda kullanılan havuzlama yöntemleri maksimum, ortalama ve minimum havuzlamadır. Döşemelere ayrılan görüntü belli bir grup döşemeyi kapsayacak şekilde (filtre boyutu kadar) ayrılır ve bu döşeme gruplarında adım sayısı kadar kayan havuzlama filtresi, maksimum havuzlama için en büyüğü, ortalama havuzlama için ortalaması, minimum havuzlama için minimum olanları alarak birleştirir. Şekil 3.3' te maksimum, ortalama ve minimum havuzlama örneği verilmiştir. Havuzlama katmanına giren girdi boyutu GG×GY×GD, filtre boyutu F×F, adım sayısı S olmak üzere, çıktı boyutu ÇG×ÇY×GD şeklindedir ve çıktının genişliği ve yüksekliği, Eşitlik (3.9) ve (3.10)' da verildiği gibi hesaplanmaktadır. Havuzlama katmanından çıkan görüntünün derinliği değişmemektedir.

$$ÇG = (GG - F)/S + 1 \quad (3.9)$$

$$ÇY = (GY - F)/S + 1 \quad (3.10)$$



Şekil 3.3. Havuzlama İşlemi

3.2.1.4. Yığın (batch) normalizasyonu katmanı

Girdi verilerinin sıfır merkezli ve sıfırla bir arasında yeniden değer alması veri normalleştirme işlemidir. ESA, verilerin hepsini aynı anda işlemek yerine mini yığınlara bölerek işlemektedir. Yığın normalleştirme algoritmasına göre mini yığındaki veriler toplanıp toplam veri sayısına bölünür ve ortalama bir değer elde edilir (Çizelge 3.2-(3.11)). Tüm verilerden bu ortalama değer çıkarılarak karesi alınır ve hepsi toplanarak toplam veri sayısına bölünür (mini yığın varyansı) (Çizelge 3.2-(3.12)). Böylece girdi verileri normalize edilmiş olur (Çizelge 3.2-(3.13)). Normalize edilen veriler ölçekleme ve kaydırma parametreleri ile çarpılarak eğitilebilir, lineer bir denklem elde edilmektedir (Çizelge 3.2-(3.14)). Ölçekleme ve kaydırma parametreleri ile çarpılması, normalizasyon işleminin eğitim sırasında optimize edilebilir olmasını sağlamaktadır (Ioffe and Szegedy 2015).

Çizelge 3.2. Yığın Normalleştirme Dönüşümleri

İşlem	**Denklem**
Mini Yığın Ortalama	$\mu_B = \frac{1}{m}\sum_{i=1}^{m} x_i$ (3.11)
Mini Yığın Varyansı	$\sigma_B^2 = \frac{1}{m}\sum_{i=1}^{m}(x_i - \mu_B)^2$ (3.12)
Normalizasyon	$\hat{x}_i^{(k)} = \frac{x_i^{(k)} - \mu_B^{(k)}}{\sqrt{\sigma_B^{(k)^2} + \epsilon}}$ (3.13)
Ölçekleme ve Kaydırma	$y_i^{(k)} = \gamma^{(k)}\hat{x}_i^{(k)} + \beta^{(k)} \equiv BN_{\gamma,\beta}(x_i)$ (3.14)
μ: Ortalama değer; x: Girdi; m: Mini yığın boyutu; σ: varyans; g: Giriş boyutu olmak üzere $k \in [1, g], i \in [1, m]$; $\mu_B^{(k)}$: Boyut başına ortalama; $\sigma_B^{(k)}$: Boyut başına varyans; $\hat{x}^{(k)}$: Normalleştirilmiş aktivasyon; y_i: Yığın normalizasyonunun çıktısı; γ, β: Öğrenilebilir ağırlık parametreleri	

3.2.1.5. İletim sönümü (dropout) katmanı

Bu katmanın amacı ağın aşırı uydurma yani, ezberleme yapmasını önlemektir. Test aşamasında kullanılmayan yalnızca eğitim aşamasında kullanılan bu katmanda ağın öğrendiği bazı bilgiler sıfırlanır. İletim sönümü işleminde bir katmanın çıktısı, yeni girdi olarak bu katmana geldiğinde, verilen iletim sönümü katsayısı kadar sıfırlanır ve küçültülür. İletim sönümü katsayısı genelde 0.2 ila 0.5 arasında bir değer seçilmekle birlikte, sıfırlanacak verilerin toplam veri sayısına oranıdır (Srivastava et al. 2014).

3.2.1.6. Düzleştirme (flatten) katmanı

Tam bağlı sınıflandırma katmanları 3B tensörlerle değil 1B vektörlerle işlem yapabilmektedir. Bu nedenle tam bağlı katmanlara girdi gönderilirken bu katmanda düzleştirme işlemi yapılır. Örneğin, 3×3×64 boyutundaki girdi bu katmandan geçtiğinde tam bağlı katmana 576 elemanlı 1B vektör şeklinde verilir.

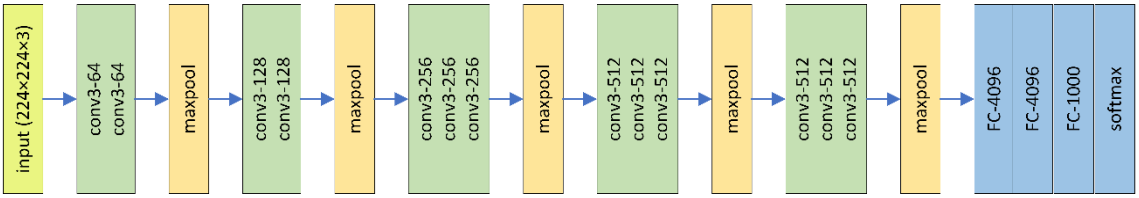
3.2.1.7. Tam bağlı (fully connected) katman

Klasik çok katmanlı sinir ağlarına benzeyen bu katmanlar ESA' ların son katmanlarıdır. Bu katmanlardaki tam bağlantı hesaplamaları ağır iş yükü gerektirdiği için iletim sönümü kullanılabilir. Bu katmanların amacı sınıfa özel özellikler çıkararak girdinin hangi sınıfa ait olduğunu tahmin eden çıktı üretmektir. ESA' larda tam bağlı katmanlar yerine küresel havuzlama katmanı da kullanılabilir. Küresel havuzlama katmanında, her özellik haritasının ortalaması alınarak elde edilen vektör doğrudan sınıflandırma çeşidine göre softmax veya sigmoid katmanına bağlanır.

3.2.2. Ön-eğitilmiş ESA Modelleri

3.2.2.1. VGGNet

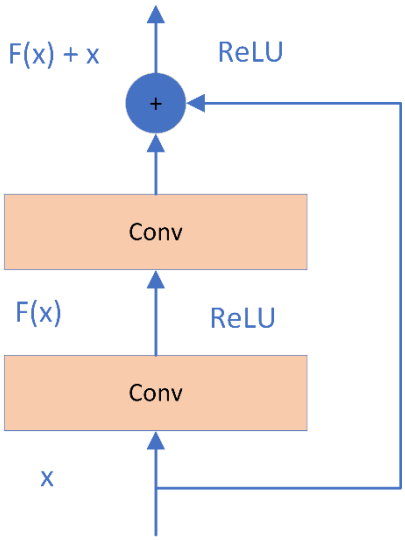
Simonyan ve Zisserman tarafından AlexNet'in daha derin bir konfigürasyonu olarak modellenmiştir (Simonyan and Zisserman 2015). Toplam 6 farklı ESA konfigürasyonu kullanılmıştır; A, A-LRN, B, C, D (VGG16) ve E (VGG19), sırasıyla 11, 11, 13, 16, 16, 19 ağırlıklı katmanlar ile kullanılmıştır. VGG16, ILSVRC-2014' e sunulan, 1000 sınıfa ait 14 milyondan fazla görüntüden oluşan bir veri kümesini sınıflandırmış bir modeldir. Giriş görüntüleri 224×224 boyutunda kullanılmıştır. Şekil 3.4' te VGG16 mimarisi verilmiştir. İlk iki katmanda 64 kanallı 3×3 boyutlu filtre kullanılmıştır. Ardından maksimum havuzlama 2 adım kaydırmalı şeklinde kullanılmış, havuzlama katmanından sonraki evrişim katmanı 256 kanallı 3×3 boyutlu filtre ile kullanılmıştır. Bundan sonra 2 set, 3 evrişim katmanı ve maksimum havuzlama katmanı vardır. Her biri aynı dolguya (doldurma miktarı 1) sahip 3×3 boyutunda 512 filtreye sahiptir ve bu aşamalardan sonraki görüntü daha sonra iki evrişim katmanından oluşan yığına aktarılır. Evrişim katmanları ReLU aktivasyon fonksiyonlarıyla birlikte kullanılmıştır. 3 adet tam bağlı katmandan sonra 1000 çıkışlı softmax fonksiyonu ile sonlanmaktadır. Toplamda 138 milyon parametreye sahiptir. İlk 5 (top-5) test hata oranı %7.32' dir.



Şekil 3.4. VGG16 Mimarisi

3.2.2.2. ResNet

Kaiming He ve ekibinin ILSVRC 2015 için tasarladığı 152 katmanlı mimaridir (He et al. 2016). İlk 5 test hata oranı %3.6' dır. Bir ağın derinliğinin artması aşırı uydurma problemine yol açabilmektedir. Kaiming derinlik arttırmanın aşırı uydurma probleminden önce kaybolan gradyan problemine sebep olabileceğine inanarak ResNet mimarisini tasarlamıştır. Kaybolan gardayan problemine göre geri yayalım sırasında ağın derinliği nedeniyle ağın üst katmanlarından ilk katmanlarına doğru gradyan azalmakta ve sıfırlanmaktadır. Böylece ilk katmanların ağırlıkları güncellenmemektedir. Standart bir ESA mimarisinde girdi bir katmandan geçtiğinde oluşan çıktı ardından gelen katmana girdi olarak verilmektedir ve bu olay art arda gelen tüm katmanlarda devam etmektedir. Eğer bir katmanda ağırlıklar güncellenmez ya da sıfırlanırsa, o katmanın ağa katkısı olmayacaktır. ResNet mimarisi artık (residual) bloklar sayesinde, her iki katmanda bir girdi değerini çıkışa ekleyerek bu sorunun üstesinden gelmektedir. Şekil 3.5' te artık blokların yapısı verilmiştir. ResNet 18, 50, 101, 152 gibi birçok versiyona sahiptir.

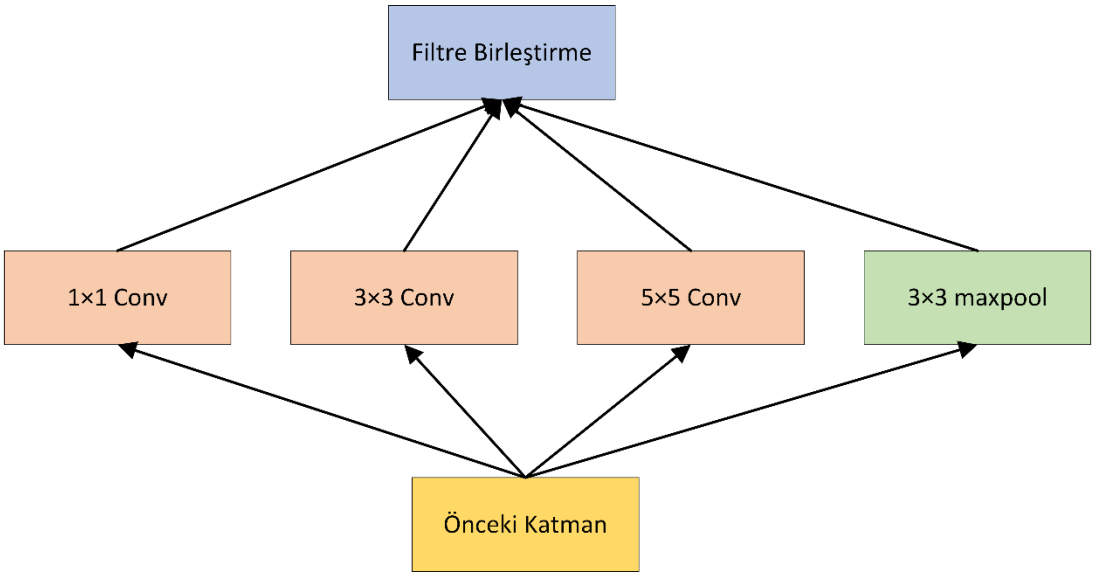


Şekil 3.5. Artık (Residual) Blokların Yapısı

3.2.2.3. GoogLeNet (Inception)

Christian Szegedy tarafından ILSVRC 2014 için tasarlanmış bir modeldir (Szegedy et al. 2015). İlk 5 hata oranı %6.6'dır. Görüntünün geniş bir alanına dağılmış daha global özellikler için daha büyük filtreler tercih edilirken, diğer yandan daha küçük filtreler, görüntü çerçevesi boyunca dağıtılan alana özgü özelliklerin tespit edilmesinde iyi sonuçlar sağlamaktadır. Inception'da katman sayısında daha derine inmek yerine, daha da genişler. Aynı katman içinde farklı boyutlarda birden çok filtre kullanılır. InceptionV1, toplamda 22 katmana sahip olmasına rağmen parametre sayısı (4 milyon) AlexNet'e göre düşüktür. Naif inception modülüne göre 1×1, 3×3, 5×5 boyutlu filtrelere sahip evrişim katmanları ve 3×3 boyutlu filtreye sahip maksimum havuzlama katmanı paralel olarak gerçekleşmektedir böylece, ağ genişlemektedir. Şekil 3.6' da naif inception modülü verilmiştir. Naif inception modülünden çıkan çıktının boyutu çok büyük olacağından maliyeti azaltmak için her işlemden önce 1×1 boyutunda filtreler kullanılarak boyut azaltma işlemi yapılmıştır. InceptionV2 ve V3'de, V1'den farklı olarak 3×3 filtre boyutuna sahip evrişim katmanları, yığın normalizasyonu ve iletim sönümü kullanılmıştır. InceptionV4'te artık (residual) bloklar ve inception modülleri

birleştirilmiştir. InceptionResNet versiyonları, InceptionV4' ün farklı filtre boyutları kullanılmış modelleridir (Szegedy et al. 2017). Xception, "Extreme Inception" olarak adlandırılır ve Inception mimarisinin daha güçlü bir versiyonudur (Chollet 2017).



Şekil 3.6. Naif Inception Modülü
(Conv: Evrişim İşlemi; maxpool: Maksimum Havuzlama İşlemi)

3.2.2.4. DenseNet

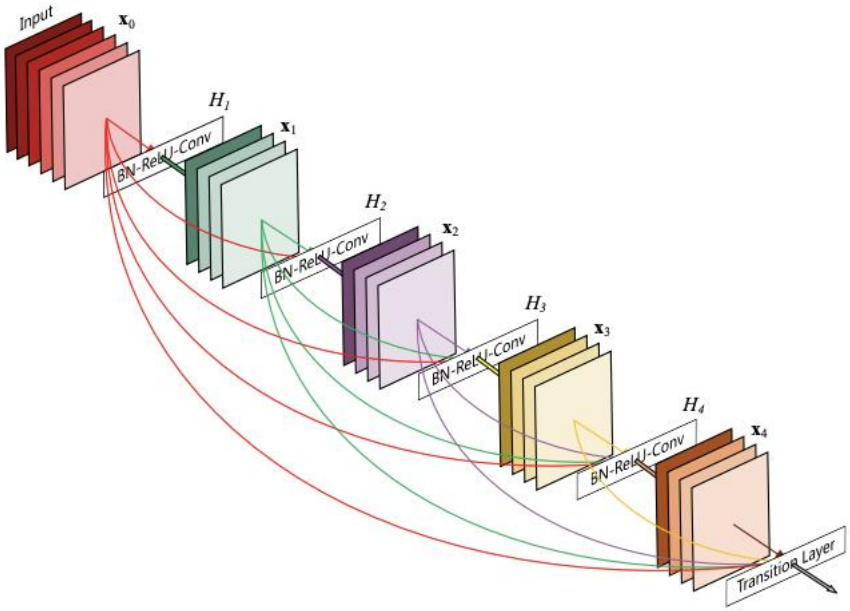
Huang ve arkadaşları tarafından CIFAR, SVHN ve ImageNet (ILSVRC 2012) veri setleri üzerinde eğitilerek tasarlanmış bir modeldir (Huang et al. 2016). Mimarisinde önceki tüm katmanların çıktısının birleştirildiği yoğun (dense) bloklar kullanılmıştır. Yoğun blokların birleştirme özelliği, x çıktı özelliği haritaları, H katman, i o anki katman sayısı olmak üzere Denklem (3.15)' te verildiği gibi formülleştirilmektedir. Yoğun bloklar sayesinde, her katman önceki tüm katmanların özelliklerini yeniden kullanmaktadır. Böylece, özellik yayılımı güçlendirilmiş ve kaybolan gradyan problemi azaltılmıştır. Ayrıca az sayıda filtre kullanımı da modelin parametre sayısını azaltmıştır. Yoğun bloklar, arka arkaya gelen yığın (batch) normalizasyonu, ReLU ve evrişim

işlemlerinden oluşmaktadır (Şekil 3.7). Yoğun bloklar içinde özellik haritalarının boyutları sabit kalırken, filtre sayıları bloklar arasında değişmektedir (3×3-1×1). Yoğun bloklar arasında geçiş katmanı denilen, 1×1 evrişim ve 2×2 ortalama havuzlama işlemi içeren katmanlar vardır. Büyüme oranı, her katmanda ağa ne kadar bilgi ekleneceğini düzenleyen bir hiperparametredir (k). Çizelge 3.3' te, ImageNet veri seti için tasarlanmış DenseNet201' in mimarisi verilmiştir. DenseNet201' in ilk 5 hata oranı %6.34 ila %5.54 arasındadır.

Çizelge 3.3. DenseNet201 Mimarisi

Katmanlar	**Çıkış Boyutu**	**İşlem**
Conv	112×112	7×7 conv, stride 2
Pooling	56×56	3×3 max-pool, stride 2
DB1	56×56	1×1 conv 3×3 conv] ×6
TL1	56×56	1×1 conv
	28×28	2×2 avg-pool, stride 2
DB2	28×28	1×1 conv 3×3 conv] ×12
TL2	28×28	1×1 conv
	14×14	2×2 avg-pool, stride 2
DB3	14×14	1×1 conv 3×3 conv] ×48
TL3	14×14	1×1 conv
	7×7	2×2 avg- pool, stride 2
DB4	7×7	1×1 conv 3×3 conv] ×32
CL	1×1	7×7 global average pool 1000D fully connected layer, softmax

Giriş boyutu: 224×224×3; k = 32; Conv: Evrişim Katmanı; DB: Yoğun Blok; TL: Geçiş Katmanı; conv: Konvolüsyon; max-pool: Maksimum Havuzlama; avg-pool: Ortalama Havuzlama; global average pool: Küresel Ortalama Havuzlama; fully connected layer: Tam Bağlı Katman.



Şekil 3.7. 5 Katmanlı Yoğun Blok Yapısı (k = 4)
(Huang et al. 2016)

$$x_i = H_i([x_0, x_1 \dots x_{i-1}) \tag{3.15}$$

3.2.3. ESA' ların Eğitim Süreci ve Hiperparametreleri

Öncelikle ESA için kullanılacak veri seti hazırlanmalıdır. Sınıflandırma için kullanılacak veri seti hazırlığında eğitim, doğrulama ve test aşamalarında kullanılacak veriler ve sayıları belirlenmelidir. Daha sonra, etiketlenmiş görüntüler sınıflarına ait klasörlere ayrılmalıdır. Eğitim, doğrulama ve test aşamaları için kullanılacak veri sayıları önemlidir, çünkü ağ ne kadar çok örnek görürse genelleme yeteneği o kadar artar. Bu yüzden veri setinin çok sayıda örnek içermesi ve eğitim örneklerinin fazla olması gerekmektedir. Eğitim, doğrulama ve test veri setinin ayrımında çeşitli yöntemler kullanılabilir. Genellikle, iki klasörden biri test verilerini içerirken diğer klasörden 0.25, 0.3 gibi seçilen yüzde değerinde veriler doğrulamada, kalanlar ise

eğitimde kullanılmaktadır. Bir diğer sık kullanılan yöntem ise eğitim, doğrulama ve test verileri için ayrı ayrı üç klasör oluşturmaktır ve test ile doğrulama verileri eşit sayıda alınmaktadır.

Eğitim, doğrulama ve test veri setleri oluşturulduktan sonra, ağ inşa edilmelidir. Evrişim, aktivasyon, maksimum havuzlama, tam bağlı katmanlar gibi katmanalar art arda konularak kullanılacak ağ modeli oluşturulmalıdır. Bu aşamada girdi boyutu, filtre sayıları ve boyutları gibi katmanlara ait hiperparametreler belirlenmelidir.

Veriler eğitim aşamasına girmeden önce ağı beslemesi için uygun şekilde ön işlemeden geçirilmelidir. Görüntü içerikleri kod çözerek RGB noktalarına dönüştürüldükten sonra, bu noktalar ondalık tensörlere dönüştürülmelidir. Daha sonra görüntü noktaları 0 ile 255 yani, dönüştürülen tensörler için [0,1] aralığında yeniden ölçeklendirilmelidir. Eğitim için veri setinin yetersiz olması ya da aşırı uydurma gibi sorunların üstesinden gelebilmek için veri çoğaltma (data augmentation) (Shorten and Khoshgoftaar 2019) adı verilen bir yöntem kullanılmaktadır. Sonsuz veri olduğunda ağ olabilecek tüm veri dağılımlarını hesaplayabilir ve aşırı uydurma yapamaz. Veri çoğaltma yöntemi eldeki görüntülere çeşitli değişimler uygulayarak biraz değişmiş görüntüleri veri setine ekleyerek ağa verir böylece gerçeğe yakın daha fazla eğitim verisi oluşturulur. Görüntüyü derece cinsinden rastgele döndürme, yatayda ve dikeye kaydırma, burkma yakınlaştırma, kaydırma, döndürme vb. işlemler sonrası oluşan görüntü noktalarının doldurulması gibi yöntemler, en sık kullanılan veri çoğaltma teknikleridir. Veri çoğaltma yöntemi kullanıldığında eğitim aşamasında ağ aynı görüntüyü ikinci kez görmemektedir. Buna rağmen çoğaltılan yeni görüntüler, çoğaltıldığı görüntülerle ilişkili olduğu için aşırı uydurmaya kesin bir çözüm değildir.

Eğitim aşaması dört ana adımdan oluşmaktadır. İlk adımda eğitim örnekleri ve bu örneklere karşılık gelen hedeflerden oluşan bir yığın (batch) oluşturulur. Hesap yükünün azaltılması amacıyla veri setinden görüntüler yığınlar şeklinde parça parça ağdan

geçirilmektedir. Genellikle yığın boyutu (batch size) GPU mimarisi nedeniyle ikinin katları şeklinde belirlenmektedir. Ağdan geçirilecek yığın sayısı, adım başı tur sayısını (step per epoch) belirlerken, tüm veri setinin ağdan kaç kez geçirileceği ise tur sayısını (epoch) belirlemektedir. Örneğin, 2000 tane görüntüden oluşan eğitim seti için yığın boyutu 20 seçildiğinde adım başı tur sayısı 100' dür yani, 100 adet yığın ağdan geçirilecek demektir. Bu örnek için tur sayısı sayısını 10 belirlediğimizde, 10 kere 100 adet yığın ağdan geçirilecek, yani tüm veri seti 10 kez eğitim aşamasından geçecek demektir.

İkinci adımda ağ eğitim örneklerinden olan tahminleri elde etmede öznitelik çıkarma aşaması ve ileri yayılma sürecinden geçirilir. İleri yayılma sürecinde geleneksel sinir ağlarından farklı olarak net girdileri hesaplamak için iç çarpım işlemi yerine evrişim işlemi kullanılır. Evrişim işleminden sonra aktivasyon fonksiyonu olarak türevlenebilir ReLU kullanımı yaygındır.

Üçüncü adımda ise tahmin değerleri ile hedef değerler arasındaki fark alınarak kayıp değeri mevcut yığın için hesaplanır. Kayıp değerinin hesaplanması kayıp fonksiyonları kullanılarak hesaplanmaktadır. Kayıp fonksiyonu problemin tipine göre seçilmelidir. Problem tipi ikili veya çok etiketli çoklu sınıflandırma ise ikili çapraz entropi (binary cross-entropy), tek etiketli çoklu sınıflandırma ise kategorik çapraz entropi (categorical cross-entropy), bağlanım (regression) ise ortalama kare hata (mse) kullanılmaktadır. Entropinin matematiksel formülü Denklem (3.16)' da verilmiştir, düzensizliğin ölçülmesinde kullanılan bir yöntemdir. Denklem (3.17)' de verilen Çapraz entropiye lojistik kayıp da denilmektedir. Denklem (3.18)' de verilen ikili çapraz entropi eşitliğinde, N veri sayısı olmak üzere, y_i hedefleri, p(y_i) ise tahminleri temsil etmektedir. İkili çapraz entropi, tahminlerin sigmoid aktivasyonundan geçirildikten sonra çapraz entropiye girmesidir ve sigmoid kaybı da denilmektedir. Sigmoid kaybına benzer şekilde, kategorik entropi, tahminlerin softmax aktivasyonundan geçirildikten sonra çapraz entropiye girmesidir ve softmax kaybı da denilmektedir. Kayıp değeri en

küçültmek istenilen değer olduğu için ağın başarım oranını ölçmede bir kriter olarak kullanılmaktadır.

$$H(q) = -\sum_{c=1}^{c} q(y_i)\log\left(q(y_i)\right) \tag{3.16}$$

$$H_{p(q)} = -\sum_{i=1}^{i} q(y_i)\log\left(p(y_i)\right. \tag{3.17}$$

$$H_{p(q)} = -\frac{1}{N}\sum_{i=1}^{N} y_i \log\big(p(y_i)\big) + (1-y_i)\log\left(1-p(y_i)\right) \tag{3.18}$$

Eğitim sürecinin dördüncü aşamasında ağdaki tüm ağırlıklar o yığın için bulunan kayıp değerini azaltacak şekilde geri yayılım (backpropagation) (Hecht-Nielsen 1982) geçirerek güncellenir. Geri yayılım algoritmasının temelinde zincir türev işlemleri yatmaktadır. Çok boyutlu girdilerin türevine gradyan denmektedir. Geri yayılım algoritması ile ağdaki her bir fonksiyon türevlenebilir olduğundan sondan başlayarak geriye doğru her katmanın, zincir türev kuralına göre o katmanın kayıp değerine ne kadar katkı yaptığı (gradyanı) hesaplanmaktadır.

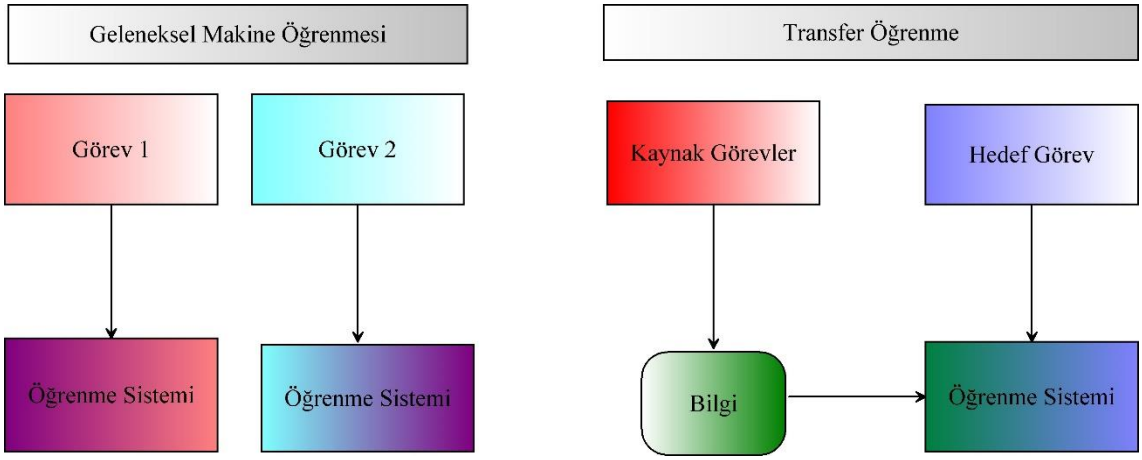
Kaybın gradyanının, ağırlıkları nasıl güncelleyeceğini optimizasyon (eniyileme) algoritmaları belirlemektedir. En temel optimizer, Stokastik Gradyan İnişidir (SGD). Bir f(x) fonksiyonunun a noktasındaki türevi negatif ise, x' in a noktası yakınlarındaki değişimler, f(x) fonksiyonunun değerini azaltır, pozitif ise arttırır. x değeri, f(x) fonksiyonunun değerini azaltmak için türevin aksi yönünde değiştirilirken arttırmak için türevin yönünde değiştirilir. SGD' ye göre, geri yayılım ile hesaplanan gradyan, öğrenme oranı denilen bir katsayı ile çarpılır ve bulunan değerin aksi yönünde ağırlıkların güncellenmesi kayıp değerini azaltacaktır. Öğrenme oranı (learning rate) denilen hiperparametre, ağırlıkların ne kadar büyüklükte arttırılacağını ya da azaltılacağını belirlemede kullanılan bir katsayıdır. Veriyi yığınlara ayırarak uygulanan

SGD' ye mini yığın SGD, tüm veri kullanılarak uygulanan SGD' ye yığın SGD, her bir iterasyonda tek bir veri kullanılarak uygulanan SGD' ye gerçek SGD isimleri verilmiştir. Yığın ve gerçek SGD kullanıldığında ağırlıklar daha gerçekçi güncellenecek ve ağ başarımı artacaktır fakat maliyeti yüksektir. Bu sebeple, mini yığın SGD kullanımı yaygındır. SGD yalnızca mevcut gradyan değerini göz önüne alarak ağırlık optimizasyonunu sağlamaktadır. Mevcut gradyana ek olarak önceki ağırlık güncellemelerini de göz önüne alarak optimizasyonu sağlayan, temel olarak SGD' den türemiş AdaGrad (Duchi and Singer 2011), Adam (Kingma and Ba 2014), AdaDelta (Zeiler 2012), RMSProp (Tieleman and Hinton 2012), Momentumlu SGD (Sutskever et al. 2013) gibi çeşitli optimizerler mevcuttur. Bu optimizerler, fizikten esinlenen momentum kavramını kullanarak SGD kullanımında ortaya çıkan, eniyileme işleminin genel minimuma ulaşmadan yerel minimumda sıkışması sorununu çözmektedir. Momentum, önceki güncelleme değeridir.

3.3. Derin Transfer Öğrenme (DTÖ)

Ön-eğitimli evrişimli sinir ağı, daha önce büyük ölçekli görüntü sınıflandırma probleminde büyük veri seti kullanılarak eğitilmiş ve kaydedilmiş bir ağ modelidir. Transfer öğrenmede, ön-eğitimli model ya olduğu gibi ya da mevcut probleme göre özelleştirilerek kullanılmaktadır. Eğer bir model yeterince büyük ve genel bir veri kümesi üzerinde eğitilmişse, bu model görsel dünyanın genel bir modeli olarak her probleme uyarlanabilir. Böylece, mevcut problemdeki sınıflar ön-eğitilmiş ağdaki sınıflardan tamamen farklı olsa bile transfer öğrenme probleme çözüm getirebilir. Gerçek dünyada transfer öğrenmenin birçok örneği ile karşılaşılabilir. Örneğin, elektronik org çalmayı öğrenmek piyano öğrenmeyi kolaylaştırabilir. Transfer öğrenmenin temeli, önceden öğrenilmiş bilgileri saklamak ve başka bir öğrenmede yeniden kullanmaktır.

Transfer öğrenme, bir veya daha fazla kaynak görevinden bilgiyi çıkarmayı ve bilgiyi bir hedef göreve uygulamayı hedefler. Transfer öğrenmenin geleneksel makine öğrenmesine göre avantajları vardır. Şekil 3.8, geleneksel öğrenme ve transfer öğrenme tekniklerinin öğrenme süreçleri arasındaki farkı göstermektedir. Transfer öğrenmede kaynak ve hedef görevlerin rolleri simetrik değildir (Şekil 3.8). Geleneksel makine öğrenme teknikleri her bir işi sıfırdan öğrenmeye çalışırken, transfer öğrenme teknikleri daha önceki bazı görevlerden ulaştığı bilgiyi daha az eğitim verisine sahip olan bir hedef göreve aktarmaya çalışır. Böylece, daha az eğitim verisi ile daha yüksek başarı gösteren ve daha hızlı öğrenen modeller elde edilebilir. Öğrenilen bilgilerin taşınabilir olması transfer öğrenmeyi geleneksel öğrenmeden ayıran en önemli avantajlardan biridir.



Şekil 3.8. Makine Öğrenmesi ve Transfer Öğrenmenin Öğrenme Süreçleri

Transfer öğrenme uygulanırken üç aşama üzerinde durulmalıdır. İlk aşamada hangi bilginin aktarılacağı belirlenmelidir. Bazı bilgiler kaynak görev için özel bilgilerdir ve hedef görevin performansını arttırmada geçersiz olabilir. İkinci aşamada aktarılacak bilgiler tespit edildikten sonra bu bilgilerin nasıl aktarılacağı belirlenmelidir. Bilgiyi aktarmak için hedef göreve karşılık gelen öğrenme algoritmaları belirlenmelidir. Üçüncü aşamada ise hangi durumlarda bilginin aktarılmaması gerektiği belirlenmelidir.

Kaynak görev ve hedef görevin ortak etkileşim alanları yoksa aktarım başarısız olabilir ve hedef görevdeki performansa zarar verebilir. Bu durum negatif transfer olarak adlandırılmaktadır

Transfer öğrenme farklı öğrenme temelli üç alt kümede, endüktif (tümevarım) transfer öğrenimi, transdüktif (dönüştürücü) transfer öğrenimi ve denetimsiz transfer öğrenimi olarak kategorize edilmektedir. Bu kategoriler kaynak ve hedef etki alanları ile görevleri arasındaki durumlar göz önünde bulundurularak oluşturulmuştur (Çizelge 3.4 ve Çizelge 3.5).

Çizelge 3.4. Makine Öğrenmesi ve Transfer Öğrenmede Kaynak ve Hedef Etki Alanları ile Görevleri Arasındaki Durumlar

Öğrenme Türü	**Kaynak ve Hedef Alanları**	**Kaynak ve Hedef Görevleri**
Geleneksel Makine Öğrenmesi	Aynı	Aynı
Endüktif Transfer Öğrenimi	Aynı	Farklı fakat ilişkili
Transdüktif Transfer Öğrenimi	Farklı fakat ilişkili	Aynı
Denetimsiz Transfer Öğrenimi	Farklı fakat ilişkili	Farklı fakat ilişkili

Çizelge 3.5. Transfer Öğrenme Çeşitlerine Göre Kaynak ve Hedef Etki Alanlarındaki Etiketler Arasındaki Durumlar

Transfer Öğrenme Çeşitleri	**Alt Alanları**	**Kaynak Alan Etiketleri**	**Hedef Alan Etiketleri**	**Görevler**
Endüktif Transfer Öğrenimi	Çoklu Görev Öğrenme	Var	Var	Regresyon, Sınıflandırma
	Kendi Kendine Öğrenilen Öğrenme	Yok	Var	Regresyon, Sınıflandırma
Transdüktif Transfer Öğrenimi	Alan Adaptasyonu, Örnek Seçim Önyargısı, Ortak Değişken Kayması	Var	Yok	Regresyon, Sınıflandırma

Denetimsiz Transfer Öğrenimi	Yok	Yok	Kümeleme, Boyutlama

1. Endüktif (Tümevarım) Transfer Öğrenimi (Inductive Transfer Learning): Kaynak ve hedef etki alanları aynı fakat kaynak ve hedef görevleri farklıdır. Endüktif öğrenme, kaynak etki alanındaki etiketli verilerin kullanılamadığı durumdur. Kaynak etki alanındaki farklı etiketli ve etiketsiz verilerin durumlarına göre, endüktif transfer öğrenme iki durumda kategorize edilmektedir:

a. Çoklu Görev Öğrenme (Multi-task Learning): Kaynak etki alanında çok fazla etiketli veri varsa ve hedef etki alanının verileri de etiketli ise çoklu görev öğrenme hem hedef hem de kaynak görevi aynı anda öğrenmeye çalışırken, kaynak görevden bilgi aktararak hedef görevde yüksek performans elde etmeyi amaçlamaktadır.

b. Kendi Kendine Öğrenilen Öğrenme (Self-taught Learning): Kaynak etki alanında etiketli veri yoksa ve hedef etki alanının verileri etiketli ise kaynak ve hedef etki alanları arasındaki etiket boşlukları farklı olabilir, bu da kaynak etki alanının yan bilgilerinin doğrudan kullanılamayacağını gösterir.

2. Transdüktif (Dönüştürücü) Transfer Öğrenimi (Transductive Transfer Learning): Kaynak ve hedef etki alanları farklıyken kaynak ve hedef görevleri aynıdır. Bu durumda, hedef etki alanında etiketli veri bulunmazken, kaynak etki alanında çok sayıda etiketli veri kullanılabilir. Kaynak ve hedef alanlar arasındaki farklı durumlara göre, transdüktif transfer öğrenme iki durumda kategorize edilmektedir:

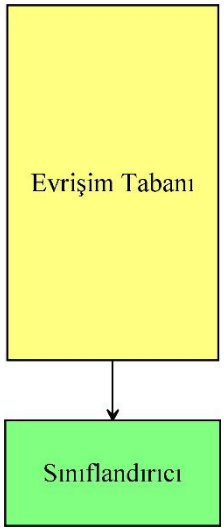
a. Kaynak ve hedef etki alanları arasındaki özellik uzayları farklıdır.

b. Alanlar arasındaki özellik uzayları aynıdır, ancak giriş verilerinin marjinal olasılık dağılımları farklıdır. Bu durum, metin sınıflandırmasında bilgi aktarımı için alan adaptasyonu ve varsayımları benzer olan örnek seçim yanlılığı veya ortak değişken kayması ile ilgilidir.

3. Denetimsiz Transfer Öğrenimi (Unsupervised Transfer Learning): Kaynak ve hedef etki alanları farklıyken aynı zamanda kaynak ve hedef görevleri de farklıdır. Kaynak ve hedef etki alanlarının ikisinde de etiketli verinin bulunmadığı durumdur. Kümelenme, boyut azalması ve yoğunluk tahmini gibi hedef alandaki denetimsiz öğrenme görevlerini çözmeye odaklanmaktadır.

3.3.1. Transfer Öğrenmenin ESA Problemlerine Uygulanması

Transfer öğrenme kullanılan bir ESA' nın genel yapısı evrişim tabanı ve sınıflandırıcıdan oluşmaktadır (Şekil 3.9). Evrişim tabanı özellik çıkarma işlemi yapar. Sınıflandırıcı ise, evrişim tabanına eklenir ve evrişim tabanından çıkan özellikleri sınıflandırır. İlk aşamada ön-eğitilmiş bir ESA modeli seçilmelidir. Daha sonra bu modelin sınıflandırıcı katmanı çıkarılarak probleme uygun olan, yeni sınıflandırıcı katman eklenmelidir. Kaynak ve hedef etki alanlarındaki veri setlerinin benzerlikleri ve boyutları göz önüne alınarak probleme uygun şekilde ön-eğitilmiş model özelleştirilmelidir.



Şekil 3.9. ESA' ların Genel Yapısı

Genelde, ön-eğitilmiş ESA modelleri olarak ImageNet, LabelMe gibi devasa veri setleri üzerinde eğitilmiş ve başarısını kanıtlamış AlexNet, VGG16, Xception, Inception, ResNet, DenseNet vb. ağlar kullanılmaktadır. Evrişim tabanı görüntüden özellik çıkarma görevini üstlenir ve görüntüdeki nesneye ait genel kavramları hedef görevden bağımsız olarak öğrenir. Evrişim tabanının öğrendiği bilgiler daha genel ve kullanışlıdır. Evrişim tabanının aksine sınıflandırıcı katmanın öğrendikleri sınıfa özel bilgilerdir. Sınıflandırıcı katman, görüntüde o sınıfın olup olmadığı olasılığını öğrenir. Sınıflandırıcı katman nesnenin görüntüdeki yeriyle ilgili bilgi üretemezken bu bilgi evrişimli katmanlarda tutulmaya devam eder. Bu yüzden nesnenin yerinin önemli olduğu görevlerde sınıflandırıcı katmanlar kullanışsızdır.

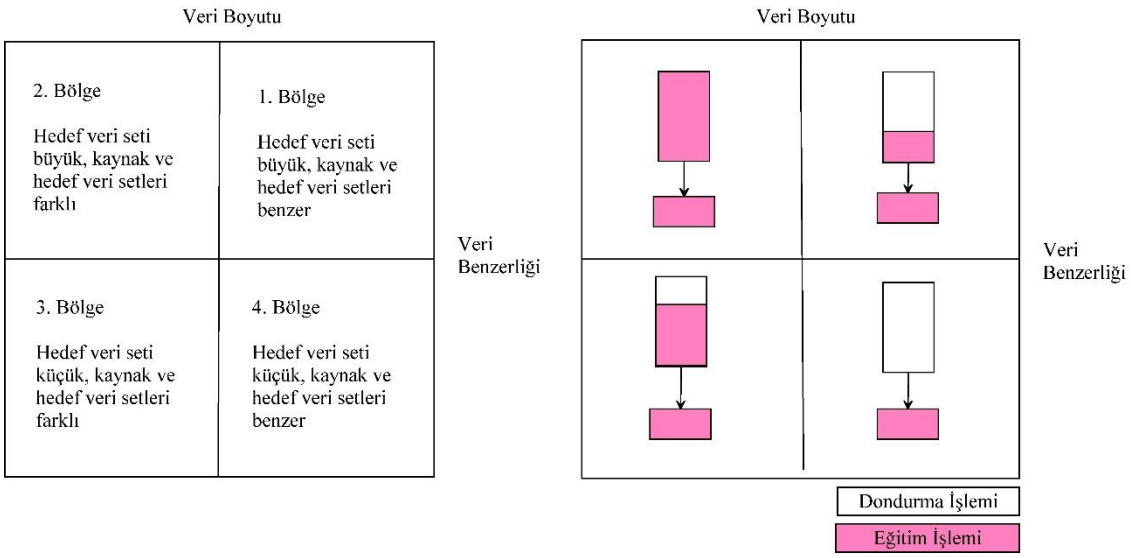
Ön-eğitilmiş modele birçok farklı yöntemle sınıflandırıcı eklenebilir. Görüntü sınıflandırma problemleri için standart yaklaşım tamamen bağlı katmanlar (Fully connected layers) eklemektir. Bu yöntemin içeriği, tamamen bağlı katmanlardan oluşan bir yığın ve ardından softmax, sigmoid gibi sınıflandırma problemine uygun aktif katman kullanmaktır. Tam bağlı katmanlar yöntemine benzer bir başka yöntem, evrişim tabanına küresel ortalama havuzlama (Global average pooling) katmanı eklemektir. Bu

yaklaşımda, evrişimsel tabanın üstüne tamamen bağlı katmanlar eklemek yerine, küresel bir ortalama havuz katmanı eklenir ve çıktısı doğrudan softmax, sigmoid gibi aktif katmana bağlanır. Sınıflandırıcı eklemenin bir diğer yöntemi ise evrişim tabanını sadece özellik çıkarıcı olarak kullanmak ve evrişim tabanından gelen özellikleri makine öğrenmesi veya istatiksel sınıflandırıcı algoritmaları üzerinde eğitmektir.

Ön-eğitilmiş bir ESA modelini özelleştirmenin iki yolu vardır:

Özellik çıkarma: Evrişim tabanından özellik çıkarma işlemi için iki farklı yol bulunmaktadır. İlk seçenekte evrişim tabanı hedef veri setinde çalıştırılır ve özellik çıkartma işlemi yapılır. Çıkarılan özellikler diske kaydedilip kendi başına bir girdi olarak seçilen sınıflandırıcıya verilir. Bu çözüm, evrişim tabanını baştan eğitmek gerektirmediği için hızlı ve basittir fakat veri setindeki her bir görüntü evrişim katmanlarından yalnızca bir defa geçeceği için veri çoğaltma işlemi uygulanamaz. Bu durumda veri seti az olan bir problemin çözümünde uygun olmayabilir. İkinci seçenek, ön-eğitilmiş modelin evrişim tabanına tam bağlı katmanlar ya da küresel ortalama havuz katmanı eklenerek tüm girdilerle en baştan eğitmektir. Bu seçenek zaman ve donanım açısından maliyetli olacaktır fakat tüm resimler her epochta evrişimli tabandan geçeceği için veri çoğaltma işlemi uygulanabilir.

Hassas Ayar: Evrişim tabanının öğrendiği özelliklerin genelliği ve yeniden kullanılabilirliği modelin derinliğine bağlıdır. Modelin ilk katmanları çok genel özellikler (köşeler, kenarlar, renkler, dokular vb.) çıkarırken son katmanlara ilerledikçe soyut kavramlar ve sınıfa özel özellikler (göz, kulak vb.) çıkarmaktadır. Bu nedenle kaynak ve hedef etkileşim alanlarındaki veri setleri boyut-benzerlik matrisine göre incelenmelidir. Veri setlerinin uyumluluğuna göre evrişim tabanı tamamen eğitilebilir, üstten birkaç katmanı dondurulabilir ya da evrişim tabanı tamamen dondurulabilir. Bu sürece hassas ayar denilmektedir.



Şekil 3.10. Boyut-Benzerlik Matrisi

Şekil 3.10' da verilen boyut-benzerlik matrisine göre;

Bölge 1, hedef görevde kullanılacak veri setinin büyük ve kaynak görevde kullanılan veri setiyle benzer olması durumudur. Bu durumda büyük veri seti olduğu için aşırı uydurma sorunu oluşmadan evrişim tabanının üst katmanlarından birkaç tanesinin ve sınıflandırıcının eğitilmesi gerekir. Evrişim tabanının çoğu katmanı dondurularak kullanılabilir.

Bölge 2, hedef görevde kullanılacak veri setinin büyük ancak kaynak görevde kullanılan veri setiyle farklı olması durumudur. Bu durumda evrişim tabanı ve sınıflandırıcı hedef görevdeki veri seti ile en baştan eğitilmelidir. Evrişim tabanının mimarisi tamamen kullanılırken ağırlıkları başlangıç değeri olarak kullanılır.

Bölge 3, hedef görevde kullanılacak veri setinin küçük ve kaynak görevde kullanılan veri setiyle farklı olması durumudur. Veri seti sayısı her sınıf için 1000'in altında ise

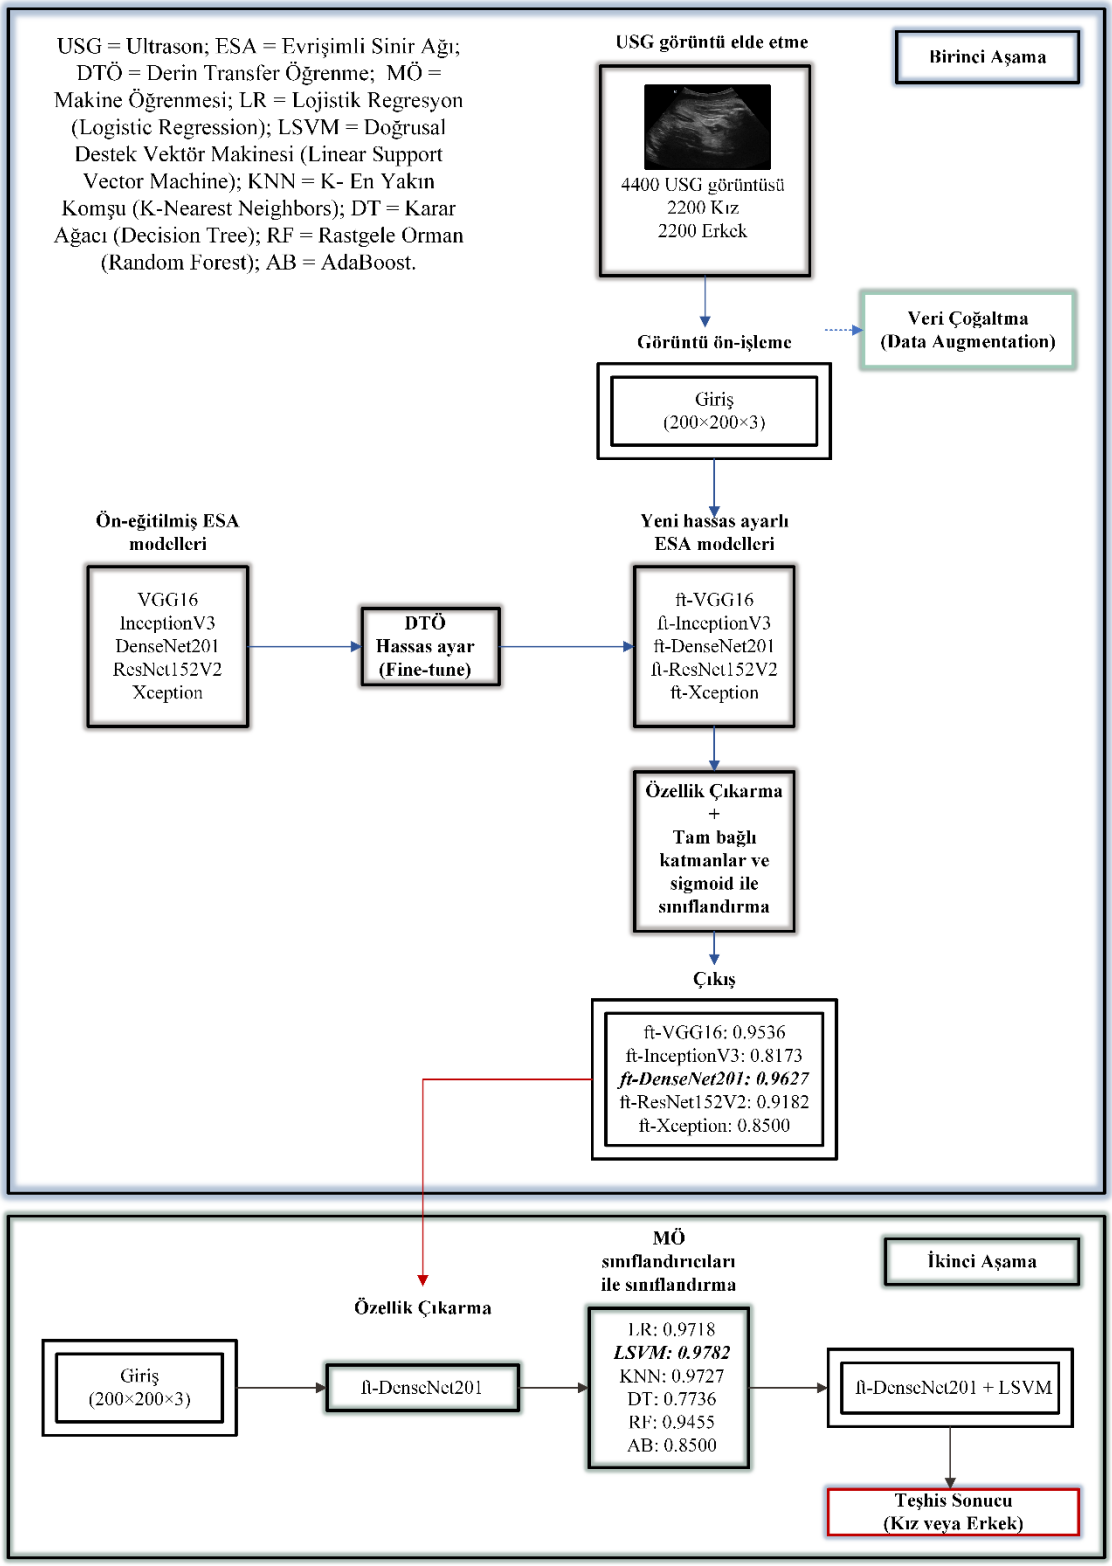
veri seti boyutu küçük kabul edilir. Eğitilecek ve dondurulacak katman sayısı arasında bir denge bulmanın zor olduğu durumdur. Bu durumda, veri çoğaltma tekniği kullanmanın yanı sıra aşırı uydurmayı önlemek için üstten çoğu katman ve sınıflandırıcı eğitilmelidir. Evrişim tabanının genel özellik çıkaran en alt katmanları dondurulmalıdır.

Bölge 4, hedef görevde kullanılacak veri setinin küçük ancak kaynak görevde kullanılan veri setiyle benzer olması durumudur. Bu durumda evrişim tabanı orijinal formunda tutulmalı ve daha sonra çıktıları sınıflandırıcıyı beslemelidir. Yani, evrişim tabanının tümü dondurulmalı yalnızca eklenen sınıflandırıcı katmanı eğitilmelidir.

Transfer öğrenmenin ESA' lara uygulanması, Oquab yöntemi veya transfer evrişimli sinir ağı olarak da isimlendirilmektedir (Oquab et el. 2014).

3.4. Metodoloji ve Materyal

Fetüs cinsiyetinin tespiti için önerilen yaklaşımda, veri seti iki aşamalı deney topluluğundan geçirilmiştir. Birinci aşamada, veri seti ile en uyumlu, özellik çıkarıcı evrişim tabanını bulmak, ikinci aşamada ise, en başarılı sınıflandırıcıyı bulmak hedeflenmiştir. Bu nedenle, veri setine iki farklı sınıflandırma metodu uygulanmıştır. Birinci aşamada, ön-eğitilmiş ESA modellerinden VGG16, InceptionV3, ResNet152V2, DenseNet201 ve Xception ağlarına derin transfer öğrenme teknikleri uygulanarak yeni hassas ayarlı (fine-tuned, ft-) modeller elde edilmiştir. Bu modeller üzerinde veri seti eğitilerek sınıflandırma yapılmıştır. İkinci aşamada, birinci aşamadaki sınıflandırma sonucunda, 0.9627 test accuracy (doğruluk) ile en başarılı model seçilen, ft-DenseNet201, özellik çıkarıcı ağ olarak kullanılırken, Lojistik Regresyon (Logistic Regression-LR), Doğrusal Destek Vektör Makinesi (Linear Support Vector Machine-LSVM), K-En Yakın Komşu (K-Nearest-Neighbor-KNN), Karar Ağacı (Decision Tree-DT), Rastgele Orman (Random Forest-RF) ve AdaBoost (AB) algoritmaları ise sınıflandırıcı olarak kullanılmıştır (Şekil 3.11).



Şekil 3.11. Önerilen Modele Genel Bakış

Uygulama Anaconda3 Python 3.7 dağıtımlı Spyder IDE' de yazılmıştır. Anaconda, R ve Python programlama dillerini ve veri bilimi paketlerini destekleyen, açık kaynaklı, Windows, Linux ve MacOS işletim sistemlerinde kullanılabilir bir dağıtımdır. Anaconda Navigator isimli masaüstü grafik kullanıcı arabirimi olduğu için paketleri yüklemek, güncellemek ve kullanmak açısından Linux işletim sistemlerinde terminal kullanımını kısıtlayarak veri bilimi uygulamalarında kolaylık ve avantajlar sağlamaktadır. Spyder veri bilimi için önemli ve temel Python kitaplıklarını destekleyen ve Python dilinde yazılmış bir IDE' dir. Kolay hata ayıklama ve kodu otomatik tamamlama gibi kod yazmada kolaylıklar sağlayan yönü oldukça gelişmiştir.

Uygulamanın birinci ve ikinci aşamasında, DÖ kütüphanelerinden Keras (Chollet 2017) ağırlıklı olarak kullanılmıştır. Keras, tensör kütüphanelerinden olan Theano (Bastien et al. 2012) ve TensorFlow' u (Dillon et al. 2017) arka uç (backend) olarak kullanan, Python dilini destekleyen bir DÖ kütüphanesidir. Uygulamanın ikinci aşamasında, Python dilini destekleyen bir MÖ kütüphanesi olan Scikit-learn (Pedregosa et al. 2011), MÖ sınıflandırıcılarının kodlanmasında kullanılmıştır. Keras ve Scikit-learn kütüphanelerinin yanında, etkileşimli görselleştirmeler oluşturmada kullanılan grafik kütüphanesi Matplotlib (Shopbell et al. 2005), doğrusal cebir işlemleri için kullanılan NumPy (Oliphant 2006) kütüphanesi ve veri çerçevelerinin (data frame) yönetiminde kullanılan Pandas (McKinney 2011) kütüphanesi sıklıkla uygulamada kullanılmıştır.

DÖ uygulamalarında matematiksel hesaplamaların yükü, zaman tasarrufu ve hesaplama maliyetini düşürmek için GPU destekli kod çalıştırmayı gerektirmektedir. Uygulamada tüm kodlar, NVIDIA GeForce GTX 1660 TI GPU, Ubuntu işletim sistemine sahip bilgisayarda çalıştırılmıştır. CUDA, NVIDIA tarafından geliştirilmiş, algoritmaların GPU üzerinde çalıştırılmasını destekleyen, paralel programlama için gerekli sürücüleri içeren bir mimaridir. Anaconda, yalnızca NVIDIA GPU' lar için CUDA' yı desteklemektedir. Uygulamada, ESA modellerinin eğitimini hızlandırmak için, cuDNN (Chetlur et al. 2014) kütüphanesi ve CUDA kullanılmış, Keras ve TensorFlow GPU destekli kurulmuştur.

3.4.1. Görüntü Elde Etme ve Ön-işleme

Veri setinin toplanması için, 30.03.2020 - 30.12.2020 tarihleri arasında, uzman bir jinekolog ile çalışılmıştır. Görüntüler, Mindray DC7 cihazı kullanılarak uzman jinekolog tarafından obstetrik muayene sırasında gerçek zamanlı olarak etiketlenerek kaydedilmiştir. Uzman jinekolog, OUSG yöntemi ile cinsiyetin kesinlik vereceği, gebeliğin 16. haftasından itibaren gebeliğin son haftaları dahil, tüm gebelik dönemlerinden, fetüslerin cinsiyet içeren bölgesini kaydetmiştir. Hasta kimlik bilgileri uzman jinekolog tarafından gizli tutulmuştur. Çalışmanın gerçekleştirilmesi için, Çankırı Karatekin Üniversitesi Etik Kurulu' ndan 14.07.2020 tarihli etik belgesi ve Çankırı Karatekin Hastanesi' nden 30.12.2020 tarihli, ŞİR/MD/20-984 sayılı veri temin ve izin belgesi alınmıştır.

Çalışmada kullanılan görüntülerde, genital organ içeren bölümler kesilmemiş, tüm USG görüntüsü şeklinde kullanılmıştır. Ağın tüm olasılıkları olabildiğince tanıması amacıyla, aynı fetüse ait, farklı prob açılarıyla elde edilmiş görüntüler veri setine eklenmiştir. Veri setindeki her görüntü fetüsün genital organını içermektedir. Bunun yanında, fetüse ait organların sınıflandırılması veya genital organın lokalizasyonu amaçlanmadığı için, görüntüdeki diğer organlar cinsiyet sınıflandırmasına engel olmamıştır. Bu nedenle de, genital organa odaklanan herhangi bir lokalizasyon algoritması kullanılmadan sınıflandırma yapılmıştır.

Bu tür sınıflandırma problemlerinde aşırı uyumu önlemek ve verimli performans ölçümleri yapabilmek için dengeli bir veri seti kullanmak oldukça önemlidir. Bu nedenle, çalışmada her iki sınıf için eşit sayıda USG görüntüsü kullanılmıştır. Böylece 2200 erkek, 2200 kız cinsiyetli olmak üzere, fetüs cinsiyeti içeren 790×592 ve 790×532 boyutlarında, 2-D, B Mod görüntüler ile toplam 4400 adetlik veri seti oluşturulmuştur.

Çizelge 3.6. Önerilen Yöntemde Kullanılan Veri Setlerindeki Veri Dağılımı

Hassas Ayarlı ESA Modellerinde Kullanılan Veri Setlerindeki Veri Dağılımı			
Sınıf	**Eğitim Görüntüleri**	**Doğrulama Görüntüleri**	**Test Görüntüleri**
Kız	1100	550	550
Erkek	1100	550	550
Toplam	2200	1100	1100

Hassas Ayarlı ESA + MÖ Modellerinde Kullanılan Veri Setlerindeki Veri Dağılımı		
Sınıf	**Eğitim Görüntüleri**	**Test Görüntüleri**
Kız	1650	550
Erkek	1650	550
Toplam	3300	1100

Çizelge 3.6' da, kullanılan tekniklere göre veri setinin sınıf başına dağılımı verilmiştir. Bir yapay sinir ağı olarak ESA modellerinin öğrenme süreçleri, eğitim, doğrulama ve test aşamalarından geçirilmiştir. Bu üç aşama için yapılan veri seti dağılımı, model seçimi ve performans tahmininin aynı anda gerçekleştirildiği yöntemdir. Bu yöntemle doğrulama performanslarının verdiği sonuçla modelin parametrelerinde iyileştirmeler yapılırken, test aşaması tahmin sonuçlarını vermektedir. Veri seti, hassas ayarlı ESA modellerinin uygulamasında, %50 eğitim, %25 doğrulama ve %25 test seti olmak üzere üçe bölünürken, hassas ayarlı ESA ve MÖ sınıflandırıcılarının hibrit uygulamasında, eğitim ve doğrulama verileri birleştirilerek %75 eğitim, %25 test seti olmak üzere ikiye bölünmüştür. Bunun sebebi, eğitim aşamasında beş kat çapraz doğrulama yapılmasıdır. Sınıf başına düşen veri dengeli tutulmuştur. İkili sınıflandırma için veri setinin yeterince büyük olması ve eğitim setine veri çoğaltma (data augmentation) teknikleri uygulanırken, doğrulama ve test setine uygulanmaması, bu oranların seçilmesinin sebebidir.

Veri setindeki tüm görüntüler, RGB (red, green, blue) modda kaydedilmiştir ve uygulamada RGB modda kullanılmıştır. Normalizasyon için, piksel değerleri 0-255 aralığından, sinir ağı modelleri için tercih edilen 0-1 aralığına yeniden ölçeklendirilmiştir. Girdi boyutunun uygulama için kullanılan tüm ön-eğitilmiş ESA modellerine uygun olabilmesi için 200×200 boyutlarında, tüm görüntüler yeniden boyutlandırılmıştır. Böylece, tüm ESA modellerinde aynı girdi boyutu (200×200×3)

kullanılmıştır. Hassas ayarlı ESA modelleri ile yapılan sınıflandırmada, eğitim seti için gerçek zamanlı veri çoğaltma (data augmentation) tekniği kullanılarak eğitim performansının yükseltilmesi amaçlanmıştır. Veri çoğaltma ile var olan orijinal veriler biraz değiştirilerek yapay veriler elde edilir ve böylece, bu yapay veriler eğitim setine eklenerek ağın eğitim performansı arttırılır, ezberleme olasılığı düşürülür (Shorten and Khoshgoftaar 2019). Çizelge 3.7' de, eğitim setine uygulanan veri çoğaltma teknikleri verilmiştir. Eğitim süreci için kullanılan görüntülere, veri çoğaltma ile 40 derece rastgele döndürme (rotation), 0.2 değerinde genişlik ve yükseklik kaydırma (width and height shift), saat yönünün tersine kaydırma (shear) ve yakınlaştırma (zoom) uygulanmıştır ve girdinin sınırları dışında kalan noktalar en yakın (nearest) modla doldurulmuştur. Böylece, eğitim sırasında eğitim için ayrılmış veriler gerçek zamanlı olarak çoğaltılmıştır. ESA modelleri kullanarak özellik çıkarma işlemi yapmak ve bu özellikleri bir MÖ sınıflandırıcısına vererek sınıflandırmak hızlı ve basittir fakat, veri setindeki her bir görüntü evrişim katmanlarından yalnızca bir defa geçeceği için veri çoğaltma işlemi uygulanamaz. Bu nedenle hassas ayarlı DenseNet201 (ft-DenseNet201) ve MÖ sınıflandırıcılarının kullanıldığı yöntemlerde veri çoğaltma tekniği kullanılmamıştır.

Çizelge 3.7. Uygulamada Kullanılan Veri Çoğaltma Yöntemleri

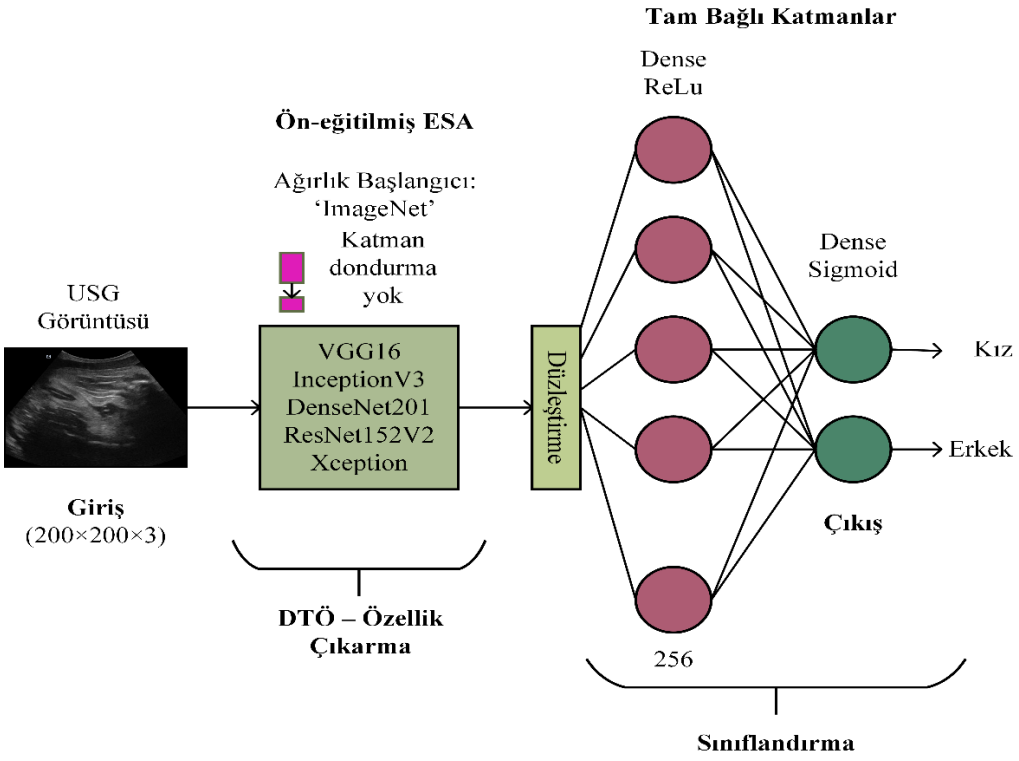
Veri Çoğaltma (Data Augmentation) Teknikleri	**Aralık-Oran**
Rotation	40
Width shift	0.2
Height shift	0.2
Shear	0.2
Zoom	0.2
Fill mode	nearest

3.4.2. Birinci Aşama: En İyi Özellik Çıkarıcının Bulunması

Fetüs cinsiyetinin tespiti ve sınıflandırılması için ilk aşamada kullanılan yöntemde, USG görüntüleri 200×200×3 girdi boyutuyla, VGG16, InceptionV3, ResNet152V2, DenseNet201 ve Xception ağlarına verilerek bu ağlara, probleme uygun DTÖ teknikleri

uygulanmıştır. Bu aşamanın asıl amacı, veri setiyle en uyumlu özellik çıkarıcı evrişim tabanını bulmaktır. Bu nedenle, kullanılan ön-eğitilmiş ağlara aynı DTÖ teknikleri uygulanmış, aynı hiperparametreler ile aynı sınıflandırıcı ve tam bağlı katmanlar kullanılmıştır.

Şekil 3.12' de ağlara uygulanan hassas ayar (fine-tuning) aşamaları verilmiştir. Orijinal ağların sınıflandırma yapan son katmanları çıkarılmış, özellik çıkarma işlemi yapan evrişim tabanları kullanılmıştır. Evrişim tabanlarından sonra, 256 nöronluk ara katman ve 1 nöronluk çıkış katmanı olmak üzere, iki adet tam bağlı katman eklenmiştir. Ara katmanda aktivasyon fonksiyonu olarak ReLu (Agarap 2018), çıkış katmanında ikili sınıflandırma problemlerinde kullanılan sigmoid kullanılmıştır. Matematiksel olarak, f(x) = max(0, x) şeklinde ifade edilen ReLu sayesinde tüm nöronlar aynı anda etkinleştirilmez. Bu özellik, diğer aktivasyon fonksiyonlarına göre avantaj sağlamaktadır. Çıkış katmanında kullanılan sigmoid sınıflandırma görevini üstlenmektedir. Matematiksel olarak, f(x) = $1/1 + e^{-x}$ şeklinde ifade edilen sigmoid, 0-1 aralığında değerler alır. Sınıflandırma için 0.5 değerinde eşik (threshold) değeri belirlenmiştir. Böylece, 0-1 aralığında çıktı veren bir tahmin, 0.5 değerinin altındaysa kız sınıfını temsil eden 0 değerini, 0.5 değerinin üzerindeyse erkek sınıfını temsil eden 1 değerini almıştır. Transfer öğrenmede, hedef görevde kullanılacak veri setinin büyük ancak, kaynak görevde kullanılan veri setiyle farklı olması durumunda, evrişim tabanı ve sınıflandırıcı, hedef görevdeki veri seti ile en baştan eğitilmelidir. Bu nedenle, bu ağlar sadece hassas ayarlı (fine-tuned) model olarak kullanılmıştır. Uygulama aşamasında bu ağların ağırlıkları, 'imagenet' ağırlıklarından başlatılmıştır. Böylece, veri seti ile en baştan eğitilmiştir ve herhangi bir katman dondurma (freezing) işlemi uygulanmamıştır. Bu durum, özellikle eğitim aşamasında, yüksek hesaplama yükü gerektirmiştir fakat, GPU kullanımı bu yükü oldukça hafifletmiştir.



Şekil 3.12. Kullanılan Ön-eğitilmiş ESA' larda Hassas Ayar Detayları

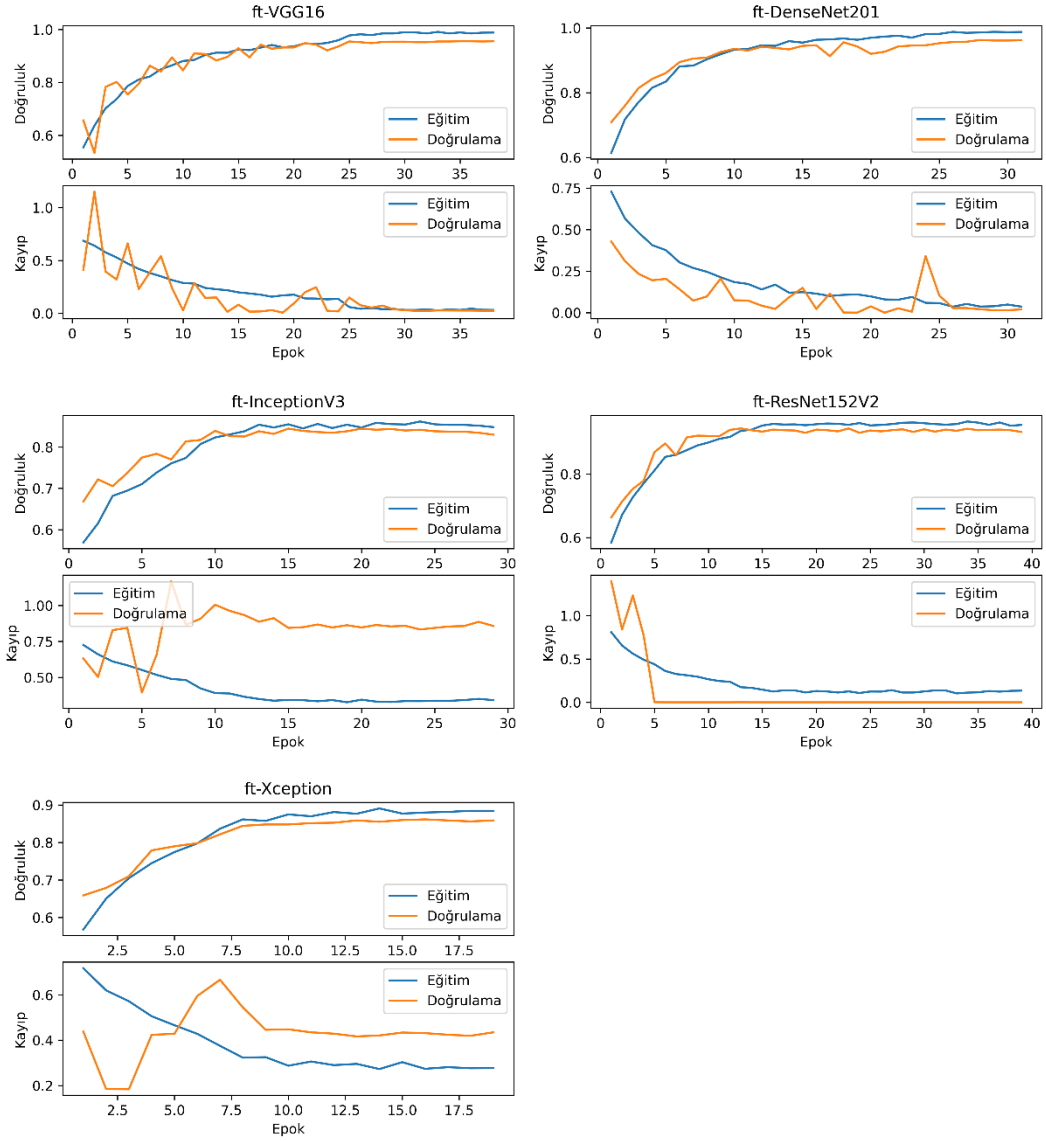
DÖ uygulamalarında, zaman ve bellek maliyetini düşürmek için veri seti mini yığınlar şeklinde ağa verilmektedir. Böylece, model aynı anda mini yığın sayısı kadar veri işler. Belirlenen mini yığın değeri, GPU belleğine sığmalıdır, bu nedenle ikinin katları şeklinde belirlenmelidir. Mini yığın değeri büyük verildiğinde, ağ ezber yapabilmekte ve öğrenme süresi uzamaktadır. Küçük bir değer verildiğinde ise, kayıp değeri artar ve gürültü ortaya çıkar fakat bu salınım optimizasyon algoritması ve öğrenme oranıyla azaltılabilir. Bu bilgiler, kullanılan GPU özellikleri ve deney yapılan her ağın hesaplama yükü göz önüne alınarak mini yığın boyutu (batch size) 16 alınmıştır. Eğitim, doğrulama ve test aşamalarında, her ağ için aynı mini yığın boyutu değeri kullanılmıştır. Kaybın gradyanının, ağırlıkları nasıl güncelleyeceğini optimizasyon algoritmaları belirlemektedir. Uygulamada, her ağ için, RMSprop (Seyyarer et al. 2019) optimizeri kullanılmıştır. RMSprop, mini yığın öğrenmede çok iyi tanınan bir algoritmadır ve her

parametre için ayrı bir öğrenme hızı seçerek azalan öğrenme oranıyla başa çıkmayı hedefler.

Öğrenme oranı, ağırlıkların ne kadar büyüklükte arttırılacağını ya da azaltılacağını belirlemede kullanılan bir katsayıdır. Ön-eğitilmiş bir ESA modeli kullanırken, küçük bir öğrenme oranı kullanılmalıdır. Çünkü, yüksek öğrenme oranları önceki bilgileri kaybetme riskini artırır. Düşük bir öğrenme oranına sahip olmak, ESA ağırlıklarının çok erken ve çok fazla bozulmasına sebep olacaktır. Uygulama için, başlangıç öğrenme oranı (learning rate) 2e-5 alınmıştır. Öğrenme oranının büyük bir değer olması, ağın ezber yapma olasılığını arttıracağı için, eğitim sırasında 'validation loss' (doğrulama kaybı) değerini izleyen 'Keras ReduceLROnPlateau Callbacks' ile öğrenme oranı denetlenmiştir. Bu fonksiyon ile eğitim ve doğrulama aşaması gerçekleşirken, validation loss metriğinin 5 epoch gelişmemesi durumunda öğrenme oranı 0.1 faktör değeriyle çarpılarak yeni öğrenme oranının kullanılması hedeflenmiştir. Mevcut yığın için kayıp değerini hesaplayan kayıp fonksiyonu olarak, uygulamanın ikili sınıflandırma problemi olmasının gereği, 'binary cross-entropy' (ikili çapraz entropi) kullanılmıştır.

Eğitim aşaması için epoch sayısı 100 belirlenmiştir fakat, eğitim sırasında, 'Keras EarlyStopping Callbacks' ile, 'training accuracy' (eğitim doğruluğu) değerinin 5 epoch boyunca iyileşmemesi durumunda eğitim ve doğrulama aşamasının durdurulması sağlanmıştır. Böylece, her ağın eğitiminde, öğrenme sürecinin tamamlanması farklı epoch' larda gerçekleşmiştir. Eğitim aşamasının her adımındaki mevcut durum öğrenme eğrileri ile değerlendirilebilir. Modelin ne kadar iyi öğrendiğini, eğitim veri setinden hesaplanan eğitim öğrenme eğrisi, modelin ne kadar iyi genelleştirme yaptığı ise doğrulama veri setinden hesaplanan doğrulama öğrenme eğrisi vermektedir. Performans öğrenme eğrileri, modelin değerlendirileceği ve seçileceği metriğe göre hesaplanan öğrenme eğrileridir. Şekil 3.13' de ağların doğruluk (accuracy) ve kayıp (loss) metriğine göre çizilmiş performans öğrenme eğrileri verilmiştir. Şekil 3.13' e ait bir grafikte mavi eğri, eğitim doğruluk ve kayıp metriklerini, turuncu eğri ise, doğrulama doğruluk ve kayıp metriklerini vermektedir. Doğruluk (accuracy) öğrenme eğrilerine bakıldığında,

her ağ için iyi bir uyum olduğu görülmektedir. Eğitim ile doğrulama arasındaki boşluk genelleme açığı olarak adlandırılır ve modelin başarımının neredeyse her epoch' ta eğitim veri kümesinde, doğrulama veri kümesine göre daha yüksek olmasının normalidir.



Şekil 3.13. Uygulamada Kullanılan Hassas Ayarlı ESA' ların Öğrenim Eğrileri

Ağlara uygulanan hassas ayar ve seçilen hiperparametrelerin aynı tutulmasıyla en yüksek değerde accuracy metriğine sahip modelin evrişim tabanı, ikinci aşamada özellik çıkarıcı olarak kullanılmıştır. Bu aşamanın sonuçlarına göre, 0.9627 ile en yüksek accuracy değerini, ft-DenseNet201 (fine-tuned DenseNet201, hassas ayarlı DenseNet201) ağı vermiştir ve bu ağın evrişim tabanı, ikinci aşamada özellik çıkarıcı olarak kullanılmıştır.

3.4.3. İkinci Aşama: En İyi Sınıflandırıcının Bulunması

Uygulamanın bu aşamasında, özellik çıkarma işleminden sonra, bu özellikler, Lojistik Regresyon (Logistic Regression-LR), Doğrusal Destek Vektör Makinesi (Linear Support Vector Machine-LSVM), K-En Yakın Komşu (K-Nearest-Neighbor-KNN), Karar Ağacı (Decision Tree-DT), Rastgele Orman (Random Forest-RF) ve AdaBoost (AB) algoritmaları ile eğitilmiş ve sınıflandırılmıştır. Bu aşamanın amacı, farklı sınıflandırma algoritmaları ile deney sayısını arttırmak ve en verimli sınıflandırma sonucunu elde etmektir.

ESA' lar önce düşük seviyeli özellikleri tanımlarlar ve ardından daha karmaşık kalıpları öğrenmek için bu özellikleri tanımayı ve birleştirmeyi öğrenirler. Bu farklı özellik düzeyleri, ağın farklı katmanlarından gelmektedir. ESA' ların ilk katmanları çok genel özellikler çıkarırken son katmanlarına ilerledikçe soyut kavramlar ve sınıfa özel özellikler çıkarılır. Çizelge 3.8' de, özellik çıkarmak için kullanılan ft-DenseNet201 ağının mimarisi verilmiştir. Birinci aşamadaki ft-DenseNet201 ağının evrişim tabanı kullanılarak özellik çıkarma işlemi yapılmıştır. ft-DenseNet201 ağının son nitelik haritasının şekline (6×6×1920) göre, 69120 sayısal özellik elde edilmiştir.

Çizelge 3.8. ft-DenseNet201’ in Evrişim Tabanı

Katmanlar	**Çıkış Boyutu**	**İşlem**
Conv	100×100	7×7 conv, stride 2
Pooling	50×50	3×3 max-pool, stride 2
DB1	50×50	1×1 conv 3×3 conv] ×6
TL1	50×50	1×1 conv
	25×25	2×2 avg-pool, stride 2
DB2	28×28	1×1 conv 3×3 conv] ×12
TL2	25×25	1×1 conv
	12×12	2×2 avg-pool, stride 2
DB3	12×12	1×1 conv 3×3 conv] ×48
TL3	12×12	1×1 conv
	6×6	2×2 avg- pool, stride 2
DB4	6×6	1×1 conv 3×3 conv] ×32

Giriş boyutu: 200×200×3; k = 32; Conv: Evrişim Katmanı; DB: Yoğun Blok; TL: Geçiş Katmanı; conv: Konvolüsyon; max-pool: Maksimum Havuzlama; avg-pool: Ortalama Havuzlama.

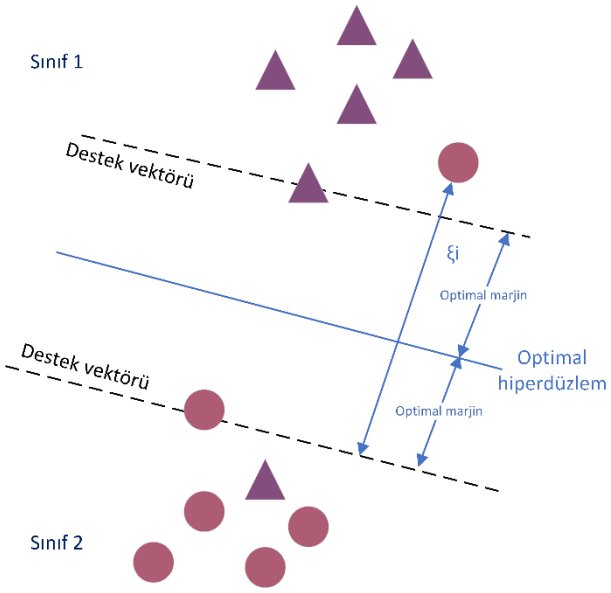
LR, doğrusal olarak ayrılamayan örneklerin sınıflandırılmasında sigmoid fonksiyonunu kullanarak bir eşik değer yardımıyla tahmin üretir. Tahmin, eşik değerinin altında ya da üstünde olma durumuna göre etiketlendirilir. Denklem (3.19)’ da verilen genel bir regresyon modeli, sigmoid fonksiyonu ile kullanıldığında Denklem (3.20)’ de verilen eşitlik ile çıktı için olasılık değeri hesaplanır. Hata fonksiyonunun hesaplanması için sigmoid fonksiyonu, logaritmik dönüşüm işleminden geçmelidir. Bu işleme göre, minimize edilmesi gereken optimizasyon problemi Denklem (3.21)’ de verilmiştir. Uygulama için L2-norm düzenlenmiş LR kullanılmıştır. Optimizasyon algoritması olarak, L2-norm penalty (ceza) ile uyumlu ve kısıtlı optimizasyon problemlerinde kullanılan ‘lbfgs’ (Large-scale Bound-constrained Optimization) (Byrd et al. 1995) kullanılmıştır. Yanlış sınıflandırılmış örneklere gösterilen toleransı belirleyen penalty (ceza) parametresi 1 alınmıştır.

$$f_w(x) = w_0 + w_1x_1 + w_2x_2 + \cdots + w_nx_n + \varepsilon = w^Tx \tag{3.19}$$

$$f_w(x) = \sigma(w^T x) = \frac{1}{1+ e^{-w^t x}} \tag{3.20}$$

$$E(w) = \frac{1}{m}\sum_{i=1}^{m}(y_i - 1)\log\big(1 - f_w(x_i)\big) - y_i \log\left(f_w(x_i)\right) \tag{3.21}$$

SVM, çeşitli boyutlarda hiper düzlem kullanarak verileri sınıflandırır. Sınıf tanımlayıcılarının kenarına yerleştirilen destek vektörleri arasındaki mesafenin (kenar payı) en büyük uzunlukta olmasını ve sınıfların en iyi şekilde ayrılmasını sağlayan hiper düzlem, optimal hiper düzlem olarak ifade edilir. Sınıf 1' e ait bir örnek, Sınıf 2' ye çok yakın uzaklıkta olursa kenar payının küçülmesine neden olur. Kenar payının küçülmesi, modelin genelleme yeteneğini engelleyeceği için, esnek kenar payı (slack variable) kullanılır. Esnek değişken kullanımı, bazı örneklerin hatalı sınıflandırılmasına izin verir fakat, gürültülü verilerin sınıflandırılmasını sağlar. Şekil 3.14' de, doğrusal olmayan ayrılabilir sınıflandırmada esnek değişken durumu verilmiştir. Esnek değişken kullanılan bir SVM algoritmasında, Denklem (3.22)' de verilen amaç fonksiyonunun, Denklem (3.23)' te verilen kısıt ile en küçüklenmesi hedeflenir. Denklem (3.22)' de kullanılan c hiperparametresi küçük verilirse daha geniş bir kenar payı oluşturulur ve hatalı sınıflandırılmış örneklere tolerans gösterilir. Veriler, girdi uzayında doğrusal olarak ayrılabiliyorsa, daha yüksek boyutlu bir uzayda eşleme yapamaya gerek olmadığı için doğrusal çekirdek (linear kernel) kullanılır. Uygulamada kernel fonksiyonu 'linear' kullanılmıştır ve c hiperparametresi 0.025 alınmıştır.



Şekil 3.14. Doğrusal Olmayan Ayrılabilir Sınıflandırmada Esnek Değişken Durumu

$$\frac{1}{2} < w, w > + c \sum_{i=1}^{n} \varepsilon_i \tag{3.22}$$

$$y_i(< w, x_i > + \beta) - 1 + \varepsilon_i \geq 0\,,\ \varepsilon_i \geq 0,\ i = 1 \ldots n \tag{3.23}$$

KNN, sınıfı bilinmeyen örneğin, diğer örneklere olan uzaklıkları ölçülerek en yakın sınıfa dahil edilmesi mantığı ile çalışır. Farklı uzaklık ölçüm yöntemleri sınıflandırma performansını etkiler. Uygulamada Denklem (3.24)' te verilen Öklid mesafesi kullanılmıştır. En yakın k adet komşusunun etiketlerine göre çoğunluğun etiketi verinin sınıflandırılması için tanımlayıcıdır. Bu nedenle, ikili sınıflandırma problemlerinde k parametresi mutlaka tek bir sayı olmalıdır. Uygulama için k parametresinin değeri 3 alınmıştır.

$$d(x_i, y_i) = \sqrt{\sum_{i=1}^{m} (x_i - y_i)^2}\,, \qquad i = 1,2, \ldots, m \tag{3.24}$$

DT, bağımlı değişkenin kategorik olduğu durumlarda LR' ye alternatif bir yöntemdir. DT' nin aranan sınıfı sağlayan başlangıç düğümü kök düğümdür. Kök düğümünden sonraki dallanma kararında, her örnek değişken, eğitim örneklerinin sınıflandırmasına karar vermek için istatistiksel test kullanılarak değerlendirilir. Uygulamada, değişken seçimi kararı ve ikili dallanma için Denklem (3.25)' te verilen Gini kriteri kullanılmıştır. Buradaki P_i, veri setindeki bir örneğin bir sınıfa ait olma olasılığıdır. Tüm değişkenlerin Gini indeksi hesaplandıktan sonra, minimum indekse sahip değişken seçilerek DT dallandırılır. Sınıflandırmanın mükemmel yapılması Gini indeksinin 0 değerini almasıyla mümkündür. Bu nedenle, Gini indeksi düşük olan bir değişken bölme işlemi istenir. DT, dallanmayı belirtilen durdurma kriterlerinden biri ile karşılaşana kadar sürdürür. Maksimum derinlik belirtmek durdurma kriterlerinden biridir. DT' nin derinliğinin çok küçük olması veri setinin iyi tanımlanamamasına neden olurken çok büyük tanımlanmasında ise modelin temsil yeteneği düşük olabilir. Uygulamada maksimum derinlik 5 alınmıştır.

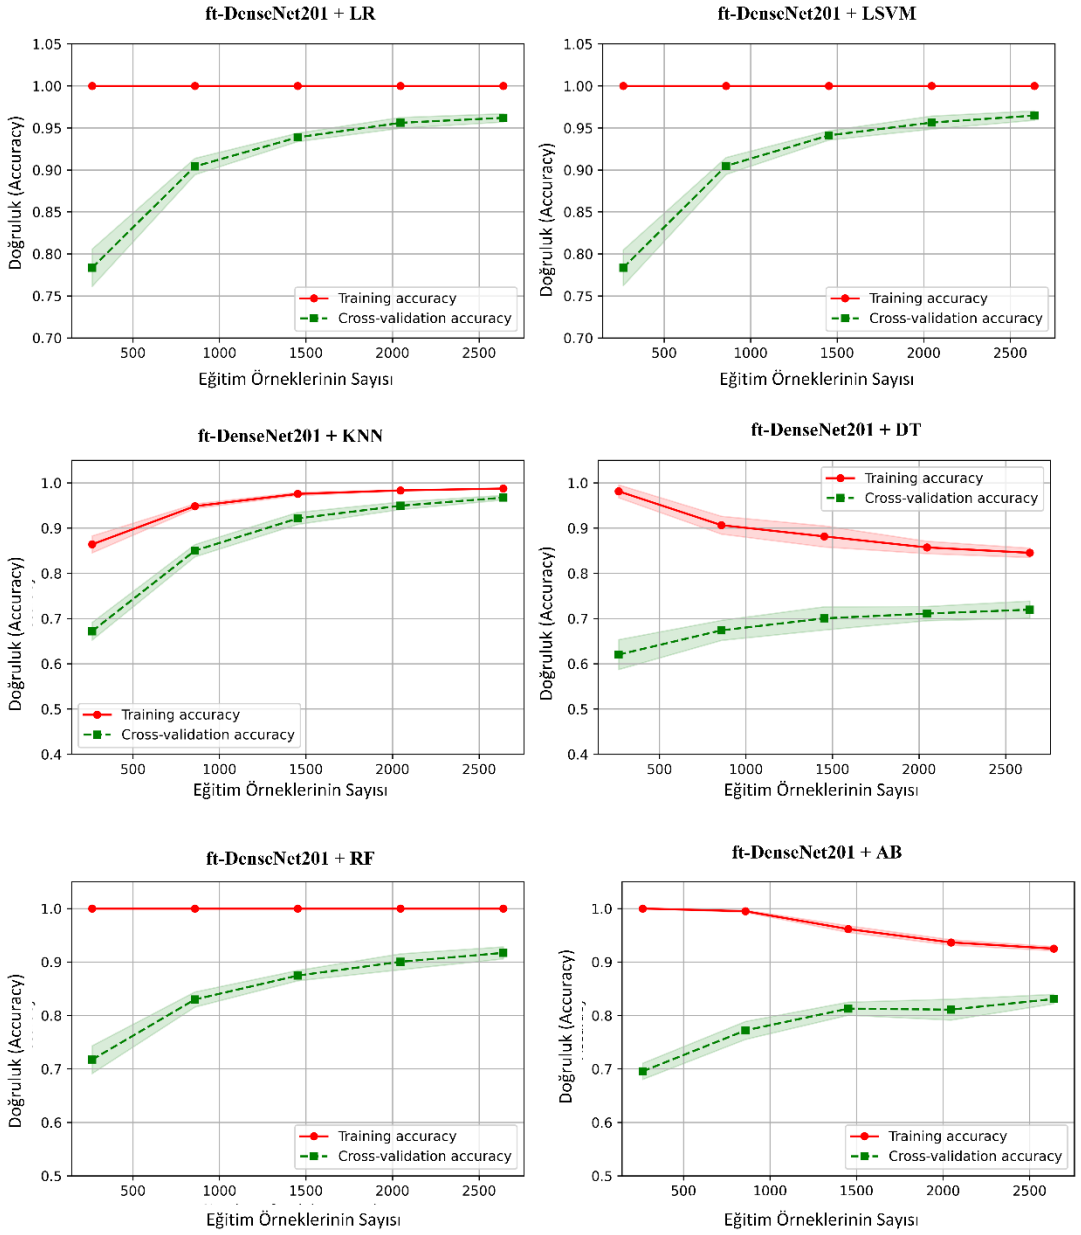
$$Gini(x) = 1 - \sum_{i=1}^{m} P_i^2 \tag{3.25}$$

RF algoritmasında, rastlantısal olarak seçilen DT' ler bir araya gelerek birden fazla DT üretilir. Her üretilen DT' den tahmin yapılır ve oylama ile en iyi çözümü seçilir. Böylece sınıflandırma oranının yükseltilmesi amaçlanır. Uygulamada, ormandaki ağaç sayısı 50 alınmıştır ve ağaçların parametreleri DT sınıflandırıcısındaki değerlerle aynı alınmıştır.

AB algoritması, her bir öznitelikten zayıf bir sınıflandırıcı (örneğin küçük karar ağaçları) oluşturarak karar sınırları için negatif ve pozitif örneklerin ağırlıklı ortalamasını alır. Hata oranı en düşük zayıf sınıflandırıcılar tespit edilir ve ağırlıklar güncellenerek bir olasılık dağılım fonksiyonu oluşturulur. İlerleyen adımlarda bu işlemler tekrar edilir. Böylece zayıf sınıflandırıcılar kullanılarak güçlü bir sınıflandırıcı

meydana getirilir. Uygulama için algoritmanın sonlandırılacağı maksimum sınıflandırıcı sayısı 50 alınmıştır.

Bu algoritmalara eğitim aşamasıyla birlikte beş kat çapraz doğrulama uygulanmıştır. Çapraz doğrulama yapılırken ayrı bir doğrulama seti oluşturmaya ihtiyaç yoktur. Eğitim seti, her iterasyonda rastgele 5 ayrı sete bölünerek 4 set eğitim, 1 set doğrulama için kullanılır. Şekil 3.16' da bu aşamaya ait öğrenme eğrileri verilmiştir. Öğrenme eğrilerinde, x ekseni algoritmaların accuracy (doğruluk) metriğinin değerini, y ekseni ise, eğitim verilerinin sayısını vermektedir. Şekil 3.16' ya ait bir öğrenme eğrisindeki kırmızı eğri, eğitim doğruluğu (training accuracy) metriğini, yeşil eğri ise, beş kat çapraz doğrulamaya ait doğruluk (cross validation accuracy) metriğini vermektedir. Öğrenme eğrilerini incelediğimizde, ft-DenseNet201 + DT ve ft-DenseNet201 + AB algoritmalarının eğitim puanı, eğitim seti arttıkça azalmıştır. Bu, daha fazla eğitim verisinin olmasından algoritmaların genelleme yeteneğinin etkilenmeyeceğini gösterir. Diğer algoritmalarda ise daha fazla eğitim örneği eklemek genellemeyi arttıracaktır.

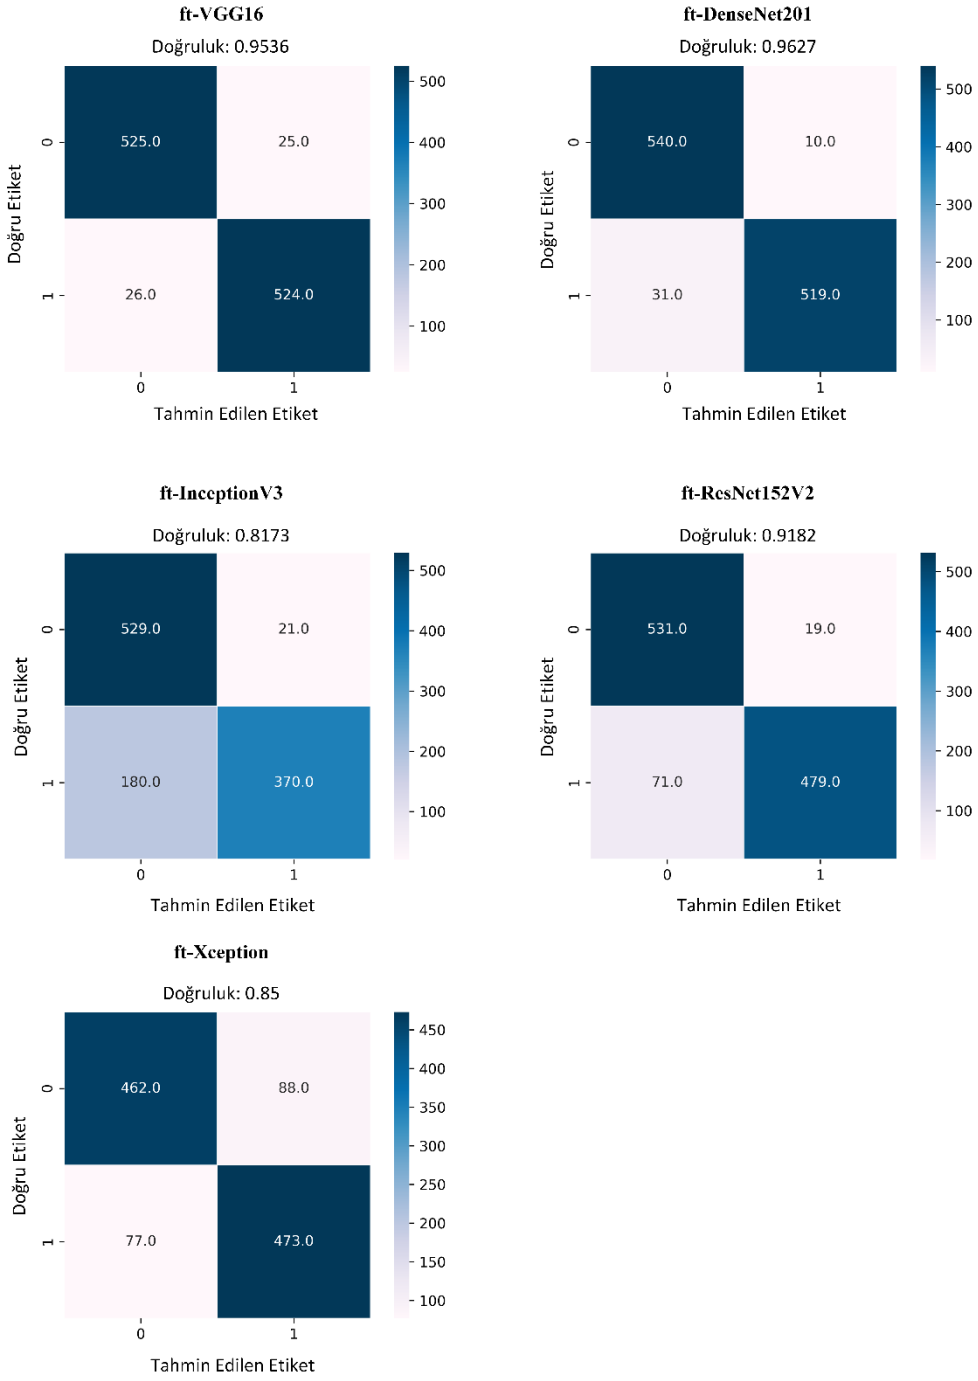


Şekil 3.15. Uygulamada Kullanılan MÖ Sınıflandırıcılarının Öğrenme Eğrileri

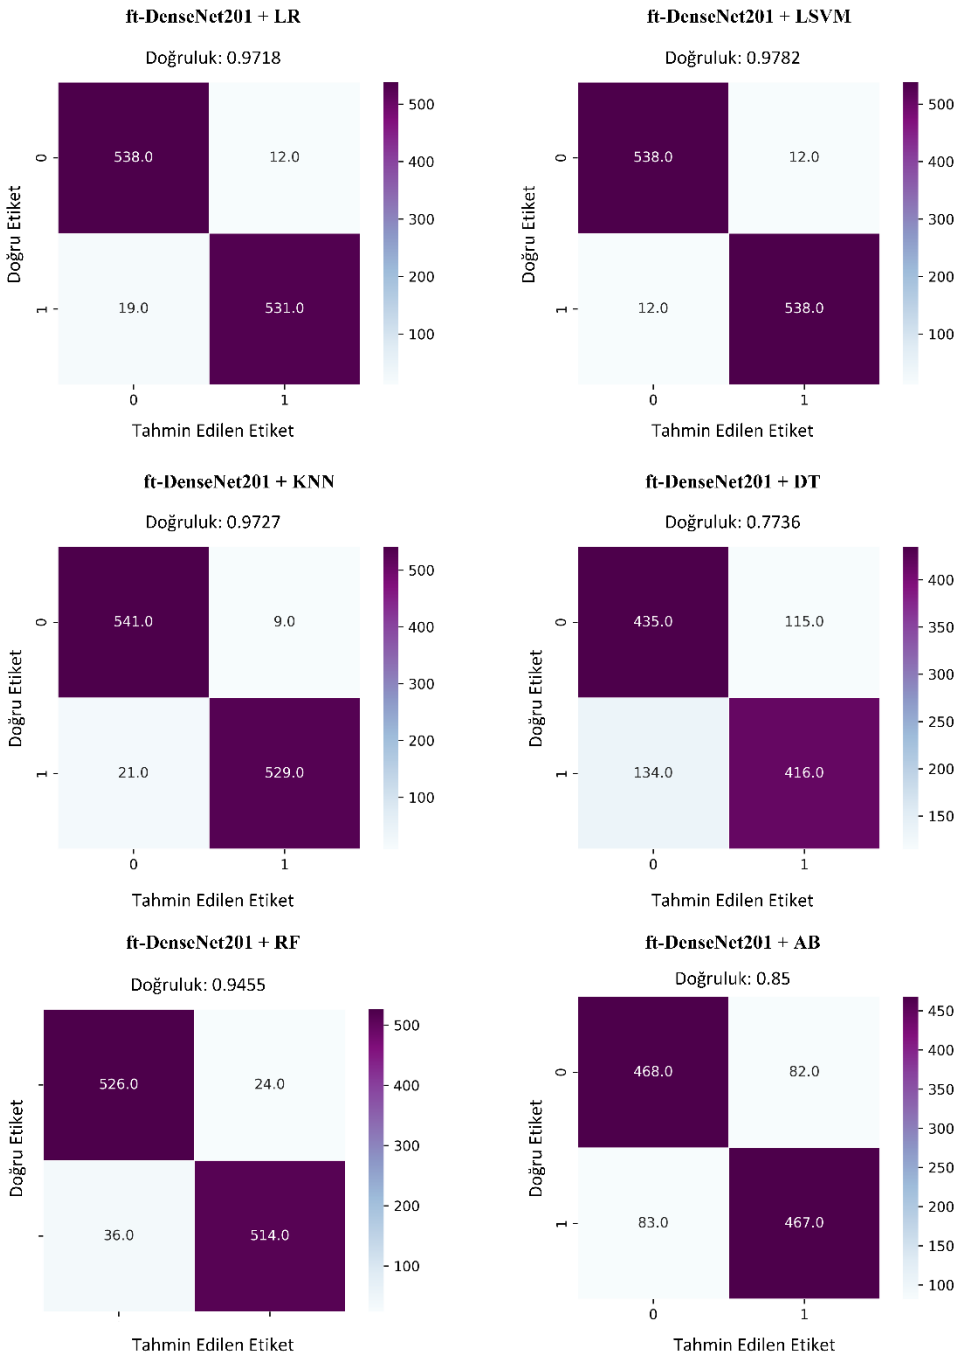
4. BULGULAR

Test aşaması, ağın öğrenme süreci olan eğitim aşamasından ve modelin genelleştirme yeteneğini sınayan doğrulama aşamasından sonra yapılmaktadır. Test aşamasında kullanılan test veri seti, ağın hiç görmediği görüntülerden oluşmaktadır. Test aşamasında, ağ verilen görüntünün sınıfını, tahmin değeri sıfıra yakınsa kız, bire yakınsa erkek şeklinde tahmin etmektedir. Test aşamasının sonunda, tahmin edilen etiketler meydana gelir ve gerçek değerlerle seçilen performans ölçütleri kullanılarak kıyaslanır. Böylece, uygulamanın başarı oranı belirlenmektedir.

Kıyaslama matrisi (confusion matrix), tahmin edilenler ile gerçek etiketlerin sayısını vermektedir. Kız sınıfını negatif sınıf, erkek sınıfını pozitif sınıf olarak değerlendirdiğimizde, kıyaslama matrisi aynı zamanda Doğru Pozitif (DP), Yanlış Negatif (YN), Doğru Negatif (DN), Yanlış Pozitif (YP) değerlerini de vermektedir. Şekil 4.1' de uygulamada kullanılan algoritmalara ait kıyaslama matrisleri verilmiştir. ft-DenseNet201 + LSVM' ye ait matris incelendiğinde, 550 adet kız sınıfına ait görüntüden 538 adeti doğru, 12 adeti yanlış tahmin edilmişken, 550 adet erkek sınıfına ait görüntüden ise 538 adeti doğru, 12 adeti yanlış tahmin edilmiştir. Tüm algoritmaların kıyaslama matrisleri incelendiğinde, ft-DenseNet201 + LSVM algoritmasının sınıfları eşit miktarda ve en az yanlış tahminle ayırt ettiği gözlenmektedir (DP = DN = 538, YP = YN = 12).



Şekil 4.1. Uygulamada Kullanılan Hassas Ayarlı ESA' ların Kıyaslama Matrisleri



Şekil 4.2. Uygulamada Kullanılan MÖ Sınıflandırıcılarının Kıyaslama Matrisleri

Çizelge 4.1' de, algoritmaların başarısını doğruluk açısından değerlendirmek için kullanılan performans ölçütleri ve formülleri verilmiştir. Doğruluk (accuracy), doğru

şekilde sınıflandırılan görüntülerin yüzdesini temsil etmektedir ve aynı zamanda genel piksel doğruluğu olarak da bilinir. En temel performans ölçütüdür. Hassasiyet (precision), sonuçların ne kadar yararlı olduğunu anlamamıza, geri çağırma (recall) ise, sonuçların ne kadar eksiksiz olduğunu anlamamıza yardımcı olur. F_1 skor, precision ve recall ölçütlerinin harmonik ortalamasını belirler. ESA algoritmalarında kayıp fonksiyonu olarak ikili sınıflandırma problemlerinde kullanılan ikili çapraz entropi kullanılmıştır.

Çizelge 4.1. Performans Metrikleri

Performans Metriği	**Formül**	
Accuracy (Doğruluk)	$\frac{DP + \mathrm{D}N}{DP + \mathrm{Y}P + \mathrm{Y}N + \mathrm{D}N}$	(4.1)
Precision (Hassasiyet)	$\frac{DP}{DP + \mathrm{Y}P}$	(4.2)
Recall (Geri Çağırma)	$\frac{DP}{DP + \mathrm{Y}N}$	(4.3)
F_1 Skor	$2\ X\ \frac{Precision\ X\ Recall}{Precision +\ Recall}$	(4.4)
İkili Çapraz Entropi	$H_p(q) = -\frac{1}{N}\sum_{i=1}^{N} y_i \log\big(p(y_i)\big) + (1 -\ y_i)\log\,(1 - p(y_i))$	(4.5)

DP: Doğru Pozitif; DN: Doğru Negatif; YP: Yanlış Pozitif; YN: Yanlış Negatif; N: Test seti boyutu; y: Etiket; y_i = 0 => p(0) = kız olma olasılığı, 1 – p(0) = erkek olma olasılığı.

Çizelge 4.2' de uygulamanın birinci aşamasına ait sonuçlar verilmiştir. Birinci aşamada kullanılan hassas ayarlı ESA sınıflandırıcılarından ft-DenseNet201 en yüksek accuracy ve en düşük loss değerini vererek ikinci aşamada özellik çıkarıcı ağ seçilmiştir. Çizelge 4.3' te uygulamada kullanılan on bir adet sınıflandırıcı algoritmanın performans ölçütlerine göre sonuçları verilmiştir. Bu sonuçlar incelendiğinde, ft-DenseNet201 + LSVM algoritmasının her bir performans ölçütü için en yüksek ve dengeli sonuçlar verdiği gözlenmektedir. ftDenseNet + LR ve ft-DenseNet + KNN algoritmaları da yüksek sonuçlar vermesine rağmen, kıyaslama matrisleri incelendiğinde, sınıflar arası tahmin oranlarının dengesiz olduğu görülmektedir.

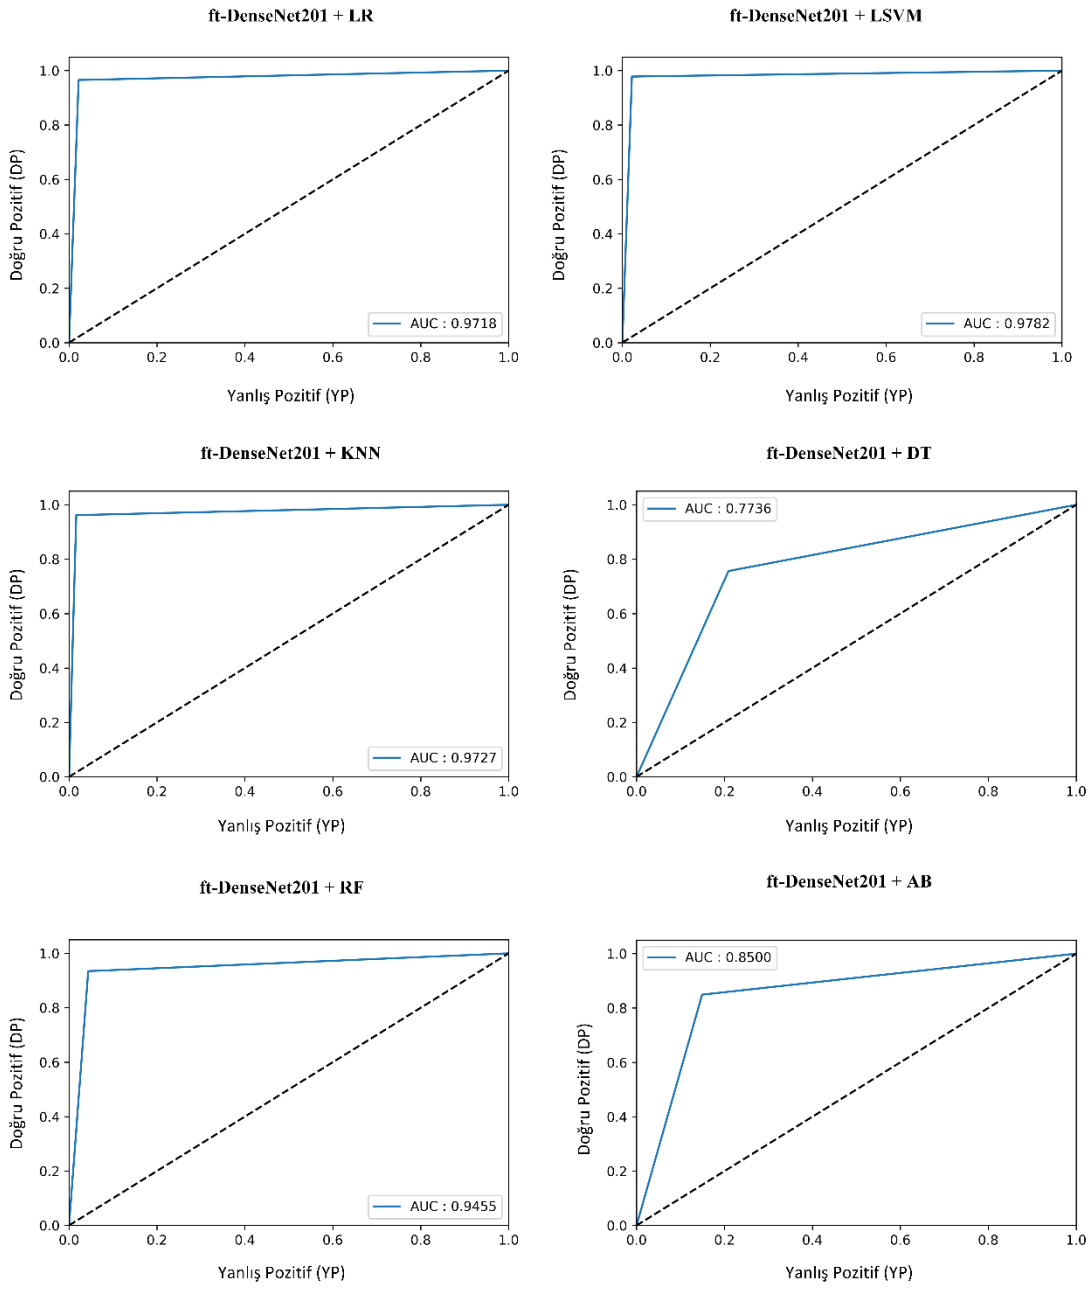
Çizelge 4.2. Birinci Aşamada Kullanılan DÖ Algoritmalarının Performans Metriklerine Göre Test Sonuçları

	ft-VGG16	**ft-InceptionV3**	**ft-DenseNet201**	**ft-ResNet152V2**	**ft-Xception**
Test Accuracy	0.9536	0.8173	***0.9627***	0.9182	0.8500
Test Loss	1.0797	1.6859	***0.3361***	0.6015	0.3927

Çizelge 4.3. Uygulamada Kullanılan Tüm Algoritmaların Performans Metriklerine Göre Test Sonuçları

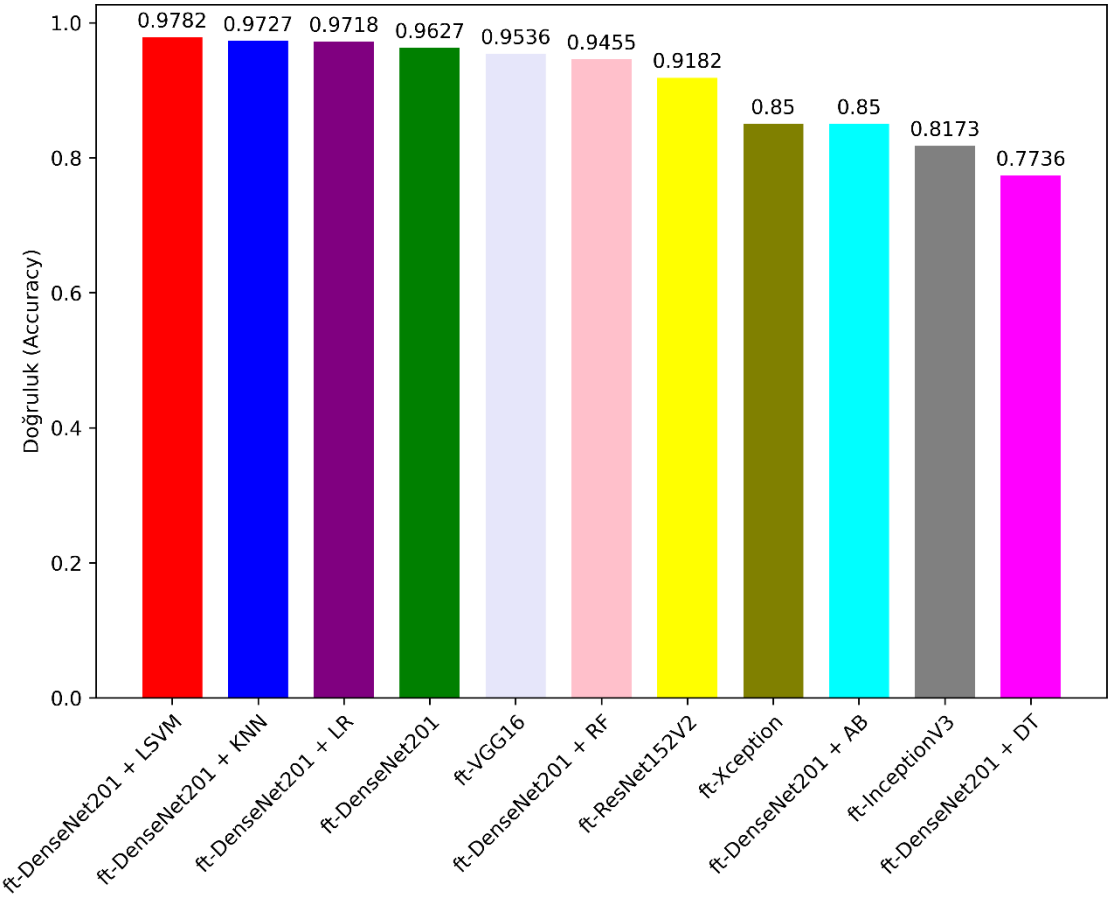
		Makro Ortalama		
Algorithm	**Test Accuracy**	**Precision**	**Recall**	**F_1 Score**
ft-VGG16	0.9536	0.9536	0.9536	0.9536
ft-InceptionV3	0.8173	0.8462	0.8173	0.8134
ft-DenseNet201	0.9627	0.9634	0.9627	0.9627
ft-ResNet152V2	0.9182	0.9220	0.9182	0.9180
ft-Xception	0.8500	0.8501	0.8500	0.8500
ft-DenseNet201 + LR	0.9718	0.9719	0.9718	0.9718
ft-DenseNet201 + LSVM	***0.9782***	***0.9782***	***0.9782***	***0.9782***
ft-DenseNet201 + KNN	0.9727	0.9730	0.9727	0.9727
ft-DenseNet201 + DT	0.7736	0.7740	0.7736	0.7736
ft-DenseNet201 + RF	0.9455	0.9457	0.9455	0.9454

Receiver Operating Characteristic (Alıcı işletim karakteristiği, ROC) eğrisi, doğru pozitiflerin yanlış pozitiflere oranıdır. ROC eğrisi sol üst köşeye yaklaştıkça, testin genel doğruluğu artar. ROC eğrisi, sınıflandırıcının yanlış pozitifleri eleme ve doğru pozitifleri tespit etme yetenekleri arasındaki dengeyi ne kadar iyi kurabildiğini gösterir. AUC (Area Under the ROC Curve) (ROC eğrisinin altında kalan alan) değeri, iki sınıfın ne kadar iyi ayırt edilebildiğinin bir ölçüsüdür ve mükemmel ayrımcılık için 1' e yakın olması istenir. Şekil 4.3' te ikinci aşamada kullanılan sınıflandırıcılara ait ROC eğrileri verilmiştir. Eğriler incelendiğinde, ft-DenseNet201 + LSVM algoritmasının 0.9782 ile en yüksek AUC değeri verdiği gözlenmektedir.



Şekil 4.3. Uygulamada Kullanılan MÖ Sınıflandırıcılarının ROC Eğrileri

5. SONUÇ VE TARTIŞMA



Şekil 5.1. Uygulamada Kullanılan Tüm Algoritmaların Test Doğruluğu Sıralaması

Bu uygulamada, doktordan bağımsız fetüs cinsiyetinin USG görüntülerinden teşhis edilebilmesi için iki aşamada toplam 11 algoritma denenmiştir. 2200 kız ve 2200 erkek cinsiyetli fetal USG görüntülerinden oluşan bir veri setine dayanarak, deneysel sonuçlar, ft-DenseNet201 + LSVM algoritmasının yaklaşık %98 (0.9782) test doğruluğu ile en doğru sınıflandırma ve cinsiyet teşhisi yapan yöntem olduğunu göstermiştir (Şekil 5.1). Şekil 5.1' de verilen test doğrulukları incelendiğinde, ft-DenseNet201 + KNN (0.9727) ve ft-DenseNet201 + LR (0.9718) algoritmalarının ft-DenseNet201 + LSVM algoritmasına oldukça yakın sonuç ürettikleri ve üç algoritmanın

da %97' nin üzerinde cinsiyet tahminini doğru yaptıkları gözlenmektedir. Uzman tarafından yapılan Fetal USG taramasının duyarlılığının değişken ve sonografi uzmanının deneyimine bağlı olduğu göz önüne alındığında, üç algoritmanın da cinsiyet teşhisinde, bir uzmanın teşhisine göre daha güvenilir ve objektif yöntemler olduğu ispatlanmıştır. Fetüs cinsiyetinin USG görüntülerinden teşhisi için önerilen bu üç hibrit algoritma, otomatiktir ve doğrulukları oldukça yüksektir. Bu algoritmalar ve sonuçları ile birlikte, uzmanın herhangi bir müdahalesi olmadan fetüs cinsiyetinin DÖ teknikleriyle teşhis edilebileceği kanıtlanmıştır.

Şekil 5.1 incelendiğinde, başarılı sonuç veren algoritmaların yanı sıra, %85 ve altında doğruluk sonucu veren algoritmaların (ft-Xception-%85, ft-DenseNet201 + AB-%85, ft-InceptionV3-%8173, ft-DenseNet201 + DT-%7736) problem çözümünde başarısız oldukları ve fetal USG görüntülerini sınıflandırmada zayıf yöntemler olduğu gözlenmektedir. Uygulamanın birinci aşamasında en iyi özellik çıkarıcı ağ araması yapıldığı için, kullanılan derin ağlara aynı DTÖ teknikleri uygulanmış (hassas ayar), aynı ağ hiperparametreleri kullanılmıştır. ft-Xception ve ft-InceptionV3 ağlarının başarısızlık nedeni, uygulanan DTÖ tekniklerinin ve seçilen ağ hiperparametrelerinin bu ağlarla uyum sağlamamış olmasından kaynaklanabilir. Uygulamada kullanılan derin ağlara, en iyi ağ hiperparametrelerinin seçildiği (örneğin, en iyi optimizer) ve ağın ihtiyacına göre hassas ayarlanması için yeni deneylerin yapılması, başarı sonuçlarını yükseltecek, özellikle zayıf algoritmaları geliştirecektir. Bunun yanı sıra, Doğal görüntüler üzerinde eğitilen bazı modeller, düşük kontrastlı ve doku açısından zengin fetal USG görüntüleri için ideal olmayabilir. Ayrıca en iyi ağ hiperparametrelerinin seçildiği deneyler, ESA hiperparametrelerinin ve modellerin sayısı göz önüne alındığında, hesaplama yükü nedeniyle donanım ve zaman açısından oldukça maliyetli olacaktır.

Sınıflandırıcıların test sonuçları incelendiğinde, MÖ sınıflandırıcılarını, ft-DenseNet201 ağının sınıflandırıcısı (tam bağlı katmanlar ve sigmoid) ile kıyaslarsak, LSVM, KNN ve LR algoritmalarının daha başarılı sınıflandırma yaptıkları gözlenmektedir. Tang, 2013'

te yaptığı bir çalışmada softmax ve SVM sınıflandırıcılarını kıyaslamış, ESA ve SVM algoritmasının birlikte kullanıldığında softmaxtan daha başarılı olduğunu savunmuştur (Y. Tang 2013). Özellikle ft-DenseNet201 + LSVM algoritmasının, ft-DenseNet201 + sigmoid algoritmasından daha yüksek sonuç vermesi, bu tez çalışması için Tang' ın teorisini destekler niteliktedir.

Derin öğrenme ile elde edilebilecek büyük performans iyileştirmesi büyük ölçüde büyük eğitim örneği içeren veri setlerine bağlıdır. Bununla birlikte, diğer alanlardaki büyük ve halka açık veri kümeleriyle karşılaştırıldığında (örneğin, ImageNet), medikal USG alanındaki veri kümelerinin kamuya açık erişilebilirliği yoktur. Sınırlı eğitim verileri, tıbbi USG görüntü analizinde derin öğrenme yöntemlerinin daha fazla uygulanması için bir darboğaz görevi görmektedir. Bu tez çalışmasında, veri örneklerinin tek bir tesisten (yani tek bir hastane ve doktor) toplanması, çalışma için bir eksiklik oluşturmaktadır. Farklı doktorlar tarafından etiketlenmiş ve farklı cihazlardan elde edilen, daha büyük bir veri setine sahip olmak, önerilen yöntemlerin tümünün genelleme yapma yeteneğini arttıran birinci faktör olacaktır.

Çizelge 5.1' de verilen, literatürdeki fetal genital organ sınıflandırması içeren çalışmalar incelendiğinde; bu çalışmalarda, doğrudan fetal cinsiyetin tespiti ve sınıflandırılması yapılmamıştır. Ancak, fetal USG görüntülerinden oluşan veri setlerinde, cinsiyet tanımlayan özellikleri içeren görüntüler tespit edilmiştir. Bu tez çalışmasında kullanılan veri seti ve çalışma amacının literatürdeki diğer çalışmalardan farklı olması, ilk kez yapılan bir çalışma olduğunu göstermektedir. Bu çalışmada gerçekleştirilen fetüs cinsiyeti sınıflandırması yaklaşık %98 doğruluk oranıyla gelecek vadeden bir çalışmadır. Fetüs cinsiyeti teşhisinde, 11 farklı modern tekniğin, alanında uzman kişiler tarafından hazırlanmış, spesifik bir veri setine uygulanmasıyla uzmanlara, invaziv olmayan OUSG cinsiyet teşhisi yöntemini destekleyici, farklı ve yeni bir yöntem sunması bu çalışmayı ilgi çekici kılmaktadır.

Çizelge 5.1. Fetal Genital Organ Sınıflandırması İçeren Makalelere Genel Bakış ve Karşılaştırma

Referans	**Veri Seti**	**Yöntem**	**Amaç**	**Metrikler ve Sonuç**
(S. Tang and Chen, 2009)	Fetal genital organ içeren görüntü: 658 Fetal genital organ içermeyen görüntü: 500	Özellik çıkarma: Görüntü işleme teknikleri Sınıflandırma: Radyal Temelli Fonksiyon Ağı, Geri Yayılım Ağı, SVM	Asya ülkelerindeki cinsiyet seçici kürtajları ve ultrason teknisyenlerinin fetüsün cinsiyetini etik olmayan bir şekilde tanımlamasını önlemek için fetal genital organları otomatik tanıma ve konumlama algoritması önerilmiştir. USG görüntülerinde fetal genital organların mevcut olup olmadığı konusunda bir karar oluşturmak için sınıflandırma yapılmıştır.	Geometrik Ortalama; SVM algoritması 89.01 ile en yüksek geometrik ortalama sonucunu vermiştir.
(Kumar et al., 2016)	7568 fetal USG görüntüsü	Özellik çıkarma: Hassas ayarlı AlexNet Sınıflandırma: Çoklu Sınıf SVM	Fetal yapıların analizi ve yorumlanması için 13 fetal anatomik yapı, 3 yapısal olmayan anlık görüntü sınıflandırması yapılmıştır. Sınıflandırılan anatomik yapıların içinde genital organ sınıfı da vardır.	Doğruluk (Accuracy); Genital organ sınıfı, %23.8 doğruluk vermiştir.
(Sridar et al., 2019)	4074 fetal USG görüntüsü Genital organ sınıfı: 72 görüntü	Kırpılmış ve bütün görüntülerden çıkarılan özellikler karar füzyonu ile birleştirilmiştir. Özellik çıkarma: Hassas ayarlı AlexNet Sınıflandırma: Çoklu Sınıf SVM	Fetal yapıların analizi ve yorumlanması için 14 farklı fetal yapının sınıflandırılması yapılmıştır. Sınıflandırılan anatomik yapıların içinde genital organ sınıfı da vardır.	Doğruluk (Accuracy), Hassasiyet (Precision), Geri Çağırma (Recall), Cohen k; 14 fetal yapı, %97.05 ortalama doğruluk ile sınıflandırılmıştır. Genital organ sınıfı %99 doğruluk vermiştir.
(Lakra et al., 2019)	Genital organ içeren fetal USG görüntü: 6027 Genital organ içermeyen fetal USG görüntü: 15585	ResNet-18 ve ResNet-34	Hindistan'da cinsiyet seçici kürtajları önlemek ve gizliliğin korunması için fetal USG görüntüleri, genital organ içeren görüntü, genital organ içermeyen görüntü şeklinde sınıflandırılmıştır. Böylece, cinsiyet tanımlayan özellikleri içeren görüntüler tespit edilmiştir.	Doğruluk (Accuracy), Hassasiyet (Precision), Geri Çağırma (Recall), F1 skor; Beş kat çapraz doğrulama ile %83.63 doğruluk elde edilmiştir.
(Sivari, 2021)	Kız genital organı içeren fetal USG görüntü: 2200 Erkek genital organı içeren fetal USG görüntü: 2200	Hassas ayarlı VGG16, DenseNet201, InceptionV3, ResNet152V2, Xception, LR, KNN, LSVM, DT, RF, AB	Fetüs cinsiyetinin uzmandan bağımsız, otomatik, objektif, daha güvenilir teşhisi ve sınıflandırılması.	Doğruluk (Accuracy), Hassasiyet (Precision), Geri Çağırma (Recall), F1 skor, ROC, Karışıklık Matrisi; ft-DenseNet201 + LSVm algoritması 0.9782 doğruluk ile en yüksek doğrulukta cinsiyet tahmini yapmıştır.

Bu uygulama, ev tipi ultrason cihazlarına entegre edilerek ebeveynler, muayene olmadan bebeklerinin cinsiyetlerini öğrenebilir ve böylece, uzmanların iş yüküne hafifletici destek sağlanabilir. Şu anda içinde bulunduğumuz pandemi dönemi ve ileride insanlığın karşılaşacağı olası pandemi dönemleri için, insanları uzman ve hastane bağımlılığından kurtaran mühendislik uygulamaları oldukça önemlidir. Bu tez çalışması, sağlık alanında geliştiren mühendislik çalışmalarına otomatik, objektif ve yüksek güvenilirlik sağlaması ile katkı sağlamaktadır.

Bu çalışma, tıp literatürü için, invaziv olmayan fetal cinsiyet teşhisi yöntemi olan OUSG yöntemine opsiyon olarak, yeni bir cinsiyet teşhisi yöntemidir. Yöntem, doktorların kullandığı USG cihazlarına entegre edilerek, doktorun teşhisini destekleyici, daha güvenilir ve objektif bir yöntem olarak kullanılabilir. Gelecekte, bu tür uygulamalarla birlikte, uzmandan bağımsız, fetüs anormalliklerini, gelişimini izleyen ve teşhis edebilen akıllı USG cihazları üretilebilir.

KAYNAKLAR

Açar, G., & Karaoğlu, N. (2018). Fetal Gelişim, Plasenta Fizyolojisi ve Patolojisi. *Turkiye Klinikleri J Fam Med-Special Topics*, *9*(1), 9–15.

Agarap, A. F. M. (2018). Deep Learning using Rectified Linear Units (ReLU). *ArXiv*, (1), 2–8.

Akolekar, R., Bower, S., Flack, N., Bilardo, C. M., & Nicolaides, K. H. (2011). Prediction of miscarriage and stillbirth at 11-13 weeks and the contribution of chorionic villus sampling. *Prenatal Diagnosis*, *31*(1), 38–45.

Altunyurt, S., Pala, G., & Mantar, Ö. (2010). Ultrasonografi İle İlk Trimester Cinsiyet Tayini. *Türk Jinekoloji ve Obstetrik Derneği Dergisi, (TJOD Derg)*, *7*(1), 23–28.

Ammini, A. C., Pandey, J., Vijyaraghavan, M., & Sabherwal, U. (1994). Human female phenotypic development: role of fetal ovaries. *The Journal of Clinical Endocrinology & Metabolism*, *79*(2), 604–608.

Aydın, R., Kızılkaya, T., Hancıoğlu Aytaç, S., & Taşlar, N. (2020). COVID-19 Pandemisinde; Gebelik, Doğum ve Doğum Sonu Dönemde Kadınların Sosyal Destek Gereksinimi ve Ebelik Yaklaşımları. *Journal of Turkish Studies*, *15*(4), 679–690.

Bastien, F., Lamblin, P., Pascanu, R., Bergstra, J., Goodfellow, I., Bergeron, A., … Bengio, Y. (2012). *Theano: new features and speed improvements*. Retrieved from http://arxiv.org/abs/1211.5590

Baumgartner, C. F., Kamnitsas, K., Matthew, J., Fletcher, T. P., Smith, S., Koch, L. M., … Rueckert, D. (2017). SonoNet: Real-Time Detection and Localisation of Fetal Standard Scan Planes in Freehand Ultrasound. *IEEE Transactions on Medical Imaging*, *36*(11), 2204–2215.

Bellman, R. E. (2010). *Dynamic Programming*. Princeton Landmarks in Mathematics and Physics.

Bertrand, J., Rappaport, R., & Sizonenko, P. (1993). Timing of sexual differentiation in the human fetus. In *Pediatric Endocrinology* (pp. 88–99). Baltimore: Williams & Wilkins.

Bindiya, H. M., Chethana, H. T., & Kumar, S. P. (2018). Detection of Anomalies in Fetus using Convolution Neural Network. *International Journal of Information Technology and Computer Science*, *10*(11), 77–86.

Blumberg, B. D., Golbus, M. S., & Hanson, K. H. (1975). The psychological sequelae of abortion performed for a genetic indication. *American Journal of Obstetrics and*

Gynecology, *122*(7), 799–808.

Brattain, L. J., Telfer, B. A., Dhyani, M., Grajo, J. R., & Samir, A. E. (2018). Machine learning for medical ultrasound: status, methods, and future opportunities. *Abdominal Radiology*, *43*(4), 786–799.

Byrd, R. H., Lu, P., Nocedal, J., & Zhu, C. (1995). A Limited Memory Algorithm for Bound Constrained Optimization. *SIAM Journal on Scientific Computing*, *16*(5), 1190–1208.

Çağlar, M., & Oskay, Ü. Y. (2020). COVID-19 Pandemisi Sürecinde Gebelik ve Doğum Yönetimi. *Health Sciences Journal of Nursing Cilt*, *2*(2), 99–104.

Chetlur, S., Woolley, C., Vandermersch, P., Cohen, J., Tran, J., Catanzaro, B., & Shelhamer, E. (2014). *cuDNN: Efficient Primitives for Deep Learning*. Retrieved from http://arxiv.org/abs/1410.0759

Chollet, F. (2017a). *Deep Learning with Python*. Manning Publications.

Chollet, F. (2017b). Xception: Deep learning with depthwise separable convolutions. *Proceedings - 30th IEEE Conference on Computer Vision and Pattern Recognition, CVPR 2017*, *2017-Janua*, 1800–1807. Institute of Electrical and Electronics Engineers Inc.

Colmant, C., Morin-Surroca, M., Fuchs, F., Fernandez, H., & Senat, M. V. (2013). Non-invasive prenatal testing for fetal sex determination: Is ultrasound still relevant? *European Journal of Obstetrics and Gynecology and Reproductive Biology*, Vol. 171, pp. 197–204. Elsevier Ireland Ltd.

Cunningham, F. G., Leveno, K. J., Bloom, S. L., Spong, C. Y., & Dashe, J. S. (2014). *Williams Obstetrics* (24th ed.). Mc Graw Hill Education.

Dennis Lo, Y. M., Corbetta, N., Chamberlain, P. F., Rai, V., Sargent, I. L., Redman, C. W. G., & Wainscoat, J. S. (1997). Presence of fetal DNA in maternal plasma and serum. *Lancet*, *350*(9076), 485–487.

Dillon, J. V., Langmore, I., Tran, D., Brevdo, E., Vasudevan, S., Moore, D., … Saurous, R. A. (2017). TensorFlow Distributions. *ArXiv*. Retrieved from http://arxiv.org/abs/1711.10604

Duchi, J., Hazan, E., & Singer, Y. (2010). Adaptive subgradient methods for online learning and stochastic optimization. *COLT 2010 - The 23rd Conference on Learning Theory*, *12*, 257–269.

Dudek, R. W. (2016). *BRS Embriyoloji* (6th ed.; T. İREZ & M. ERKAN, Eds.). İstanbul: İstanbul Tıp Kitabevleri.

Efrat, Z., Perri, T., Ramati, E., Tugendreich, D., & Meizner, I. (2006). Fetal gender

assignment by first-trimester ultrasound. *Ultrasound in Obstetrics and Gynecology*, *27*(6), 619–621.

Enzensberger, C., Pulvermacher, C., Degenhardt, J., Kawacki, A., Germer, U., Gembruch, U., … Axt-Fliedner, R. (2012). Fetal loss rate and associated risk factors after amniocentesis, chorionic villus sampling and fetal blood sampling. *Ultraschall in Der Medizin*, *33*(7).

Erbil, N., & Sağlam, G. (2010). Gebelikte bebeğin cinsiyetini belirleme ve tahmin etmeye ilişkin geleneksel inanç, uygulamalar ve bazı sosyo-demografik özelliklerle ilişkisi. *Uluslararası İnsan Bilimleri Dergisi*, *7*, 347–359.

Feldman, K. W., & Smith, D. W. (1975). Fetal phallic growth and penile standards for newborn male infants. *The Journal of Pediatrics*, *86*(3), 395–398.

Fuchs, F., & Riis, P. (1956). Antenatal sex determination. *Nature*, Vol. 177, p. 330. Nature Publishing Group.

Handyside, A. H., Kontogianni, E. H., Hardy, K., & Winston, R. M. L. (1990). Pregnancies from biopsied human preimplantation embryos sexed by Y-specific DNA amplification. *Nature*, *344*(6268), 768–770.

Harrington, K., Armstrong, V., Freeman, J., Aquilina, J., & Campbell, S. (1996). Fetal sexing by ultrasound in the second trimester: Maternal preference and professional ability. *Ultrasound in Obstetrics and Gynecology*, *8*(5), 318–321.

He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, *2016-Decem*, 770–778.

Hecht-Nielsen, R. (1989). Theory of the backpropagation neural network. *International Joint Conference on Neural Networks*, *1*, 593–605.

Hemalatha, R. J., Vijaybaskar, V., & Thamizhvani, T. R. (2019). Automatic localization of anatomical regions in medical ultrasound images of rheumatoid arthritis using deep learning. *Proceedings of the Institution of Mechanical Engineers, Part H: Journal of Engineering in Medicine*, *233*(6), 657–667.

Huang, G., Liu, Z., van der Maaten, L., & Weinberger, K. Q. (2016). Densely Connected Convolutional Networks. *Proceedings - 30th IEEE Conference on Computer Vision and Pattern Recognition, CVPR 2017*, *2017-January*, 2261–2269. Retrieved from http://arxiv.org/abs/1608.06993

Hubel, D. H., & Wiesel, T. N. (1968). Receptive fields and functional architecture of monkey striate cortex. *The Journal of Physiology*, *195*(1), 215–243.

Huynh, B., Drukker, K., & Giger, M. (2016). Computer-aided diagnosis of breast ultrasound images using transfer learning from deep convolutional neural

networks. *Medical Physics*, *43*(6), 3705–3705.

Ioffe, S., & Szegedy, C. (2015). Batch normalization: Accelerating deep network training by reducing internal covariate shift. *32nd International Conference on Machine Learning, ICML 2015*, *1*, 448–456.

Kingma, D. P., & Ba, J. (2014). Adam: A Method for Stochastic Optimization. *3rd International Conference on Learning Representations, ICLR 2015 - Conference Track Proceedings*, 1–15. Retrieved from http://arxiv.org/abs/1412.6980

Klages, K., Kundu, S., Erlenwein, J., Elsaesser, M., Hillemanns, P., Scharf, A., & Staboulidou, I. (2017). Maternal anxiety and its correlation with pain experience during chorion villus sampling and amniocentesis. *Journal of Pain Research*, *10*, 591–600.

Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). ImageNet Classification with Deep Convolutional Neural Networks. *Advances in Neural Information Processing Systems*, *25*. Retrieved from http://code.google.com/p/cuda-convnet/

Kumar, A., Sridar, P., Quinton, A., Kumar, R. K., Feng, D., Nanan, R., & Kim, J. (2016). Plane identification in fetal ultrasound images using saliency maps and convolutional neural networks. *Proceedings - International Symposium on Biomedical Imaging*, *2016-June*, 791–794.

Lakra, P. P., Kumar, A., Mohanram, N., Krishnamurthi, G., & Thittai, A. K. (2019). Deep-Learning based Identification of Frames Containing Foetal Gender Region during Early Second Trimester Ultrasound Scanning. *IEEE International Ultrasonics Symposium, IUS*, *2019-Octob*, 471–474.

Lee, D. T. S., Sahota, D., Leung, T. N., Yip, A. S. K., Lee, F. F. Y., & Chung, T. K. H. (2006). Psychological responses of pregnant women to an infectious outbreak: A case-control study of the 2003 SARS outbreak in Hong Kong. *Journal of Psychosomatic Research*, *61*(5), 707–713.

Liang, X., Yu, J., Liao, J., & Chen, Z. (2020). Convolutional Neural Network for Breast and Thyroid Nodules Diagnosis in Ultrasound Imaging. *BioMed Research International*, *2020*.

Linde, A. R., & Siqueira, C. E. (2018). Women's lives in times of Zika: Mosquito-controlled lives? *Cadernos de Saude Publica*, *34*(5).

Liu, J., & Li, P. F. (2018). A Mask R-CNN Model with Improved Region Proposal Network for Medical Ultrasound Image. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, *10955 LNCS*, 26–33. Springer Verlag.

Liu, S., Wang, Y., Yang, X., Lei, B., Liu, L., Li, S. X., … Wang, T. (2019). Deep Learning in Medical Ultrasound Analysis: A Review. *Engineering*, *5*(2), 261–275.

Makiyan, Z. (2016). Studies of gonadal sex differentiation. *Organogenesis*, *12*(1), 42–51.

McKinney, W. (2011). pandas: a Foundational Python Library for Data Analysis and Statistics. *Python for High Performance and Scientific Computing*, 1–9. Retrieved from http://pandas.sf.net

Moore, K. L., Persaud, T. V. N., & Torchia, M. G. (2016). Pla-centa and Fetal Membrane. In *The Developing human: clinically oriented embryology* (10th ed., pp. 107–118). Philadelphia: Elsevier Health Sciences.

Odeh, M., Grinin, V., Kais, M., Ophir, E., & Bornstein, J. (2009, January). Sonographie fetal sex determination. *Obstetrical and Gynecological Survey*, Vol. 64, pp. 50–57.

Oliphant, T. E. (2006). *Guide to NumPy*. Retrieved from http://www.trelgol.com

Oquab, M., Bottou, L., Laptev, I., & Sivic, J. (2014). Learning and transferring mid-level image representations using convolutional neural networks. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 1717–1724. IEEE Computer Society.

Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., … Perrot, M. (2011). Scikit-learn: Machine Learning in Python Pedregosa, Varoquaux, Gramfort et al. In *Journal of Machine Learning Research* (Vol. 12). Retrieved from http://scikit-learn.org.

Reddy, U. M., Filly, R. A., & Copel, J. A. (2008). Prenatal imaging: Ultrasonography and magnetic resonance imaging. *Obstetrics and Gynecology*, Vol. 112, pp. 145–157. https://doi.org/10.1097/01.AOG.0000318871.95090.d9

Royal College of Obstetricians & Gynecologists (RCOG). (2020). *Coronavirus (COVID-19) infection in pregnancy information for healthcare professionals.*

Sadler, T. W. (2012). *Langman's Medical Embryology* (12th ed.). Baltimore: Lippincott Williams&Wilkins.

Salomon, L. J., Winer, N., Bernard, J. P., & Ville, Y. (2008). A score-based method for quality control of fetal images at routine second-trimester ultrasound examination. *Prenatal Diagnosis*, *28*(9), 822–827.

Savaş, S., Topaloğlu, N., Kazcı, Ö., & Koşar, P. N. (2019). Classification of Carotid Artery Intima Media Thickness Ultrasound Images with Deep Learning. *Journal of Medical Systems*, *43*(8).

Scholly, T. A., Sutphen, J. H., Hitchcock, D. A., Mackey, S. C., & Langstaff, L. M. (1980). Sonographic determination of fetal gender. *American Journal of Roentgenology*, *135*(6), 1161–1165.

Seyyarer, E., Uckan, T., Hark, C., Ayata, F., Inan, T., & Karci, A. (2019). Applications and Comparisons of Optimization Algorithms Used in Convolutional Neural Networks. *2019 International Conference on Artificial Intelligence and Data Processing Symposium, IDAP 2019*. Institute of Electrical and Electronics Engineers Inc.

Sharma, S., Sharma, S., & Athaiya, A. (2020). Activation Functions in Neural Networks. *International Journal of Engineering Applied Sciences and Technology*, *04*(12), 310–316.

Shopbell, P. L., Britton, M. C., Ebert, R., Barrett, P., Hunter, J., Miller, J. T., … Greenfield, P. (2005). *matplotlib-A Portable Python Plotting Package* (Vol. 347).

Shorten, C., & Khoshgoftaar, T. M. (2019). A survey on Image Data Augmentation for Deep Learning. *Journal of Big Data*, *6*(1).

Simonyan, K., & Zisserman, A. (2015). Very deep convolutional networks for large-scale image recognition. *3rd International Conference on Learning Representations, ICLR 2015 - Conference Track Proceedings*, 1–14.

Speroff, L., Glass, R. H., & Kase, N. G. (1994). Normal and abnormal sexual development. In *Clinical gynecologic endocrinology and infertility* (5th ed., pp. 321–360). Baltimore: Williams & Wilkins.

Sridar, P., Kumar, A., Quinton, A., Nanan, R., Kim, J., & Krishnakumar, R. (2019). Decision Fusion-Based Fetal Ultrasound Image Plane Classification Using Convolutional Neural Networks. *Ultrasound in Medicine and Biology*, *45*(5), 1259–1273.

Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. (2014). Dropout: A simple way to prevent neural networks from overfitting. *Journal of Machine Learning Research*, *15*(56), 1929–1958.

Sutskever, I., Martens, J., Dahl, G., & Hinton, G. (2013). On the importance of initialization and momentum in deep learning. *30th International Conference on Machine Learning, ICML 2013*, (PART 3), 2176–2184.

Szegedy, C., Ioffe, S., Vanhoucke, V., & Alemi, A. A. (2017). Inception-v4, inception-ResNet and the impact of residual connections on learning. *31st AAAI Conference on Artificial Intelligence, AAAI 2017*, 4278–4284.

Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., … Rabinovich, A. (2015). *Going Deeper with Convolutions*.

Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., & Wojna, Z. (2016). Rethinking the Inception Architecture for Computer Vision. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, *2016-Decem*, 2818–2826. IEEE Computer Society.

Tabor, A., Vestergaard, C. H. F., & Lidegaard. (2009). Fetal loss rate after chorionic villus sampling and amniocentesis: An 11-year national registry study. *Ultrasound in Obstetrics and Gynecology*, *34*(1), 19–24.

Tang, S., & Chen, S. P. (2009). A fast automatic recognition and location algorithm for fetal genital organs in ultrasound images. *Journal of Zhejiang University: Science B*, *10*(9), 648–658.

Tang, Y. (2013). *Deep Learning using Linear Support Vector Machines*. Retrieved from http://arxiv.org/abs/1306.0239

Tegnander, E., & Eik-Nes, S. H. (2006). The examiner's ultrasound experience has a significant impact on the detection rate of congenital heart defects at the second-trimester fetal examination. *Ultrasound in Obstetrics and Gynecology*, *28*(1), 8–14.

Tieleman, T., & Hinton, G. (2012). Lecture 6.5-rmsprop: Divide the gradient by a running average of its recent magnitude. *COURSERA: Neural Networks for Machine Learning*, *4*(2), 26–31.

TNSA. (2018). Türkiye Nüfus ve Sağlık Araştırması. In *Hacettepe Üniversitesi Nüfus Etütleri Enstitüsü*.

Wang, G. (2016). A perspective on deep imaging. *IEEE Access*, Vol. 4, pp. 8914–8924. Institute of Electrical and Electronics Engineers Inc.

Woo, J. (2001). A short History of Amniocentesis, Fetoscopy and Chorionic Villus Sampling. In *History of Ultrasound in Obstetrics and Gynecology*. British Medical Ultrasound Society.

Yüksel, M. U., & Ertuğrul, D. Ç. (2017). Fetal Kalp Hızı Monitörizasyon Sistemi İçin Doppler CihazımGeliştirilmesi (mDoppler). *Ulusal Biyomedikal Cihaz Tasarımı ve Üretimi Sempozyumu*, 10–17.

Yüreğir, Ö., Büyükkurt, S., Koç, F., & Pazarbaşı, A. (2012). Prenatal (Doğum Öncesi) Tanı. *Arşiv Kaynak Tarama Dergisi*, *21*(1), 80–94.

Zeiler, M. D. (2012). *ADADELTA: An Adaptive Learning Rate Method*. Retrieved from http://arxiv.org/abs/1212.5701

ÖZGEÇMİŞ

Adı Soyadı	: Esra SİVARİ
Doğum Yeri	: Yapraklı / ÇANKIRI
Doğum Tarihi	: 23.08.1993
Medeni Hali	: Bekar
Yabancı Dili	: İngilizce
Adres	: Çankırı Karatekin Üniversitesi, Uluyazı Kampusu, Mühendislik Fakültesi Zemin Kat 18100 Merkez/Çankırı
e-posta	:

Eğitim Durumu

Lise	: Ankara Hurin Yavuzalp Lisesi (2007-2011)
Lisans	: Konya Selçuk Üniversitesi Yabancı Diller Meslek Yüksek Okulu İngilizce Hazırlık Sınıfı (2012-2013) Konya Selçuk Üniversitesi Mühendislik Fakültesi Bilgisayar Mühendisliği (2013-2017)
Yüksek Lisans	: Çankırı Karatekin Üniversitesi Fen Bilimleri Enstitüsü Elektrik Elektronik Mühendisliği ABD (2019-2021)

Çalıştığı Kurum/Kurumlar

Çankırı Karatekin Üniversitesi Mühendislik Fakültesi Bilgisayar Yazılımı ABD Araştırma Görevlisi (2020-Devam Ediyor)