

**BAŐKENT ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ  
BİLGİSAYAR MÜHENDİSLİĐİ ANABİLİM DALI  
BİLGİSAYAR MÜHENDİSLİĐİ TEZLİ YÜKSEK LİSANS PROGRAMI**

**DERİN ÖĐRENME MODELLERİ İLE PARKİNSON HASTALIĐININ  
TEŐHİSİNDE TRANSFER ÖĐRENME TEKNİĐİNİN ETKİNLİĐİNİN  
ARAŐTIRILMASI**

**HAZIRLAYAN**

**ECEM ZORA**

**YÜKSEK LİSANS TEZİ**

**ANKARA – 2024**



**BAŞKENT ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ  
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI  
BİLGİSAYAR MÜHENDİSLİĞİ TEZLİ YÜKSEK LİSANS PROGRAMI**

**DERİN ÖĞRENME MODELLERİ İLE PARKİNSON HASTALIĞININ  
TEŞHİSİNDE TRANSFER ÖĞRENME TEKNİĞİNİN ETKİNLİĞİNİN  
ARAŞTIRILMASI**

**HAZIRLAYAN**

**ECEM ZORA**

**YÜKSEK LİSANS TEZİ**

**TEZ DANIŞMANI**

**DR. ÖĞR. ÜYESİ MEHMET DİKMEN**

**ANKARA – 2024**

**BAŞKENT ÜNİVERSİTESİ**  
**FEN BİLİMLERİ ENSTİTÜSÜ**

Bilgisayar Mühendisliği Anabilim Dalı Bilgisayar Mühendisliği Tezli Yüksek Lisans Programı çerçevesinde Ecem Zora tarafından hazırlanan bu çalışma, aşağıdaki jüri tarafından Yüksek Lisans Tezi olarak kabul edilmiştir.

Tez Savunma Tarihi: 24 / 05 / 2024

**Tez Adı:** Derin Öğrenme Modelleri ile Parkinson Hastalığının Teşhisinde Transfer Öğrenme Tekniğinin Etkinliğinin Araştırılması

**Tez Jüri Üyeleri ( Unvanı, Adı - Soyadı, Kurumu )**

**İmza**

Dr. Öğr. Üyesi Mehmet DİKMEN, Başkent Üniversitesi

.....

Dr. Öğr. Üyesi Çağatay Berke ERDAŞ, Başkent Üniversitesi

.....

Dr. Öğr. Üyesi Koray AÇICI, Ankara Üniversitesi

.....

**ONAY**

Prof. Dr. Ömer Faruk ELALDI

Fen Bilimleri Enstitüsü Müdürü

Tarih: ... / ... / 2024

**BAŞKENT ÜNİVERSİTESİ**  
**FEN BİLİMLERİ ENSTİTÜSÜ**  
**YÜKSEK LİSANS TEZ ÇALIŞMASI ORJİNALLİK RAPORU**

Tarih: 04 / 06 / 2024

Öğrencinin Adı, Soyadı: Ecem Zora

Öğrencinin Numarası: 22110057

Anabilim Dalı: Bilgisayar Mühendisliği

Programı: Bilgisayar Mühendisliği Tezli Yüksek Lisans

Danışmanın Unvanı/Adı, Soyadı: Dr. Öğr. Üyesi Mehmet Dikmen

Tez Başlığı: Derin Öğrenme Modelleri ile Parkinson Hastalığının Teşhisinde Transfer Öğrenme Tekniğinin Etkinliğinin Araştırılması

Yukarıda başlığı belirtilen Yüksek Lisans tez çalışmamın; Giriş, Ana Bölümler ve Sonuç Bölümünden oluşan, toplam 39 sayfalık kısmına ilişkin, 04 / 06 / 2024 tarihinde tez danışmanım tarafından Turnitin adlı intihal tespit programından aşağıda belirtilen filtrelemeler uygulanarak alınmış olan orijinallik raporuna göre, tezimin benzerlik oranı % 5'dir. Uygulanan filtrelemeler:

1. Kaynakça hariç
2. Alıntılar hariç
3. Beş (5) kelimedenden daha az örtüşme içeren metin kısımları hariç

“Başkent Üniversitesi Enstitüleri Tez Çalışması Orijinallik Raporu Alınması ve Kullanılması Usul ve Esaslarını” inceledim ve bu uygulama esaslarında belirtilen azami benzerlik oranlarına tez çalışmamın herhangi bir intihal içermediğini; aksinin tespit edileceği muhtemel durumda doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi ve yukarıda vermiş olduğum bilgilerin doğru olduğunu beyan ederim.

Öğrenci İmzası: .....

**ONAY**

04 / 06 / 2024

Öğrenci Danışmanı

Dr. Öğr. Üyesi Mehmet DİKMEN

.....

## TEŐEKKÜR

Çalıőmalarımın baőından sonuna kadar destek olan, karőılaőılan zorluklar karőısında deęerli tecrübeleriyle her zaman yardımcı olan ve çalıőmamın sonuçlanabilmesi için motive eden tez danıőmanım Sayın Dr. Öğr. Üyesi MEHMET DİK MEN'e teőekkürlerimi ve saygılarımı sunuyorum.

Tez savunmamda yer alarak deęerli görüşlerini aktaran ve tezimin son őeklini almasını saęlayan Sayın Dr. Öğr. Üyesi KORAY AÇICI ve Sayın Dr. Öğr. Üyesi ÇAĖATAY BERKE ERDAŐ'a teőekkürlerimi ve saygılarımı sunuyorum.



# ÖZET

**Ecem ZORA**

## **DERİN ÖĞRENME MODELLERİ İLE PARKINSON HASTALIĞININ TEŞHİSİNDE TRANSFER ÖĞRENME TEKNİĞİNİN ETKİNLİĞİNİN ARAŞTIRILMASI**

**Başkent Üniversitesi Fen Bilimleri Enstitüsü**

**Bilgisayar Mühendisliği Anabilimi Dalı**

**2024**

Parkinson hastalığı, hareketlerin kontrolünde ve koordinasyonunda rol oynayan dopamini üreten beyin hücrelerinin kaybı nedeniyle ortaya çıkan nörodejeneratif bir hastalıktır. Parkinson Hastalığının nedeni tam olarak bilinmediğinden bu hastalığın tanısına yönelik spesifik bir test de bulunmamaktadır. Ancak kas kontrolü kaybının neden olduğu, daha fazla izlenebilen ve analiz edilebilen semptomlar vardır. Ne yazık ki, bu tür analizlere yönelik prosedürlerin çoğu pahalıdır, verimsizdir ve zayıf doğruluk sağlarken gelişmiş ekipman gerektirir. Makine öğreniminin devreye girdiği yer burasıdır. Büyük verileri analiz etme ve insan gözlemcilerin göremeyeceği ince kalıpları tespit etme yeteneği, onu daha doğru Parkinson Hastalığı tanımlaması sağlayabilecek daha hızlı bir alternatif haline getiriyor. Bu çalışmada, Parkinson hastalığının en erken belirtilerinden biri olan el ve parmaklardaki titremelerin sapsmalarına neden olduğu el yazısı görüntüleri kullanılarak Parkinson Hastalığı tespiti yapılmaktadır. Bu amaçla transfer öğrenme uygulanarak derin öğrenme modelinden yararlanılmıştır. Deneyler için 37 Parkinson hastası ve 38 kontrol bireyine ait 8 farklı el yazısı örneğini içeren PaHaW veri seti kullanılmıştır. Derin öğrenme modellerinin yüksek veri gereksinimi nedeniyle, orijinal veri kümesine hem döndürme, çevirme ve konturlar gibi geleneksel veri artırma yöntemleri hem de Aşamalı Büyüyen Üretici Çekişmeli Ağ (PGAN) ile yeni veriler üretilmiştir. Üretilen bu verilerle yeni veri kombinleri oluşturulmuş ve bu sayede derin öğrenme modellerinin performansı önemli ölçüde artırılmıştır. ImageNet ve MNIST veri setleri ile önceden eğitilen probleme AlexNet, EfficientNet-B0, GoogleNet ve ResNet50 modellerinin uyarlanması ve transfer öğrenmenin uygulanmasıyla hem PaHaW verileri hem geleneksel yöntemlerle üretilen veriler hem de PGAN ile üretilen verilerin kombini kullanılarak %98,97 doğrulukla en iyi sonuç elde edilmiştir.

**ANAHTAR KELİMELER:** Parkinson Hastalığı, Derin Öğrenme, Transfer Öğrenme, Veri Artırma, El Yazısı Görüntüleri



# ABSTRACT

**Ecem ZORA**

## **INVESTIGATION OF THE EFFECTIVENESS OF TRANSFER LEARNING TECHNIQUE IN DIAGNOSIS OF PARKINSON'S DISEASE USING DEEP LEARNING MODELS**

**Baskent University Institute of Science and Technology**

**Department of Computer Engineering**

**2024**

Parkinson's disease is a neurodegenerative disease that occurs due to the loss of brain cells that produce dopamine, which plays a role in the control and coordination of movements. Since the cause of Parkinson's Disease is not fully known, there is no specific test for the diagnosis of this disease. However, there are symptoms caused by loss of muscle control that can be further monitored and analyzed. Unfortunately, most procedures for such analysis are expensive, inefficient, and require advanced equipment while providing poor accuracy. This is where machine learning comes into play. Its ability to analyze big data and detect subtle patterns invisible to human observers makes it a faster alternative that can provide more accurate Parkinson's Disease identification. In this study, Parkinson's Disease is detected using handwriting images where tremors in the hands and fingers cause deviations, which is one of the earliest symptoms of Parkinson's disease. For this purpose, deep learning model was used by applying transfer learning. The PaHaW dataset, which includes 8 different handwriting samples from 37 Parkinson's patients and 38 control individuals, was used for the experiments. Due to the high data requirement of deep learning models, new data was generated by applying both traditional data augmentation methods such as rotation, translation and contours, and Progressive Growing of Generative Adversarial Network (PGAN) to the original dataset. With this data, new data combinations were created and thus the performances of deep learning models were significantly increased. By adapting AlexNet, EfficientNet-B0, GoogleNet and ResNet50 models to the problem pre-trained with ImageNet and MNIST datasets and applying transfer learning, the best result with 98,97% accuracy was obtained by using a combination of both PaHaW data, data produced by traditional methods and data produced by PGAN.

**KEYWORDS:** Parkinson's Disease, Deep Learning, Transfer Learning, Data Augmentation, Handwriting Images



# İÇİNDEKİLER

TEŞEKKÜR .....	i
ÖZET .....	ii
ABSTRACT.....	iv
İÇİNDEKİLER .....	vi
TABLolar LİSTESİ.....	viii
ŞEKİLLER LİSTESİ .....	ix
SİMGELER VE KISALTMALAR LİSTESİ .....	xi
1.GİRİŞ.....	1
1.1 Parkinson Hastalığının Belirtileri .....	2
1.1.1 Motor belirtiler .....	2
a) Titreme .....	2
b) Küçük el yazısı.....	3
c) Hareketlerde yavaşlama .....	3
d) Sertlik .....	3
e) Duruş bozuklukları.....	4
1.1.2 Motor olmayan belirtiler.....	4
1.2 Parkinson Hastalığının Tanısı ve Tedavisi.....	5
1.3 Tezin Amacı.....	5
1.4 Parkinson Hastalığının Teşhisi ile İlgili Literatür .....	6
1.5 El Yazısı Çizimleri ile Parkinson Hastalığının Teşhisi ile İlgili Literatür.....	7
1.6 Organizasyon.....	11
2. KULLANILAN ARAÇLAR VE YÖNTEMLER .....	12
2.1 Kullanılan Veri Seti .....	12
2.2 Veri Artırma.....	14
2.2.1 Geleneksel veri artırma yöntemleri.....	14
2.2.2 Aşamalı Büyüyen Üretici Çekişmeli Ağ (PGAN - Progressive Growing of Generative Adversarial Networks) .....	14
2.3 Derin Öğrenme .....	16
2.3.1 Transfer öğrenme .....	17
a) AlexNet .....	19
b) EfficientNet-B0 .....	20
c) GoogleNet.....	21
d) ResNet50.....	22
3. DENEYLER .....	26

<b>3.1 Veri Setinin Hazırlanması.....</b>	<b>26</b>
<b>3.2 AlexNet Sonuçları.....</b>	<b>28</b>
<b>3.3 EfficientNet-B0 Sonuçları .....</b>	<b>31</b>
<b>3.4 GoogleNet Sonuçları .....</b>	<b>33</b>
<b>3.5 ResNet50 Sonuçları.....</b>	<b>35</b>
<b>3.6 Modellerin Performanslarının Karşılaştırılması.....</b>	<b>37</b>
<b>4. SONUÇ.....</b>	<b>39</b>
<b>KAYNAKLAR .....</b>	<b>40</b>



## TABLULAR LİSTESİ

	<b>Sayfa</b>
Tablo 1.1 Parkinson hastalığının teşhisi için yapılan çalışmaların özeti.....	8
Tablo 2.1. Kullanılan veri seti hakkında genel bilgiler.....	12
Tablo 2.2. Bu çalışmada kullanılan modeller ve parametreleri.....	18
Tablo 3.1. Bu çalışmada kullanılan veri setleri ve veri sayıları.....	28
Tablo 3.2. MNIST veri seti için AlexNet modelinin hiper parametreleri.....	29
Tablo 3.3. AlexNet modelinin hiper parametreleri.....	30
Tablo 3.4. AlexNet ile elde edilmiş sonuçlar.....	30
Tablo 3.5. MNIST veri seti için EfficientNet modelinin hiper parametreleri.....	31
Tablo 3.6. EfficientNet-B0 modelinin hiper parametreleri.....	32
Tablo 3.7. EfficientNet-B0 ile elde edilmiş sonuçlar.....	32
Tablo 3.8. MNIST veri seti için GoogleNet modelinin hiper parametreleri .....	33
Tablo 3.9. GoogleNet modelinin hiper parametreleri.....	33
Tablo 3.10. GoogleNet ile elde edilmiş sonuçlar.....	34
Tablo 3.11. MNIST veri seti için ResNet50 modelinin hiper parametreleri.....	35
Tablo 3.12. ResNet50 modelinin hiper parametreleri.....	35
Tablo 3.13. ResNet50 ile elde edilmiş sonuçlar.....	36

# ŞEKİLLER LİSTESİ

	Sayfa
Şekil 1.1. Parkinson hastalarında görülen yaygın motor belirtileri ([5]'ten değiştirilerek).....	2
Şekil 2.1. Önceden doldurulmuş el yazısı şablonu [22].....	13
Şekil 2.2. (a), (b), (c) kontrol bireylere ait, (d), (e), (f) ise Parkinson hastalarına ait örnek görseller.....	13
Şekil 2.3. Örnek bir GAN mimarisi ([23]'den değiştirilerek).....	14
Şekil 2.4. PGAN mimarisi ([25]'ten değiştirilerek).....	15
Şekil 2.5. Aşamalı olarak PGAN eğitim süreci ([23]'ten değiştirilerek).....	15
Şekil 2.6. Yapay zekanın alt dalları.....	16
Şekil 2.7. Makine öğrenmesi ve derin öğrenme arasındaki mimari fark ([28]'den değiştirilerek).....	17
Şekil 2.8. CNN mimarisi ve katmanları ([30]'dan değiştirilerek).....	17
Şekil 2.9. . Makine öğrenmesi ve transfer öğrenme arasındaki fark ([31]'den değiştirilerek).....	18
Şekil 2.10. ImageNet'teki memeli alt ağacı ve araç alt ağacı için rastgele örneklenmiş 9 görüntü([34]'ten değiştirilerek).....	19
Şekil 2.11. AlexNet mimarisi ([35]'ten değiştirilerek).....	20
Şekil 2.12. EfficientNet-B0 mimarisi ([37]'den değiştirilerek).....	20
Şekil 2.13. GoogleNet başlangıç modülü.....	21
Şekil 2.14. GoogleNet mimarisi.....	22
Şekil 2.15. ResNet mimarisi.....	23
Şekil 2.16. Farklı ResNet katman mimarileri.....	24
Şekil 2.17. Karışıklık matrisi.....	24
Şekil 3.1. Geleneksel veri artırma yöntemleriyle elde edilmiş görüntülerin Birkaçı.....	26

Şekil 3.2. PGAN ile kontrol bireylere ait verilerden üretilmiş görüntülerin birkaçı.....	27
Şekil 3.3. PGAN ile Parkinson hastası bireylere ait verilerden üretilmiş görüntülerin birkaçı.....	28
Şekil 3.4. MNIST veri seti ([41]'den değiştirilerek).....	29
Şekil 3.5. AlexNet ile veri setlerine göre elde edilmiş doğruluk değerleri.....	31
Şekil 3.6. EfficientNet-B0 ile veri setlerine göre elde edilmiş doğruluk değerleri.....	33
Şekil 3.7. GoogleNet ile veri setlerine göre elde edilmiş doğruluk değerleri.....	34
Şekil 3.8. ResNet50 ile veri setlerine göre elde edilmiş doğruluk değerleri.....	36
Şekil 3.9. Uygulanan tüm modellerin veri setlerine göre başarımları.....	37

## SİMGELER VE KISALTMALAR LİSTESİ

AB	Ada Boosting
CNN	Convolutional Neural Network
DT	Decision Tree (Karar Ağacı)
EEG	Elektroensefalografi
FN	False Negative
FP	False Positive
GAN	Generative Adversarial Networks
GB	Gradient Boosting
KNN	K-Nearest Neighbors (K- En Yakın Komşu)
LR	Logistic Regression
MLP	Multi-Layer Perceptron
MNIST	Modified National Institute of Standards and Technology
MR	Manyetik Rezonans
NB	Naïve Bayes
PaHaW	Parkinson's Disease Handwriting
PGAN	Progressive Growing of Generative Adversarial Networks
RF	Random Forest (Rastgele Orman)
SVM	Support Vector Machine (Destek Vektör Makinesi)
TN	True Negative
TP	True Positive

# 1.GİRİŞ

Parkinson hastalığı, beynin substantia nigra adı verilen belirli bir bölgesindeki ağırlıklı olarak dopamin üreten nöronları etkileyen nörodejeneratif bir bozukluktur. Dopamin, beyinde üretilen ve beyindeki sinir hücreleri ile beyin ve vücudun geri kalanı arasında mesajlar iletmektedir.

Parkinson hastalığı, endişe verici şekilde günden güne artmaktadır. Dünya çapında 10 milyondan fazla insan Parkinson hastalığıyla yaşamaktadır. Türkiye Parkinson Hastalığı Derneği'ne göre Türkiye'de şu anda yaklaşık 150 bin Parkinson hastası olduğu düşünülmektedir [1]. 2022 yılında Parkinson Vakfı tarafından yapılan bir araştırma, Amerika'da her yıl yaklaşık olarak 90 bin kişiye Parkinson hastalığı tanısı konulduğunu açıklamıştır. Bundan önceki araştırmalarda tahmin edilen her yıl yaklaşık olarak 60 bin Parkinson hastalığı tanısı oranına göre %50'lik bir artış olmuştur [2].

Parkinson hastalığının görülme sıklığı yaşla birlikte artmaktadır, fakat Parkinson hastalığı tanısı %4 oranında 50 yaşından önce konulmaktadır. Erkeklerde tanı her yaştaki kadınlara göre 1,5 kat daha fazla konmaktadır [3]. Yapılan araştırmalara göre, 2030 yılına kadar Parkinson hastalığının 2 katına çıkması beklenmektedir.

Parkinson hastalığının sebebi tam olarak bilinmemektedir, fakat bilim insanları Parkinson hastalığının nedeninin genetik ve çevresel faktörlerin birleşimi olduğuna inanmaktadır [4]. Parkinson hastalığına sahip kişiler, beyinde dopamin kaybının yanı sıra, aynı semptomları göstermese de bazı ortak semptomlar bulunmaktadır. Parkinson vakalarının yaklaşık %10-%15'ine genetik sebep olmaktadır.

Bilim insanları ayrıca Parkinson hastalığının gelişme riskini azaltabilecek faktörlerin de bulunduğunu açıklamışlardır. Kafein içeren çay ve kahve tüketimini azaltmak, erkeklerde ürik asit seviyesinin normal değerinin üstünde olması, D vitamini düzeyinin yüksek olması, erken yaşlarda fiziksel aktiviteler yapmak bu faktörlerdendir.

## 1.1 Parkinson Hastalığının Belirtileri

Parkinson hastalığı belirtileri kişiden kişiye değişmektedir. Beyin, kaslara hareket eylemini yapmasını söyleyen aktivasyon sinyalleri gönderdiğinde, dopamin gereken hücreleri kullanarak hareketleri düzenlemektedir. Dopamin eksikliğinden dolayı Parkinson hastalarında en iyi bilinen motor belirtiler kas kontrolü kaybından kaynaklandığından, Şekil 1.1’de gösterildiği gibi hareketlerde yavaşlama ve titreme gibi belirtilere sebep olmaktadır [5]. Hastalığın seviyesi ilerledikçe farklı belirtiler ortaya çıkmakta ve belirtilerin seviyesi artmaktadır.



Şekil 1.1. Parkinson hastalarında görülen yaygın motor belirtileri ([5]’ten değiştirilerek)

Hareket ve kas kontrolüne bağlı olmayan motor dışı belirtiler de bulunmaktadır. Ayağa kalkıldığında düşük tansiyon, mide ve bağırsak problemleri, depresyon, uyku bozukluğu, solunum problemleri, yorgunluk ve koku kaybı bu belirtilere örnektir.

### 1.1.1 Motor belirtiler

#### a) Titreme

Genellikle Parkinson hastalığının ilk motor belirtisidir. Tipik Parkinson hastalığı titremesi dinlenme sırasında ortaya çıkmaktadır. Uyku sırasında veya vücut aktif olarak kullanıldığında titreme azalabilmektedir. Otururken veya yürürken eller titreyebilir, fakat

biriyle el sıkışırken titreme daha az fark edilebilmektedir. Titreme, genellikle ellerde meydana gelmektedir. Fakat hastalığın ilerleyen dönemlerinde titreme alt dudakta, çenede, bacaklarda veya vücudun diğer kısımlarında da ortaya çıkabilmektedir. Bu titremeler tıraş olmak, giyinmek veya yazı yazmak gibi günlük rutin aktiviteleri olumsuz yönde etkilemektedir. Bu belirti hastalığın erken evrelerinde vücudun yalnızca bir tarafını etkilerken ilerleyen dönemlerde vücudun her iki tarafını da etkileyebilmektedir. Yorgunluk ve stres de titremeyi geçici olarak kötüleştirebilmektedir. Parkinson hastalığına sahip yaklaşık %70-%90 hasta hastalığının bir noktasında titreme yaşamaktadır.

#### **b) Küçük el yazısı**

Yaşlandıkça özellikle görme bozukluğuna bağlı olarak el yazısı değişebilmektedir. Fakat mikrografi adı verilen küçük, sıkışık el yazısı Parkinson hastalığının karakteristik bir özelliğidir ve hastalığın erken belirtilerinden biridir. Kelimelerin genellikle küçük ve sıkışık yazılmasının yanı sıra, yazmaya devam ettikçe el yazısının boyutu giderek küçülebilmektedir. Hareketlerde yavaşlama, titreme ve sertlik gibi belirtiler yazmayı da etkilemektedir. Özellikle imzalarda titreme, aşağı doğru kayma ve sıkışıklık net gözlemlenebilmektedir.

#### **c) Hareketlerde yavaşlama**

Rastgele veya istemli hareketlerde, hareket esnasında yavaşlama meydana gelmektedir. Ayağa kalkarken beklenenden daha uzun sürmesi gibi hareketleri başlatmada zorluk, göz kırpmada azalma, yürürken ayakların karıştırılması, kalem tutmakta ve yazı yazmakta zorluk yaşanması buna örnektir. Bu belirtiler günlük yaşamı zorlaştırmaktadır. Çoğu insan bu belirtiyeye sahip olduğunun farkına varamamaktadır.

#### **d) Sertlik**

Parkinson hastalığının ilerleyen dönemlerinde daha çok ortaya çıkan bir belirti olmasına rağmen hastalığın erken dönemlerinde de nadiren görülebilmektedir. Kollarda ve bacaklarda normal yaşlanmadan kaynaklanan sertliğin ötesinde bir sertlik görülmektedir. Bu sertlik vücudun bir tarafında veya her iki tarafında da olabilmektedir. Bu sertlikten etkilenen kaslarda veya eklemlerde ağrıya yol açabilmektedir. Sertlik, uyku kalitesini de olumsuz etkileyebilmektedir. Sertlik, hareketlerde yavaşlama ve titremeden sonra bu hastalığın teşhisindeki önemli belirtilerden biridir.

### **e) Duruş bozuklukları**

Parkinson hastalığı, otomatik aktivitelerin kontrolünü etkilediğinden beynin dik durmaya yönelik otomatik hatırlatmaları olmadan duruş değişiklikleri meydana gelebilmektedir. Bu değişiklikler, kamburlaşmaya, omuzların çökmesine, bel kavisinin azalarak başın veya tüm vücudun öne eğilmesine neden olabilmektedir. Kas sertliği, titreme, hareketlerde yavaşlama ve uzun süre aynı pozisyonda kalmak da duruş bozukluklarına yol açabilmektedir. Duruş bozukluğundan dolayı esneklik kaybı olmaktadır ve bu kayıp, giyinmek veya sandalyeden kalkmak gibi günlük hareketleri yapmayı zorlaştırmaktadır. Bunun yanı sıra kötü duruş dengenin bozulmasına ve bu bozukluktan kaynaklanan düşmelere neden olabilmektedir. Bu belirti genellikle hastalığın ilerleyen dönemlerinde görülmektedir.

#### **1.1.2 Motor olmayan belirtiler**

Hareket ve kas kontrolüyle bağlı olmayan birçok belirti bulunmaktadır. Parkinson hastaları üzerinde en az motor belirtiler kadar olumsuz etkilere sebep olabilmektedir. En sık karşılaşılan belirtiler kaygı, koku kaybı, kabızlık, depresyon ve uyku bozukluğudur. Bu belirtilerin çoğu tespit edildiğinde tedavi edilebilmektedir. Parkinson hastalığı, kişileri duygusal olarak da etkileyebilmektedir [6].

Parkinson hastaları, Parkinson hastalığına sahip olmayan kişilere göre çok daha fazla depresyon ve kaygı yaşayabilmektedir. Fakat sürekli kaygı halinde veya sıklıkla depresyon durumunda olan kişilerde farklı problemler olabilmektedir.

Parkinson hastalarında dikkat dağılması ve düzensizlik hissi bilişsel bozukluklar görülebilmektedir. Birden fazla kişiyle sohbet ederken sohbete odaklanmakta problem yaşamaktadırlar. Tek başına sorumluluk almaları veya bir durum karşısında seçim yapmaları gerektiğinde bunalmış hissedebilmektedirler. Bunun yanı sıra, konuşurken kelime seçmekte veya bazı bilgileri hatırlamakta zorlanabilmektedirler.

Yutma güçlüğü, mide bulantısı ve kabızlık Parkinson hastalığının en yaygın motor olmayan belirtilerindendir. Doktorlar bu belirtilerin sebebinin iki farklı durumdan kaynaklandığını belirtmektedir. Bunlardan ilki, sertliğe ve hareketlerde yavaşlamaya sebep olan beyindeki değişiklikler, yutma ve sindirim sistemiyle ilgili kasları da etkilemektedir. İkincisi ise Parkinson hastalığı direkt olarak sindirim sistemini kapsayan sinirleri de etkileyebilmektedir.

Hastalığın ilerleyen dönemlerinde, Parkinson hastalarında demans adı verilen daha önemli veya ciddi hafıza ve düşünme problemleri ortaya çıkabilmektedir. Bunun yanı sıra, Parkinson hastaları, ciddi kafa karışıklığından dolayı olmayan şeyleri görebilmekte veya doğru olmayan şeylere inanabilmektedir.

Doktorlar bu motor olmayan belirtilerin erken evrede değil daha çok ilerleyen evrelerde ortaya çıktığını düşünmektedir. Hastanın günlük yaşamını etkileyen kalıcı problemlere sebep olmaktadır.

Baş dönmesi, vertigo veya düşük kan basıncı, Parkinson hastalarında sıklıkla görülmektedir. Fakat sıklıkla görülmesine rağmen hastalığın ilerleyen dönemlerinde ortaya çıkmaktadır.

Koku kaybı, Parkinson hastalığının erken belirtilerinden biridir, fakat Parkinson hastalarının hepsinde bu belirti olmayabilir. Bu durumdan kaynaklı az bilinen bir belirti olduğundan doktorların Parkinson tanısı koymasını kolay olmamaktadır.

## **1.2 Parkinson Hastalığının Tanısı ve Tedavisi**

Parkinson hastalığını teşhis edebilecek spesifik bir test bulunmamaktadır. Beynin manyetik rezonans görüntülemesi (MR) veya kan çalışması gibi testler, Parkinson hastalığı tanısının konulmasına yardımcı olmaktadır [7]. Bu hastalığı teşhis eden kesin bir test olmadığından Parkinson hastalığının erken evrede teşhis edilmesi zor olabilmektedir.

Parkinson hastalığının belirtileri ve ilerleme hızı hastalarda farklılık göstermektedir. Bu hastalığın erken evrede belirtileri hafiftir. Parkinson hastalığı tanısının konulabilmesi için motor belirtilerden hareketlerde yavaşlama, titreme veya sertlikten bir veya daha fazlasının bulunması gerekmektedir.

Parkinson hastalığını iyileştirmek mümkün olmasa da erken tanı ile erken tedavi mümkün olabilmektedir. Erken tedavi, hastalığın ilerlemesini geciktirmeye yardımcı olmakta ve hastanın yaşam kalitesini artırmaktadır [8].

## **1.3 Tezin Amacı**

Bu tez çalışmasında hem Türkiye’de hem de dünyada hızla artan Parkinson hastalığının teşhisinde derin öğrenme modelleri ile transfer öğrenme tekniğinin etkinliğinin araştırılması amaçlanmıştır. Derin öğrenme modelleri daha fazla veri gerektirdiğinden farklı veri artırma yöntemleri ile yeni veriler üretilmiş ve hem farklı modellerin hem de farklı veri kombinlerinin başarımı nasıl etkilediği karşılaştırılmıştır. Kullanılan veri artırma yöntemleri,

geleneksel yöntemler ve Aşamalı Büyüyen Üretici Çekişmeli Ağ (PGAN)'dır. Kullanılan derin öğrenme modelleri ise AlexNet, EfficientNet-B0, GoogleNet ve ResNet50 şeklindedir.

#### **1.4 Parkinson Hastalığının Teşhisi ile İlgili Literatür**

Parkinson hastalığını teşhis eden kesin bir test veya tetkik bulunmamaktadır. Hastalığın erken evrede teşhisi oldukça önemli olduğundan bu teşhisin bilgisayar ile yapılabilirliği birçok çalışmanın araştırma konusu olmaktadır. Bu çalışmalar en belirgin motor belirtilerin etkilediği el yazısı, çizim, konuşma ve yürüyüş üzerine yoğunlaşmaktadır. Hastalığın teşhisi için bilgisayar tabanlı sistemlerin kullanılmasının hem daha kesin hem de daha objektif olacağı düşünülmektedir. Araştırmacılar farklı cihazlar kullanarak farklı veriler üretebilmekte ve hastalığın teşhisi için farklı yöntemler kullanabilmektedir. Bu çalışmalarda, hastaların ses kayıtları, çizimleri, yürüyüşleri, EEG (Elektroensefalografi) görüntüleri veya MR (Manyetik Rezonans) görüntüleri kullanılmaktadır.

Literatürde Parkinson hastalığını ses kayıtlarından teşhis etmeyi amaçlayan çalışmalar bulunmaktadır. 2022 yılında Ketkar et al., teknik bilgisi olmayan kullanıcıları hedef alarak makine öğrenmesini tıp alanına kolay bir şekilde entegre etmek için çalışmışlardır. 754 özelliğe sahip 201 ses kaydı içeren bir veri seti kullanmışlardır. 4 farklı test senaryosu oluşturup her test senaryosu için makine öğrenmesi sınıflandırıcılarından Destek Vektör Makinası (SVM) ve Rastgele Orman (RF) algoritmalarını kullanarak model oluşturmuşlar ve en uygun modeli seçmişlerdir. SVM, 3 test senaryosunda en uygun model seçilirken, RF ise sadece 1 test senaryosunda en uygun model seçilmiştir. Sonuç olarak en yüksek doğruluğa %80,39 doğruluk ile SVM ulaşmıştır [9].

Bir diğer çalışmada ise Yadav, 23 Parkinson hastası ve 8 sağlıklı bireye ait 23 özelliğe sahip 197 ses kaydı içeren bir veri seti kullanarak Parkinson hastalığını teşhis etmeyi amaçlamıştır. Karar Ağacı (DT), K En Yakın Komşu (KNN), Rastgele Orman (RF), Torbalama (Bagging), Ayarlanabilir Artırma (AdaBoosting) ve Gradyan Artırma (GB) algoritmalarını kullanmıştır. DT %94,87 doğruluk ile Parkinson hastalığını teşhis etmiştir [10].

Parkinson hastalığını yürüyüş verilerini kullanarak teşhis etmeyi amaçlayan çalışmalar da bulunmaktadır. Li et al., Parkinson hastalarından ve sağlıklı bireylerden alınan yürüyüş verileri ile makine öğrenmesi yöntemlerini kullanarak Parkinson hastalarını sağlıklı bireylerden ayırmayı amaçlamıştır. 214'ü Parkinson hastası ve 92'si sağlıklı bireylerden oluşan, yürüyüş ölçümü olarak kuvvet sensörü içeren bir veri setini kullanmışlardır. Makine

öğrenmesi algoritmalarından Lojistik Regresyon (LR), SVM, DT ve KNN algoritmalarını kullanmış ve en yüksek doğruluğa %85 doğruluk ile SVM ulaşmıştır [11].

Bir başka çalışmada ise Ferreira et al., 63 Parkinson hastası ve 63 sağlıklı bireylerin kendi seçtikleri yürüme hızı sırasında elde edilen yürüyüş verilerini içeren veri setini kullanarak yürüyüş özelliklerine dayalı olarak Parkinson hastalığını teşhis etmek için farklı makine öğrenmesi algoritmalarını incelemiştir. Yaptıkları çalışmada Saf Bayes (NB), SVM, DT, RF, LR ve Çok Katmanlı Algılayıcı (MLP) algoritmalarını kullanmışlardır. NB, diğer algoritmalara kıyasla en yüksek doğruluk olan %84,6 doğruluk ile Parkinson hastalığını teşhis etmiştir [12].

Bir diğer çalışmada Aşuroğlu vd. Parkinson hastalarında giyilebilir sensör yardımıyla hareket değişikliklerini tespit etmeyi, kaydedilen verilerin sinyal çeşitliliği açısından analiz edilmesini ve hastalığın kişiselleştirilmiş bir profilinin belirlenmesini amaçlamışlardır. 93 Parkinson hastası ve 73 kontrol bireylerin yürüyüş sinyallerinden oluşan veri setini kullanmışlardır. Bu sinyaller, düz bir zeminde 2 dk yürürken kaydedilmiştir. Parkinson hastalığının semptomlarının ciddiyetini tahmin etmek amacıyla sayısal özellikler üzerinde regresyon analizi için Yerel Ağırlıklı Rastgele Orman (LWRF) adı verilen hibrit bir model sunmuşlar ve %99 başarıya ulaşmışlardır [13].

Pahuja et al. ise 73 Parkinson hastasının ve 59 sağlıklı bireyin EEG görüntüleri ile Parkinson hastalığını sınıflandırmayı amaçlamışlardır. Hastalığı teşhis edebilmek için derin öğrenme algoritmalarından Evrişimli Sinir Ağları (CNN) kullanıp %93,33 doğruluk elde etmişlerdir. Bunun yanı sıra veri setindeki verilerin dengesizliğinden dolayı modelin performansını değerlendirmek için doğruluğa ek olarak F1 puanını, geometrik ortalamasını, hassasiyetini ve özgüllüğünü de ölçmüşlerdir. Bu çalışmada elde edilen sonuçları motor veya motor olmayan belirtileri temel alan mevcut bazı Parkinson hastalığını sınıflandırma çalışmaları ile karşılaştırmışlardır [14].

## **1.5 El Yazısı Çizimleri ile Parkinson Hastalığının Teşhisi ile İlgili Literatür**

Parkinson hastalığının erken evrede en belirgin belirtilerinden biri ellerde titremedir. Yapılan çalışmalarda araştırmacılar, bireylerin klinik maliyetlerini etkili bir şekilde azaltmak amacıyla Parkinson hastalarının el yazısı çizim görüntülerini kullanarak yüksek doğrulukla Parkinson hastalığının teşhisini amaçlamışlardır.

Tablo 1.1 Parkinson hastalığının teşhisi için yapılan çalışmaların özeti

Çalışma Adı	Veri Seti İçeriği	Kişi Sayısı	Kullanılan Yöntem	Doğruluk
Ketkar & Gawade [9]	Konuşma veri seti	23 Parkinson hastası, 8 sağlıklı birey	SVM, RF	SVM ile %80,39
Yadav [10]	Konuşma veri seti	23 Parkinson hastası, 8 sağlıklı birey	DT, KNN, RF, Bagging, AB, GB	DT ile %94,87
Li & Li [11]	Yürüyüş veri seti	214 Parkinson hastası, 92 sağlıklı birey	LR, SVM, DT, KNN	SVM ile %85
Ferreira vd. [12]	Yürüyüş veri seti	63 Parkinson hastası, 63 sağlıklı birey	NB, SVM, DT, RF, LR, MLP	NB ile %84,6
Aşuroğlu vd. [13]	Yürüyüş veri seti	93 Parkinson hastası, 73 kontrol birey	LWRF	%99
Pahuja & Prasad [14]	EEG veri seti	73 Parkinson hastası, 59 sağlıklı birey	CNN	%93,33
Pereira vd. [15]	Spiral ve kıvrım veri seti	14 Parkinson hastası, 21 sağlıklı birey	CNN	%80,19
Das vd. [16]	Spiral ve dalga veri seti, spiral, küp ve üçgen veri seti	27 Parkinson hastası, 28 sağlıklı birey & 10 Parkinson hastası, 10 sağlıklı birey	KNN, SVM, RF, MLP, NB	RF ile %79,7 (Veri seti 1 için) SVM ile %97,8 (Veri seti 2 için)
Khatamino vd. [17]	Spiral veri seti	57 Parkinson hastası, 15 sağlıklı birey	CNN	%88,89
Li vd. [18]	Spiral veri seti	37 Parkinson hastası, 38 sağlıklı birey	VGG16, AlexNet, CC-Net	CC-Net ile %89,3
Alissa vd. [19]	Beşgen ve küp veri seti	58 Parkinson hastası, 29 sağlıklı birey	CNN	%93,53
Naseer vd. [20]	Spiral ve el yazısı çizimleri veri seti	37 Parkinson hastası, 38 sağlıklı birey	AlexNet	%98,28

Pereira et al., Parkinson hastalığı ile ilgili araştırmalarda yardımcı olması açısından muayene sırasında bilgi çıkarabilen bir dizi sensörden oluşan akıllı bir kalem aracılığıyla yeni bir veri seti oluşturmayı ve CNN algoritmasını kullanarak Parkinson hastalığını teşhis etmeyi amaçlamışlardır. 14 Parkinson hastasının ve 21 sağlıklı bireyin spiral ve kıvrım

çizimlerini içeren bir veri seti oluşturmuşlardır. Bu veri setini spiral ve kıvrım olarak ikiye ayırıp farklı görüntü çözünürlükleri ile ikisine de CNN algoritmasını ayrı ayrı uygulamışlar ve ImageNet kullanarak %80,19 doğruluk ile Parkinson hastalığını teşhis etmişlerdir [15].

Das et al., görüntü işleme ve makine öğrenmesi tekniklerini kullanarak Parkinson hastalığını erken teşhis eden hibrit füzyon tabanlı bir yaklaşım önermeyi amaçlamışlardır. Bu çalışmada, 2 farklı veri seti üzerinde Ayrık Dalgacık Dönüşümü (DWT) katsayılarını ve Yönlü Gradyanlar Histogramu (HOG) özelliklerinin birleşimini kullanmışlardır. İlk veri seti, 27 Parkinson hastasının 51 spiral ve 51 dalga çizimlerini ve 28 sağlıklı bireyin 51 spiral ve 51 dalga çizimlerini, ikinci veri seti ise 10 Parkinson hastasının 54 spiral, 54 küp ve 58 üçgen çizimlerini ve 10 sağlıklı bireyin 54 spiral, 54 küp ve 58 üçgen çizimlerini içermektedir. Her iki veri seti için de ayrı ayrı makine öğrenmesi algoritmalarından KNN, SVM, RF, MLP ve NB'i kullanmışlardır. İlk veri setinde %79,7 doğruluk ile RF, ikinci veri setinde ise %97,8 doğruluk ile SVM Parkinson hastalığını teşhis etmiştir [16].

Khatamino et al., Parkinson hastalarının spiral çizimlerini içeren Statik Spiral Test'in (SST) yanı sıra Dinamik Spiral Test'i (DST) de içeren yeni bir veri seti sunmuşlardır. 57 Parkinson hastasının ve 15 sağlıklı bireyin grafik tablet kullanılarak oluşturulmuş spiral çizimlerini içermektedir. Veri setinin ilk testi klinik tanılarda çok yaygın kullanılan SST'dir. Bu testte ekranda 3 farklı spiral belirlemek ve hastalardan dijital kalemle takip etmeleri istenmektedir. Bu test ile hastanın motor işlevselliğine bakılabilmekte ve titreme düzeyi hesaplanabilmektedir. Veri setinin ikinci testi ise DST'dir. SST'den farklı spiral çizim ekranda sabit durmaz ve belirli zaman aralıklarında kaybolur. Bu şekilde çizimin Parkinson hastası tarafından hatırlanması zorlaştırılır. Sahip oldukları çizimlere baktıklarında çoğu hastanın spiralleri tam olarak takip edemediğini belirtmişlerdir. Veri setinin son testi ise Belirli Noktada Stabilite Testi'dir (BNST). Bu testte ise ekranda kırmızı bir nokta bulunur ve hastalardan o noktaya belli bir süre kalem ile basılı tutmaları istenir ve bu şekilde hastaların el titreme düzeyi ölçülebilmektedir. Sundukları veri setini kullanarak CNN tabanlı derin öğrenme sistemi önermişler ve önerdikleri derin öğrenme modelinin performansını değerlendirmek için K Katmanlı Çapraz Doğrulama ve Birini Dışarıda Bırakan Çapraz Doğrulama (LOOCV) tekniklerini kullanmışlardır. SST'yi içeren çizimler kullanıldığında %79,78 doğruluk, DST'yi içeren çizimler kullanıldığında ise %88,89 doğruluk elde etmişlerdir [17].

Bir başka çalışmada Li et al., Parkinson hastalığının teşhisini kolaylaştırmak ve yüksek doğrulukla teşhis etmek için spiral çizimin çeşitli özelliklerini incelemeyi ve el çizimine dayalı bir algoritma geliştirmeyi amaçlamışlardır. 37 Parkinson hastasının ve 38 sağlıklı bireyin daire, spiral ve kıvrım çizimlerinden oluşan HandPD veri setini ve 43 Parkinson hastasının ve 43 sağlıklı bireyin spiral çizimlerinden oluşan kendi veri setlerini kullanmışlardır. Kendi veri setindeki çizimlerin HandPD veri setindeki çizimlere göre Parkinson hastalarının ellerindeki titreşimi daha iyi gösterdiğini belirtmişler ve bu titreşimi dikkate alacak AlexNet yapısına dayalı olan bir Sürekli Evrişimli Ağ (CC-Net) mimarisi önermişlerdir. Hem kendi oluşturdukları veri seti için hem de HandPD veri seti için CC-Net, VGG16 ve AlexNet algoritmalarını kullanıp karşılaştırmışlardır. Kendi oluşturdukları veri seti AlexNet ile %81,5, VGG16 ile %84,8 ve CC-Net ile %89,3 doğruluk ile Parkinson hastalığını teşhis etmiştir [18].

Alissa et al., Parkinson hastalarını sağlıklı bireylerden ayırmak için CNN'i kullanarak hastanın hareketlerindeki sapmaları tespit etmeyi amaçlamışlardır. Bunun yanı sıra Parkinson hastalığını ayırt etmede hangi çizimin (beşgen ve küp) daha etkili olduğunu ve veri artırma tekniklerinin uygulanmasının sınıflandırma performansına etkisini incelemiştir. 58 Parkinson hastasının ve 29 sağlıklı bireyin küp ve beşgen çizimlerini içeren veri seti kullanmışlardır. Önceki çalışmalarda kullanılan veri setlerinin özelliklerini incelemişler ve çizim esnasında basıncın etkili olup olmadığını incelemeye karar vermişlerdir. Veri seti az sayıda çizim içerdiği için veri artırma tekniklerinden döndürme, yakınlaştırma ve yatay çevirmeyi uygulamışlardır. Basıncı olmadan ve gri tonlamalı beşgen çizimlerin CNN ile %93,53 doğruluk ile Parkinson hastalığını küp çizimlerinden daha iyi teşhis ettiğini göstermişlerdir [19].

Naseer et al., Parkinson hastalığını el yazısı görüntülerini kullanarak teşhis etmeyi amaçlamışlardır. Transfer öğrenme ve geleneksel veri artırma yöntemlerini içeren bir Derin CNN algoritması önermişlerdir. 37 Parkinson hastasının ve 38 sağlıklı bireyin dijital kalem kullanılarak çizilen 8 farklı el yazısı görüntülerini içeren PaHaW veri setini kullanmışlardır. Veri seti, yüzeydeki hareketin yanı sıra havadaki hareketi de içermektedir. Havadaki hareketin hastalığın teşhisini olumsuz yönde etkileyebileceği düşünüldüğünden havadaki hareket değerlerini görüntülerden kaldırıp veri setindeki görüntüleri artırmak için geleneksel veri artırma yöntemlerinden döndürme, çevirme, kontur ve keskinleştirmeyi kullanmışlardır. AlexNet algoritmasını ImageNet ve MNIST veri seti üzerinde eğitip transfer öğrenme ile

daha sonra eğitilmiş AlexNet'i PaHaW veri setini üzerinde kullanıp %98,28 doğruluğa ulaşmışlardır [20].

## **1.6 Organizasyon**

Tezin ilerleyen bölümleri şu şekilde organize edilmiştir: İkinci bölümde tezde kullanılan veri seti, veri artırma için kullanılan yöntemler ve kullanılan modellerin detaylandırıldığı KULLANILAN ARAÇLAR VE YÖNTEMLER bölümü bulunmaktadır. Üçüncü bölümde verilerin artırılması, modellerin elde edilen veri setlerine uygulanması ve elde edilen sonuçlar DENEYLER bölümünde bulunmaktadır. SONUÇ bölümünde ise tezin genel değerlendirmesi ve ileri zamanlarda yapılabilecek çalışmaların önerisi sunulmuştur.



## 2. KULLANILAN ARAÇLAR VE YÖNTEMLER


### 2.1 Kullanılan Veri Seti

Bu çalışmada Drotar et al. tarafından Çek Cumhuriyeti'nin Masaryk Üniversitesi ve St. Anne's Üniversite Hastanesi Birinci Nöroloji Bölümündeki Hareket Bozuklukları Merkezi ile iş birliği yapılarak elde edilen Parkinson Hastalığı El Yazısı Veritabanı (PaHaW) kullanılmıştır [21], [22]. Veri seti, 37 Parkinson hastasından ve 38 kontrol bireyden alınan el yazısı çizimlerinden oluşmaktadır. Kullanılan verilere ait bazı bilgiler Tablo 2.1'de gösterilmiştir.

Tablo 2.1. Kullanılan veri seti hakkında genel bilgiler.

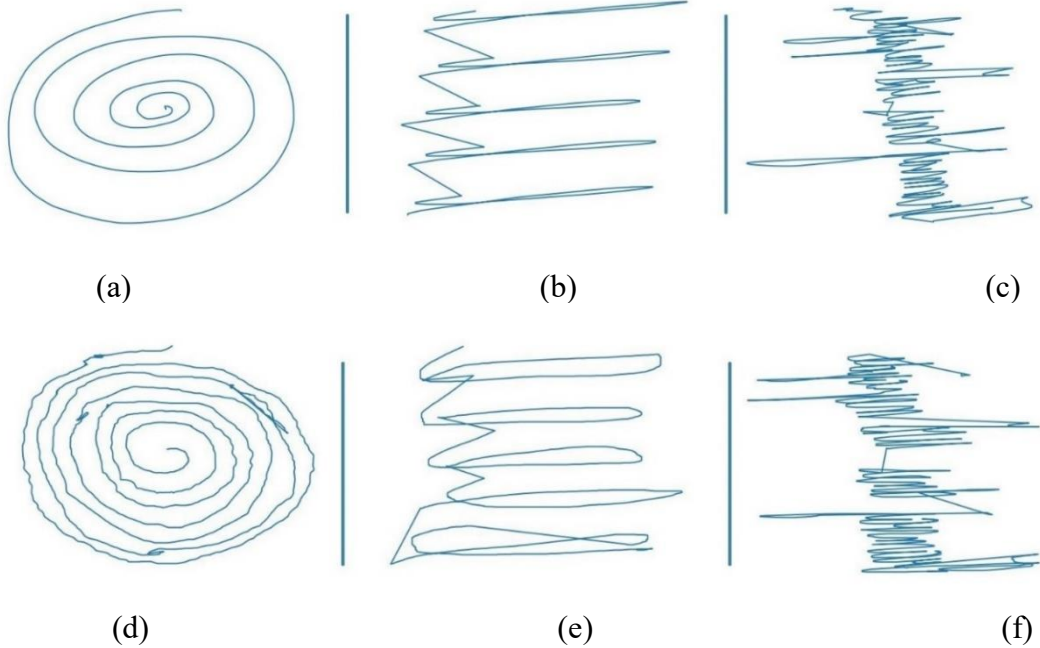
	<b>Parkinson Hastaları</b>	<b>Kontrol Bireyler</b>
<b>Kişi Sayısı</b>	37	38
<b>Kadınların Sayısı</b>	18	18
<b>Erkeklerin Sayısı</b>	19	20
<b>Yaş Aralığı</b>	36-90	44-92

Her bireye ilk olarak önceden doldurulmuş şablona göre normal bir hızda görevi tamamlaması istenmiştir. Daha sonra çizimler, Intuos 4M (Wacom) tablet üzerine koyulan boş bir kağıt şablon üzerinde özel mürekkepli bir kalem kullanılarak yapılmıştır. Yazı yüzeyine uygulanan basınç ve yazı yüzeyi üzerindeki hareketler kaydedilmiştir. Tablet, zaman damgası, x koordinatı, y koordinatı, basınç, eğim ve yükseklik gibi dinamik özellikleri yakalamıştır.



Şekil 2.1. Önceden doldurulmuş el yazısı şablonu [22]

Erişilen veri setindeki “.svc” uzantılı sinyaller zamana bağlı olarak tablet üzerindeki kalemin kaydedilen x ve y koordinat bilgileri kullanılarak grafikleştirilerek “.jpg” olarak kaydedilmiştir. Kaydedilen veri setinde 295 Parkinson hastasından ve 302 kontrol bireyden alınan toplamda 597 görsel bulunmaktadır. Kaydedilen verilere ait örnek görseller Şekil 2.2’de gösterilmiştir.



Şekil 2.2. (a), (b), (c) kontrol bireylere ait, (d), (e), (f) ise Parkinson hastalarına ait örnek görseller

Parkinson hastalarının çizimlerinde kontrol bireylerin çizimlerinin aksine kalemi tutarken titremeler ve yazarken sapmalar olduğu görülmektedir.

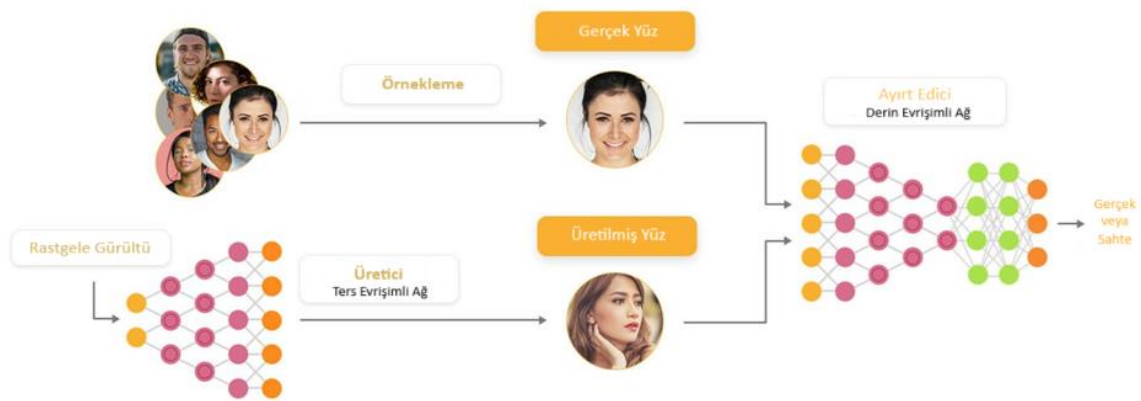
## 2.2 Veri Artırma

### 2.2.1 Geleneksel veri artırma yöntemleri

Derin öğrenme, daha karmaşık bir yapı olduğu için modeli eğitirken fazla veri kullanmak doğru tahminler yapabilme açısından önemlidir. Mevcut veri setindeki görsellere belirli açılarda döndürme, yatay veya dikey çevirme, içe veya dışa doğru ölçeklendirme, keskinleştirme ve kırpma gibi geleneksel veri artırma yöntemlerini uygulayarak yeni ve sentetik veri oluşturulmaktadır. Bu sayede modeli daha fazla veri ile eğiterek modelin aşırı öğrenmesine engel olunabilmektedir.

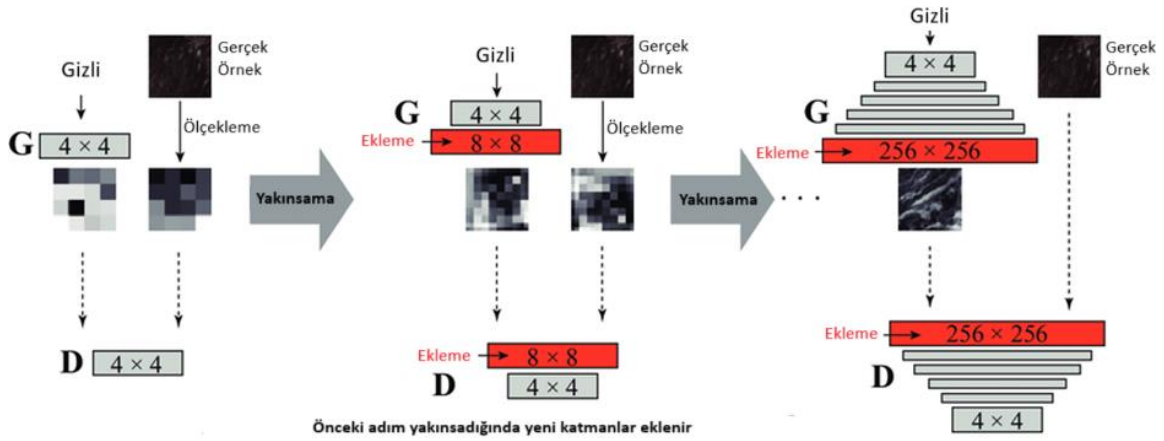
### 2.2.2 Aşamalı Büyüyen Üretici Çekişmeli Ağ (PGAN - Progressive Growing of Generative Adversarial Networks)

Derin öğrenme tabanlı üretici bir model olan Üretici Çekişmeli Ağ (GAN - Generative Adversarial Network) görüntü sentezi, restorasyonu, veri artırma ve benzeri alanlarda kullanılmaktadır. GAN, üretici ve ayırt edici ağların rekabet ve iş birliği ile veri örnekleri üretebilen derin öğrenme modelidir. Şekil 2.3'te örnek gösterildiği gibi üretici ağ, rastgele gürültüden gerçekçi veri örnekleri üretmeye çalışırken, ayırt edici ağ bu üretilen örnekleri gerçek veri örneklerinden ayırt etmeye çalışır. Bu iki ağ birlikte eğitilirken, üretici ağ gerçek veri örneklerine benzer görüntüler üretmeyi, ayırt edici ağ bu üretilen görüntüleri gerçek veri örneklerinden ayırt edebilmeyi öğrenir.

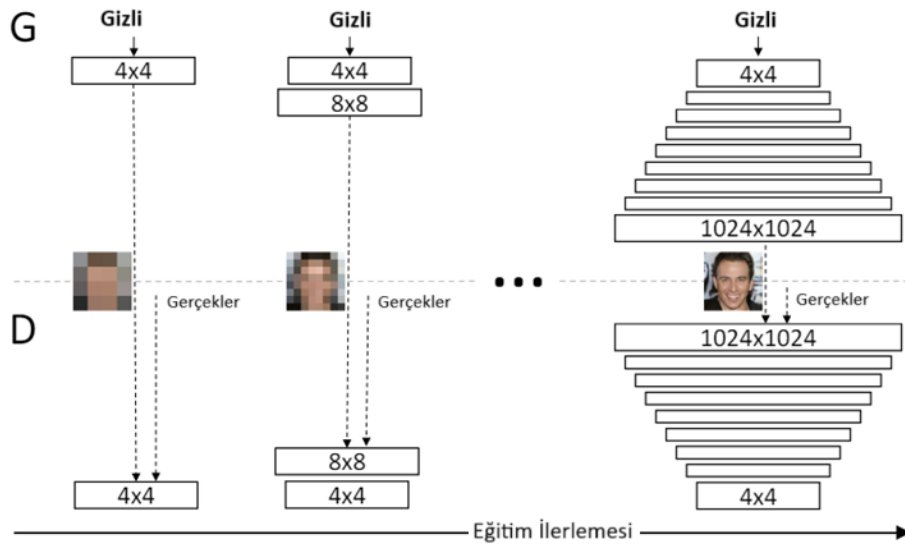


Şekil 2.3. Örnek bir GAN mimarisi ([23]'den değiştirilerek)

PGAN, GAN adlı üretici derin öğrenme modelinin bir türüdür. PGAN modeli, GAN modelinin temel fikrini korurken getirdiği yenilik üretici ve ayırt edici ağları aşamalı olarak büyütme süreciyle eğitmesidir [24].



Şekil 2.4. PGAN mimarisi ([25]'ten değiştirilerek)



Şekil 2.5. Aşamalı olarak PGAN eğitim süreci ([23]'ten değiştirilerek)

PGAN modeline ait eğitim süreci Şekil 2.5'te gösterilmektedir. G, Generator yani Üretici ağ, D, Discriminator yani Ayırt edici ağ temsil etmektedir. Her bir adımda algoritma kademeli olarak büyüyerek eğitime devam etmektedir. İlk adımda 4x4 görüntüler üretilirken, son adımda 1024x1024 görüntüler üretilmektedir [24].

### 2.3 Derin Öğrenme

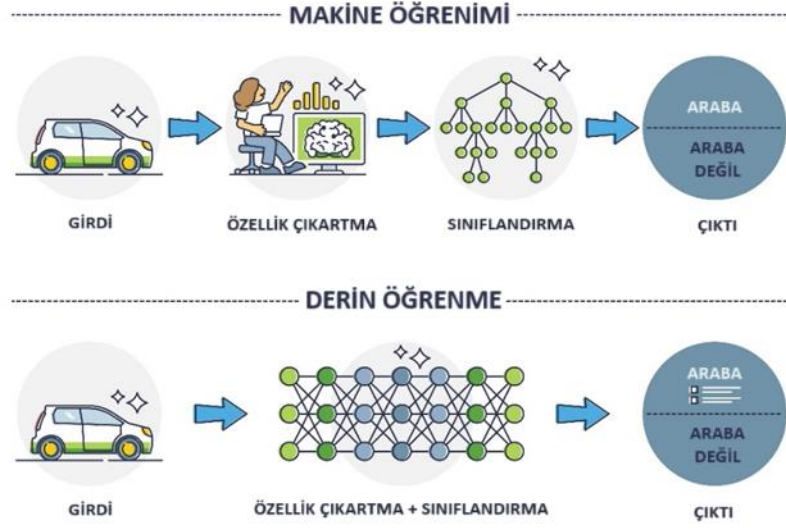
Makine öğrenmesi, bilgisayarların doğrudan programlanmadan, verilerde istatistiksel teknikler ve örüntü tanıma gerçekleştirerek verilen görevleri yerine getirmesini sağlayan bir yapay zekâ dalıdır [26]. Derin öğrenme, nesne tanıma, konuşma tanıma, doğal dil işleme gibi alanlarda çok katmanlı yapay sinir ağlarını kullanan bir yapay zekâ yöntemi olup Şekil 2.6’da gösterildiği gibi makine öğrenmesinin bir çeşididir ve geleneksel makine öğrenimi yöntemlerinden farklı olarak kodlanmış kurallar ile öğrenmek yerine; resim, video, ses ve metinlere ait verilerin simgelerinden otomatik olarak öğrenebilmektedir [27].



Şekil 2.6. Yapay zekanın alt dalları

Derin öğrenme, büyük ölçekli veriler ile esnek bir şekilde çalışabilmektedir. Veri sayısı çoğaldıkça sonuçlar o kadar kesin ve doğru olur. Derin öğrenmede kullanılan yapay zeka modelleri, girdi katmanı, gizli katmanlar ve çıkış katmanına sahiptir.


Makine öğrenmesinden mimari farkı Şekil 2.7’de gösterildiği gibi birden fazla gizli katmana sahip olmasıdır ve makine öğrenmesinde özellik çıkarımı ayrı bir adımken derin öğrenmede modeller özellik çıkarımını otomatik yapabilmektedir. Makine öğrenmesi, az veri seti ile çalışabilirken; derin öğrenme modelin aşırı öğrenmesini engellemek ve daha iyi sonuç vermek için daha fazla veriye ihtiyaç duymaktadır. Bu yüzden, derin öğrenme modellerinin eğitim süreci daha uzun olabilmektedir.



Şekil 2.7. Makine öğrenmesi ve derin öğrenme arasındaki mimari fark ([28]'den değiştirilerek)

### 2.3.1 Transfer öğrenme

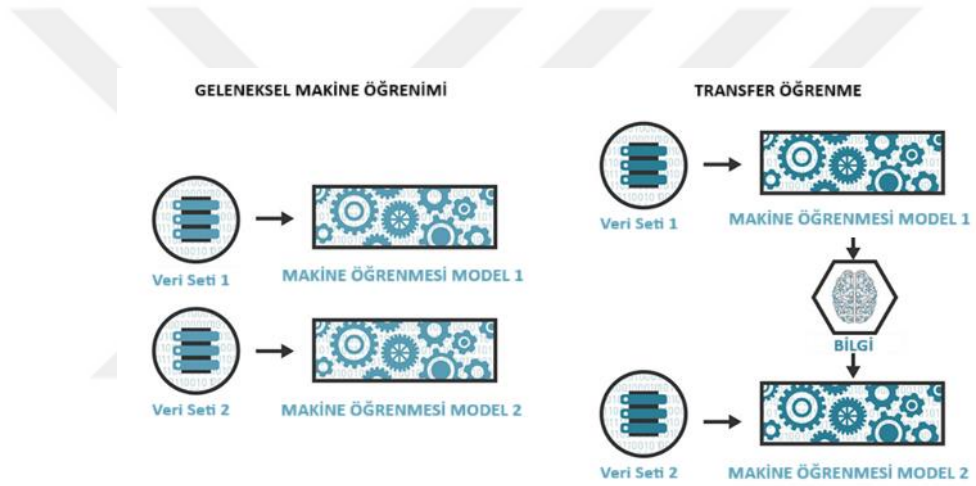
Derin sinir ağları, bilgisayarlı görme, konuşma tanıma, robotik ve örüntü tanıma gibi birçok yapay zeka uygulamasında yaygın olarak kullanılmaktadır. En çok tercih edilen şekli, çoklu evrişimli katmanlardan oluşan CNN'lerdir. CNN'ler, ileri beslemeli mimariye sahiptir ve tamamen bağlı katmanlara kıyasla daha iyi genelleme yapmaktadır [28]. Daha çok örüntü tanıma, sınıflandırma, sinyal işleme, tıp ve savunma sanayinde kullanılmaktadır. CNN'ler, Şekil 2.8'de gösterildiği gibi evrişim, havuzlama ve tam bağlı katmanlardan oluşmaktadır ve bu katmanların çeşitli şekillerde birleştirilmesi ile birbirinden farklı evrişimli ağ mimarileri ortaya çıkmaktadır.



Şekil 2.8. CNN mimarisi ve katmanları ([30]'dan değiştirilerek)

CNN'lerin ağır karmaşıklığı veya veri setinin büyüklüğü nedeniyle standart işlemciler üzerinde eğitilmesi oldukça zordur. Bu nedenle güçlü grafik işlemcilere ihtiyaç duyulmaktadır. Transfer öğrenme, uzun süren eğitimler sonucunda eğitilmiş bir modelden elde edilen özelliklerin, ağırlıkların vb. ikinci bir ilgili görevde yeniden kullanılmasıdır. Yeni bir model geliştirilerek veya önceden eğitilmiş bir model kullanılarak gerçekleştirilebilmektedir. Böylelikle daha az veri ile daha hızlı eğitilen ve başarıyı yüksek olan modeller elde edilmektedir.

Makine öğrenmesinden farkı ise Şekil 2.9'de gösterildiği gibi makine öğrenmesinde her bir görev için sıfırdan öğrenme yapılmasıdır. Hem veri setinin büyüklüğünden hem de modelin karmaşıklığından eğitim süresi çok uzun sürebilmektedir.



Şekil 2.9. Makine öğrenmesi ve transfer öğrenme arasındaki fark ([31]'den değiştirilerek)

Bu çalışmada kullanılan CNN'ler; ImageNet veri seti üzerinde eğitilmiş AlexNet, EfficientNet-B0, GoogleNet, ResNet50'dir. Söz konusu ağların katman, derinlik, parametre sayısı ve görüntü giriş boyutları Tablo 2.1'de verilmiştir [32].

Tablo 2.2. Bu çalışmada kullanılan modeller ve özellikleri

	AlexNet	EfficientNet-B0	GoogleNet	ResNet50
<b>Katman sayısı</b>	8	237	22	50
<b>Parametre sayısı</b>	60 milyon	5,3 milyon	4 milyon	25 milyon
<b>Giriş Boyutları</b>	224x224	224x224	224x224	224x224


### a) AlexNet

AlexNet, ilk olarak 2012 yılında ImageNet görsel tanıma yarışmasında kullanılmış ve bu yarışmada ilk sırayı almıştır [33]. ImageNet, büyük çaplı bir görsel veri tabanıdır ve genellikle derin öğrenme algoritmalarının eğitimi için kullanılmaktadır. 2009 yılında Jia Deng önderliğinde oluşturulmuş ve hala geliştirilmektedir. WordNet'te bulunan eş anlamlı kelime öbeklerini göstermek için kelime başına ortalama 1000 görüntü sağlanması hedeflenmiştir ve Şekil 2.10'da veri tabanından örnekler gösterilmiştir [34]. ImageNet veri seti, 1000 nesne sınıfını kapsamaktadır ve 1.281.167 eğitim verisi, 50.000 doğrulama verisi ve 100.000 test verisini içermektedir.



Şekil 2.10. ImageNet'teki memeli alt ağacı ve araç alt ağacı için rastgele örneklenmiş 9 görüntü ([34]'ten değiştirilerek)

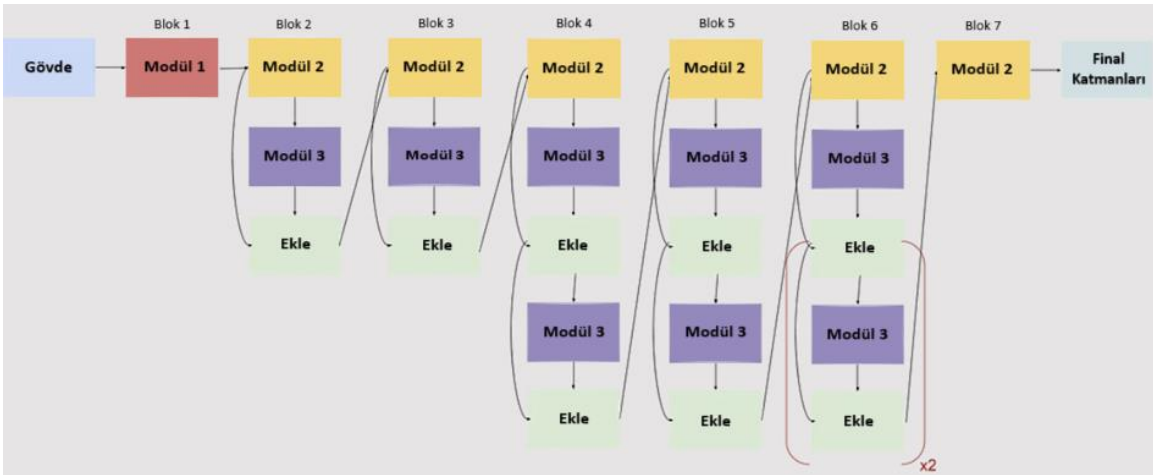
AlexNet mimarisi, Şekil 2.11'de gösterildiği gibi evrişimli, havuzlama ve tam bağlı katmanları içermektedir. Evrişimli katman, resimdeki özellikleri öğrenmek, havuzlama katmanı, resmi küçültmek ve özelliklerini daha iyi öğrenmek ve tam bağlı katman ise resimdeki özellikleri sınıflandırmak için kullanılmaktadır. AlexNet, daha hızlı olması sebebiyle aktivasyon fonksiyonu olarak Doğrultulmuş Lineer Birimi (ReLU) kullanmaktadır.



Şekil 2.11. AlexNet mimarisi ([35]'ten değiştirilerek)

### b) EfficientNet-B0

EfficientNet, 2019 yılında International Conference on Machine Learning (ICML)'de yayınlanan makalede ImageNet sınıflandırma probleminde 66M parametre hesaplama yükü ile %84,4'lük doğruluğa ulaşmıştır [36]. EfficientNet-B0'dan başlayıp B7'ye kadar numaralandırılmıştır. Model katmanları Şekil 2.12'de gösterilmiş modüllerden oluşmaktadır [37]. Bu modüllerin sayıları değiştirilerek farklı mimariler ortaya çıkmıştır. En küçük ve hafif modeli B0, 237 katmandan oluşmakta ve 5,3M parametre içermektedir. En büyük ve ağır modeli B7 ise 813 katmandan oluşmakta ve 66M parametre içermektedir.



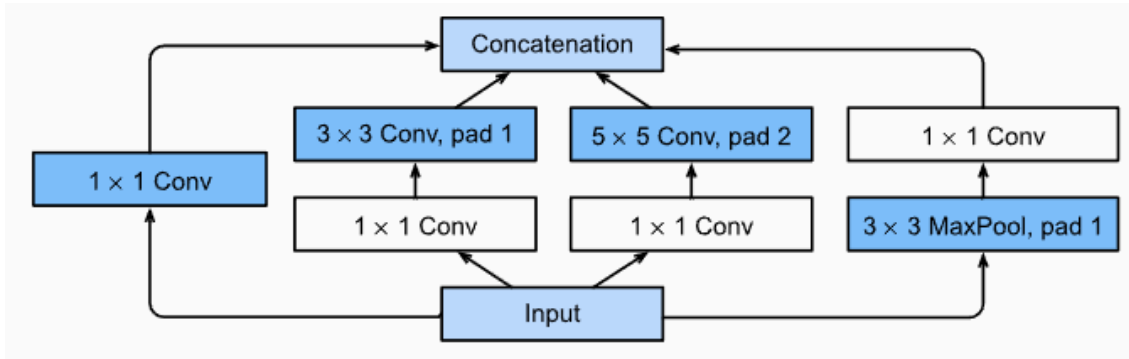
Şekil 2.12. EfficientNet-B0 mimarisi ([37]'den değiştirilerek)

Her modül, özellik çıkarma işleminin verimli olması için çok sayıda katman içermektedir. Birinci modül, evrişim ve normalizasyon katmanından oluşmaktadır. İkinci modül ise havuzlama ve evrişim katmanından, üçüncü modül, özellik çıkarmada verimli olan

birçok katmandan oluşmaktadır. Diğer modüller de aynı katmanlara sahiptir, fakat son modül, aşırı öğrenmeyi engelleyecek eksilmeler içermektedir.

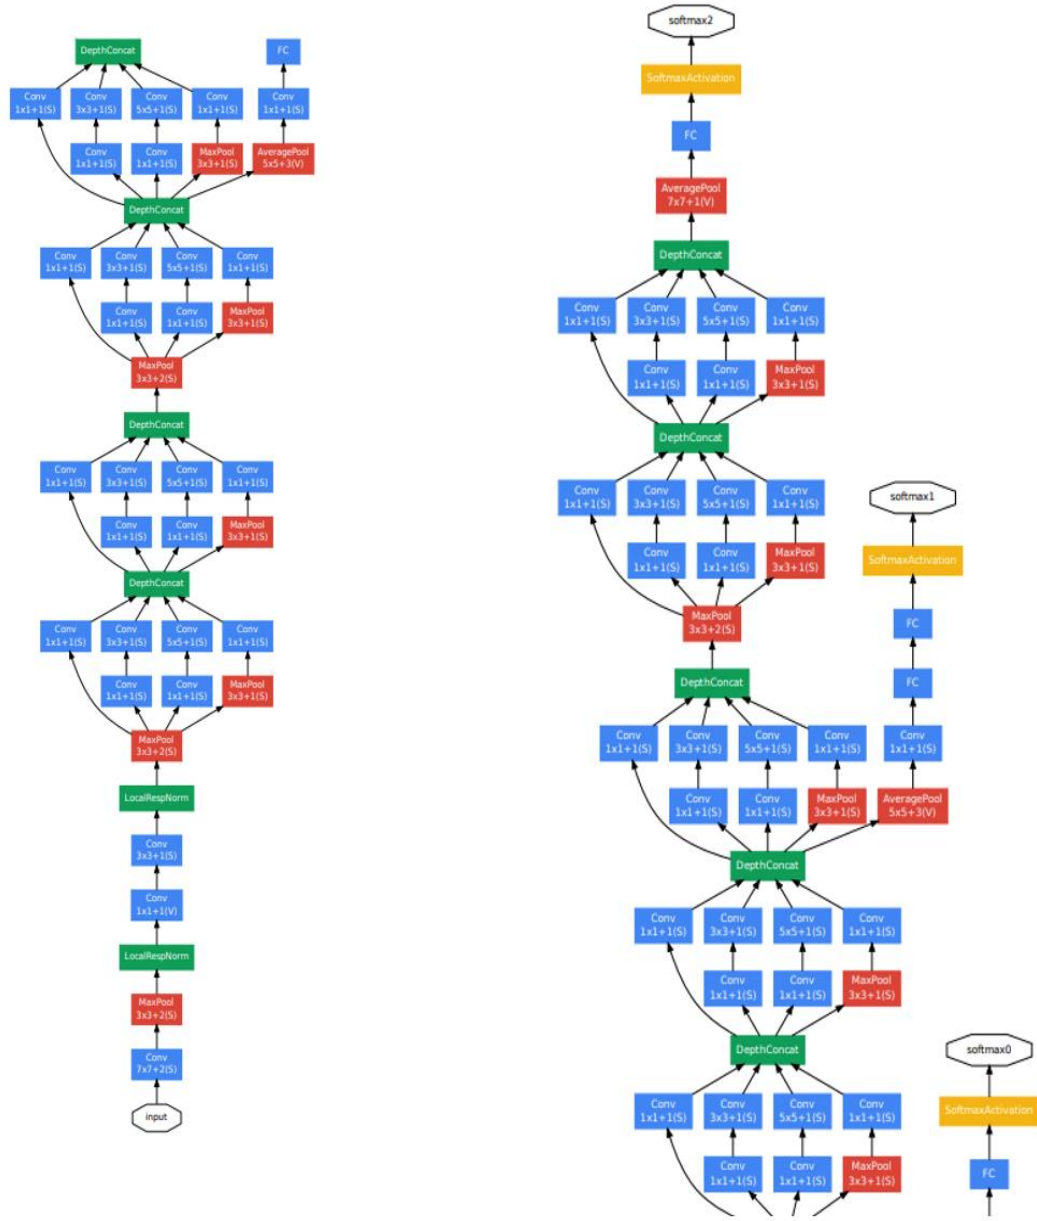
### c) GoogleNet

GoogleNet, 2014 yılında Google bünyesindeki araştırmalar tarafından geliştirilmiş ve ImageNet görsel veri tanıma yarışmasında birinci olmuştur. GoogleNet temel evrişim bloğuna “Başlangıç Bloğu” adı verilir. 2.13’te gösterilen başlangıç bloğu giriş katmanından sonra veriler katmanlara dağılır. Son olarak, her daldaki çıkışlar kanal boyutu boyunca birleştirilir ve bloğun çıkışını oluşturur [38].



Şekil 2.13. GoogleNet başlangıç modülü

GoogleNet, üç grup halinde düzenlenmiş ve daha detaylı mimarisi Şekil 2.14’te gösterilmiştir [38]. Bu mimari 22 katman derinliğe sahiptir ve AlexNet’e kıyasla parametre sayısı 60 Milyondan, 4 Milyona düşürülmüştür.



Şekil 2.14. GoogleNet mimarisi

#### d) ResNet50

ResNet, 2015 yılında derin ağların eğitimini kolaylaştırmak için oluşturulmuş bir sinir ağı türüdür. Sinir ağları daha fazla katman eklendikçe eğitim süreci zorlaşır ve aşırı öğrenme sorunları ortaya çıkabilmektedir. Bu sorunları çözmek için, Şekil 2.15'te gösterildiği gibi ResNet, her katmandan geçen veriyi bir önceki katmandan geçen veriyle birleştiren bağlantıları atlamayı içeren bir yapı kullanmaktadır [39].



layer name	34-layer	50-layer	101-layer
conv1	7 × 7,64, stride 2		
	3 × 3 max pool, stride 2		
conv2_x	$\begin{bmatrix} 3 \times 3,64 \\ 3 \times 3,64 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1,64 \\ 3 \times 3,64 \\ 1 \times 1,256 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1,64 \\ 3 \times 3,64 \\ 1 \times 1,256 \end{bmatrix} \times 3$
conv3_x	$\begin{bmatrix} 3 \times 3,128 \\ 3 \times 3,128 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1,128 \\ 3 \times 3,128 \\ 1 \times 1,512 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1,128 \\ 3 \times 3,128 \\ 1 \times 1,512 \end{bmatrix} \times 4$
conv4_x	$\begin{bmatrix} 3 \times 3,256 \\ 3 \times 3,256 \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1,256 \\ 3 \times 3,256 \\ 1 \times 1,1024 \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1,256 \\ 3 \times 3,256 \\ 1 \times 1,1024 \end{bmatrix} \times 23$
conv5_x	$\begin{bmatrix} 3 \times 3,512 \\ 3 \times 3,512 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1,512 \\ 3 \times 3,512 \\ 1 \times 1,2048 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1,512 \\ 3 \times 3,512 \\ 1 \times 1,2048 \end{bmatrix} \times 3$
	average pool,2048-d fc		

Şekil 2.16. Farklı ResNet katman mimarileri

## 2.4 Performans Değerlendirme Metrikleri

KULLANILAN ARAÇLAR VE YÖNTEMLER başlığı altında incelenmiş olan AlexNet, EfficientNet, GoogleNet ve ResNet50 algoritmaları kullanılmıştır. Bu algoritmaların sonuçlarının değerlendirilmesi için doğruluk, kesinlik, duyarlılık ve F1-skor metrikleri hesaplanmıştır.

		Gerçek	
		Hasta	HastaDeğil
Tahminlenen	Hasta	TP	FP
	HastaDeğil	FN	TN

Şekil 2.17. Karışıklık matrisi

Doğruluk, modelin sınıflandırmayı ne kadar başarılı yapabildiğini belirten metriktir. Matematiksel formülü 2.1’de yer almaktadır.

$$Doğruluk = \frac{TP + FP}{TP + FP + FN + TN} \quad (2.1)$$

Kesinliğin matematiksel formülü 2.2’de yer almaktadır.

$$Kesinlik = \frac{TP}{TP + FP} \quad (2.2)$$

Duyarlılığın matematiksel formülü 2.3’te yer almaktadır.

$$Duyarlılık = \frac{TP}{TP + FN} \quad (2.3)$$

Kesinlik ve duyarlılık değerlerine bağlı olarak F1-skor’un matematiksel hesabı 2.4’te yer almaktadır.


$$F1 = 2 \times \frac{Kesinlik \times Duyarlılık}{Kesinlik + Duyarlılık} \quad (2.4)$$

### 3. DENEYLER

Bu bölümde KULLANILACAK ARAÇLAR VE YÖNTEMLER başlığı altında açıklanmış olan veri artırma yöntemleri ve derin öğrenme modelleri sonucunda elde edilen sonuçlara ilişkin detaylar bulunmaktadır.

#### 3.1 Veri Setinin Hazırlanması


Oluşturulan veri seti toplamda 597 görüntü içerdiği ve kullanılacak olan derin öğrenme algoritmalarının başarımlarını arttırmak için bu veriler üzerinde 2 farklı veri artırma yöntemi uygulanmıştır. İlk olarak gerçek veri setine geleneksel veri artırma yöntemleri uygulanmış, daha sonra PGAN ile gerçek veri setine benzer yeni veriler üretilmiştir.




Şekil 3.1. Geleneksel veri artırma yöntemleriyle elde edilmiş görüntülerin birkaçı

Orijinal veriye ilk olarak medyan filtresi uygulanmış ve gri tonlamaya çevrilmiştir. Daha sonra 45, 90, 135, 180, 225, 270 ve 315 derece olacak şekilde çevrilmiş, sonrasında da yatay ve dikey yansımalar uygulanmıştır. Keskinleştirme ve kenar tespiti yöntemleri ile resmin keskinliği arttırılmıştır. Yüksek geçiren ve alçak geçiren filtreler uygulanarak çoğaltılmak istenen veriye ait 2 görüntü kaydedilmiştir. Şekil 3.1’de gösterildiği gibi orijinal veri setine döndürme, yansıtma ve filtreleme uygulanarak orijinal veriden 16.716 görüntü üretilmiştir.

İkinci veri artırma yöntemi olarak PaHaW veri seti PGAN algoritmasına girdi olarak verilmiş ve bu veriler üzerinden benzer görüntüler oluşturmak amaçlanmıştır. PGAN algoritması ile çalışabilmek için geliştirici sayfasında belirtilmiş gerekli Torchvision, Scipy ve Visdom kütüphaneleri yüklenmiştir [40]. Torchvision, görüntü işleme ve bilgisayarla görme uygulamaları için PyTorch ile entegre çalışan bir kütüphanedir. Scipy, bilimsel ve teknik hesaplamalar için geniş kapsamlı bir Python kütüphanesidir. Visdom ise deneyler sırasında görselleştirme ve izleme işlemleri için kullanılan bir kütüphanedir. Veri setini PGAN modeli ile kullanabilmek için kılavuzda açıklanan bir .json dosyası oluşturulmuştur. Bu dosya içerisinde veri seti yolu ve her bir adımda ne kadar yenileme yapılacağı bilgisi yer almaktadır. Parkinson hastası ve kontrol bireylerin verileri algoritmaya ayrı ayrı girdi olmuştur. Modelin mimarisi gereği her bir adımda büyümesi, işlemleri yavaşlatmakta ve adımın bitme süresi uzamaktadır. Kullanılan donanım gereği model eğitiminin tüm adımları çalıştırılmamıştır. 6 adım sonunda, 128x128 çözünürlükte görseller 48 saatten uzun bir sürede üretilmiş ve her seferinde 16 görüntü kaydedilmiştir. Görüntüler üretilirken adım adım üretilen görüntüler Visdom üzerinden canlı olarak takip edilmiştir. Üretilen görüntüler göz ile de kontrol edilmiş ve anlamlı olmayan veriler çıkartılmıştır. Toplamda PGAN ile 928 görüntü üretilmiştir. Şekil 3.2 ve Şekil 3.3’te PGAN ile üretilen görüntülerden örnekler gösterilmiştir.



Şekil 3.2. PGAN ile kontrol bireylere ait verilerden üretilmiş görüntülerin birkaçı



Şekil 3.3. PGAN ile Parkinson hastası bireylere ait verilerden üretilmiş görüntülerin birkaçı

Bu çalışmada her model için 4 farklı veri seti kullanılmıştır. Kullanılan veri seti ve veri sayısı Tablo 3.1’de gösterilmiştir. İlk veri seti PaHaW veri setindeki orijinal verileri içermektedir. İkinci veri seti PaHaW veri setindeki orijinal verilerin yanı sıra geleneksel veri artırma yöntemleriyle üretilmiş verileri de içermektedir. Üçüncü veri seti ise PaHaW veri setindeki orijinal verilerin yanı sıra PGAN ile üretilmiş verileri de içermektedir. Son veri seti, PaHaW veri setindeki orijinal verilerden, PGAN ile üretilmiş verilerden ve geleneksel veri artırma yöntemleriyle üretilmiş verilerden oluşmaktadır.

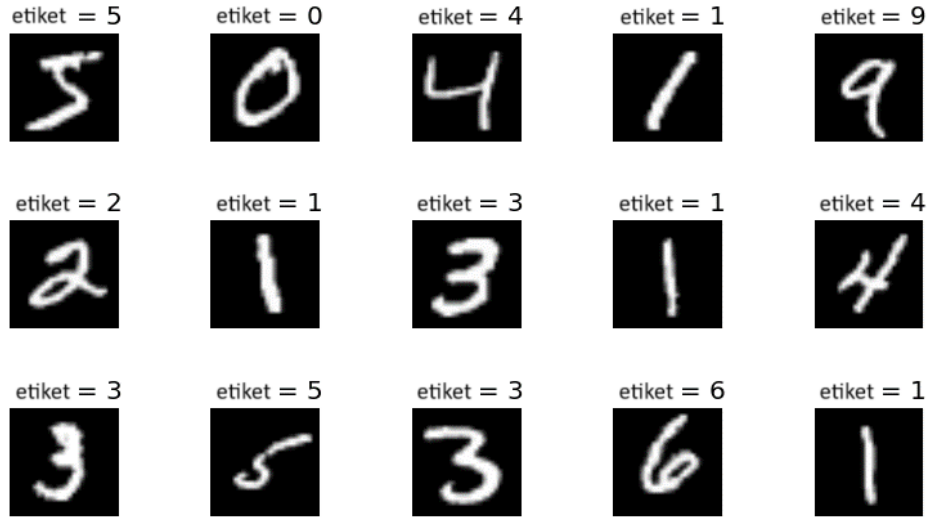
Tablo 3.1. Bu çalışmada kullanılan veri setleri ve veri sayıları

Veri Seti	Veri Sayısı	İsimlendirilmesi
PaHaW	597	Veri Seti-1
PaHaW + Çoğaltılmış	17,313	Veri Seti-2
PaHaW + PGAN	1525	Veri Seti-3
PaHaW + PGAN + Çoğaltılmış	18,241	Veri Seti-4

### 3.2 AlexNet Sonuçları

Bu çalışmada, ImageNet veri seti ile önceden eğitilip ağırlıkları kaydedilmiş bir AlexNet modeli MNIST veri seti ile eğitilmiştir. MNIST (Modified National Institute of Standards and Technology), 0-9 arasında tek haneli el yazısı rakamlarının küçük, kare 28x28 piksel gri tonlamalı görüntülerinden oluşan büyük bir veri tabanıdır ve Şekil 3.4’te gösterilmiştir [41]. Kullanılan veri seti el yazısı çizimlerini içerdiğinden el yazısı rakamları içeren MNIST veri setinin kullanılması doğruluğu artırabileceğinden Parkinson hastalığının teşhisinde faydalı olabileceği düşünülmüştür [20]. Toplamda 70.000 el yazısı rakam

görüntülerinden oluşmaktadır. Bunların 60.000'i eğitim verisi ve 10.000'i ise test verisi olarak ayrılmıştır.



Şekil 3.4. MNIST veri seti ([41]'den değiştirilerek)

Bu görüntüler hem AlexNet hem de daha sonra uygulanacak modellerin mimarisine uygun olacak biçimde çift doğrusal enterpolasyon (bilinear interpolation) yöntemi kullanılarak 224x224 olarak yeniden boyutlandırılmıştır. Tablo 3.2'de belirtilen model parametreleri ile model eğitilmiştir. Transfer öğrenme tekniği ile %99,64'lük başarımlar elde edilmiştir. Eğitim bittikten sonra, eğitilen AlexNet modeline ait ağırlıklar kaydedilmiştir.

Tablo 3.2. MNIST veri seti için AlexNet modelinin hiper parametreleri

	<b>Toplu Boyut</b>	<b>Öğrenme Oranı</b>	<b>Momentum</b>
AlexNet	64	0,001	0,9

Oluşturulmuş olan veri setleri AlexNet mimarisinin giriş boyutuna uygun olacak biçimde aynı yöntem ile 224x224 olarak yeniden boyutlandırılmıştır. Farklı çalışmalarda eğitim verisi genelde %80 veya %90 olarak ayrılmıştır. Veri setindeki görüntü sayısından dolayı %80 eğitim ve %20 test olacak şekilde ayrılmasına karar verilmiştir. Yapılan çalışma sonrası oluşan modelin ağırlıkları öncelikle Veri Seti-1 ile çalıştırılmış daha sonra sırasıyla

Veri Seti-2, Veri Seti-3 ve Veri Seti-4 ile çalıştırılmıştır. Ayrıca transfer öğrenmenin etkisine bakabilmek için Veri Seti-1 transfer öğrenme olmadan AlexNet ile eğitilmiştir. Bu ayarlar ile Tablo 3.3'te belirtilen hiper parametreler kullanılmıştır.

Tablo 3.3. AlexNet modelinin hiper parametreleri

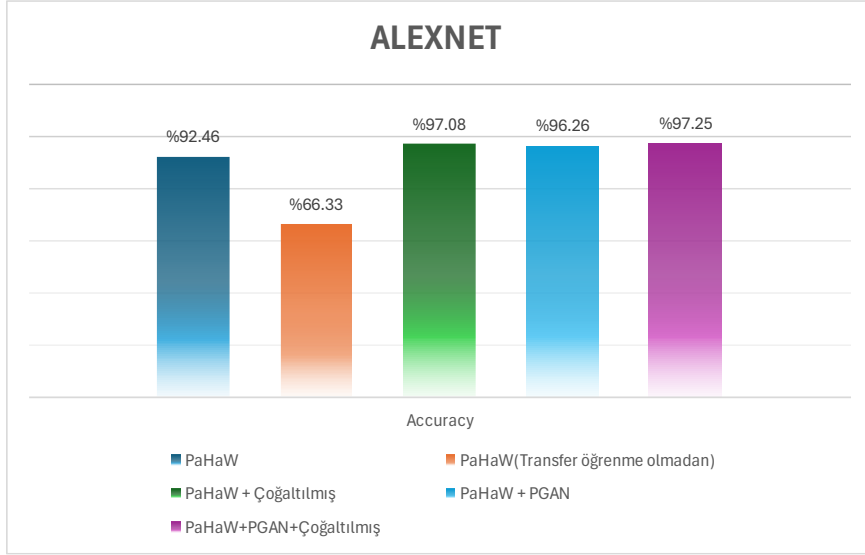
	<b>Toplu Boyut</b>	<b>GPU Yüğü</b>	<b>Öğrenme Oranı</b>	<b>Momentum</b>	<b>Sabır</b>
<b>Veri Seti-1</b>	32	1,6/6 GB	0,0001	0,9	150
<b>Veri Seti-1 (Transfer Öğrenme Olmadan)</b>	32	1.8/6 GB	0.0001	0.9	150
<b>Veri Seti-2</b>	32	4,6/6 GB	0,0001	0,9	150
<b>Veri Seti-3</b>	32	2,3/6 GB	0,0001	0,9	150
<b>Veri Seti-4</b>	16	4,6/6 GB	0,0001	0,9	150

Aşırı öğrenmeyi engellemek için sabır değeri ile erken durdurma tekniğı kullanılmıştır. Eğitim sırasında belirlenen değere kadar performansta bir iyileştirme olmaması durumunda eğitimi sonlandırmıştır.

Veri Seti-1'e ait başarıım oranı %90,46, Veri Seti-1 (Transfer Öğrenme Olmadan)'e ait başarıım oranı %66,33, Veri Seti-2'ye ait başarıım oranı %97,06, Veri Seti-3'e ait başarıım oranı %96,26 ve Veri Seti-4'e ait başarıım oranı %97,25 olmuştur. AlexNet için elde edilen sonuçlar Tablo 3.4'te ve Şekil 3.5'te gösterilmiştir.

Tablo 3.4. AlexNet ile elde edilmiş sonuçlar

	<b>Kesinlik</b>	<b>Duyarlılık</b>	<b>F1-Skor</b>
Veri Seti-1	%92,11	%92,82	%92,46
Veri Seti-1 (Transfer Öğrenme Olmadan)	%64,76	%67,24	%65,98
Veri Seti-2	%96,86	%97,13	%96,99
Veri Seti-3	%96,02	%93,47	%94,73
Veri Seti-4	%96,75	%97,42	%97,08



Şekil 3.5. AlexNet ile veri setlerine göre elde edilmiş doğruluk değerleri

### 3.3 EfficientNet-B0 Sonuçları

ImageNet veri seti ile önceden eğitilip ağırlıkları kaydedilmiş bir EfficientNet-B0 modeli Tablo 3.6’da belirtilen model parametreleri kullanılarak MNIST veri seti ile eğitilmiştir. Transfer öğrenme tekniği ile %96,72’lik başarımlar elde edilmiştir. Eğitim bittikten sonra, eğitilen EfficientNet-B0 modeline ait ağırlıklar kaydedilmiştir.

Tablo 3.5. MNIST veri seti için EfficientNet-B0 modelinin hiper parametreleri

	Toplu Boyut	Öğrenme Oranı	Momentum
EfficientNet-B0	196	0,001	0,9

Önceden belirtildiği gibi verilerin %80’i eğitim ve %20’si test olacak şekilde ayrılmıştır. Önceki adımda kaydedilen ağırlık dosyası kullanılarak model sırasıyla Veri Seti-1, Veri Seti-2, Veri-Seti-3 ve Veri Seti-4 ile ayrı ayrı eğitilerek sonuçları kaydedilmiştir. Ayrıca transfer öğrenmenin etkisine bakabilmek için Veri Seti-1 transfer öğrenme olmadan EfficientNet-B0 ile eğitilmiştir. Bu ayarlar ile Tablo 3.7’te belirtilen hiper parametreler kullanılmıştır.

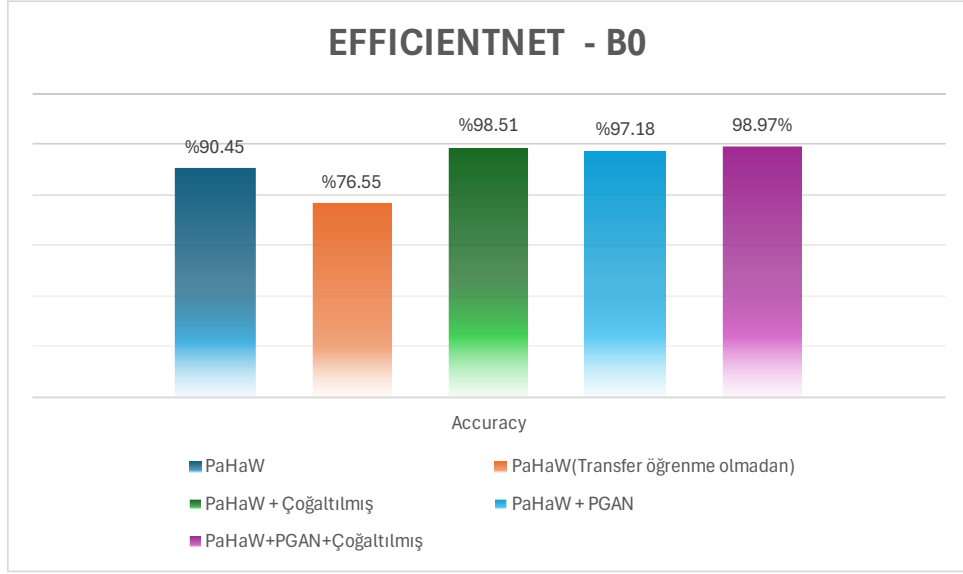
Tablo 3.6. EfficientNet-B0 modelinin hiper parametreleri

	<b>Toplu Boyut</b>	<b>GPU Yüğü</b>	<b>Öğrenme Oranı</b>	<b>Momentum</b>	<b>Sabır</b>
<b>Veri Seti-1</b>	32	3,8/6 GB	0,0001	0,9	150
<b>Veri Seti-1 (Transfer Öğrenme Olmadan)</b>	32	3.6/6 GB	0.0001	0.9	150
<b>Veri Seti-2</b>	32	4,7/6 GB	0,0001	0,9	150
<b>Veri Seti-3</b>	32	4,3/6 GB	0,0001	0,9	150
<b>Veri Seti-4</b>	32	4,8/6 GB	0,0001	0,9	150

Veri Seti-1'e ait başarıım oranı %90,45, Veri Seti-1 (Transfer Öğrenme Olmadan)'e ait başarıım oranı %76,55, Veri Seti-2'ye ait başarıım oranı %98,51, Veri Seti-3'e ait başarıım oranı %97,18 ve Veri Seti-4'e ait başarıım oranı %98,97 olmuştur. EfficientNet-B0 için elde edilen sonuçlar Tablo 3.8'de ve Şekil 3.6'da gösterilmiştir.

Tablo 3.7. EfficientNet-B0 ile elde edilmiş sonuçlar

	<b>Kesinlik</b>	<b>Duyarlılık</b>	<b>F1-Skor</b>
Veri Seti-1	%93,78	%86,15	%89,80
Veri Seti-1 (Transfer Öğrenme Olmadan)	%69,21	%97,38	%80,91
Veri Seti-2	%98,75	%97,56	%98,15
Veri Seti-3	%96,12	%95,63	%95,87
Veri Seti-4	%98,67	%98,87	%98,77



Şekil 3.6. EfficientNet-B0 ile veri setlerine göre elde edilmiş doğruluk değerleri

### 3.4 GoogleNet Sonuçları

ImageNet veri seti ile önceden eğitilip ağırlıkları kaydedilmiş bir GoogleNet modeli Tablo 3.9’da belirtilen model parametreleri kullanılarak MNIST veri seti ile eğitilmiştir. Transfer öğrenme tekniği ile %99,46’lık başarımla elde edilmiştir. Eğitim bittikten sonra, eğitilen GoogleNet modeline ait ağırlıklar kaydedilmiştir.

Tablo 3.8. MNIST veri seti için GoogleNet modelinin hiper parametreleri

	<b>Toplu Boyut</b>	<b>Öğrenme Oranı</b>	<b>Momentum</b>
GoogleNet	64	0,001	0.9

Tablo 3.9. GoogleNet modelinin hiper parametreleri


	<b>Toplu Boyut</b>	<b>GPU Yüğü</b>	<b>Öğrenme Oranı</b>	<b>Momentum</b>	<b>Sabır</b>
<b>Veri Seti-1</b>	32	2,4/6 GB	0,0001	0,9	150
<b>Veri Seti-1 (Transfer Öğrenme Olmadan)</b>	32	2.4/6 GB	0.0001	0.9	150
<b>Veri Seti-2</b>	32	4,2/6 GB	0,0001	0,9	150
<b>Veri Seti-3</b>	32	2,9/6 GB	0,0001	0,9	150
<b>Veri Seti-4</b>	32	4,4/6 GB	0,0001	0,9	150

Diğer iki modelde olduğu gibi verilerin %80'i eğitim ve %20'si test olacak şekilde ayrılmıştır. Önceki adımda kaydedilen ağırlık dosyası kullanılarak model sırasıyla Veri Seti-1, Veri Seti-2, Veri-Seti-3 ve Veri Seti-4 ile ayrı ayrı eğitilerek sonuçları kaydedilmiştir. Ayrıca transfer öğrenmenin etkisine bakabilmek için Veri Seti-1 transfer öğrenme olmadan GoogleNet ile eğitilmiştir. Bu ayarlar ile Tablo 3.10'da belirtilen hiper parametreler kullanılmıştır.

Veri Seti-1'e ait başarımlar oranı %80,90, Veri Seti-1 (Transfer Öğrenme Olmadan)'e ait başarımlar oranı %80,40, Veri Seti-2'ye ait başarımlar oranı %69,67, Veri Seti-3'e ait başarımlar oranı %96,33 ve Veri Seti-4'e ait başarımlar oranı %77,56 olmuştur. GoogleNet için elde edilen sonuçlar Tablo 3.11'de ve Şekil 3.7'de gösterilmiştir.

Tablo 3.10. GoogleNet ile elde edilmiş sonuçlar

	<b>Kesinlik</b>	<b>Duyarlılık</b>	<b>F1-Skor</b>
Veri Seti-1	%84,83	%74,93	%79,57
Veri Seti-1 (Transfer Öğrenme Olmadan)	%76,82	%86,09	%81,19
Veri Seti-2	%70,07	%68,79	%69,42
Veri Seti-3	%96,23	%93,96	%95,08
Veri Seti-4	%73,48	%83,95	%78,37



Şekil 3.7. GoogleNet ile veri setlerine göre elde edilmiş doğruluk değerleri

### 3.5 ResNet50 Sonuçları

ImageNet veri seti ile önceden eğitilip ağırlıkları kaydedilmiş bir ResNet50 modeli Tablo 3.12’de belirtilen model parametreleri kullanılarak MNIST veri seti ile eğitilmiştir. Transfer öğrenme tekniği ile %99,64’lük başarımlar elde edilmiştir. Eğitim bittikten sonra, eğitilen ResNet50 modeline ait ağırlıklar kaydedilmiştir.

Tablo 3.11. MNIST veri seti için ResNet50 modelinin hiper parametreleri

	<b>Toplu Boyut</b>	<b>Öğrenme Oranı</b>	<b>Momentum</b>
ResNet50	32	0,001	0,9

Önceki modellerde olduğu gibi verilerin %80’i eğitim ve %20’si test olacak şekilde ayrılmıştır. Önceki adımda kaydedilen ağırlık dosyası kullanılarak model sırasıyla Veri Seti-1, Veri Seti-2, Veri Seti-3 ve Veri Seti-4 ile ayrı ayrı eğitilerek sonuçları kaydedilmiştir. Ayrıca transfer öğrenmenin etkisine bakabilmek için Veri Seti-1 transfer öğrenme olmadan ResNet50 ile eğitilmiştir. Bu ayarlar ile Tablo 3.13’te belirtilen hiper parametreler kullanılmıştır.

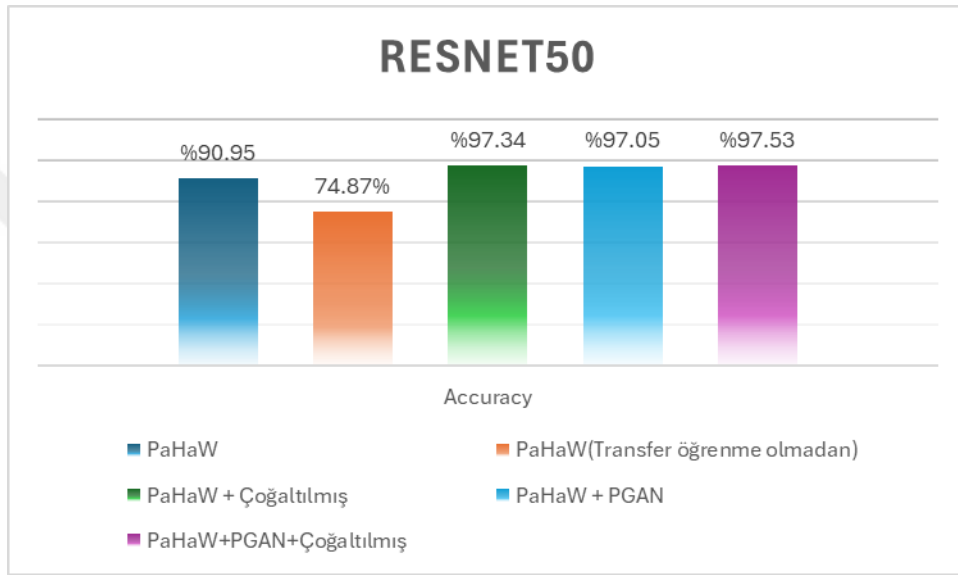
Tablo 3.12. ResNet50 modelinin hiper parametreleri

	<b>Toplu Boyut</b>	<b>GPU Yüğü</b>	<b>Öğrenme Oranı</b>	<b>Momentum</b>	<b>Sabır</b>
<b>Veri Seti-1</b>	32	3,8/6 GB	0,0001	0,9	150
<b>Veri Seti-1 (Transfer Öğrenme Olmadan)</b>	32	3.3/6 GB	0.0001	0.9	150
<b>Veri Seti-2</b>	32	4,7/6 GB	0,0001	0,9	150
<b>Veri Seti-3</b>	32	4,1/6 GB	0,0001	0,9	150
<b>Veri Seti-4</b>	32	4,9/6 GB	0,0001	0,9	150

Veri Seti-1’e ait başarımlar oranı %90,95, Veri Seti-1 (Transfer Öğrenme Olmadan)’e ait başarımlar oranı %74,87, Veri Seti-2’ye ait başarımlar oranı %97,34, Veri Seti-3’e ait başarımlar oranı %97,05 ve Veri Seti-4’e ait başarımlar oranı %97,53 olmuştur. ResNet50 için elde edilen sonuçlar Tablo 3.14’te ve Şekil 3.8’de gösterilmiştir.

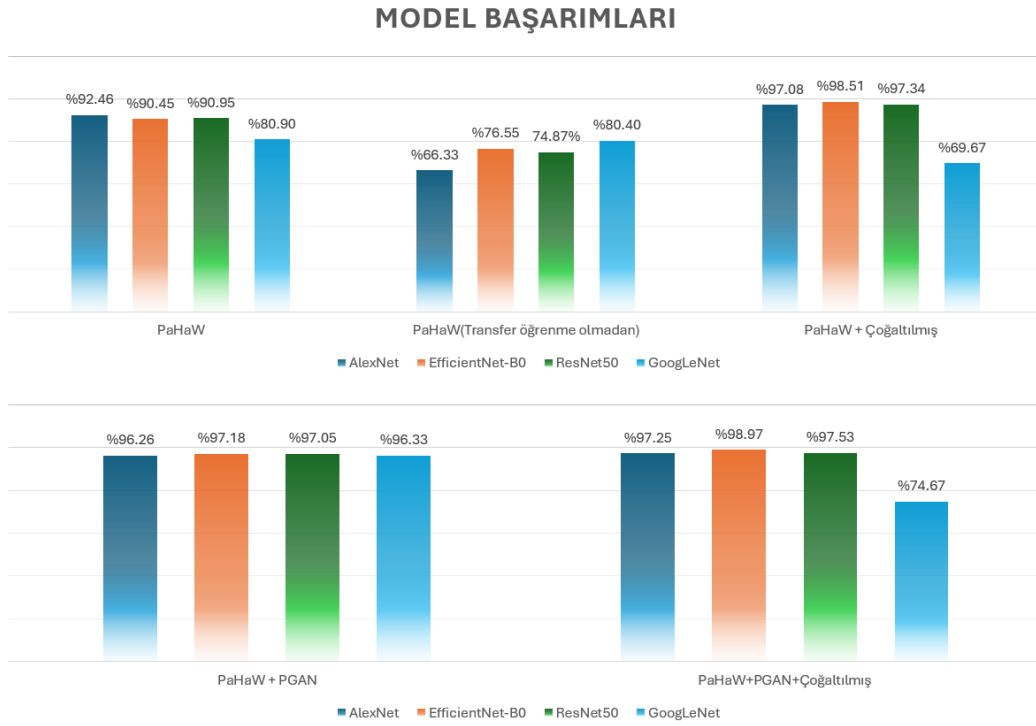
Tablo 3.13. ResNet50 ile elde edilmiş sonuçlar

	<b>Kesinlik</b>	<b>Duyarlılık</b>	<b>F1-Skor</b>
Veri Seti-1	%90,58	%90,32	%90,45
Veri Seti-1 (Transfer Öğrenme Olmadan)	%87,38	%57,96	%69,69
Veri Seti-2	%97,05	%96,69	%96,87
Veri Seti-3	%95,33	%97,08	%96,20
Veri Seti-4	%97,16	%96,82	%96,99



Şekil 3.8. ResNet50 ile veri setlerine göre elde edilmiş doğruluk değerleri

### 3.6 Modellerin Performanslarının Karşılaştırılması



Şekil 3.9. Uygulanan tüm modellerin veri setlerine göre başarımları

Şekil 3.9.'da da görüldüğü gibi AlexNet modelinin en iyi başarımı %97,25 ile Veri Seti-4 yani hem orijinal veri hem PGAN ile üretilmiş hem de geleneksel veri artırma yöntemleri ile üretilmiş veriler kullanılarak elde edilmiştir.

EfficientNet-B0 modelinin en iyi başarımı %98,97 ile aynı AlexNet modelinde olduğu gibi Veri Seti-4 yani hem orijinal veri hem PGAN ile üretilmiş hem de geleneksel veri artırma yöntemleri ile üretilmiş veriler kullanılarak elde edilmiştir.

GoogLeNet modelinin en iyi başarımı %96,33 ile diğer 2 modelden farklı olarak Veri Seti-3 yani hem orijinal veri hem de PGAN ile üretilmiş veriler kullanılarak elde edilmiştir.

Son olarak ResNet50 modelinin en iyi başarımı %97,53 ile aynı AlexNet ve EfficientNet-B0 modellerinde olduğu gibi Veri Seti-4 yani hem orijinal veri hem PGAN ile üretilmiş hem de geleneksel veri artırma yöntemleri ile üretilmiş veriler kullanılarak elde edilmiştir.

Genel olarak tüm modellere bakıldığında %98,97 başarımla en yüksek başarıma sahip model EfficientNet-B0 olmuştur.

Sonuçlara bakıldığında modelleri eğitirken verinin artması genel olarak doğruluğu artırmıştır. Geleneksel yöntemler ile veri setindeki görüntülerin farklı varyasyonları elde edilirken, PGAN ile veri setine benzer görüntüler elde edilmiştir. Bu yüzden uygulanan iki farklı veri artırma yönteminden PGAN ile veri artırmanın Parkinson hastalığının teşhisinde daha uygun olduğu düşünülmektedir.

Transfer öğrenme olmadan sonuçların yüksek başarıma ulaşmadığı görülmüştür. Transfer öğrenme sonucu yüksek doğruluk ile Parkinson hastalığının teşhis edilebildiği belirlenmiştir. Bunun sebebi transfer öğrenmede kullanılan veri setlerinin ve görevlerin benzer olmasıdır.

## 4. SONUÇ

Bu çalışmada Parkinson hastalığı teşhisi derin öğrenme algoritmaları kullanılarak gerçekleştirilmiş ve karşılaştırmalar yapılmıştır. Hastalığın teşhisinde, bireyin Parkinson hastası olup olmadığı şeklinde tahminleme işlemi sınıflandırma algoritması olarak ele alınmıştır. Araştırmanın motive edici yanı, günümüz dünyasında hızla gelişen teknolojileri ve yazılım araçlarını kullanma deneyimine erişmek ve gerçek hayatta insan hayatına dokunabilecek, erken teşhis ile hastalık ile erkenden savaşabilme fırsatı verebilmektir.

Çalışma sırasında Parkinson hastalarına ait verileri içeren PaHaW veri setinin, geleneksel veri artırma yöntemleri ve PGAN ile yeni veriler üretilerek veri sayısı artırılmıştır. Bu veriler ile PaHaW veri seti farklı şekillerde kombin edilerek çalışma sırasında kullanılmak üzere çeşitli veri setleri oluşturulmuş ve bu veri setlerinin modellerin başarımına etkisi analiz edilmiştir. En iyi sonucu PaHaW + PGAN ile üretilmiş veriler + geleneksel veri artırma yöntemleri ile üretilmiş verileri içeren veri setini kullanan EfficientNet-B0 modeli vermiştir. GoogleNet modeline ait tahmin etme performansı, diğer derin öğrenme modellerine göre düşük çıkmıştır. Bunun sebebinin parametre sayısının diğer modellere göre daha az olmasından kaynaklandığı düşünülmektedir. Kullanılan donanım gereği bazı modeller eğitilirken GPU RAM miktarı yetersiz kaldığı için toplu boyut değişiklik göstermiştir.

Tez çalışmasında kullanılan veri seti, düzgün dağılımdan uzak yapıdadır. Bazı bireylerin çizimlerinde eksiklikler vardır ve veri setindeki ham görüntü sayısı derin öğrenme modellerinin düzgün eğitilebilmesi için çok azdır. Bu şekilde veri setleri üzerinde derin öğrenme algoritmalarının kullanımı ile ilgili performansı iyileştirecek çalışmalar yapmak mümkündür. Daha çok kontrol grubu ve Parkinson hastası bireylerin el yazısı görüntüleri ile PaHaW veri setinin genişletilmesi, genç yaştaki Parkinson hastalarının ve kontrol grubu bireylerin veri setine dahil edilmesi ve bu çalışmada kullanılan hem veri artırma yöntemlerine ek olarak hem de derin öğrenme yöntemlerine ek olarak daha büyük ve yeni modeller kullanılarak sistemin Parkinson hastalığını teşhis etme yeteneğinin daha iyi olacağı beklenmektedir.

## KAYNAKLAR

- [1] “Dünya Parkinson Günü - TPHD,” *TPHD*, Mar. 19, 2019, [Online], Available: [turkiyeparkinsonhastaligidernegi.com/dunya-parkinson-gunu/](http://turkiyeparkinsonhastaligidernegi.com/dunya-parkinson-gunu/)
- [2] C. Marras et al., “Prevalence of Parkinson’s disease across North America,” *NPJ Parkinson’s Disease*, vol. 4, no. 1, Jul. 2018, doi: 10.1038/s41531-018-0058-0.
- [3] “Statistics,” *Parkinson’s Foundation*, [Online], Available: [parkinson.org/understanding-parkinsons/statistics](http://parkinson.org/understanding-parkinsons/statistics)
- [4] “Causes,” *Parkinson’s Foundation*, [Online], Available: [parkinson.org/understanding-parkinsons/causes](http://parkinson.org/understanding-parkinsons/causes)
- [5] C. C. M. Professional, “Parkinson’s Disease,” *Cleveland Clinic*, [Online], Available: [my.clevelandclinic.org/health/diseases/8525-parkinsons-disease-an-overview](http://my.clevelandclinic.org/health/diseases/8525-parkinsons-disease-an-overview)
- [6] R. F. Pfeiffer, “Non-motor symptoms in Parkinson’s disease,” *Parkinsonism & Related Disorders (Online)/Parkinsonism & Related Disorders*, vol. 22, pp. S119–S122, Jan. 2016, doi: 10.1016/j.parkreldis.2015.09.004.
- [7] N. Singh, V. Pillay, and Y. E. Choonara, “Advances in the treatment of Parkinson’s disease,” *Progress in Neurobiology*, vol. 81, no. 1, pp. 29–44, Jan. 2007, doi: 10.1016/j.pneurobio.2006.11.009.
- [8] W. Wang, J. Lee, F. Harrou, and Y. Sun, “Early detection of Parkinson’s disease using deep learning and machine learning,” *IEEE Access*, vol. 8, pp. 147635–147646, Jan. 2020, doi: 10.1109/access.2020.3016062.
- [9] Y. Ketkar and S. Gawade, “A decision support system for selecting the most suitable machine learning in healthcare using user parameters and requirements,” *Healthcare Analytics*, vol. 2, p. 100117, Nov. 2022, doi: 10.1016/j.health.2022.100117.

- [10] S. Yadav, M. K. Singh, and S. Pal, “Artificial intelligence model for Parkinson disease detection using machine learning algorithms,” *Deleted Journal*, vol. 1, no. 2, pp. 899–911, Mar. 2023, doi: 10.1007/s44174-023-00068-x.
- [11] A. Li and C. Li, “Detecting Parkinson’s Disease through Gait Measures Using Machine Learning,” *Diagnostics*, vol. 12, no. 10, p. 2404, Oct. 2022, doi: 10.3390/diagnostics12102404.
- [12] M. I. A. S. N. Ferreira, F. A. Barbieri, V. C. Moreno, T. Penedo, and J. M. R. S. Tavares, “Machine learning models for Parkinson’s disease detection and stage classification based on spatial-temporal gait parameters,” *Gait & Posture*, vol. 98, pp. 49–55, Oct. 2022, doi: 10.1016/j.gaitpost.2022.08.014.
- [13] T. Aşuroğlu, K. Açııcı, Ç. B. Erdaş, M. K. Toprak, H. Erdem, and H. Oğul, “Parkinson’s disease monitoring from gait analysis via foot-worn sensors,” *Biocybernetics and Biomedical Engineering*, vol. 38, no. 3, pp. 760–772, Jan. 2018, doi: 10.1016/j.bbe.2018.06.002.
- [14] G. Pahuja and B. Prasad, “Deep learning architectures for Parkinson’s disease detection by using multi-modal features,” *Computers in Biology and Medicine*, vol. 146, p. 105610, Jul. 2022, doi: 10.1016/j.compbimed.2022.105610.
- [15] C. C. S. Pereira, S. A. T. Weber, C. Hook, G. J. De Magalhães Rosa, and J. P. Papa, “Deep Learning-Aided Parkinson’s Disease Diagnosis from Handwritten Dynamics,” *2016 29th SIBGRAPI Conference on Graphics, Patterns and Images (SIBGRAPI)*, Oct. 2016, doi: 10.1109/sibgrapi.2016.054.
- [16] H. S. Das, A. Das, A. Neog, S. Mallik, K. Bora, and Z. Zhao, “Early detection of Parkinson’s disease using fusion of discrete wavelet transformation and histograms of oriented gradients,” *Mathematics*, vol. 10, no. 22, p. 4218, Nov. 2022, doi: 10.3390/math10224218.
- [17] P. Khatamino, İ. Cantürk, and L. Ozyilmaz, “A Deep Learning-CNN based System for Medical Diagnosis: An application on Parkinson’s Disease handwriting drawings,”

2018 6th International Conference on Control Engineering & Information Technology (CEIT), Oct. 2018, doi: 10.1109/ceit.2018.8751879.

- [18] Z. Li, J. Yang, Y. Wang, M. Cai, X. Liu, and L. Kang, “Early diagnosis of Parkinson’s disease using Continuous Convolution Network: Handwriting recognition based on off-line hand drawing without template,” *Journal of Biomedical Informatics*, vol. 130, p. 104085, Jun. 2022, doi: 10.1016/j.jbi.2022.104085.
- [19] M. Alissa et al., “Parkinson’s disease diagnosis using convolutional neural networks and figure-copying tasks,” *Neural Computing & Applications*, vol. 34, no. 2, pp. 1433–1453, Sep. 2021, doi: 10.1007/s00521-021-06469-7.
- [20] A. Naseer, M. Rani, S. Naz, M. I. Razzak, M. Imran, and G. Xu, “Refining Parkinson’s neurological disorder identification through deep transfer learning,” *Neural Computing & Applications*, vol. 32, no. 3, pp. 839–854, Feb. 2019, doi: 10.1007/s00521-019-04069-0.
- [21] P. Drotár, J. Mekyska, I. Rektorová, L. Masarová, Z. Smékal, and M. Faundez-Zanuy, “Analysis of in-air movement in handwriting: A novel marker for Parkinson’s disease,” *Computer Methods and Programs in Biomedicine*, vol. 117, no. 3, pp. 405–411, Dec. 2014, doi: 10.1016/j.cmpb.2014.08.007.
- [22] P. Drotár, J. Mekyska, I. Rektorová, L. Masarová, Z. Smékal, and M. Faundez-Zanuy, “Evaluation of handwriting kinematics and pressure for differential diagnosis of Parkinson’s disease,” *Artificial Intelligence in Medicine*, vol. 67, pp. 39–46, Feb. 2016, doi: 10.1016/j.artmed.2016.01.004.
- [23] clickworker, “Generative Adversarial Networks (GANs): A complete guide,” *clickworker.com*, Nov. 07, 2022, [Online], Available: [clickworker.com/ai-glossary/generative-adversarial-networks/](https://clickworker.com/ai-glossary/generative-adversarial-networks/)

- [24] T. Karras, T. Aila, S. Laine, and J. Lehtinen, “Progressive growing of GANs for improved quality, stability, and variation,” *arXiv.org*, Oct. 27, 2017, [Online], Available: [arxiv.org/abs/1710.10196](https://arxiv.org/abs/1710.10196)
- [25] R. Togo, T. Ogawa, and M. Haseyama, “Synthetic gastritis image generation via Loss Function-Based Conditional PGGAN,” *IEEE Access*, vol. 7, pp. 87448–87457, Jan. 2019, doi: 10.1109/access.2019.2925863.
- [26] K. Bingöl, A. E. Akan, H. T. Örmecioğlu, and A. Er, “Depreme dayanıklı mimari tasarımda yapay zeka uygulamaları: Derin öğrenme ve görüntü işleme yöntemi ile düzensiz taşıyıcı sistem tespiti,” *Gazi Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi*, vol. 35, no. 4, pp. 2197–2210, Jul. 2020, doi: 10.17341/gazimmfd.647981
- [27] “DERİN ÖĞRENME,” *Google Books*. [Online], Available: [books.google.com.tr/books?id=nqcqEAAAQBAJ&printsec=frontcover&hl=tr#v=onepage&q&f=false](https://books.google.com.tr/books?id=nqcqEAAAQBAJ&printsec=frontcover&hl=tr#v=onepage&q&f=false)
- [28] “Deep Learning vs Machine Learning: The Ultimate Battle,” May 02, 2022, [Online], Available: [turing.com/kb/ultimate-battle-between-deep-learning-and-machine-learning](https://turing.com/kb/ultimate-battle-between-deep-learning-and-machine-learning)
- [29] S. Indolia, A. K. Goswami, S. P. Mishra, and P. Asopa, “Conceptual understanding of Convolutional Neural Network- a deep learning approach,” *Procedia Computer Science*, vol. 132, pp. 679–688, Jan. 2018, doi: 10.1016/j.procs.2018.05.069.
- [30] “A Guide to Convolutional Neural Networks — the ELI5 way | Saturn Cloud Blog,” Nov. 20, 2023, [Online], Available: [saturncloud.io/blog/a-comprehensive-guide-to-convolutional-neural-networks-the-eli5-way/](https://saturncloud.io/blog/a-comprehensive-guide-to-convolutional-neural-networks-the-eli5-way/)
- [31] D. Martinez, “Is Transfer Learning the final step for enabling AI in Aviation? - Datascience.aero,” *Datascience.aero*, Jan. 07, 2021, [Online], Available: [datascience.aero/transfer-learning-aviation](https://datascience.aero/transfer-learning-aviation)

- [32] K. Team, “Keras documentation: Keras Applications.”, [Online], Available: [keras.io/api/applications/](https://keras.io/api/applications/)
- [33] A. Krizhevsky, I. Sutskever, and G. E. Hinton, “ImageNet Classification with Deep Convolutional Neural Networks,” *Neural Information Processing Systems*, vol. 25, pp. 1097–1105, Dec. 2012, [Online]. Available: [books.nips.cc/papers/files/nips25/NIPS2012\\_0534.pdf](https://books.nips.cc/papers/files/nips25/NIPS2012_0534.pdf)
- [34] J. Deng, W. Dong, R. Socher, L.-J. Li, N. K. Li, and N. L. Fei-Fei, “ImageNet: A large-scale hierarchical image database,” *2009 IEEE Conference on Computer Vision and Pattern Recognition*, Jun. 2009, doi: 10.1109/cvpr.2009.5206848.
- [35] X. Han, Y. Zhong, L. Cao, and L. Zhang, “Pre-Trained AlexNet Architecture with Pyramid Pooling and Supervision for High Spatial Resolution Remote Sensing Image Scene Classification,” *Remote Sensing*, vol. 9, no. 8, p. 848, Aug. 2017, doi: 10.3390/rs9080848.
- [36] M. Tan and Q. V. Le, “EfficientNet: Rethinking model scaling for convolutional neural networks,” *arXiv (Cornell University)*, Jan. 2019, doi: 10.48550/arxiv.1905.11946.
- [37] V. Agarwal, “Complete Architectural Details of all EfficientNet Models,” *Medium*, Dec. 14, 2021. [Online]. Available: [towardsdatascience.com/complete-architectural-details-of-all-efficientnet-models-5fd5b736142](https://towardsdatascience.com/complete-architectural-details-of-all-efficientnet-models-5fd5b736142)
- [38] C. Szegedy et al., “Going deeper with convolutions,” *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Jun. 2015, doi: 10.1109/cvpr.2015.7298594.
- [39] K. He, X. Zhang, S. Ren, and J. Sun, “Deep Residual Learning for Image Recognition,” *arXiv (Cornell University)*, Jan. 2015, doi: 10.48550/arxiv.1512.03385.
- [40] “Progressive growing of GANs (PGAN),” *PyTorch*, [Online], Available: [pytorch.org/hub/facebookresearch\\_pytorch-gan-zoo\\_pgan/](https://pytorch.org/hub/facebookresearch_pytorch-gan-zoo_pgan/)

[41] “MNIST handwritten digit database, Yann LeCun, Corinna Cortes and Chris Burges.”,  
[Online], Available: [yann.lecun.com/exdb/mnist/](http://yann.lecun.com/exdb/mnist/)

