



T.C.
GÜMÜŞHANE ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ



**PEDİATRİK AKCİĞER RÖNTGEN GÖRÜNTÜLERİNDEN
EVİRİŞİMSEL SINIR AĞI İLE PNÖMONİ TESPİTİ**

YÜKSEK LİSANS TEZİ

YASİN DEMİR

**AĞUSTOS 2021
GÜMÜŞHANE**

T.C.
GÜMÜŞHANE ÜNİVERSİTESİ
LİSANÜSTÜ EĞİTİM ENSTİTÜSÜ

BİYOTEKNOLOJİ ANABİLİM DALI

PEDİATRİK AKCİĞER RÖNTGEN GÖRÜNTÜLERİNDEN
EVİRİŞİMSEL SİNİR AĞI İLE PNÖMONİ TESPİTİ

YÜKSEK LİSANS TEZİ

YASİN DEMİR

Gümüşhane Üniversitesi Lisansüstü Eğitim Enstitüsü
“Biyoteknoloji Anabilim Dalı”
Yüksek Lisans Programında Kabul Edilen Tezdir.

Tezin Enstitüye Verildiği Tarih : 13/07/2021

Tezin Sözlü Savunma Tarihi : 19/08/2021

AĞUSTOS 2021

ÖZET
YÜKSEK LİSANS TEZİ

PEDİATRİK AKCİĞER RÖNTGEN GÖRÜNTÜLERİNDEN
EVİRİŞİMSEL SİNİR AĞI İLE PNÖMONİ TESPİTİ

Yasin DEMİR

Gümüşhane Üniversitesi
Lisansüstü Eğitim Enstitüsü
Biyoteknoloji Anabilim Dalı

Danışman: Dr. Öğr. Üyesi Özkan BİNGÖL

2021, 56 Sayfa

Bu çalışmada çocuklarda ciddi tehdit oluşturan ve ölümlere neden olabilen pnömoni hastalığının tespiti üzerinde çalışılmıştır. Bu hastalığının tespitinde akciğer röntgen görüntüleri önemli bir rol oynamaktadır. Çünkü bu görüntüleri elde etmek için kullanılan cihazlar diğer görüntüleme cihazlarına göre daha yaygındır ve daha düşük radyasyon yaymaktadırlar. Akciğer röntgen görüntülerinin yorumu radyologlar tarafından yapılmaktadır. Ancak kullanılan bazı görüntülerin belirsiz olması, hastalık belirtilerinin birbirlerine benzemesi ve yoğun iş temposu gibi olumsuz koşullar uzmanların röntgenleri yorumlamasını zorlaştırabilmektedir. Bu çalışmada akciğer röntgen görüntülerini sağlıklı ve pnömoni olarak sınıflandırabilecek ve uzmanlara yardımcı olabilecek evrişimsel sinir ağı modelleri geliştirilmiştir.

Evrişimsel sinir ağı modellenirken iki farklı yaklaşım kullanılmıştır. Birincisi, özgün olarak en baştan tüm katmanların belirlenerek ağı modellenmesi, ikincisi ise transfer öğrenme yöntemiyle bir ağ modellenmesi şeklindedir. Evrişimsel sinir ağları genellikle ilgili veri seti boyutu arttıkça daha iyi sonuç vermektedirler. Bu çalışmada da 5 yaş altı çocuklara ait önden çekilmiş 5840 görüntüden oluşan hazır bir veriseti kullanılmıştır. Bu veriseti önerilen yöntem için kısmen küçük bir veriseti olması ağı eğitiminde modelin ezberlemesine neden olmuştur. Ezber sonucunda eğitim ve test doğruluğu arasındaki farkın açıldığı gözlemlenmiştir. Bu farkı azaltmak amacıyla veri artırma ve regülasyon yöntemleri kullanılmış, önemli ölçüde ağı eğitimi iyileştirmiştir.

Özgün olarak tasarlanan ilk modelde %93.43 doğruluk oranına ulaşılırken, transfer öğrenme yaklaşımı ile geliştirilen modelde %97.12 doğruluk oranı elde edilmiştir. Çalışma sonucunda ulaşılan yüksek başarı oranları, burada önerilen yaklaşımların akciğer röntgen görüntülerinin yorumlanmasında uzmanlara yardımcı olabileceğini göstermektedir. Ayrıca önerilen model salgın dönemlerinde (bir pnömoni türü olan COVID-19 gibi) hızlı ve doğru teşhislerin konulmasına da yardımcı olabilir.

Anahtar Kelimeler: Akciğer röntgen görüntüleri, Evrişimsel sinir ağı, Pediatri, Pnömoni, Transfer öğrenme

ABSTRACT

MS THESIS

DETECTION OF PNEUMONIA FROM PEDIATRIC LUNG X-RAY IMAGES WITH CONVOLUTIONAL NEURAL NETWORK

Yasin DEMİR

Gümüşhane University

The Graduate School of Natural and Applied Sciences

Department of Biotechnology

Supervisor: Assist. Prof. Dr. Özkan BİNGÖL

2021, 56 pages

In this study, it has been researched on the detection of pneumonia disease, that seriously threatens children and might cause deaths. Lung x-ray displays have an important role in detection of this disease. Because those devices which are used to gain this displays are more common than any other display devices and spreads lower radiation. The analysis of lung x-ray displays are made by radiologists. However, some adverse conditions such as vague image, similarity of symptoms with other diseases and intense work schedule may make it difficult to analyze x-ray displays. In this study, it has been developed Convolutional neural network models which can classify lung x-ray displays correctly (with pneumonia) and help the experts.

Two different approach has been used while modelling convolutional neural network. The first is modelling the network via determining all layers at the beginning originally, and the second is modelling the network using transfer learning methodology.

Convolutional neural networks generally result better when the related data set size is bigger. In this study, a ready dataset composed of previously displayed 5840 x-ray images of children under age 5. Although this dataset is relatively small for the suggested method, It caused the memorization of the model in the training of the network. After memorization, it has been observed that correlation difference between the training and test accuracy grows. In order to reduce this difference, data increase and regulation methods were used and the training of the network is significantly better.

In the first model that was originally designed, %93.43 accuracy rate was gained; on the other hand %97.12 accuracy rate was gained in transfer learning model. High success rate reached in the results of the study shows that suggested methods can help experts to analyze lung x-ray displays. Besides, suggested methodology may help quick and accurate diagnosis in epidemic periods (such as COVID-19/a kind of pneumonia).

Keywords: Chest x-ray images, Convolutional neural network, Pediatrics, Pneumonia, Transfer learning

TEŞEKKÜR

Bu çalışma Gümüşhane Üniversitesi Lisansüstü Eğitim Enstitüsü Biyoteknoloji Anabilim Dalı'nda Yüksek Lisans Tezi Olarak hazırlanmıştır.

Çalışma sırasında bilgi ve tecrübeleriyle yol gösteren, yardımlarını esirgemeyen Sayın Hocam Dr. Öğr. Üyesi Özkan Bingöl'e ve tüm çalışmam süresince bana destek olan babam Mustafa Demir, annem Zahide Demir, kardeşlerim Elif Aybüke Demir, Şeyma Aymaz'a, eniştem Samet Aymaz'a sonsuz teşekkürlerimi sunarım.

Yasin DEMİR
Gümüşhane, 2021

İÇİNDEKİLER

Sayfa No

ÖZET.....	IV
ABSTRACT.....	VI
TEŞEKKÜR.....	VIII
İÇİNDEKİLER.....	IX
ŞEKİLLER DİZİNİ.....	XII
TABLolar DİZİNİ.....	XIII
SEMBOLLER ve KISALTMALAR DİZİNİ.....	XV
1. GENEL BİLGİLER.....	1
1.1. Amaç	1
1.2. Kapsam.....	3
1.3. Önceki Çalışmalar	4
2. MATERYAL VE YÖNTEMLER.....	8
2.1. Pnömoni Hastalığı	8
2.1.1. Pnömoni Belirtileri.....	10
2.1.2. Pnömoni Teşhisi.....	10
2.1.3. Akciğer Röntgen Görüntülerinde Pnömoni.....	11
2.2. Derin Öğrenme	12
2.2.1. Derin Öğrenme Modelleri	14
2.2.1.1. Çok Katmanlı Algılayıcılar.....	14
2.2.1.2. Evrişimsel Sinir Ağı.....	15
2.2.2. Regülasyon Yöntemleri.....	22
2.2.2.1. L1 / L2 Düzenleme (L1/L2 Normalization).....	22
2.2.2.2. Bırakma Katmanı (Dropout).....	23
2.2.2.3. Veri artırma (Data Augmentation).....	23
2.2.2.4. Erken Durdurma (Early Stopping).....	23
2.2.3. Optimizasyon Algoritmaları.....	23
2.2.3.1. Gradyan Azalma (Gradient Descent).....	24
2.2.3.2. Momentumlu Gradyan Azalma (Gradient Descent with Momentum).....	24

2.2.3.3.	RMS-Prop (Root Mean Square Propagation).....	25
2.2.3.4.	Adam (Adaptive Moment Estimation).....	25
2.2.4.	Transfer Öğrenme	25
2.2.4.1.	AlexNet.....	25
2.2.5.	Performans Ölçütü.....	26
2.3.	Veri Artırma Yöntemleri.....	27
2.3.1.	Yansıma (Reflection)	28
2.3.2.	Döndürme (Rotation)	28
2.3.3.	Ölçekleme (Scale)	29
2.3.4.	Eğme (Shear).....	30
2.3.5.	Kaydırma(Translation)	30
2.3.6.	Kırpma (Crop)	31
2.3.7.	Kontrast (Contrast).....	32
3.	YAPILAN ÇALIŞMALAR	33
3.1.	Özgün Evrişimsel Sinir Ağı Kullanarak Pnömoni Tespiti	33
3.1.1.	Veri Kümesi	33
3.1.2.	Özgün Evrişimsel Sinir Ağı Modeli Tasarımı.....	34
3.1.2.1.	Ağ Mimarisinin İlk Katmanlarının Belirlenmesi.....	34
3.1.2.2.	Evrişim İşleminin Arttırılması.....	34
3.1.2.3.	Aynı Sayıdaki Kanal Sayısı ile Evrişim İşleminin Arttırılması.....	35
3.1.2.4.	L2 Normalizasyon İşlemi.....	35
3.1.2.5.	Tam Bağlı Katman Sayısının Arttırılması.....	36
3.1.2.6.	Bırakma Katmanının Etkisi.....	36
3.1.2.7.	Veri Artırma İşlemleri.....	37
3.1.2.8.	Modelin Başarım Ölçüm Sonuçları.....	43
3.2.	Transfer Öğrenme ile Önerilen Evrişimsel Sinir Ağı.....	43
3.2.1.	Veri Artırma Yöntemleri Uygulanan AlexNet Mimarisi Performansı.....	44
3.2.2.	Tam Bağlantılı Katman Sayısının Yeniden Düzenlenmesi.....	44

3.2.3.	Toplu Normalleştirme ve ReLU Katmanlarının Etkisi	45
3.2.4.	Tam Bağlantılı Katman Sayısının Arttırılması.....	45
3.2.5.	Öğrenme Oranının Etkisi	45
3.2.6.	Bırakma Katmanının Etkisi	46
3.2.7.	Kırpma Veri Artırma Yöntemi.....	47
3.2.8.	Modelin Başarım Ölçüm Sonuçları.....	48
4.	SONUÇ VE ÖNERİLER	50
5.	KAYNAKÇA	52
	ÖZGEÇMİŞ	

ŞEKİLLER DİZİNİ

Sayfa No

Şekil 2.1. Pnömonili akciğer grafileri	12
Şekil 2.2. Derin öğrenme modeli	14
Şekil 2.3. Evrişimsel sinir ağı genel mimarisi	16
Şekil 2.4. Sigmoid fonksiyonu	19
Şekil 2.5. Tanh fonksiyonu	20
Şekil 2.6. ReLU fonksiyonu.....	20
Şekil 2.7. Leakly ReLU fonksiyonu.....	21
Şekil 2.8. Softmax fonksiyonu	22
Şekil 2.9. Erken durdurma	23
Şekil 2.10. X yansıma	28
Şekil 2.11. Y yansıması.....	28
Şekil 2.12. Döndürme	29
Şekil 2.13. Yatay ölçekleme.....	29
Şekil 2.14. Dikey ölçekleme	29
Şekil 2.15. Yatay eğme	30
Şekil 2.16. Dikey eğme	30
Şekil 2.17. Yatay kaydırma.....	31
Şekil 2.18. Dikey kaydırma.....	31
Şekil 2.19. Kırpma yöntemi	31
Şekil 2.20. Normal ve kontrast görüntü	32
Şekil 3.1. Normal ve pnömoni görüntüler.....	33
Şekil 3.2. Önerilen ağın mimarisi	42
Şekil 3.3. Transfer öğrenme yöntemi kullanılarak önerilen model.....	48

TABLolar DİZİNİ

Sayfa No

Tablo 2.1. Beş yaş altı çocukların pnömoni etkenleri (Durmus vd., 2008).	9
Tablo 2.2. Karmaşıklık matrisi	26
Tablo 3.1. Evrişim, Toplu Normalizasyon, ReLU, Tanh katmanlarının etkisi.....	34
Tablo 3.2. Evrişim işleminin arttırılması	35
Tablo 3.3. Aynı sayıdaki kanal sayısı ile evrişim işleminin arttırılması.....	35
Tablo 3.4. L2 Normalizasyon'un modele etkisi	36
Tablo 3.5. Tam bağlı katmanın modele etkisi.....	36
Tablo 3.6. Bırakma katmanının modele etkisi	37
Tablo 3.7. X ve Y yansıma yönteminin modele etkisi.....	37
Tablo 3.8. Döndürme yönteminin modele etkisi.....	37
Tablo 3.9. Yatay Eğme yönteminin modele etkisi.....	38
Tablo 3.10. Dikey eğme yönteminin modele etkisi	38
Tablo 3.11. Yatay ölçekleme yönteminin modele etkisi.....	39
Tablo 3.12. Yatay kaydırma yönteminin modele etkisi	39
Tablo 3.13. Dikey kaydırma yönteminin modele etkisi.....	40
Tablo 3.14. Yatay ve dikey kaydırma yönteminin modele etkisi	40
Tablo 3.15. Yatay ve dikey kaydırma yönteminin modele etkisi	40
Tablo 3.16. Veri artırma yöntemlerinin performansı	41
Tablo 3.17. En iyi test doğruluğu veren veri artırma yöntemlerinin performansları .	41
Tablo 3.18. Kontrast işleminin ağıın performansına etkisi	42
Tablo 3.19. Önerilen modele ait karmaşıklık matrisi.....	43
Tablo 3.20. Önerilen ESA modelinde sınıflandırma başarısı	43
Tablo 3.21. Önceden eğitilmiş evrişimsel sinir ağlarının performansı	44
Tablo 3.22. Veri artırma yöntemleri AlexNet ile uygulanması	44
Tablo 3.23. Tam bağlantılı katmanların performansı	45
Tablo 3.24. Toplu normalizasyon ve ReLU fonksiyonlarının etkisi.....	45
Tablo 3.25. İki tam bağlı katmanın modelin performansına etkisi	45
Tablo 3.26. Öğrenme oranının test doğruluğuna etkisi.....	46
Tablo 3.27. Bırakma katmanı oranlarının etkisi – 1.....	46

Tablo 3.28. Bırakma katmanı oranlarının etkisi – 2.....	46
Tablo 3.29. Kırpma veri artırma yönteminin etkisi.....	47
Tablo 3.30. Aynı veri seti ile çalışılan makalelerin test doğruluk oranları	48
Tablo 3.31. Karmaşıklık matrisi	49
Tablo 3.32. Önerilen ESA modelinde sınıflandırma başarısı	49



SEMBOLLER ve KISALTMALAR DİZİNİ

AUC	:Eğri Altındaki Alan
BT	:Bilgisayarlı Tomografi
ESA	:Evrişimsel Sinir Ağı
DVM	:Destek Vektör Makinesi
GYA	:Geriye Yayılım Algoritması
COVID-19	:Koronavirüs
NLP	:Doğal Dil İşleme
ROI	:İlgi Alanı
RSV	: Respiratuar Sinsisyal Virüs
RT-PCR	:Gerçek Zamanlı Polimeraz Zincir Reaksiyonu
SGİ	:Stokastik Gradyan İniş
TKP	:Toplum Kökenli Pnömoni
WHO	:Dünya Sağlık Örgütü

1. GENEL BİLGİLER

1.1. Amaç

Bakteri, virüs ve mantarlar gibi patojenlerin akciğere yerleşmesi sonucu akciğerlerdeki hava keseciklerine iltihaplı bir sıvı dolarak pnömoni hastalığına neden olmaktadır. Bu durum ateş, öksürük, nefes darlığı gibi sağlık problemlerine ve ilerleyen durumlarda ölümlere yol açmaktadır. Pnömoni beş yaş altındaki çocuklarda, 65 yaş üzerindeki yetişkinlerde, kalp yetmezliği, diyabet veya Kronik Obstrüktif Akciğer Hastalığı (KOAH) gibi belirli rahatsızlıkları olan kişilerde veya bağışıklık sistemi zayıf olan insanlarda daha ciddi olma eğilimindedir. Gelişmekte olan ülkelerde 2 yaşın altındaki bebeklerde ölümlerin yaklaşık %80'inin nedeni pnömoni kökenlidir (URL-1, 2020). 2017 yılındaki Dünya Sağlık Örgütü'nün raporunda 5 yaş altı çocuklardaki ölümlerin %15'inin pnömoni nedeniyle olduğu bildirilmiştir (URL-2, 2021).

5 yaş altındaki çocuklarda bakteri ve virüsten kaynaklı pnömoniler yaygın olarak görülmektedir. Bakteriyel pnömoni için tanı koyulamaması, uygun tedavi geliştirilememesi, ciddi rahatsızlıklara hatta ölümlere neden olmaktadır (Garnacho-Montero vd., 2010; Mandell vd., 2007). Koronavirüs (COVID-19) salgını gibi pnömoni hastalıkları, bulaş riskinden dolayı vaka sayılarının hızla artmasına neden olduğu için erken teşhis çok önemlidir. Gelişmekte olan ve gelişmiş ülkelerde salgın durumundaki pnömoninin erken teşhisi ve tedavi yöntemleri çocuklarda görülen yüksek ölüm oranlarını azaltmak için oldukça önemlidir (Ypsilantis ve Montana, 2017).

Pnömoni tespiti için Ters Transkripsiyon Polimeraz Zincir Reaksiyonu (RT-PCR) testleri ile doğru sonuç alınabilmektedir. Ancak RT-PCR cihazları birçok hastanede bulunmaması, test sonuçlarının zaman alması, RT-PCR test kitlerinin yaygın olmaması, tedarik sıkıntısı gibi dezavantajları bulunmaktadır. Buna ek olarak geleneksel RT-PCR test kiti ile elde edilen pnömoni tespitinde yanlış negatifler hastalığın boyutunu artırmaktadır. Hastalığın başlarında ve sonlarında alınan örnekler, materyalin istenilen seviyede alınamaması, laboratuvarlara sevkinin gecikmesi sonucun negatif çıkmasına neden olabilmektedir. PCR kitlerindeki bu dezavantajlar nedeniyle uzmanlar pnömoni tespitinde alternatif olarak çeşitli görüntüleme yöntemleri kullanmaktadırlar.

Pnömoni akciğer dokusunda beyaz lekeler olarak görülmekte bu sayede radyolojik görüntülerle yakalanabilmektedir. Bilgisayarlı Tomografi (BT) ve Akciğer grafisi, genellikle pnömoniyi teşhis etmek için ilk muayenelerden biri olarak kullanılır. BT taraması, tanının net olmadığı, tedaviye yanıt vermeyen hastalarda teknik avantajlarından dolayı düşük doz olarak önerilmektedir. BT taramanın çocuklarda oluşturacağı yan etki, pahalı olması, daha yavaş sonuç alınması ve kırsal kesimlerde yaygın olarak bulunmaması dezavantaj oluşturmaktadır. Bu nedenlerden dolayı çocuk ve genç yaştaki gruplarda BT'den önce röntgen görüntüleri tercih edilmelidir. Sandal vd. (2016) yaptığı araştırmada vakalarda BT görüntüleri ve Akciğer grafisi kıyaslandığında pnömoni tanı sonuçlarının dengeli olduğu, BT görüntülerinin vakaların %57'sinde tedavi sürecinde etkisinin gözlenmediği, bununla birlikte akciğer grafisi görüntüleri vakaların %74'ünde klinik bulgular ile tanı için yeterli olduğunu tespit ettiler (Sandal vd., 2016). Gaál vd. (2020) tarafından göğüs röntgeni, bilgisayarlı tomografi ve manyetik rezonans görüntülemeye göre daha düşük radyasyon verdiği belirtilmiştir (Gaál vd., 2020). Franquet (2001) göğüs radyografisinin, pnömoni tanısında hızlı ve düşük maliyetli bir test olduğunu ifade etmiştir (Franquet, 2001). Rand (1997) çalışmasında akciğer röntgen görüntüleri ile elde edilen sonuçların yeterli olmaması, önerilen tedavi doğrultusunda iyileşmenin olmadığı durumlarda diğer görüntüleme yöntemlerinin kullanılacağını belirtmiştir (Rand, 1997). Akciğer grafisi iyi bir tanı aracı olmakla beraber takip sürecinde de çok değerlidir (Franquet, 2001). Pnömoniyi saptamak için en iyi görüntüleme yöntemi göğüs radyografileridir (World Health Organization, 2001).

Akciğer röntgen görüntülerinin de bazı sınırlılıkları vardır. Akciğer röntgen görüntülerinden pnömoni tespiti tecrübeli uzmanlar için bile zor bir görevdir. Pnömoninin akciğerlerde belirsiz olması, diğer hastalıklarla benzerlik göstermesi, deneyimli radyologları bile zorlamaktadır. Çocukluk çağı pnömonisinde yüksek ölüm oranlarının azalmasını sağlamak amacıyla hızlı teşhis koymak önemli yer tutmakta olup, dünya genelinde radyolog sayısının az olması ve röntgen görüntülerindeki tanı zorluğu iyileşme sürecini olumsuz etkileyebilmektedir. Koronavirüs gibi yeni tip salgınlarda pnömoni tespiti için virüsün erken tespit edilememesi durumunda bulaşıcılığı yüksek olduğundan salgının boyutunu da artıracaktır. Erken ve doğru teşhis önemli bir yer tutmaktadır. Elde edilen veriler doğrultusunda pnömoni tespiti için uzmanlara destek olabilecek yapay zekâ çözümlerinin hastalığa hızlı ve doğru tanı koyulabileceğini göstermiştir.

1.2. Kapsam

Pnömoni tespiti için akciğer röntgen görüntüleri kullanılarak, derin öğrenme yöntemleri tercih edilmiştir. Bu çalışmada 5 yaş altındaki çocuklara ait önden çekilmiş 5840 akciğer röntgen görüntüleri üzerinde çalışıldı. Küçük boyutlu ve dengesiz dağılım(1341 adet normal, 3875 adet pnömoni) gösteren bir veri setidir. Derin öğrenme ağlarını zorlayan veri setinin küçük olması, verilerin dengesiz dağılım göstermesi, çok riskli grupta yer alan çocuklara ait olması ve bu alanda sınırlı çalışma olması veri seti seçiminde etkili olmuştur. Pediatrik akciğer görünümü, gelişim aşamalarına bağlı olarak erişkin akciğer görünümünden farklıdır. Pediatrik akciğer röntgen görüntülerinde, çocuğun uzuvlarının görüntüde çıkması ve duruş bozuklukları ve vücuda bağlı diğer araçların bulunması nedeniyle yetişkin akciğer röntgen görüntülerine oranla daha gürültülidir. Veri setindeki bu gibi sınırlılıklar derin öğrenme yöntemlerinin performansını da test etme imkânı vermiştir.

Yapay sinir ağları ile görüntü verilerini eğitirken, yüksek derecede hesaplama karmaşıklığı, zaman maliyeti, donanım gereksinimi nedenleriyle güçlük yaşandığı belirtilmiştir (O'Shea ve Nash, 2015). Bu dezavantajlardan dolayı klasik yapay sinir ağı yerine akciğer röntgen görüntüleri ile pnömoni tespiti için derin öğrenme yöntemleri tercih edilmiştir. Derin öğrenme yönteminin seçilmesinin başka bir nedeni de derin öğrenme algoritması olan evrişimsel sinir ağlarının görüntülerde yüksek doğruluk oranları ile görüntüleri sınıflandırabilmesidir. Evrişimsel sinir ağı (ESA) görüntülerden özellikler çıkararak, görüntüleri ayırt edebilme ve sınıflandırma yeteneğine sahiptir.

Çalışmada özgün geliştirilen ESA ve transfer öğrenme kullanılarak geliştirilen ESA olmak üzere iki ayrı mimari tasarlandı. Özgün geliştirilen ESA ile mimarideki tüm katmanlar ve hiper parametreler sürekli güncellenerek, en iyi sonuç elde edilmeye çalışıldı. Özgün mimarinin geliştirilmesi ciddi zaman maliyeti getirdi ve hedeflenen test doğruluğu değerine ulaşamadı. Akciğer röntgen görüntüleri spesifik bir alan olması ilk bakışta transfer öğrenme yönteminin tercih edilmemesine neden oldu. Ancak çalışmada küçük veri seti kullanılması, transfer öğrenme yönteminde daha iyi bir performans sağladı. Transfer öğrenme yöntemi ile önceden eğitilen ağ ile katmanların ve hiper parametrelerin belirlenmesi için gereken zaman özgün geliştirilen ESA'ya göre büyük ölçüde azaldı. Transfer öğrenme modelinde AlexNet mimarisi güncellenerek, ek katmanlar eklendi. Önerilen ağ performansı iyileştirildi.

Veri setinin küçük boyutlu olması her iki mimari için de ilk test doğruluğu hedeflenen test doğruluğu için yeterli değildi. Her iki mimaride de eğitim ve test doğruluğu arasında önemli derecede farkın oluşması bunun sonucu aşırı uyum sorunu oluştu. Ağın performansını iyileştirmek amacıyla veri artırma, bırakma, L2 düzenleme gibi regülasyon yöntemleri uygulandı. Yine döndürme, eğme, yansıma gibi çeşitli veri artırma yöntemleri kullanıldı. Regülasyon ve veri artırma yöntemlerinin test doğruluğunu olumlu etkilediği görüldü. Önerilen ağların eğitim süresi göz önüne alındığında, donanım özelliklerinin özellikle ekran kartı performansı eğitim süresini oldukça hızlandırdığı görülmüştür.

Yeni tip hastalıkların küçük veri seti ile tespiti, erken müdahale imkânı ve yüksek doğruluk oranı ile uzmanlara destek olabilecek bir sistem geliştirilmiştir. 5 yaş altı çocuklarda uzman desteğiyle erken pnömoni tespiti sağlanarak, ciddi yaralanma ve ölümlerin en aza indirilmesi amaçlanmıştır.

1.3. Önceki Çalışmalar

Çocuklarda ciddi bir hastalık olan pnömoni tespiti üzerine literatürde derin öğrenme, makine öğrenmesi, yapay sinir ağları sıklıkla kullanılmıştır. Yine pnömoni tespitinde akciğer röntgen görüntüleri önemli bir yer tuttuğu görülmüştür. Bu görüntülerden pnömoni tespiti amacıyla uzmanlara yardımcı olabilecek otomatik bir sistemin geliştirilmesi üzerinde çalışmalar bulunmaktadır.

Fizman vd. (2000) çalışmalarında göğüs röntgen raporlarından akut bakteriyel pnömoninin otomatik tespiti için uzmanlar, doktorlar ve sıradan kişilerden oluşan bir deney grubu ile ikili karşılaştırmalarda, sonuçlar incelendiğinde bazı doktorlar ve Doğal Dil İşleme (NLP) sistemi arasında küçük farklılıkların bulunduğunu, NLP sistemi rapor üzerindeki pnömoni tanısında diğer deneklerden daha iyi performans gösterdiğini belirtmişlerdir (Fizman vd., 2000).

Matsuki vd. (2002) çalışmalarında yapay sinir ağları ile BT görüntülerinden akciğer kanseri teşhisi için yardımcı bir program önermiştir. Radyologlar ve yapay sinir ağı performansı kıyaslandığında, yapay sinir ağı modeli ile 0.951 tespit oranı elde edilirken radyologlar ise 0.831 tespit oranı ile yapay sinir ağlarından daha düşük performans elde edilmiştir. Yapay sinir ağı modelini kullanan radyologların tespit oranı ise 0.959'a yükseldiği görülmüştür (Matsuki vd., 2002).

Yapay sinir ağını kullanan radyologların pnömoni tespitindeki oranının yüksek olması, tıbbi kuruluşlarda yapay sinir ağı kullanan uzmanların önemini arttırmaktadır.

Parveen ve Sathik (2011) çalışmalarında, akciğer röntgeninde kemik; yüksek emilim (beyaz), doku; orta emilimde bir yerde (gri), Hava; düşük emilim (siyah) olarak görülmesine bağlı olarak bu renklerle pnömoni tespitinde bulunmuşlardır. Hasta zatürre olduğunda, akciğerler su veya balgamla dolar bu da radyasyonun emiliminin daha fazla olmasına neden olur. Denetimsiz öğrenme görüntü analizi, bulanık c-ortalama kümeleme algoritması ile akciğer bölgesindeki pnömoni ve normal kısımlar renklendirilmiştir. Kullanılan algoritma ile yapılan renklendirme, uzmanların pnömoni durumunu kolay ve doğru bir şekilde tespit etmesine yardımcı olacağı belirtilmiştir (Parveen ve Sathik, 2011).

Sousa vd. (2013) çalışmalarında çocuklara ait pnömoni tespiti için akciğer röntgen görüntüleri sınıflandırmak için üç makine öğrenimi sınıflandırıcısı Destek Vektör Makinesi (DVM), K-En Yakın Komşular ve Naive Bayes önermiştir. DVM ile çapraz doğrulama da kullanılarak %77 ile en iyi sonucu elde edilmiştir. Çapraz doğrulama yöntemi ile aşırı uyum olup olmadığı test edilmiştir (Sousa vd., 2013).

Anthimopoulos vd. (2016) çalışmalarında interstisyel akciğer hastalıklarını tanıma için derin ESA modeli önermişlerdir. ESA mimarileri karşılaştırıldığında LeNet, AlexNet ve VGG Net dokuların sınıflandırılması ve tespiti için önerilen ESA algoritmasının diğer algoritmalara göre % 85.61 doğruluk oranı ile daha başarılı sonuç verdiğini tespit etmişlerdir (Anthimopoulos vd., 2016).

Alakwaa vd. (2017) çalışmalarında akciğer kanseri tespiti için akciğer BT görüntüleri kullanılarak ESA önermişlerdir. LUNA veri setinde nodül tespiti için U-net ESA mimarisi kullanılmış, doğruluk oranı % 86.6 olarak tespit edilmiştir (Alakwaa vd., 2017).

Kermany vd. (2018) çalışmalarında pnömoni tespiti için ESA modeli ile çocuk akciğer röntgen görüntüleri kullanılarak viral ve bakteriyel pnömoni sınıflandırılması yapılmış %92,8 doğruluk oranında başarı elde etmişlerdir (Kermany vd., 2018).

Varshni vd. (2019) akciğer röntgen görüntülerinden pnömoni tespiti için Densenet-169 ESA modeli ve DVM sınıflandırıcı kullanarak, 0.80 Eğri Altındaki Alan (AUC) skoru elde edildi. Resnet-50, Densenet-169'a göre 0.7749 AUC skoru ile daha iyi sonuç vermesine rağmen C ve gama hiper parametresi uygulandığında Dense-net-169+DVM modelinin daha iyi AUC skoru verdiği sonucuna ulaşılmıştır (Varshni vd., 2019).

Gülgün ve Erol (2019)'a göre göğüs röntgen görüntülerinin sınıflandırılması amacıyla ESA, Veri Artırmalı ESA ve Transfer Öğrenimi derin öğrenme modelleri kıyaslanarak, %93,4 doğruluk ile veri artırmalı ESA modeli diğerlerine göre en başarılı sonucu vermiştir (Gülgün ve Erol, 2019).

Toğaçar vd. (2019) çalışmalarında pnömoni tespiti için akciğer röntgen görüntülerinin kullanıldığı ESA modelleyerek, farklı sınıflandırıcıların başarımlarını karşılaştırmaları yapılmış, destek vektör makineleri diğer sınıflandırıcılardan yüksek doğruluk oranı olan %95.8 başarı oranı elde etmiştir (Toğaçar vd., 2019).

Islam vd. (2019) X ışını görüntülerinden pnömoni tespiti için sıkıştırılmış algılama (Compressed Sensing) tabanlı derin öğrenme yöntemi kullanılarak, %97.34 tahmin doğruluğu tespit edilmiştir (Islam vd., 2019).

Chandra ve Verma (2020) çalışmalarında pnömoninin otomatik tespiti için akciğer grafi görüntülerinden akciğer segmentlerine ayrılmış İlgi Alanı (ROI) sınırlı özellik çıkarma yöntemi ile makine öğrenmesi yöntemi lojistik regresyon sınıflandırıcı kullanmış, %95.63 oranında doğruluk elde edilirken, ayrılmış ROI sınırlı özellik çıkarma yöntemi kullanılmadan ise %92.23 oranında doğruluk elde edilmiştir (Chandra ve Verma, 2020).

Rahman vd. (2020) çalışmalarında önceden eğitilmiş sinir ağları AlexNet, ResNet18, DenseNet201 ve SqueezeNet üzerinde üç sınıflandırma yapılmış, 1 (normal ve pnömoni), 2 (bakteriyel, viral pnömoni ve normal), 3 (bakteriyel ve viral pnömoni) sınıflandırma doğruluğu sırasıyla % 98, % 95 ve % 93,3 bulunmuştur (Rahman vd., 2020).

Hidayatullah ve Violina (2020) çalışmalarında yeniden boyutlandırma, kırpma aralığı, yakınlaştırma, dikey yansıma ön işlemleri ile veri artırılarak, VGG16, InceptionV3, VGG19, Xception, DenseNet121 ve ResNet50 mimarileri üzerinde doğruluk kıyaslaması yapılmış, VGG16 % 92.15 tüm mimariler içerisinde en yüksek doğruluğa sahip olduğu bulunmuştur (Hidayatullah ve Violina, 2020).

Hashmi vd. (2020) çalışmalarında röntgen görüntüleri üzerinde pnömoni tespiti için veri setinde 5156 eğitim verisi, 700 test verisi bulunması ile veri oranı dengesizliğinden dolayı veri kümesi karıştırılarak, eğitim ve test verisi şeklinde yeniden düzenlendi. Veri artırma teknikleri ile transfer öğrenme uygulanarak, çıkan sonuçlar tekrar ağırlıklar ile hesaplanıp ağırlıklı sınıflandırma ile 98.43% test doğruluğu elde edilmiştir (Hashmi vd., 2020).

Punn ve Agarwal (2021) alışmalarında akciğer röntgen görüntüleri kullanarak, COVID-19'un erken tanı ve teşhisine yardımcı olmak amacıyla ResNet-v2, DenseNet169, ve NASNetLarge ağıları üzerinde ikili ve çoklu sınıflandırma yapılmış ve NASNetLarge ağıının daha iyi performans gösterdiği tespit edilmiştir (Punn ve Agarwal, 2021).

Nino G. vd. (2021) alışmalarında COVID-19 pediyatrik hastaların (0-18 yaş) akciğer görüntüleme özelliklerini değerlendiren sistematik bir literatür araştırması yapıldı. COVID-19'lu çocuklarda göğüs BT bulguları, pediyatrik popülasyonda erken teşhis ve hızlı müdahale için yararlı olabileceği sonucuna ulaşıldı (Nino vd., 2021).



2. MATERYAL VE YÖNTEMLER

2.1. Pnömoni Hastalığı

Pnömoni, bağışıklık sisteminin patojenlere karşı yetersiz kalmasıyla patojenlerin akciğer dokusunda tahribat oluşturmalarıdır. Bakteri, virüs ve mantarlar gibi patojenler akciğerlerdeki hava keselerinin veya alveollerin sıvı ile dolması veya iltihaplanmasına neden olur, bunun sonucunda pnömoni oluşur. Pnömoni, akut olarak başlayan öksürükle birlikte akciğer röntgen görüntülerinin belirli bölgelerinde saptanan akciğer bulguları, dört günden fazla süren ateş, nefes darlığı ve/veya hızlı ve sık nefes alma gibi sorunların bulunduğu başka nedenlerle açıklanamayan hastalık olarak tanımlanabilir (Şen ve Özhan, 2017). Pnömoni genellikle damlacık yoluyla bulaşan insan kaynaklı bir hastalıktır. Genellikle kış ve ilkbahar aylarında görülür.

Dünya genelinde çocukluk çağındaki ölümlerin başında pnömoni gelmektedir. Dünya sağlık örgütü verilerine göre her yıl 0 – 5 yaş arası 155 milyon çocuğa pnömoni tanısı konulmakta, 20 milyona yakını hastanede tedaviye devam etmekte, 2 milyondan fazla çocuğun ölümüne neden olmaktadır (Rudan, 2008; Wardlaw vd., 2006).

1-3 aylık çocuklarda bakteriyel pnömoni viral pnömoniye kıyasla daha yaygındır. Bu çocuklarda en yaygın görülen ölümcül bakteri türü pnömokok pnömonidir. Bu bakterinin neden olduğu yuvarlak pnömoni çocuklarda yetişkinlere göre daha fazladır (Eggli ve Newman, 1993). Üç ay- beş yaş arasındaki çocuklarda ise viral pnömoni daha fazla görülür (Durmus, Adak ve Onel, 2008). Virüslerden kaynaklanan pnömoniler genellikle bakteriyel pnömoniye de sebep olmaktadır. En yaygın görülen virus, respiratuar sinsisyal virüstür (RSV) (JUVÉN ve diğerleri, 2000). Tablo 2.1’de yaşlara göre sık rastlanan pnömoni çeşitleri verilmiştir (Durmus ve diğerleri, 2008).

Tablo 2.1. Beş yaş altı çocukların pnömoni etkenleri (Durmus vd., 2008).

Yaş	Sık Rastlanan Patojenler	Kaynak
Yeni doğan dönemi	Escherichia coli	Bakteri
	B grubu streptokoklar	
	Listeria monocytogenes	
1-3 ay	Chlamydia trachomatis	Bakteri
	Streptococcus pneumoniae	
	Adenovirüs	Virüs
	Influenza virüsü	
	Parainfluenza virusü (tip 1-3)	
	RSV	
3 ay – 5 yaş	Chlamydia pneumoniae	Bakteri
	Mycoplasma pneumoniae	
	Streptococcus pneumoniae	
	Adenovirüs	Virüs
	Influenza virüsü	
	Parainfluenza virüsü	
	Rinovirüs	
	RSV	

Bakteriyel pnömoni genelde sağ üst lobda yoğunlaşma gösterirken, viral pnömoni her iki akciğerde daha yaygın olarak meydana gelir. Bakteriyel pnömoni, acil antibiyotik tedavisi için derhal sevk gerekirken viral pnömoni için destekleyici bakımla tedavi edilir. Bu nedenle doğru ve erken teşhis şarttır. Teşhiste anahtar unsurlardan biri röntgen görüntüleridir çünkü göğüs röntgeni rutin olarak alınır ve farklı pnömoni türleri arasında ayırım yapılmasına da yardımcı olabilir.

Günümüzde bağışıklama politikaları ve antibiyotiklerin yaygın kullanımı ile infeksiyon hastalıklarında ölümler azalırken toplumda gelişen pnömoniler halen yüksek riskli bir hastalık ve ölüm nedenidir (URL-4, 2021). Toplum kökenli pnömoniler (TKP) çocukları ciddi bir şekilde etkileyen tehlikeli bir akciğer enfeksiyonudur. Antibiyotik ve yardımcı tedavilere rağmen ölüm oranları ciddi seviyededir (Özlü ve diğerleri, 2009). Toplum kökenli pnömoni de tanı ve sürecin takibi için yaygın olarak göğüs radyografisi kullanılır ve genellikle diğer görüntüleme yöntemlerinin kullanılmasını gerektirmez (Tanaka vd., 1996). Yeterli semptom gösteren bireyler için, akciğer grafisinde infiltrasyon görülmesi pnömoni tespiti için kâfidir (Şen ve Özhan, 2017). TKP’de tanı ve tedaviyi planlamak amacıyla ilk aşamada akciğer röntgen görüntüsü çekilmesi önerilir. Bewick vd. (2010) çalışmalarında akciğer röntgen görüntüleri erken çekilen grubun hastanede kaldığı süre, geç çekilen gruba göre çok daha düşük bulunmuş olup, erken tedavinin önemini göstermiştir (Bewick vd., 2010).

Pnömoni tanısında akciğer grafisi önemli bir yer tutmaktadır. 5 yaş altındaki düşük riskli hastalarda akciğer grafisinin alternatifi olarak, titiz bir klinik takip tercih edilebilir (Neuman vd., 2011).

2.1.1. Pnömoni Belirtileri

Pnömoni hastalığına yakalanan bebek ve okul öncesi çocuklar genellikle öksürük ile başvurur. Kusma, göğüs ağrısı ve karın ağrısı da görülebilir. Bazen ateş ve taşipne, diğer birkaç solunum semptomuyla birlikte görülebilir (Toikka vd., 1999). Pnömoniye neden olabilecek semptomlar arasında nefes darlığı, göğüste takırdama, gürültülü nefes alma, beslenme güçlüğü, ateş, hızlı nefes alma yer alır (Margolis ve Gadomski, 1998).

Kanadalı bir görev gücü 1997 yılında literatürü inceleyerek pediatrik pnömoni teşhisi için kılavuzlar yayınladı. Solunum sıkıntısı, taşipne, çatırtılar ve azalmış nefes sesleri belirtilerinin her birinin yokluğu pnömoniyi doğru bir şekilde dışladığı sonucuna varmışlardır (2. düzey kanıt, %100 özgüllük) (Jadavji vd., 1997).

Aşağıdaki durumlar pnömoni belirtisi içerebilir: (URL-3, 2020)

- Yeşilimsi, sarı ve hatta kanlı mukus üretebilen öksürük
- Ateş, terleme ve titreyen titreme
- Nefes darlığı
- Hızlı, sık nefes
- Derin nefes aldığınızda veya öksürdüğünüzde kötüleşen keskin veya saplanan göğüs ağrısı
- İştahsızlık, düşük enerji ve yorgunluk
- Özellikle küçük çocuklarda bulantı ve kusma

2.1.2. Pnömoni Teşhisi

Pnömoni tanısı koyabilmek için balgam, plevral sıvı veya diğer biyolojik materyalin incelenmesi, solunum sekresyonları, kan kültürü gibi birtakım prosedürler gereklidir. Buna rağmen serolojik kan testleri, pnömoniye tanısı koymak için sınırlı klinik değere sahiptir (Lichenstein vd., 2003). Pnömonilerin birçoğunda, ayrıntılı tanı testleri uygulandığında dahi, hastaların % 33-45'inde pnömoniye neden olan organizma tespit edilemez (Franquet, 2001). Radyografik bulgular tanıyı daraltmada, tanıya yardımcı olmada etkili olabilmektedir (Franquet, 2001).

Uzmanlar zatürre durumunda, aşağıdaki testlerden birkaçını yapabilir(URL-3, 2020, s. 3).

- Pnömoninin oluşup oluşmadığı, ne boyutta ve nerede oluştuğunun teşhis edilmesi için genellikle akciğer röntgen görüntüleri kullanılır.
- Kan testleri, enfeksiyonu anlama ve mikrobu tespit etmek amacıyla yapılır.
- Kandaki oksijen miktarı için nabız oksimetresi kullanılır. Pnömoni, kana yeterince oksijen taşımamasını engelleyebilir.

Uzmanlar hastaneye yatış gerçekleştiğinde, ileri boyutlarda semptomlar ve kronik rahatsızlık varsa, pnömoni teşhisi için başka testler yapabilir (URL-3, 2020);

- Kan gazı testi, hastalığın ilerleyen boyutlarda olması ile birlikte uzmanlar tarafından genellikle kan oksijen seviyesi ölçülmesi gerekebilir.
- Balgam testi, pnömoniye neden olan mikropların tespit edilmesi için derinden gelen bir öksürükle bir balgam numunesi verilebilir.
- Kan kültürü, bakteriyel bir enfeksiyonun kanda bulunup bulunmadığının tespiti ile birlikte mikrobun da tespit edilmesine yardımcı olur.
- Polimeraz zincir reaksiyonu (PCR) testi, alınan numunelerde pnömoniye neden olan mikropların olup olmadığını kontrol eder.
- Bronkoscopi, solunum yollarını görmek, akciğer hastalıklarını tanı ve tedavi etmek amacıyla kullanılır.
- Göğüs bilgisayarlı tomografi (BT) taraması ve akciğer röntgen görüntüleri, pnömoninin akciğere ne kadar yayıldığı görülebilir.
- Plevral sıvı kültürü ile plevral zarlar arasındaki sıvı artışı tespit edilerek pnömoninin varlığı anlaşılabilir.


2.1.3. Akciğer Röntgen Görüntülerinde Pnömoni

Akciğer röntgen çekim sayısı, kişinin klinik değerlendirme süreci sonucu değişiklik gösterebilir. Pnömoni tanısı sonucu tedavi süreci bittiğinde bir kez yeterli olmaktadır. Tanıya rağmen tedavide olumsuz yanıt alınması durumunda hastanın akciğer grafileri ve toraks bilgisayarlı tomografi çekilmesi gereklidir (Cunha, 2000).

Akciğer röntgen görüntülerinde pnömoniler;

- Lober (segmenter, multilober)
- Bronko pnömoni
- Interstisyel pnömoni olarak sınıflandırılabilir (Şen ve Özhan, 2017)

Şekil 2.1’de pnömonili akciğer grafileri gösterilmiştir. Lober pnömoni, radyolojik olarak belirlenen pnömoninin akciğer dokusunun bir veya daha fazla lobunda görülmesi olarak tanımlanabilir. Resim-1a’da kalp kenarını silmiş sağ orta lob pnömonisi, resim 1b’de üst lob pnömonisi gösterilmiştir. Resim 1c ve 1d’de görülen interstisyel pnömoniler her iki akciğerde lob sınırı göstermeyen, retikülodüğümler gölgeleri göstermektedir. Resim 1e’de pnömoni çeşitlerinden multilober pnömoni görülmektedir. Bronko pnömoniler çoğu zaman her iki akciğerde, lob sınırı dışında, kısmen yoğunlaşmış ve yamalı görünümündedirler. (Şen ve Özhan, 2017).



Şekil 2.1. Pnömonili akciğer grafileri (Şen ve Özhan, 2017)

2.2. Derin Öğrenme


Yapay zekâ, insan beynindeki sinaps ve nöronlardan ilham alınarak, geliştirilen bir modeldir. Yapay zekâ ile öznitelik çıkarma, tanıma, sınıflandırma, ayırt etme gibi yetenekleri bilgisayarların öğrenmesi sağlanır. Yapay zekâ karmaşık problemleri çözebilir, modele deneyim kazandırılarak performansı geliştirebilir.

Yapay zekânın en yaygın yöntemlerinden yapay sinir ağları ile birçok problem çözülebilmekteydi ancak ilerleyen yıllarda veri boyutunun artması, karmaşık problemlerin ortaya çıkması, gizli katman ve düğüm sayısını arttırdığından hesap gücüne duyulan ihtiyaç donanım sınırlılığına neden olmuştur. 2000’li yılların başında bu alanda oldukça ciddi bir duraklama yaşanmıştır (Şeker vd., 2017). Donanım ve ekran kartlarındaki gelişmeler işlem gücü ve zaman maliyetini düşürdüğünden yapay sinir ağları yeniden popüler olmaya başlamıştır (Schmidhuber, 2015).

Yapay zekânın bir alt alanı özellikle karar verme süreçlerinde kullanılan makine öğrenmesi alanıdır. Makine öğrenmesi genel olarak denetimli, denetimsiz ve takviyeli öğrenme olmak üzere üç çeşittir. Denetimli öğrenme ile etiketlenmiş veriler ile eğitim yapılarak, yeni gelen verilerden doğru sonuçlar üretilmesi sağlanır. Denetimsiz öğrenmede ise denetimli öğrenmenin aksine etiketlenmiş veri bulunmamaktadır, hiç görmediği veriler üzerinde benzerlik, farklılık gibi özelliklerine göre gruplandırma yapılmaktadır. Takviyeli öğrenme ile sistemin doğru kararları ödüllendirilir, yanlış kararları cezalandırılır. Makine öğrenmesi yaklaşımı kullanılırken özellik vektörü çıkarılması gerekmektedir. Uzman kişilere ihtiyaç duyulan özellik çıkarma işlemi için veri üzerinde önışlemler, boyut küçültme, özellik belirleme vb. işlemler maliyeti artırmaktadır. Bu dezavantajdan kurtulabilmek için yapay zekâ ile veriden özellik çıkarılması daha az maliyetli ve daha kolay bir işlemdir. Bu kısımda derin öğrenme kavramı ile karşılaşılacaktır.

Makine öğrenmesinin alt dallarından birisi de derin öğrenme yöntemidir. Derin öğrenme, bilgisayarların öğrenme sürecinde verilerden probleme özgü özellikler çıkarılarak oluşan çok katmanlı bir yapıdır. Derin öğrenme ile elle çıkarılan özellikler yerine probleme özgü veriyi en iyi tanımlayan öznitelikleri kendisi belirlemektedir.

Derin öğrenmenin diğer yaklaşımlara kıyasla daha fazla veri ile çalışabilmesi, daha çok işlem gücü, uzman ihtiyacı olmadan özniteliklerin belirlenmesi gibi özellikleri onu daha fazla öne çıkarmaktadır. Şekil 2.2’de derin öğrenme modeli; akciğer röntgen görüntüsünün olduğu giriş katmanı, yuvarlak şekillerle ifade edilen perseptronlar; öznitelik çıkarma ve sınıflandırma işlemini göstermektedir.



Şekil 2.2. Derin öğrenme modeli

2.2.1. Derin Öğrenme Modelleri

Günümüzde derin öğrenme ile birçok model geliştirilmiştir. Bazı derin öğrenme modelleri aşağıda belirtilmiştir (Doğan ve Türkoğlu, 2019);

- Evrişimsel Sinir Ağı (ESA, CNN - Convolutional Neural Networks)
- Tekrarlayan Sinir Ağı (RNN - Recurrent Neural Networks)
- Uzun-Kısa Süreli Hafıza (LSTM- Long Short-Term Memory)
- Kısıtlı Boltzmann Makinesi (RBM- Restricted Boltzmann Machine)
- Derin İnanç Ağı (DBN- Deep Belief Network)
- Derin Oto-Kodlayıcılar (AE- Auto Encoder)

2.2.1.1. Çok Katmanlı Algılayıcılar

Tek katmanlı algılayıcıların doğrusal olmayan problemleri çözmemesi, çok katmanlı algılayıcıların ortaya çıkmasına neden olmuştur. Çok katmanlı algılayıcılar için en az üç katman gereklidir. İlk katman girdi katmanı, son katman çıktı katmanıdır. Ortada bulunan en az bir veya daha fazla bulunan katmanlar ise gizli katmandır. Gizli katman sayısı kritik öneme sahiptir. Birkaç gizli katmanı bulunan ağlar yalnızca doğrusal problemleri çözebilirken, karmaşık problemleri çözmede daha başarısızdır. Gizli nöron sayısının artması ağın genelleştirme yapmasını önlemektedir. Ayrıca gizli katman sayısının artması donanım ihtiyacı ve zaman maliyetine de neden olabilmektedir. Çok katmanlı algılayıcılarda ağın eğitimi iki yönlüdür; İleri yayılım ve Geri Yayılım.

- İleri yayılım; sisteme verilen girdi ilk ağırlıklar ile çarpılıp, elde edilen değerler toplanarak, “bias” değeri eklenir. “Net” değeri hesaplandıktan sonra aktivasyon fonksiyonu sonucu bir sonraki nörona iletir. Bu işlemler sürekli tekrar edilerek, sonunda çıktı katmanından çıktılar elde edilir.

- Geri yayılım ve Ağırlık iyileştirme; Çıktılardaki hatalar temel alınarak sinir ağındaki ağırlıkların yeniden güncellenmesi için kullanılır. Asıl sonuç ve istenilen sonuç arasındaki hata miktarını dikkate alarak, yapılan iyileştirmedir.

2.2.1.2. Evrişimsel Sinir Ağı


ESA, çok katmanlı bir algılayıcı çeşittir. Büyük veri ile çalışabilme, özellik çıkarma, hesaplama gücü ve sınıflandırma başarısı ile derin öğrenme yöntemlerinden ESA dikkat çekmektedir. LeCun vd. (1989) ilk kez el yazısıyla posta kodu tanıma için ESA'yı kullandı. ESA'nın öncekilere kıyasla en büyük avantajı, ilgili özellikleri herhangi bir insan denetimi olmaksızın tespit edebilmesi onu ön plana çıkarmaktadır (LeCun vd., 1989).

ESA'lar, tam bağlantılı ağlardan hesaplama açısından daha verimli çalışmaktadır. Ağın performansını artırmak amacıyla çok fazla deneme imkânı olması ve ağın hiper parametrelerinin ayarlanması daha kolaydır. Büyük miktarda veri ile çalışabilmesi sonucunda en güçlü modellerden biri haline gelmiştir. Görüntü tanıma, ses tanıma, tıbbi tanı ve sınıflandırma gibi alanlarda literatür incelendiğinde önemli başarılar elde etmiş bir ağıdır. Görüntü işleme alanında en başarılı sonuçlar elde edilmiştir. Görüntü işlemenin yanında doğal dil işleme problemleri, ilaç keşfi, akıl zekâ oyunları içinde kullanılmaktadır.

MNIST ve NORB veri kümeleri üzerinde denenen bir çalışmada ESA ile, öğrenme için gerekli zaman maliyetinin diğer yöntemlere göre daha az olduğu ve çalışmanın o döneme kadar ki en başarılı sonucu verdiği belirtilmiştir (Ciresan vd., 2011). Görüntüleri doğru bir şekilde sınıflandırmak ve tespit etmek için yarışılan ImageNet Yarışması'nda (2014), en iyi dereceleri elde eden ekiplerin tamamı ESA algoritmaları kullanmışlardır (Girshick vd., 2014). Problemin karmaşıklığı nedeniyle yapay zeka için en zorlu oyun olarak bilinen Go oyununda ESA tabanlı AlphaGo ilk kez profesyonel bir sporcuyla yenebilen program olmuştur (Lee ve diğerleri, 2016).

Evrişimsel Sinir Ağı Katmanları

ESA katmanları, şekil 2.3'de sırasıyla giriş, evrişim, havuzlama ve tam bağlantılı katmanlardan oluşmaktadır.



Şekil 2.3. Evrişimsel sinir ağı genel mimarisi

Giriş Katmanı: ESA'nın ilk katmanıdır. Veri setindeki görüntü, ses ve diğer verilerin ağı verildiği katmandır. Giriş katmanında örneğin görüntü verildiğinde, bilgisayar bu veriyi anlamlandırması için görüntüyü sayısal değerlere çevirmesi gerekir. Pnömoni veri setindeki görüntülerden örnek verecek olursak, 322 piksel genişlik, 322 piksel yüksekliği olan siyah beyaz yani gri seviye olan görüntüler 1 kanalı ile ifade edilip bilgisayar da $[322 \times 322 \times 1]$ matris şekline dönüştürülür. Veri setinde renkli bir görüntü söz konusu olduğunda, $[322 \times 322 \times 3]$ şeklinde matris olarak ifade edilir. Renkli görüntüler 3 kanal ile gösterilmektedir, kırmızı, yeşil ve mavi renkleri ifade eder.

Görüntünün giriş boyutu büyük seçilmesi, donanım yetersizliğine neden olmasıyla birlikte ağı eğitme süresini de olumsuz etkileyebilmektedir. Bununla birlikte görüntülerde daha fazla öznetelik çıkaracağından ağı performansını olumlu etkileyebilir. Giriş boyutu küçük seçilirse, daha az öznetelik belirleneceğinden ağı performansı düşebilir. Bu değerlendirmeler göz önüne alınarak, giriş boyutu ağı performansına göre uygun bir değer seçilmelidir.

Evrişim Katmanı: Görüntüler gibi girdilere sahip problemlerin çözümü için yapay sinir ağları ile modeli eğitmek, çok büyük parametreler üzerinden işlem yapmasına neden olabileceği gibi, kimi zaman modelin eğitiminin mümkün olmasını da engellemektedir. Geleneksel yapay sinir ağlarındaki bu problemi en aza indiren evrişim katmanı son derece önemli bir katmandır. Evrişim işlemi ile özellikler çıkarılırken, modelin karmaşıklığı da azalmaktadır.

Evrişim işlemi görüntüyü oluşturan dikdörtgensel bir matris üzerinde yapılır. Bu matris üzerinde farklı özellikleri çıkaran filtreler kaydırılarak yeni bir matris elde edilir. Bu oluşan matris ile ESA'nın en önemli işlevi özellik haritası çıkarılmaktadır. Görüntüye 2×2 , 3×3 , 5×5 , 7×7 gibi filtrelerle birlikte, adım sayısı, dolgu gibi işlemleri uygulayarak evrişim işlemi yapılır.

Evrişim işlemindeki üç önemli hiper parametre filtre boyutu, adım ve kanal sayısıdır. Evrişim işlemi giriş boyutu üzerinden sol köşeden başlanarak giriş matrisinde tüm alanlar gezinir. Bu işlem sırasında evrişim filtresine denk gelen girdi ağırlıkları ile evrişim filtresinin ağırlıkları çarpılarak, toplanır. Bu işlem matrisin tüm elemanları tarafından tekrarlanır. Her bir kanal için elde edilen çarpımların toplamı alınarak, çıktı verisinde karşılık gelen bu toplam değere “bias” değeri eklenerek evrişim işlemi tamamlanır.

Filtre: Filtreler ile öğrenilmesi gereken görüntü üzerinden tekrar tekrar geçileceğinden öğrenmeyi olumlu etkileyebilir. Filtre dikey ve yatay olarak hareket ettirilir ve her bölge için hesaplama tekrarlanır ve öznitelikler oluşur (Murphy, 2012). Filtre, görüntünün sol üst kısmından başlayarak soldan sağa doğru adım sayısına göre hareket eder, görüntünün kenarına geldiğinde aşağı satıra geçerek tüm görüntü gezilir. Seçilecek filtre, görüntü ile karşılaştırıldığında benzerlik olduğunda bu bölgelerde daha yüksek değerlerde, benzerlik olmadığında daha düşük değerlerde olacaktır. Giriş görüntüsü üzerinde çok farklı filtreler uygulanması ile farklı özellikler öğrenilir. Evrişim katmanında kullanılabileceği gibi havuzlama katmanında da kullanılmaktadır.

Adım: Adım sayısı, girdi görüntüsünde filtrenin soldan sağa ve yukarıdan aşağı ilerleme miktarını ifade etmektedir. Evrişim ve havuzlama katmanlarında kullanılmaktadır. Adım sayısı arttıkça matrisin boyutu küçülmektedir. Adım sayısının artıp azalması çıkış matrisinin boyutunu etkilemektedir.

Dolgu: Çıkış matrisinin boyutunu kontrol etmek için dolgu işlemi uygulanır. Dolgu ile giriş ve çıkış matrisi aynı boyutta olması sağlanır. Matrisin dış çevresine ekstra pikseller eklenir, genellikle 0 değerlerinden oluşur. Giriş katmanı veya sonraki katmanlarda ağırlık köşe ve kenarlardaki öğrenimini artırmak amacıyla kullanılır.

Aktivasyon Katmanı: Evrişim katmanından sonra gelen aktivasyon katmanı ile nörona ulaşan net bilgi, aktivasyon fonksiyonu ile hesaplanır, amaç üretilen çıktıyı sınırlamak ve ağırlık daha hızlı öğrenmesini sağlamaktır. Tanh, Sigmoid, ReLU gibi birçok farklı aktivasyon fonksiyonu vardır.

Havuzlama Katmanı: Her evrişim katmanından sonra görüntüde havuzlama işlemi yapılarak, ortalama ya da maksimum değere bakılarak havuzu tek bir değere düşürür. Amaç ise matrisin boyutunu küçültmek ve parametre sayısını düşürmektir. Bu durum eğitilen ağırlık donanım gereksinimleri ve eğitim süresini de etkilemektedir.

Havuzlama katmanı iki farklı şekilde yapılır. Maksimum havuzlama ile matristeki en büyük değer alınır. Ortalama havuzlama ile matristeki tüm ağırlıkların ortalama değeri alınır.

Tam Bağlantılı Katman (Fully Connected Layer): Önceki katmanlardan gelen öznitelikler burada tek boyutlu bir vektör şekline getirilir, buna düzleştirme (Flattening) denir. Bu katman öznitelik çıkarma işlemi için kullanılmaz, sınıflandırma amacıyla kullanılır. Her nöron bir sonraki katmandaki tüm nöronlara bağlıdır, tam bağlantılı katman adı da buradan gelmektedir. Bundan dolayı giriş nöronu tüm nöronları etkilemektedir. Tek tam bağlantılı katman kullanılacağı gibi birden fazla tam bağlantılı katmanda kullanılabilir. Tam bağlantılı katmana kadar olan diğer katmanlarda parametre sayısının fazla olması bu katmanda yüksek işlem gücü maliyeti getireceğinden matrisin yükseklik ve genişlik değerleri azaltılırken, kanal sayısı arttırılmalıdır (Kuş, 2019).

Evrişimsel Sinir Ağının Eğitilmesi

ESA'nın eğitim adımları aşağıda gösterilmektedir (Özkan ve Ülker, 2017);

Adım 1. ESA'yı oluşturan evrişim katmanı, havuzlama katmanı, tam bağlantılı katman ve sınıflandırma katmanı kaç adet olacağı ve nasıl sıralanacağı belirlenir.

Adım 2. Model tasarlandıktan sonra evrişim ve havuzlama katmanlarında önemli bir yere sahip filtre boyutları, filtre sayısı, dolgu ve adım miktarı parametreleri belirlenir.

Adım 3. Modele eğitim veri setinden bir görüntü verilerek ağın eğitimi başlatılır. Bu görüntü evrişim, havuzlama, tam bağlantılı katmanlarda ilerleyerek sonuç değeri üretilen aşama ileri besleme diye adlandırılarak eğitimin birinci kısmı tamamlanır.

Adım 4. Ağda gerçekleşen sonuçlar ile beklenen sonuçların farkı ile hata değeri hesaplanır.

Adım 5. Elde edilen hata değeri ile ağdaki bütün ağırlıklarda güncelleme yapılmaktadır. Bu işlem için Geriye Yayılım Algoritması (GYA) kullanılır ve eğitimin ikinci kısmını oluşturmaktadır. GYA hatayı minimuma düşürmek için Stokastik Gradyan İniş (SGİ) optimizasyon algoritması kullanılır. Ağırlıkların güncellenmesiyle hata miktarı düşürülmesi, dolayısıyla ağın tahmin başarısının arttırılması amaçlanmaktadır. ESA'larda ağırlıkların güncellenmesi için farklı gradyan tabanlı optimizasyon algoritmaları kullanılmaktadır. GYA'da her bir ağırlığın değeri Gradyan iniş yöntemine göre hesaplanırken kısmi türev kullanılır ve Zincir kuralına göre yapılır.

Adım 6. Eğitim kümesindeki bütün görüntüler için Adım 3-5 tekrar edilir.

Epok Süresi: Model eğitilirken, ağırlıkların güncellemek için tüm eğitim veri setini kullandığı yinedir.

Evrişimsel Sinir Ağında Kullanılan Hiper Parametreler

Veri setinin boyutu, katman sayısı, filtre sayısı, filtre boyutu, adım sayısı, dolgu miktarı, tam bağlantılı katman sayısı ve her katmandaki nöron sayısı, aktivasyon ve sınıflandırma fonksiyonları, öğrenme katsayısı, normalizasyon ve düzenleme işlemleri, optimizasyon yöntemleri gibi hiper parametreler ESA'ların başarısını doğrudan etkilemektedirler.


Aktivasyon Fonksiyonları

Sigmoid aktivasyon fonksiyonu: Fonksiyon girdisini 0 ile 1 arasında değer almasını sağlayan doğrusal olmayan sürekli bir fonksiyondur. Şekil 2.4'de grafiğin sağ ve solundaki uç değerlerde türevin 0'a yaklaştığı görülmektedir. Bu gradyan iniş parametrelerinin çok yavaş güncellemesine ve farklı yönlerde 0'a yaklaşması da optimizasyonu zorlaştırmaktadır. Denklem 2.1'de sigmoid aktivasyon fonksiyonu gösterilmektedir.

$$F(net) = \frac{1}{1+e^{-net}} \quad (2.1)$$

Bu eşitlikte;

net; Perseptron'un çıkış değeridir.




Şekil 2.4. Sigmoid fonksiyonu

Tanh (Tanjant Hiperbolik) aktivasyon fonksiyonu: -1 ile 1 aralığında değer üretir. Sigmoid fonksiyonunda olduğu gibi grafikte görülen türev alındığında degrade iniş ile farklı yönlerde 0'a yaklaşması optimizasyonu zorlaştırmaktadır.

Şekil 2.5’da Tanh fonksiyonu ifade edilmiştir. Yine değerlerin uç noktalarda olması ağırlıkların güncellemesini yavaşlatır. Denklem 2.2’de Tanh aktivasyon fonksiyonu gösterilmiştir.


$$F(net) = \frac{1-e^{-2(net)}}{1+e^{-2(net)}}, \quad -1 < F(net) < 1 \quad (2.2)$$



Şekil 2.5. Tanh fonksiyonu

ReLU aktivasyon fonksiyonu: Fonksiyona gelen girdi 0’dan küçük ve eşitse 0, büyükse girdinin kendisini çıktı olarak üretir. Sigmoid ve tanh fonksiyonlarına göre daha hızlı hesaplanır, eğitim sürecini hızlandırır. Gradyan hesaplarında şekil 2.6’daki grafikte görülen değerlerin 0 olduğu kısımda, türevinde 0 olması fonksiyonun olumsuz yanını göstermektedir. ReLU aktivasyon fonksiyonu denklem 2.3’de gösterilmektedir.

$$F(net) = \begin{cases} net & net > 0 \\ 0 & net \leq 0 \end{cases} \quad (2.3)$$




Şekil 2.6. ReLU fonksiyonu

Leaky ReLU aktivasyon fonksiyonu: ReLU’nun sıfır bölgesindeki öğrenmenin yaşandığı zorluğu giderilmesi amaçlanmaktadır.

Gradyan iniş hesabında 0 bölgesinde de türev alındığında öğrenme devam edecektir. Bu fonksiyonun kullanımı gizli katmanlarla sınırlandırılmıştır. Şekil 2.7’de Leakly ReLU fonksiyonu ifade edilmiştir.

$$F(net) = \begin{cases} net & net > 0 \\ 0.01x & net \leq 0 \end{cases}$$




Şekil 2.7. Leakly ReLU fonksiyonu

Softmax: Ağın birden fazla sınıfta sınıflandırma yapabilmek için çıkış aktivasyon fonksiyonu olarak kullanılır. Denklem 2.4’de formüle edilmiştir. Şekil 2.8’de softmax fonksiyon grafiği gösterilmiştir.

$$p = \begin{pmatrix} p_1 \\ p_2 \\ \vdots \\ p_n \end{pmatrix} \quad p_i = \frac{e^{x_i}}{\sum_{j=1}^n e^{x_j}} \quad (2.4)$$

Bu eşitlikte;

p; Çıkış olasılık vektörü



Şekil 2.8. Softmax fonksiyonu

2.2.2. Regülasyon Yöntemleri

Geliştirilen derin öğrenme ağında test doğruluğunun eğitim doğruluğuna göre daha düşük çıkması, ağın problemi ezberlemesi (Overfitting), veri yetersizliği regülasyon yöntemlerinin geliştirilmesine neden olmuştur. Regülasyon yöntemleri L1/L2 düzenleme, bırakma katmanı, veri artırma ve erken durdurma şeklinde dört başlıkta ele alınmıştır.

2.2.2.1. L1 / L2 Düzenleme (L1/L2 Normalization)

Eğitim sırasında verilerdeki aşırı uyumu önlemek amacıyla kullanılır. Gereksiz karmaşıklığı azaltır. L1 düzenleme yönteminde ağırlıkların mutlak değerlerinin toplamı eklenir. Elde edilen toplamlar düzenleme katsayısı (λ) ile çarpılıp, toplam hata fonksiyonuna eklenir. L2 düzenleme, veri kümesi değerlerini her satırda karelerin toplamı her zaman 1'e kadar olacak şekilde değiştiren normalleştirme tekniğidir. En küçük kareler ile de adlandırılmaktadır. Denklem 2.5'de L2 düzenleme formülü gösterilmektedir.

$$|W|^2 = \sum_i^n W_i^2 \quad (2.5)$$

Bu eşitlikte;

W; Sinir ağındaki ağırlığı ifade etmektedir.

2.2.2.2. Bırakma Katmanı (Dropout)


Google tarafından geliştirilen ağıdaki aşırı uyumu azaltmak için kullanılan yöntemdir. Sinir ağına eğitim uygulanırken gizli katmanlardaki bazı nöronlar rastgele çıkarılır, ağıın ezberlemesi önlenir. Çıkış katmanına uygulanmaz.

2.2.2.3. Veri artırma (Data Augmentation)

Ağıın eğitimi için yeterince veri bulunmadığında, eğitim ve test doğruluğun artırılması amacıyla kullanılır. Veriler üzerinde kontrast, parlaklık, döndürme, yansıma, büyütme-küçültme gibi birtakım yöntemler uygulanarak veri artırılabilir. Eğitim verisinin artırılması genellikle ağıın ezberlemesini azaltarak, test doğruluğunu artırmaktadır.

2.2.2.4. Erken Durdurma (Early Stopping)

Eğitim verisinde doğruluk artarken, test verisinde doğruluğun azalması ağıın ezberlemesine yol açmaktadır. Erken durdurma işleminde epok sayısı sınırsız olup, ağıın ezberlemeye başladığı anda eğitimin durdurulmasıdır. Durdurma işlemi validasyon doğruluğu referans alınarak yapılmaktadır. Şekil 2.9'da erken durdurma işlemi gösterilmektedir.



Şekil 2.9. Erken durdurma

2.2.3. Optimizasyon Algoritmaları

Yapay sinir ağlarında, ağırlıkların iyileştirilmesi öğrenmenin önemli bir adımıdır. Beklenen değer ile gerçek değer arasında hesaplamalar yapılarak hata hesaplanır, hata miktarına göre ağırlıklar güncellenir. Ağırlıkların iyileştirilmesi için GYA (Back-Propagation) kullanılır.

GYA ile sinir ağındaki her bir ağırlığın, hesaplanan hataya olan etkisini hesaplamak için gradyan tabanlı Stokastik Gradyan Azalma (Bottou, 2010), RMS-Prop, Adam (Kingma ve Ba, 2014) ve Adadelta (Zeiler, 2012) algoritmaları kullanılmaktadır.

2.2.3.1. Gradyan Azalma (Gradient Descent)

Eğitim verisinde rastgele alınan değerlerle başlayarak, global minimum değerine ulaşmayı amaçlar. Maliyet fonksiyonunu en aza indirgeyerek, küçük adımlarla minimum noktaya yaklaşma yöntemidir. Adım büyüklüğünü, adım katsayısı çarpanı belirler. Mevcut gradient'i ($\partial L / \partial w_t$), öğrenme katsayısı (a) ile çarparak mevcut ağırlığı (w_t) güncellemektedir. Denklem 2.6'da gradyan azalma ifade edilmiştir.

$$w_{t+1} = w_t - a * \frac{\partial L}{\partial w_t} \quad (2.6)$$

Bu eşitlikte;

w_{t+1} ; Sinir ağındaki bir sonraki ağırlık değeri

w_t ; Sinir ağındaki ağırlık değeri

a ; Öğrenme katsayısı

∂L ; Kayıp fonksiyonu

∂w_t ; Sinir ağındaki ağırlık değerinin türevini temsil etmektedir.

2.2.3.2. Momentumlu Gradyan Azalma (Gradient Descent with Momentum)

Gradyan azalma yöntemlerinde öğrenme adımlarının en iyi sonuca doğru hızlı hareket etmesi ve ulaşılmak istenen hedefe daha yakın olması beklenir. Atılan öğrenme adımları en iyi sonuca her zaman ulaşmayabilir. Bu sorunun çözümü için momentumlu gradyan azalma yöntemi önerilmiştir (Ruder, 2016; Qian, 1999). Geçmişteki öğrenme adımların ortalama hızı bir sonraki öğrenme adımının hızını sınırlamak için kullanılır. Bu yöntem ile üstel olarak azalan geçmişteki gradyanların dinamik ortalaması tutulur ve bu dinamik ortalamaların hesaplanması ile o yönde ilerleme sağlanır (Goodfellow vd., 2016). Bunun sonucunda öğrenme adımları en iyi sonuca doğru daha hızlı hareket eder ve daha az hedeften uzaklaşır.

2.2.3.3. RMS-Prop (Root Mean Square Propagation)

Uyarlanabilir öğrenme oranı temelli bir algoritmadır. Öğrenme adımları süresince tüm parametreler için farklı bir öğrenme oranı kullanılır. Elde edilen sonuçlara göre öğrenme oranı sürekli güncellenmektedir. Hedeften uzaklaşan noktaları dikkate almayarak, ortalama yaklaşımı kullanır, bu da yakınsamayı hızlandırabilir (Goodfellow vd., 2016). Adadelta optimizasyon yönteminde, parametrelerin kendine özgü öğrenme hızları vardır. Öğrenme hızları eğitim ilerledikçe azalmaktadır ve bir yerden sonra öğrenme işlemi durmaktadır. RMS-Prop yönteminin geliştirilmesinin bir nedenidir.

2.2.3.4. Adam (Adaptive Moment Estimation)

Klasik stokastik gradyan azalma yöntemi yerine kullanılabilecek daha verimli, bir optimizasyon algoritmasıdır. Her parametrenin öğrenme oranını dinamik bir şekilde güncellemesidir (Kingma ve Ba, 2014; Ruder, 2016). Hesaplama olarak verimlilik sağlar ve yüksek bellek gereksinimlerine ihtiyaç duymaz. Parametre güncelleme metodu olarak Adam, RMS-Prop ve Momentum algoritmaları benzerlik gösterir.

2.2.4. Transfer Öğrenme

Transfer öğrenme daha önceden eğitilmiş ağırlardaki parametrelerin başlangıç parametresi olarak kullanılarak, yeni problemlerin çözümünde kullanılmaktadır. Transfer öğrenme ile ağırlıkların güncellenmesi, yeniden eğitime gerek duyulmadan başlangıç noktası olarak önceden eğitilmiş modeller kullanılır. Bundan dolayı bilgisayar kaynaklarının kullanımı ve ağırlık eğitimi zamanı açısından kullanışlıdır. Küçük veri setlerinde aşırı uyum problemi yaşanabilmektedir. Bu yöntemle küçük veri seti bulunan problemlerde yüksek doğruluk sağlanabilir.

2.2.4.1. AlexNet

Krizhevsky vd. (2017) çalışmalarında ESA modeli ile nesne tanıma işlemini gerçekleştirmişlerdir (Krizhevsky vd., 2017). ImageNet veri seti ile eğitilen AlexNet mimarisi 2012 yılında Büyük Ölçekli Görsel Tanıma Zorluğu (ILSVRC) yarışmasını kazanmıştır. AlexNet nesne tanıma problemleri için oldukça yüksek performans göstermiştir.

AlexNet mimarisi; 224x224x3 giriş katmanı, 11x11x96 evrişim katmanı (adım:4), 3x3 maksimum havuzlama (adım:2), 5x5x256 evrişim katmanı (dolgu:2), 3x3 maksimum havuzlama (adım:2), 3x3x384 (Dolgu:1), 3x3x384 (Dolgu:1), 3x3x384 (Dolgu:1), 3x3 maksimum havuzlama (adım:2), 4096 tam bağlantılı katman, 4096 tam bağlantılı katman, 1000 tam bağlantılı katman ve softmax katmanlarından oluşmaktadır.

2.2.5. Performans Ölçütü

Eğitim aşamasının tamamlanmasının ardından tüm modeller test veri setinde test edilir. Performanslar doğruluk (Accuracy), geri çağırma (Recall), kesinlik (Precision), F1 ve AUC puanı kullanılarak değerlendirilir. Aşağıda belirtilen tanım ve denklemlerde, sağlıklı ve pnömoni hastalarını sınıflandırırken gerçek pozitif (tp), pnömoni olarak tanımlanan pnömoni görüntülerinin sayısını, gerçek negatif (tn) ise normal (sağlıklı), yanlış olarak tanımlanan normal görüntülerin sayısını ifade eder. Pozitif (fp), yanlış bir şekilde pnömoni görüntüleri olarak tanımlanan normal görüntülerin sayısını belirtir ve yanlış negatif (fn), yanlış şekilde normal olarak tanımlanan pnömoni görüntülerinin sayısını belirtir. Tablo 2.2’de karmaşıklık matrisinde değerler görülmektedir.

Tablo 2.2. Karmaşıklık matrisi

		Tahmin Edilen	
		Olumsuz	Olumlu
Gerçek Durum	Olumsuz	tn	fp
	Olumlu	fn	tp

Doğruluk: Tahmin edilen değerin gerçek değere yakınlığını belirtir. Denklem 2.7’de formüle edilmiştir.

$$Doğruluk = \frac{tp+tn}{tp+tn+fn+fp} \quad (2.7)$$

Bu eşitlikte;

tp; pnömoni röntgen görüntüleri pnömoni olarak sınıflandırılması

tn; normal röntgen görüntüleri, normal olarak sınıflandırılması

fp; normal göğüs röntgeni görüntüleri pnömoni olarak sınıflandırılması

fn; pnömoni röntgen görüntüleri normal olarak sınıflandırılması olarak ifade edilmiştir.

Kesinlik: Modelin pozitif tahmin edilenler açısından ne kadar doğru olduğunu hesaplar. Kesinlik formülü denklem 2.8’de ifade edilmiştir.

$$Kesinlik = \frac{tp}{tp+fp} \quad (2.8)$$

Duyarlılık: Modelin etiketledikten sonra yakalayabildiği gerçek pozitiflerin sayısını hesaplar. Denklem 2.9’da duyarlılık hesaplama formülü gösterilmiştir.

$$Duyarlılık = \frac{tp}{tp+fn} \quad (2.9)$$

F1: Kesinlik ve duyarlılık arasında bir denge sağlar. Denklem 2.10’da F1 skor değeri hesabı gösterilmiştir.

$$F1 \text{ Skor} = 2 \frac{Kesinlik \times Duyarlilik}{Kesinlik+Duyarlilik} \quad (2.10)$$

AUC Puanı ve ROC Eğrisi: ROC bir olasılık eğrisidir ve AUC ayrılabilirlik derecesini temsil eder.


2.3. Veri Artırma Yöntemleri

Veri setinin az olması, probleme ait yeterince görüntü bulunamaması gibi nedenler ağın ezberlemesine veya test doğruluğunun düşük değerlerde kalmasına neden olmaktadır. Bu problemlerin çözümü için kullanılan veri artırma yöntemleri ağın başarısı artırmak amacıyla sıklıkla kullanılmaktadır. Veri artırılırken problem alanıyla ilgili uygun yöntem seçilmelidir. Aksi halde veri artırımı ağın başarısını azaltırken, ağın eğitim için geçen zaman ve donanım maliyetlerini de beraberinde getirmektedir. Boyutlandırma, döndürme ve yansıtma gibi veri artırma yöntemleri bulunmaktadır. Bu çalışmada veri artırma yöntemi, her epok için eğitim verilerine rastgele uygulanır, her epokta daha farklı bir veri seti kullanılır. Her epoktaki eğitim veri seti sayısı değişmez. Dönüştürülen görüntüler bellekte saklanmaz.

2.3.1. Yansıma (Reflection)


Görüntünün yatay ve dikey olarak aynalanmasıdır. X yansıması ve Y yansıması olarak iki farklı yöntem kullanılmaktadır.

X yansıması (X Reflection): Görüntünün yatay yönde yansımasıdır. Şekil 2.10.'da hem normal hem X yansıması görülmektedir.



Şekil 2.10. X yansıma


Y yansıması (Y Reflection): Görüntünün dikey yönde yansımasıdır. Örnek resim aşağıdaki şekil 2.11.'de görülmektedir.



Şekil 2.11. Y yansıması

2.3.2. Döndürme (Rotation)

Görüntüye belirlenen açısal aralıkta veya sabit bir açıda döndürme işlemi uygulanır. Rastgele eğitim verisine uygulanabileceği gibi tüm eğitim verisine de uygulanabilir. Örnek resim şekil 2.12'de görülmektedir.




Şekil 2.12. Döndürme

2.3.3. Ölçekleme (Scale)


Görüntüye belirtilen aralık dahilinde küçültme veya büyültme işlemi yapılır.

Yatay ölçekleme (X Scale): Görüntü üzerinde belirtilen aralık içinde yatay olarak ölçekleme yapılır. Örnek resim şekil 2.13’de görülmektedir.



Şekil 2.13. Yatay ölçekleme

Dikey ölçekleme (Y Scale): Görüntü üzerinde belirtilen aralık içinde dikey olarak ölçekleme yapılır. Örnek resim şekil 2.14’de görülmektedir.




Şekil 2.14. Dikey ölçekleme

2.3.4. Eğme (Shear)


Görüntü belirlenen aralık dahilinde açısal olarak X veya Y ekseninde yeniden dönüştürülür.

Yatay Eğme (X Shear): Görüntü belirlenen aralık dahilinde açısal olarak X ekseninde yeniden dönüştürülür. Şekil 2.15’de sola eğilmiş resim görülmektedir, yatay eğme olarak adlandırılmıştır.



Şekil 2.15. Yatay eğme

Dikey Eğme (Y Shear): Görüntü belirlenen aralık dâhilinde açısal olarak Y ekseninde yeniden dönüştürülür. Örnek resim şekil 2.16’da görülmektedir.




Şekil 2.16. Dikey eğme

2.3.5. Kaydırma(Translation)


Görüntü X ve Y eksenlerine göre piksel değerinde kaydırılır. Standart olarak, siyah piksellerle artakalan kısım doldurulur. Beyaz piksellerle de doldurulabilir.

Yatay kaydırma (X Translation): Giriş görüntüsündeki her pikseli X eksenine göre yeni bir konuma taşıma işlemidir. Örnek resim şekil 2.17’de görülmektedir.



Şekil 2.17. Yatay kaydırma


Dikey kaydırma (Y Translation): Giriş görüntüsündeki her pikseli Y eksenine göre yeni bir konuma taşıma işlemidir. Örnek resim şekil 2.18’de görülmektedir.



Şekil 2.18. Dikey kaydırma

2.3.6. Kırpma (Crop)


Görüntünün X ve Y koordinatı, genişlik ve uzunluk parametrelerinin belirlenmesiyle kırpma işlemi gerçekleştirilmektedir. Akciğer röntgen görüntülerinde kırpma işlemi yapılırken boyun, kol gibi uzuvların kırılması sağlanarak, akciğer bölgesinin kırılması engellenmiştir. Kırpma yöntemi uygulanan resim şekil 2.19’da gösterilmiştir.



Şekil 2.19. Kırpma yöntemi

2.3.7. Kontrast (Contrast)

Görüntünün kontrast değerlerini artırır. Yoğunluk 0 ile 1 aralığındadır. Görüntülerin kontrast değerleri düzenlenerek eğitime uygun ayrıntılar ortaya çıkarılır ve görüntüler sınıflandırma için daha uygun hale getirilir. Şekil 2.20’de kontrast işlemi uygulanmış görüntü görülmektedir.




Şekil 2.20. Normal ve kontrast görüntü

3. YAPILAN ÇALIŞMALAR

3.1. Özgün Evrişimsel Sinir Ağı Kullanarak Pnömoni Tespiti

3.1.1. Veri Kümesi

Bu çalışmada, 2018 yılında Paul Mooney tarafından herkesin erişimine sunulan 1 – 5 yaş arası çocuklara ait önden çekilmiş göğüs röntgen görüntüleri kullanılmıştır(Mooney Paul, 2018). Veri setinde toplamda 5840 adet (jpeg formatında) görüntü mevcuttur ve bunlar eğitim ve test görüntüleri olmak üzere iki bölüme ayrılmıştır. Görüntülerin çözünürlükleri genişlik değeri 384 ile 2916, yükseklik değeri ise 127 ile 2663 piksel aralığında değişiklik göstermektedir. Eğitim seti içerisindeki görüntülerden 1341 normal, 3875 pnömoni olarak, test setindeki görüntülerin ise 234 normal ve 390 pnömoni olarak sınıflandırılmıştır. Veri setinde kişiler ile ilgili ad soyad, cinsiyet, hastalık gibi bilgiler verilmemiş olup anonimleştirilmiştir. Şekil 3.1’de çocuklara ait 6 adet normal ve 6 adet pnömoni teşhisi konulan çocuklara ait akciğer röntgen görüntüleri bulunmaktadır.



Şekil 3.1. Normal ve pnömoni görüntüler

3.1.2. Özgün Evrişimsel Sinir Ağı Modeli Tasarımı

Bu çalışmada, derin öğrenme ağlarında yüksek doğruluk oranları ile diğer sinir ağı modellerine göre öne çıkan evrişimli sinir ağı tercih edilmiştir. İlk yöntem özgün olarak tasarlanan bir ESA'nın tüm parametrelerin ve katmanlarının adım adım denenerek belirlenmesiyle oluşturulmuştur.

3.1.2.1. Ağ Mimarisinin İlk Katmanlarının Belirlenmesi

ESA modelinin ilk katmanı giriş katmanı $[286 \times 286 \times 1]$ olarak belirlendi. Giriş boyutunun yüksek boyutlu seçilmesi donanım ihtiyacını da arttırdığından eğitim için geçen süreyi artırmaktadır. Evrişim katmanı için ilk olarak 8 kanallı $[3 \times 3]$ filtre boyutlarında tek evrişim işlemi uygulandı. Sonraki denemelerde ise evrişim katmanına ek olarak toplu normalizasyon (BN – Batch Normalization) katmanı eklendi. Ayrıca, ReLU(R) ve Tanh(Tan) aktivasyon fonksiyonlarının ağın eğitimi üzerindeki etkileri incelendi. Bu denemeler sonucunda elde edilen eğitim ve test doğrulukları tablo 3.1'de verilmiştir. Tablodan da anlaşılacağı üzere, ele alınan bu farklı katman yapıları içerisinde evrişim katmanı ve ReLU aktivasyon fonksiyonunun beraber olarak kullanıldığı mimaride en yüksek test doğruluğu elde edilmiştir.

Tablo 3.1. Evrişim, Toplu Normalizasyon, ReLU, Tanh katmanlarının etkisi

Katmanlar	Epok	Eğitim Doğruluğu	Test Doğruluğu
8 (3x3)	5	0.9904	0.7131
8+BN	5	0.9827	0.7163
8+R	5	0.9923	0.7516
8+Tan	5	0.9128	0.6779
8+BN+R	5	0.9827	0.7292

3.1.2.2. Evrişim İşleminin Arttırılması

ESA'nın sığ ve derin olmasının ağın performansına etkisini incelemek amacıyla ağın mimarisi A modelinde 16 kanal sayısı ile başlayıp, H modelindeki 2048 kanal sayısına kadar evrişim işlemi uygulanmıştır. Aşağıdaki tabloda her evrişim katmanından sonra ReLU aktivasyon fonksiyonu, maksimum havuzlama katmanları eklenmiştir. Maksimum havuzlama katmanı $[2 \times 2]$ filtre ve adım sayısı 2 olarak seçilmiştir. Son evrişim katmanında ise maksimum havuzlama dâhil edilmemiştir.

Tablo 3.2’de üç evrişim katmanı bulunan ağın performansı 0.7644 oranı ile test doğruluğu daha iyi sonuçlanmıştır. Ağ derinleştikçe ağın performansı azalmaya başlamıştır.

Tablo 3.2. Evrişim işleminin arttırılması

Model	Katmanlar	Epok	Eğitim Doğruluğu	Test Doğruluğu
A	8+16	10	0.9971	0.7452
B	8+16+32	10	0.9952	0.7644
C	8+16+32+64	10	0.9425	0.6474
D	8+16+32+64+128	10	0.9923	0.7452
E	8+16+32+64+128+256	10	0.9990	0.7452
F	8..512	10	0.9942	0.7532
G	8..1024	10	1	0.7324
H	8..2048	10	0.9990	0.7468

3.1.2.3. Aynı Sayıdaki Kanal Sayısı ile Evrişim İşleminin Arttırılması

B modeli üzerinden ağın eğitimleri devam etmiştir. Kanal sayısı arttırılmadan ağın performansı incelenmiştir. Son katman çoğaltılarak, aynı boyutta filtre ve kanal sayısı uygulanarak evrişim katmanı eklenmiştir. Son katman 1, 2 ve 3 kez çoğaltıldığındaki ağın performansı incelendiğinde, tablo 3.3’e göre B modelinde test doğruluk oranı 0.76 ile en yüksek değere sahiptir.

Tablo 3.3. Aynı sayıdaki kanal sayısı ile evrişim işleminin arttırılması

Model	Katmanlar	Epok	Eğitim Doğruluğu	Test Doğruluğu
A	8+16+32+32	10	1	0.7324
B	8+16+32+32+32	10	0.9994	0.7600
C	8+16+32+32+32+32	10	0.9875	0.7260

3.1.2.4. L2 Normalizasyon İşlemi

L2 normalizasyon işlemi uygulandığında tablo 3.4 incelendiğinde test doğruluğunun olumlu etkilendiği görülmüştür.

Tablo 3.4. L2 Normalizasyon'un modele etkisi

Model	Katmanlar	Epok	Eğitim Doğruluğu	Test Doğruluğu	L2 Normalizasyon
A	8+16+32+32+32	10	0.9952	0.7588	0.0001
B	8+16+32+32+32	10	0.9994	0.7388	-

3.1.2.5. Tam Bağlı Katman Sayısının Arttırılması

ESA'nın son katmanında bulunan tam bağlantılı katman sayısı artırılarak ağın performansına etkisi incelendi. Yukarıdaki tabloda A modeli üzerinden ağın eğitimlerine devam edildi. “Tam Bağlı Katman (F2)’dan” önce “Tam Bağlı Katman (F256)”, “Tam Bağlı Katman (F512)”, “Tam Bağlı Katman (F1024)” farklı sayıdaki nöronları eklenerek ağa olan etkisi incelendi. Tablo 3.5’de B modeli test doğruluğu A ve C modeline göre en iyi test doğruluğunu vermiştir. Tam bağlı katman eklemenin etkisi incelendiğinde önceki modeldeki test doğruluğu 0.76 iken, bu modelde 0.7692 test doğruluğu ile iyileşme olmuştur.

Tablo 3.5. Tam bağlı katmanın modele etkisi

Model	Katmanlar	Epok	Eğitim Doğruluğu	Test Doğruluğu
A	8+16+32+32+32+F256+F2	10	1	0.7468
B	8+16+32+32+32+F512+F2	10	0.9904	0.7692
C	8+16+32+32+32+F1024+F2	10	0.9971	0.7372

ESA modeli 0.7692 en iyi test doğruluğu sonucu veren 8+16+32+32+32+F512+F2 modeli ile ağın eğitimine devam edilmiştir. Önceki tablolardaki veriler incelendiğinde eğitim doğruluğunun %98 üzerinde olduğu tespit edilirken, test doğruluğunun %77’in altında kaldığı görülmüştür. Veri setinin az olması, verilerin çeşitliliğinin az olması, ağı çok fazla genelleştirme yapması ve aşırı uyuma neden olduğu görülmüştür. Bu sorunları iyileştirme amacıyla regülasyon yöntemlerinin eğitim performansı test edilmiştir.

3.1.2.6. Bırakma Katmanının Etkisi

Ağıdaki aşırı uyumu, ağı ezberlemesini azaltmak amacıyla bırakma katmanı (Dropout) uygulanarak, ağın performansı incelenmiştir. 0.5 ve 0.25 oranında seyreltme oranı uygulanmış ve 0.5 seyreltme ile A modelinin test doğruluğu daha iyi sonuç verdiği görülmüştür. Bırakma katmanı yönteminin ağın performansına etkisi önceki test doğruluğu sonucundan daha düşük çıkmıştır. Bırakma katmanı işlemi veri artırma yöntemlerinden sonra tekrar denenmiştir. Tablo 3.6’da modele ait performans gösterilmiştir.

Tablo 3.6. Bırakma katmanının modele etkisi

Model	Epok	Bırakma katmanı	Eğitim Doğruluğu	Test Doğruluğu
A	10	0.5	0.9962	0.7516
B	10	0.25	0.9971	0.7244

3.1.2.7. Veri Artırma İşlemleri

Veri setinin 1341 normal görüntü, 3875 pnömoni görüntüsü ile toplam 5216 görüntü derin öğrenme ağları için küçük boyutlu olması eğitimi ve test doğruluğu olumsuz etkilediği görülerek, sonraki aşamada veri seti artırılarak ağın performansı üzerindeki etkisi incelenmiştir. Veri seti artırma yöntemlerinde özellikle en son elde edilen en iyi değer 0.7692 test doğruluğunun üzerine çıkılması hedeflenmiştir.

Veri Artırma: X ve Y Yansıma

Tablo 3.7 incelendiğinde X yansıma test doğruluğu, Y yansıma test doğruluğuna göre yüksek olmasına rağmen, veri artırma tekniği uygulanmadan alınan en iyi test sonucu 0.7692 göre düşük çıkmıştır. Bu veri artırma tekniği ağı olumsuz etkilemiştir.

Tablo 3.7. X ve Y yansıma yönteminin modele etkisi

Model	Epok	X Yansıma	Y Yansıma	Eğitim Doğruluğu	Test Doğruluğu
A	20	+		0.9885	0.7388
B	20		+	0.9770	0.6971

Veri Artırma: Döndürme

Veri setindeki görüntüleri belirli açılardaki aralıklarda rastgele döndürülerek sentetik veriler elde edilmiştir. Örnek olarak [-10 10] değeri seçilmesi, açısal olarak -10 ile 10 değerleri arasında görüntünün rastgele sola veya sağa döndürülmesi işlemidir. Tablo 3.8’de önceki verilere göre daha iyi performans sergilenerek C modelinde 0.8429 test doğruluğu değerine ulaşılmıştır. Döndürme yöntemi önerilen ağda kullanılabileceğini göstermiştir.

Tablo 3.8. Döndürme yönteminin modele etkisi

Model	Epok	Döndürme	Eğitim Doğruluğu	Test Doğruluğu
A	20	[-10, 10]	0.9837	0.7965
B	20	[-15, 15]	0.9770	0.7885
C	20	[-20, 20]	0.9712	0.8429
D	20	[-25, 25]	0.9751	0.7885

Veri Artırma: Yatay Eğme

Veri setindeki görüntüleri, yatay ekseninde açısal olarak eksi değerlerde sola, artı değerlerde sağa kaydırma işlemi uygulanmaktadır. Rastgele görüntüler seçilmiştir. Tablo 3.9 incelendiğinde test doğruluğu minimum -15 ile maksimum 15 derece aralığında rastgele görüntüler üreten B modeli 0.8045 ile en iyi performansı göstermiştir. Yatay eğme veri artırma yönteminin ağırlık performansına olumlu katkısı olmuştur.

Tablo 3.9. Yatay Eğme yönteminin modele etkisi

Model	Epok	Yatay Eğme	Eğitim Doğruluğu	Test Doğruluğu
A	20	[-20, 20]	0.9895	0.7436
B	20	[-15, 15]	0.9684	0.8045
C	20	[-10, 10]	0.9904	0.7404

Veri Artırma: Dikey Eğme

Veri setindeki görüntüleri, dikey ekseninde açısal olarak eksi değerlerde yukarı, artı değerlerde aşağı kaydırma işlemi uygulanmıştır. Rastgele görüntüler seçilmiştir. Tablo 3.10 incelendiğinde test doğruluğu minimum -25 ile maksimum 25 derece aralığında rastgele görüntüler üreten C modeli 0.8958 ile en iyi performansı göstermiştir. Önceki veri artırma yöntemlerine göre daha iyi bir sonuç elde edilmiştir.

Tablo 3.10. Dikey eğme yönteminin modele etkisi

Model	Epok	Dikey Eğme	Eğitim Doğruluğu	Test Doğruluğu
A	20	[-20, 20]	0.9779	0.8269
B	20	[-15, 15]	0.9655	0.7468
C	20	[-25, 25]	0.8984	0.8958
D	20	[-30, 30]	0.9684	0.8606

Veri artırma: Yatay Ölçekleme

Tablo 3.11 incelendiğinde veri setindeki görüntülerin fazla büyütülmesi eğitim doğruluğunu düşürmektedir. G modeli test doğruluğu 0.9199 oranı ile en yüksek doğruluk oranına sahiptir.

Tablo 3.11. Yatay ölçekleme yönteminin modele etkisi

Model	Epok	Yatay Ölçekleme	Eğitim Doğruluğu	Test Doğruluğu
A	20	[1.1, 1.9]	0.9291	0.8830
B	20	[1.1, 1.6]	0.8581	0.8750
C	20	[1.1, 1.3]	0.9329	0.8974
D	20	[0.7, 1.0]	0.9703	0.7468
E	20	[1.0, 1.7]	0.9588	0.8942
F	20	[1.0, 1.8]	0.9636	0.9022
G	20	[1.0, 1.9]	0.9338	0.9199
H	20	[1.0, 2.0]	0.9549	0.8878
I	20	[1.2, 1.9]	0.9003	0.8654

Veri artırma: Yatay Kaydırma

Yatay kaydırma, görüntünün sağa ve sola ötelenmesi yönteminin ağırlık öğrenme performansına etkisi incelendi. Örnek olarak X ekseninde -30 değeri görüntünün 30 piksel sola kaydırılması, +30 ise görüntünün 30 piksel sağa kaydırılması işlemidir. Rastgele veri集中的 görüntülere uygulanan işlem tablo 3.12’de belirtilen 0.7901 test doğruluğu değeri ile en iyi performansı sağlayan F ve H modelleri görülmüştür. Bu değerlere en yakın A modelindeki değerde eğitim ve test doğruluğu arasındaki fark düşünüldüğünde değerlendirmeye alınabilecek bir değer olduğu görülmüştür.

Tablo 3.12. Yatay kaydırma yönteminin modele etkisi

Model	Epok	Yatay Kaydırma	Eğitim Doğruluğu	Test Doğruluğu
A	5	[35, 45]	0.9300	0.7885
B	5	[25, 35]	0.9473	0.7388
C	5	[15, 25]	0.9789	0.7724
D	5	[5, 15]	0.9904	0.7772
E	5	[-15, 5]	0.9895	0.7516
F	5	[-25, -15]	0.9751	0.7901
G	5	[-25, -20]	0.9818	0.7260
H	5	[-20, -15]	0.9760	0.7901
İ	5	[-35, -25]	0.9588	0.7612
J	5	[-45, -35]	0.9674	0.7756

Veri artırma: Dikey Kaydırma

Y ekseninde piksel kaydırma yöntemi dikey olarak görüntünün kaydırılmasıdır. Veri seti üzerinde rastgele piksel boyutları belirlenerek, sentetik veri üretilmiştir. Örnek olarak [-30 30] aralığındaki -30 değeri dikey olarak yukarı yönde 30 piksel görüntünün kaydırılması, 30 değeri ise aşağı yönde resmin 30 piksel kaydırılması işlemidir.

Tablo 3.13 incelendiğinde C modeli 0.7949 değeri ile test doğruluğu en yüksek değerdir, A modelinde eğitim doğruluğu değeri C modeline oldukça yakın bir değerdedir, bu yüzden iki değerde dikkate alınarak çalışmaya devam edilmiştir.

Tablo 3.13. Dikey kaydırma yönteminin modele etkisi

Model	Epok	Dikey Kaydırma	Eğitim Doğruluğu	Test Doğruluğu
A	5	[30, 40]	0.9396	0.7724
B	5	[20, 30]	0.9703	0.7051
C	5	[10, 20]	0.9712	0.7949
D	5	[0, 10]	0.9885	0.7308
E	5	[-10, 0]	0.9827	0.7308
F	5	[-20, -10]	0.9789	0.7228
G	5	[-30, -20]	0.9616	0.7131
H	5	[-40, -30]	0.8696	0.6907

Dikey kaydırma yöntemi ile en iyi test doğruluğu değerini yakalamak için ikisi arasındaki performans test edilerek, tablo 3.14’de belirtilen A modelindeki [10 20] aralık değeri 0.7901 değeri ile daha iyi test doğruluğu vermiştir.

Tablo 3.14. Yatay ve dikey kaydırma yönteminin modele etkisi

Model	Epok	Yatay Kaydırma	Dikey Kaydırma	Eğitim Doğruluğu	Test Doğruluğu
A	5	[-25, -15]	[10, 20]	0.9310	0.7901
B	5	[-25, -15]	[30, 40]	0.9137	0.6715

X Kaydırmada tereddüt oluşturan [35 45] ve [-25 -15] değerleri arasındaki performans incelenerek, tablo 3.15’de belirtilen B modeli 0.7901 test doğruluğu ile en iyi performansı göstermiştir.

Tablo 3.15. Yatay ve dikey kaydırma yönteminin modele etkisi

Model	Epok	Yatay Kaydırma	Dikey Kaydırma	Eğitim Doğruluğu	Test Doğruluğu
A	5	[35, 45]	[10, 20]	0.9291	0.6827
B	5	[-25, -15]	[10, 20]	0.9310	0.7901

Veri artırma Yöntemleri Sonuçları

Veri artırma yöntemleri incelendiğinde veri artırımı yapılmadan önceki modelin eğitim doğruluğu 0.9904 ve doğruluğu 0.7692 iken tablo 3.16’da da belirtildiği gibi veri artırma yöntemleri uygulandıktan sonra test doğruluğu önemli ölçüde artmıştır. En iyi test doğruluğu 0.9199 ile yatay ölçekleme tekniği ile sağlanmıştır.

Tablo 3.16. Veri artırma yöntemlerinin performansı

Model	Epok	Değer	Eğitim Doğruluğu	Test Doğruluğu	Yöntem
A	20	[-20, 20]	0.9712	0.8429	Döndürme
B	20	[-15, 15]	0.9684	0.8045	Yatay Eğme
C	20	[-25, 25]	0.8984	0.8958	Dikey Eğme
D	20	[1.0, 1.9]	0.9338	0.9199	Yatay Ölçekleme
E	5	[-25, -15]	0.9751	0.7901	Yatay Kaydırma
F	5	[10, 20]	0.9712	0.7949	Dikey Kaydırma

Yukarıdaki tabloda tek yöntem kullanılarak oluşturulan veri artırma yönteminin sonuçları belirtilmiştir. Aşağıdaki tabloda veri artırma yöntemlerinin beraber kullanıldığındaki etkisi incelendi. Katmanlar 8+16+32+32+32+F512+F2 ve epok sayısı 20 belirlendi. Tablo 3.17’de belirtilen 0.9167 en iyi test doğruluğu gösteren E modeli “Yatay Eğme ve Yatay Ölçekleme” yöntemi ile diğer yöntemlere göre daha yüksek sonuç vermiştir. Tablo 3.17’de yatay ölçekleme [1.0, 1.9] aralığında tüm modellere uygulanmıştır. Farklı yöntemlerin bir arada kullanılması ile eğitim doğruluğu ve test doğruluğu arasındaki farkı da azaltarak modelin aşırı uyum sorununu engellemesi de sağlamıştır. Bir sonraki aşamada kontrast veri ön işleme adımının ağın performansına etkisi incelendi.

Tablo 3.17. En iyi test doğruluğu veren veri artırma yöntemlerinin performansları

Model	Döndürme	Yatay Eğme	Dikey Eğme	Yatay Kaydırma	Dikey Kaydırma	Eğitim Doğruluğu	Test Doğruluğu
A			[-25, 25]			0.9214	0.8926
B	[-20, 20]					0.9338	0.8990
C				[-25, -15]		0.9012	0.8478
D					[10, 20]	0.9099	0.8974
E		[-15, 15]				0.9444	0.9167

Veri artırma: Kontrast


Kontrast işlemi ile gri tonlamalı görüntüdeki yoğunluk değerlerini yeni değerlerle eşler. Tüm piksel değerlerinin alt %1’ini ve üst %1’ini doyurur.

Bu işlem görüntünün kontrast değerini artırır. Mevcut eğitim veri setine kontrast işlemi uygulanarak eğitim veri seti fiziksel olarak iki katına çıkarılmıştır. Tüm bu görüntülere de yatay eğme ve yatay ölçekleme işlemleri uygulanarak, tablo 3.18’de belirtilen 0.9327 test doğruluğu elde edilmiştir.

Tablo 3.18. Kontrast işleminin ağın performansına etkisi

Model	Kontrast	Yatay Eğme	Yatay Ölçekleme	Eğitim Doğruluğu	Test Doğruluğu
A	+	[-15, 15]	[1.0, 1.9]	0.9626	0.9327
B		[-15, 15]	[1.0, 1.9]	0.9444	0.9167

Şekil 3.2’de 0.9327 ile en iyi test doğruluğu elde edilen özgün ağıın mimarisi gösterilmiştir. Ağıın eğitiminde optimizasyon algoritması olarak RMSprop, öğrenme oranı 0.001 seçilmiştir.



Şekil 3.2. Önerilen ağıın mimarisi

3.1.2.8. Modelin Başarım Ölçüm Sonuçları

Tablo 3.19’da önerilen modele ait karmaşıklık matrisi gösterilmiştir. 204 normal görüntü ve 378 pnömoni görüntü doğrul sınıflandırılmıştır. 12 pnömoni görüntü, normal olarak, 30 normal görüntü, pnömoni olarak yanlış sınıflandırılmıştır.

Tablo 3.19. Önerilen modele ait karmaşıklık matrisi

		Gerçek		Toplam
		Normal	Pnömoni	
Tahmin	Normal	204 %32.7	12 %1.9	216
	Pnömoni	30 %4.8	378 %60.6	408
Toplam		234	390	624

Önerilen modelin başarımı için tablo 3.20’de belirtilen kesinlik, duyarlılık ve F1 skor parametrelerinden yararlanılmıştır.

Tablo 3.20. Önerilen ESA modelinde sınıflandırma başarısı

Sınıflar	Kesinlik	Duyarlılık	F1 Skor
Pnömoni	0.9692	0.9265	0.9474
Normal	0.8718	0.9444	0.9066

3.2. Transfer Öğrenme ile Önerilen Evrişimsel Sinir Ağı

Transfer öğrenme uygulanacak mimarinin seçimi için bilinen performansı kanıtlanmış derin öğrenme algoritmaları ile bu veri setindeki eğitim ve test doğruluk oranları incelendi. Bu ağlar ImageNet veri setinde eğitilmiş ve test edilmiştir. ImageNet veri seti 22.000 farklı kategoriye ait yaklaşık 15 milyon görüntü içerir ve görüntü sınıflandırması için en büyük veri kümesidir. Optimizasyon algoritması için “RMSprop” yöntemi kullanıldı, veri setindeki eğitim setinin %80’i eğitim, %20’si validasyon olarak ayrıldı.

Tablo 3.21 incelendiğinde en yüksek test doğruluğu 0.8269 değeri ile AlexNet modeli görülmektedir. AlexNet mimarisi ile eğitim süresinin, donanım ihtiyacının az olması ve iyi performans göstermesi onu diğer mimarilerden ön plana çıkarmaktadır. Ağın eğitimine AlexNet üzerinden devam edildi.

Tablo 3.21. Önceden eğitilmiş evrişimsel sinir ağlarının performansı

Mimari	Epok	Eğitim Doğruluğu	Test Doğruluğu
AlexNet	20	0.9847	0.8269
GoogleNet	20	0.9818	0.8253
Inceptionv3	20	0.9914	0.7965
ResNet18	20	0.9904	0.7965
ResNet50	20	0.9818	0.8125
ResNet101	20	0.9885	0.7949
SqueezeNet	20	0.9933	0.7420

3.2.1. Veri Artırma Yöntemleri Uygulanan AlexNet Mimarisi Performansı

Tablo 3.22’de transfer öğrenme yönteminden önce önerilen ESA’daki veri artırma parametreleri kullanılarak, AlexNet mimarisinin performansı ölçülmüştür. Yatay ölçekleme ve yatay kaydırma yöntemi ile test doğruluğu 0.9327 değeri ile en iyi sonucu vermiştir. Bu en iyi değer referans alınarak devam edecektir. Yatay ölçekleme [1.0-1.9] ve Yatay kaydırma [-25 -15] yöntemleri bundan sonraki tablolarda da kullanılacak ve tekrar tablolarda gösterilmeyecektir.

Tablo 3.22. Veri artırma yöntemleri AlexNet ile uygulanması

Döndürme	Yatay Eğme	Dikey Eğme	Yatay Ölçekleme	Yatay Kaydırma	Dikey Kaydırma	Eğitim Doğruluğu	Test Doğruluğu
[-20, 20]			[1.0, 1.9]			0.9559	0.8606
		[-25, 25]	[1.0, 1.9]			0.9051	0.9087
	[-15, 15]		[1.0, 1.9]			0.8840	0.9006
			[1.0, 1.9]	[-25, -15]		0.9348	0.9327
			[1.0, 1.9]		[10, 20]	0.9041	0.9087

3.2.2. Tam Bağlantılı Katman Sayısının Yeniden Düzenlenmesi

Tablo 3.23’de AlexNet mimarisine tam bağlantılı katman eklenerek, ağ performansı test edilmiştir. Tablo incelendiğinde tam bağlantılı katmandaki 512 parametre değeri 0.9391 test doğruluğu ile en iyi performansı göstermiştir.

Tablo 3.23. Tam bağlantılı katmanların performansı

Yeni katman	Epok	Eğitim Doğruluğu	Test Doğruluğu
F512	10	0.9300	0.9391
F1024	10	0.9012	0.9022
F256	10	0.9453	0.9231

3.2.3. Toplu Normalleştirme ve ReLU Katmanlarının Etkisi

Tablo 3.24’de toplu normalizasyon ve ReLU katmanlarının modele etkisi incelendi. Toplu normalizasyon uygulandığında test doğruluğu 0.9439 değeri ile tablodaki en yüksek test doğruluğunu göstermiştir.

Tablo 3.24. Toplu normalizasyon ve ReLU fonksiyonlarının etkisi

Yeni Katman	Epok	Eğitim Doğruluğu	Test Doğruluğu
F512+B	10	0.9616	0.9439
F512+R	10	0.9521	0.9263
F512+B+R	10	0.8533	0.9119

3.2.4. Tam Bağlantılı Katman Sayısının Arttırılması

Tam bağlantılı katmanın test doğruluğunu önemli ölçüde arttırması ile ikinci bir tam bağlantılı katmanın ağın performansındaki etkisi incelendi. Tablo 3.25’de eğitim doğruluğunun en düşük olduğu A modeli ve test doğruluğu da 0.9487 değeri ile en yüksek test doğruluğu görülmesi üzerine A modeli ile modelin eğitimi devam edildi.

Tablo 3.25. İki tam bağlı katmanın modelin performansına etkisi

Model	Yeni Katman	Epok	Eğitim Doğruluğu	Test Doğruluğu
A	F1024+B+F512+B	10	0.9319	0.9487
B	F2048+B+F512+B	10	0.9492	0.9455
C	F4096+B+F512+B	10	0.9741	0.9455

3.2.5. Öğrenme Oranının Etkisi

Öğrenme oranının modele etkisi incelendi. Tablo 3.26’da 0.9567 test doğruluğu ile B modeli en yüksek sonucu vermektedir.

Tablo 3.26. Öğrenme oranının test doğruluğuna etkisi

Model	Öğrenme Oranı	Epok	Eğitim Doğruluğu	Test Doğruluğu
A	0.0003	25	0.9722	0.9551
B	0.0005	25	0.9415	0.9567
C	0.0007	25	0.9636	0.9359
D	0.0001	25	0.9645	0.9503

3.2.6. Bırakma Katmanının Etkisi

Geliştirilen ağın problemi genelleştirememesi, ağın ezberlemesi, test doğruluğu ile eğitim doğruluğu arasındaki farkın fazla olması regülasyon yöntemlerinden bırakma katmanı tekniği kullanılarak ağı yeniden test edilmiştir. Tablo 3.27’de belirtilen A modelinde tam bağlantılı katman (F2)’dan önce eklenen D.25 (Dropout) katmanı 0.25 oranında uygulanmış 0.9535 değeri ile en iyi test doğruluğu değerini vermiştir.

Tablo 3.27. Bırakma katmanı oranlarının etkisi – 1

Model	Katmanlar	Epok	Eğitim Doğruluğu	Test Doğruluğu
A	F1024+BN+F512+BN+D.25+F2	25	0.9434	0.9535
B	F1024+BN+F512+BN+D.5+F2	25	0.9425	0.9487
C	F1024+BN+F512+BN+D.75+F2	25	0.9569	0.9439

Bu aşamada tam bağlantılı katman (F1024) ve tam bağlantılı katman (F512) arasında kullanılan bırakma katmanı tekniği test edilmiştir. Tablo 3.28’de bırakma katmanı oranı 0.5 değeri uygulanan B modeli 0.9585 ile en yüksek test doğruluğu elde edildi. Eğitim ve test doğruluğu incelendiğinde ağı ezberlemesinin önemli ölçüde azaldığı, eğitim ve test doğruluğu arasındaki farkın azaldığı görüldü.

Tablo 3.28. Bırakma katmanı oranlarının etkisi – 2

Model	Katmanlar	Epok	Eğitim Doğruluğu	Test Doğruluğu
A	F1024+BN+D.25+F512+BN+F2	25	0.9473	0.9471
B	F1024+BN+D.5+F512+BN+F2	25	0.9578	0.9583
C	F1024+BN+D.75+F512+BN+F2	25	0.9549	0.9439

3.2.7. Kırpma Veri Artırma Yöntemi

Akciğer röntgen görüntülerinde aşağıdaki şekildeki gibi kollar boyun gibi kısımların ağın performansına etkisini gözlemlemek için, pnömoniye etkisi olmayan bu kısımların kırpılarak ağın başarısına etkisi gözlenmiştir. Tablo 3.29’da eğitim veri setindeki görüntülerin tamamına uygulanan kırpma veri artırma yöntemi ile en yüksek test doğruluk oranı 0.9712 elde edilmiştir.

Tablo 3.29. Kırpma veri artırma yönteminin etkisi


Model	Katmanlar	Epok	Eğitim Doğruluğu	Test Doğruluğu
A	F1024+BN+D.5+F512+BN+F2	30	0.9069	0.9712

AlexNet mimarisine ek katmanlar eklenmiştir. Tam bağlantılı katman (1024) değeri ile birlikte yeni eklenen katmanlar eğik yazı ile tablo 3.30’da gösterilmiştir.

Tablo 3.30. AlexNet mimarisine ek katmanlar uygulanması

Katmanlar	Parametre
Giriş boyutu	224x224x3
Evrişim katmanı	11x11x96
Maksimum havuzlama	3x3
Evrişim katmanı	5x5x256
Maksimum havuzlama	3x3
Evrişim katmanı	3x3x384
Evrişim katmanı	3x3x384
Evrişim katmanı	3x3x384
Maksimum havuzlama	3x3
Tam bağlantılı katman	4096
Tam bağlantılı katman	4096
Ek Katmanlar	
<i>Tam bağlantılı katman</i>	<i>1024</i>
<i>Toplu normalizasyon</i>	
<i>Bırakma katmanı</i>	<i>0.5</i>
<i>Tam bağlantılı katman</i>	<i>512</i>
<i>Toplu normalizasyon</i>	
<i>Tam bağlantılı katman</i>	<i>2</i>
Softmax	

Şekil 3.3’de transfer öğrenme yöntemi kullanılarak önerilen modelin mimarisi gösterilmiştir.



Şekil 3.3. Transfer öğrenme yöntemi kullanılarak önerilen model

Tablo 3.31’de aynı veri seti ile elde edilen test doğruluk oranları bulunmaktadır. Önerilen ağ en iyi test doğruluk değerine ulaşmıştır. Aşağıdaki tablodaki yöntemler incelendiğinde veri artırma, farklı sınıflandırıcılar, önceden eğitilmiş ağlar ve AlexNet mimarisi görülmektedir.

Tablo 3.30. Aynı veri seti ile çalışılan makalelerin test doğruluk oranları

Yazarlar	Yöntem	Doğruluk
Chowdhury vd., 2021	ESA (4 Gizli Katman + SGİ)	%91.00
Kumari vd., 2021	Veri Artırmalı + Ön işleme + ESA	%91.18
Naskinova, 2021	Veri Artırmalı + ESA	%92.08
Gülgün ve Erol, 2019	Veri Artırmalı + ESA	%93.40
Toğaçar ve diğerleri, 2019	AlexNet + DVM	%95.80
Setiawan ve Damayanti, 2020	35 Katmanlı ESA	%96.30
Zubair, 2020	VGG16	%96.60
Bu çalışma	Veri Artırmalı + AlexNet + Ek katmanlar	%97.12

3.2.8. Modelin Başarım Ölçüm Sonuçları

Tablo 3.32’de en iyi test doğruluğu elde edilen modelin karmaşıklık matrisi verilmiştir. Tablo 3.32’de 225 ve 381 eğitilmiş ağ tarafından doğru sınıflandırmaların sayısını göstermektedir. 624 test görüntüsünden 225 tanesi normal olarak sınıflandırılmış ve tüm görüntülerin %36.1’i olmaktadır.

624 test görüntüsünden 381 tanesi pnömoni tespit edilerek, tüm test kümesinin %61.1'i olmaktadır. Pnömoni görüntülerinden 9 tanesi normal olarak sınıflandırılmış, tüm test verisinin %1.4 olduğu görülmektedir. Normal test kümesinden 9 tanesi pnömoni olarak sınıflandırılmış, tüm test verisinin %1.4'ünü göstermektedir. 234 normal tahminin %96.2'si doğru, %3.8'i yanlış sınıflandırılmış, 390 pnömoni tahmininin %97.7'si doğru, %2.3'ü yanlış sınıflandırılmıştır. 234 normal akciğer röntgen görüntüsünün %96.2'si normal, %3.8'i pnömoni tahmin edilmiştir. 390 pnömoni akciğer röntgen görüntüsünün %97.7'si pnömoni, %2.3'ü normal sınıflandırılmıştır. Genel olarak tahminlerin %97.1'i doğru, %2.9'u yanlış olarak sınıflandırılmıştır.

Tablo 3.31. Karmaşıklık matrisi

		Gerçek		Toplam
		Normal	Pnömoni	
Tahmin	Normal	225 %36.1	9 %1.4	234
	Pnömoni	9 %1.4	381 %61.1	390
Toplam		234	390	624

Önerilen modelin başarımı için tablo 3.33'de belirtilen kesinlik, duyarlılık ve F1 skor parametrelerinden yararlanılmıştır.

Tablo 3.32. Önerilen ESA modelinde sınıflandırma başarısı

Sınıflar	Kesinlik	Duyarlılık	F1 Skor
Pnömoni	0.9769	0.9769	0.9769
Normal	0.9615	0.9615	0.9615

4. SONUÇ VE ÖNERİLER

Tüm dünyada çocuk hastalıklarında ciddi ölümlere neden pnömoni hastalığının tespiti üzerinde çalışılmıştır.

Pnömoni hastalığının tespitinde akciğer röntgen görüntülerinden yararlanılmıştır. Radyologlar tarafından akciğer röntgen görüntülerinin yorumlanmasının zor olması çalışmanın önemini artırmaktadır. Bu hastalığın erken tespiti için derin öğrenme yöntemlerinden ESA geliştirilerek, uzmanlarımıza yardımcı bir sistem geliştirilmiştir. İki ayrı ESA modeli geliştirilmiştir. İlkinde tüm katmanlar en baştan özgün bir şekilde tasarlanmıştır, ikincisinde transfer öğrenme yöntemi kullanılan ağa ek katmanlar eklenerek ESA tasarlanmıştır. Elde edilen ağın performansını ölçmek için kesinlik, duyarlılık, F1 skor ve doğruluk metrikleri kullanılmıştır. Transfer öğrenme yöntemiyle geliştirilen ağın test doğruluk değeri 0.9712 değeri ile literatürdeki diğer çalışmalara göre yüksek test doğruluğu değerine ulaşmıştır. 5 yaş altı çocuklara ait önden çekilmiş akciğer röntgen görüntülerinden oluşan veri kümesinde görüntüler pnömoni ve normal olarak ikili sınıflandırma yapılmıştır.

Çalışmada aşağıdaki hususlar tespit edilmiştir;

- Özgün geliştirilen ESA ile Transfer öğrenme yöntemi ile önerilen ESA yöntemleri olmak üzere iki ayrı yöntem geliştirilmiştir. Özgün ESA ile evrişim, havuzlama, aktivasyon fonksiyonları ve tam bağlantılı katmanlar, hiper parametrelerin belirlenmesi gibi parametreler ağın eğitim süresini oldukça artırdı. Transfer öğrenme yöntemi ile önerilen ağda, ağın mevcut katmanlarına eklemeler yapılarak ağ mimarisi tasarımı çok daha hızlı oldu. Özgün geliştirilen ESA performansı ilk değeri 0.67 test doğruluk oranı ile başlarken, transfer öğrenme yöntemiyle bu değer 0.82 yüksek test doğruluğu oranı ile başlamıştır. Ağın eğitim süresi transfer öğrenme yönteminde daha kısaydı.
- Veri setini oluşturan 5 yaş altı çocuklara ait görüntülerde duruş bozuklukları, boyun, kol gibi uzuvların röntgende çıkması ESA'nın performansını önemli ölçüde etkilemektedir. Bu görüntülerde çeşitli veri ön işleme adımları ile performansın arttığı gözlenmiştir.
- Çalışılan veri setinin küçük boyutlu olması, verilerin (normal-pnömoni) dengesiz dağılım göstermesi ve görüntülerdeki kişi çeşitliliğin az olması, ESA'da ağın

ezberlemesi, aşırı uydurma problemlerine neden olmuştur. Veri artırma, regülasyon yöntemleri ile ağın performansı arttırılmıştır.

- Çalışılan küçük veri setinin olumsuzluğuna rağmen transfer öğrenme yöntemi ile geliştirilen ESA daha başarılı sonuçlar vermiştir. Transfer öğrenme uygulanan AlexNet ağı ağın eğitilme süresi, performansı, donanım gereksinimi göz önüne alındığında diğer ağlara göre hem zaman maliyet hem de performans açısından daha iyi bir sonuç vermiştir.
- Transfer öğrenme yöntemi ile önerilen evrişimsel sinir ağı mimarisi, akciğer röntgen görüntüleri gibi spesifik bir alanda da yüksek performans göstermiştir.
- Veri artırma yöntemlerinin yanında hiper parametrelerinde ağın performansını olumlu etkilediği görülmektedir.
- Küçük veri seti ile veri büyütme / veri ön işleme adımları uygulanarak derin öğrenmenin performansı arttırılabilmektedir. Evrişimsel sinir ağlarının küçük ve dengesiz yapıda olan veri setinde de kararlı sonuçlar verdiği görülmektedir.

Modelimizde dikkate alınması çok önemli olduğuna inandığımız bazı sınırlamalar mevcuttur. Bunlardan ilki, pnömoni tespitinde klinik değerlendirme akciğer röntgen görüntüleri gibi önemli bir adımdır. Hastanın geçmişinin olmaması, klinik değerlendirmeyle birlikte akciğer röntgen görüntü sonuçları daha net sonuçlar verecektir. İkinci olarak, sadece frontal göğüs röntgenleri kullanılmış, ancak yanal göğüs röntgenlerinin de tanıda yardımcı olduğu gösterilmiştir (Raoof ve diğerleri, 2012). Üçüncüsü, model çok sayıda evrişimli katman uyguladığından, çok yüksek hesaplama gücüne ihtiyaç duyar, aksi takdirde eğitim çok fazla zaman almaktadır. ESA'nın eğitimi sırasında donanım gereksinimi de ağın eğitimini oldukça etkilemektedir. Bu sınırlamalar sonraki çalışmalarda kullanılmak için önerilebilir.

5. KAYNAKÇA

- Alakwaa, W., Nassef, M. ve Badr, A., 2017. Lung Cancer Detection and Classification with 3D Convolutional Neural Network (3D-CNN), International Journal of Advanced Computer Science and Applications, 8(8), 409- 417.
- Anthimopoulos, M., Christodoulidis, S., Ebner, L., Christe, A. ve Mougiakakou, S., 2016. Lung Pattern Classification for Interstitial Lung Diseases Using a Deep Convolutional Neural Network, IEEE Transactions on Medical Imaging, 35(5), 1207-1216.
- Bewick, T., Greenwood, S. ve Lim, W. S., 2010. The Impact of An Early Chest Radiograph On Outcome In Patients Hospitalised With Community-Acquired Pneumonia, Clinical Medicine, 10(6), 563.
- Bottou, L., 2010. Large-Scale Machine Learning With Stochastic Gradient Descent. In Proceedings of 19th International Conference on Computational Statistics, 22-27 Ağustos 2010, Paris, Fransa, Eds: L., Yves; S., Gilbert, pp.177-186.
- Chandra, T. B. ve Verma, K., 2018. Pneumonia detection on chest X-Ray using machine learning paradigm. Proceedings of 3rd International Conference on Computer Vision and Image Processing, Eds: B. C. Bidyut, N. Masaki, K. Pritee, K. Sanjeev, 29 Eylül-01 Ekim 2018, Springer, pp. 21-33.
- Chowdhury, Y. S., Dasgupta, R. ve Nanda, S., 2021. Analysis of Various Optimizer on CNN Model In The Application of Pneumonia Detection. 2021 3rd International Conference On Signal Processing and Communication (ICPSC), 13-14 Mayıs 2021, Coimbatore, Hindistan, s. 417-421.
- Ciresan, D. C., Meier, U., Masci, J., Gambardella, L. M. ve Schmidhuber, J., 2011. Flexible, High Performance Convolutional Neural Networks For Image Classification. Twenty-Second International Joint Conference On Artificial Intelligence, 19-22 Temmuz 2011, Barcelona, İspanya, s. 1237-1242.
- Cunha, B. A., 2000. Community-Acquired Pneumonia: Reality Revisited. The American Journal of Medicine, 108(5), 436-437.
- Doğan, F. ve Türkoğlu, İ., 2019. Derin Öğrenme Modelleri ve Uygulama Alanlarına İlişkin Bir Derleme. Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi, 10(2), 409-445.
- Durmus, U., Adak, F. A. ve Oncel, S., 2008. Pneumonia In Children. Journal of Pediatric Infection, 2(4), 167-175.
- Egglı, K. ve Newman, B., 1993. Nodules, Masses, and Pseudomasses In The Pediatric Lung. Radiologic Clinics Of North America, 31(3), 651-666.

- Fiszman, M., Chapman, W. W., Aronsky, D., Evans, R. S. ve Haug, P. J., 2000. Automatic Detection of Acute Bacterial Pneumonia From Chest X-ray Reports. Journal of the American Medical Informatics Association, 7(6), 593-604.
- Franquet, T., 2001. Imaging Of Pneumonia: Trends And Algorithms. European Respiratory Journal, 18(1), 196-208.
- Gaál, G., Maga, B. ve Lukács, A., 2020. Attention U-Net Based Adversarial Architectures For Chest X-Ray Lung Segmentation. <https://arxiv.org/pdf/2003.10304.pdf>.
- Girshick, R., Donahue, J., Darrell, T. ve Malik, J., 2014. Rich Feature Hierarchies For Accurate Object Detection And Semantic Segmentation. Proceedings Of The IEEE Conference On Computer Vision And Pattern Recognition. 24-27 Haziran 2014, Ohio, ABD, s. 580-587.
- Goodfellow, I., Bengio, Y., Courville, A. ve Bengio, Y., 2016. Deep Learning, Vol. 1. MIT Press, ISBN: 978-026-2035-61-3, Cambridge, p. 767.
- Gülgün, O. D. ve Erol, H., 2019. Classification Performance Comparisons Of Deep Learning Models In Pneumonia Diagnosis Using Chest X-Ray Images. Turkish Journal of Engineering, 4(3), 129-141.
- Hashmi, M. F., Katiyar, S., Keskar, A. G., Bokde, N. D. ve Geem, Z. W., 2020. Efficient Pneumonia Detection in Chest Xray Images Using Deep Transfer Learning. Diagnostics, 10(6), 417.
- Hidayatullah, R. C. ve Violina, S., 2020. Convolutional Neural Network Architecture and Data Augmentation for Pneumonia Classification from Chest X-Rays Images. International Journal of Innovative Science and Research Technology, 5(2), 7.
- Islam, S. R., Maity, S. P., Ray, A. K. ve Mandal, M., 2019. Automatic Detection of Pneumonia on Compressed Sensing Images Using Deep Learning. 2019 IEEE Canadian Conference of Electrical and Computer Engineering (CCECE), 5-8 Mayıs 2019, Edmonton, Kanada, s. 1-4.
- Juven, T., Mertsola, J., Waris, M., Leinonen, M., Meurman, O., Roivainen, M., Jussi, E., Pekka, S., Ruuskanen, O., 2000. Etiology Of Community-Acquired Pneumonia In 254 Hospitalized Children. The Pediatric Infectious Disease Journal, 19(4), 293-298.
- Kermany, D. S., Goldbaum, M., Cai, W., Valentim, C. C. S., Liang, H., Baxter, S. L., ... Zhang, K., 2018. Identifying Medical Diagnoses and Treatable Diseases by Image-Based Deep Learning. Cell, 172(5), 1122-1131.
- Kingma, D. P. ve Ba, J., 2014. Adam: A Method For Stochastic Optimization. <https://arxiv.org/pdf/1412.6980.pdf>.
- Krizhevsky, A., Sutskever, I. ve Hinton, G. E., 2017. Imagenet Classification With Deep Convolutional Neural Networks. Communications of The ACM, 60(6), 84-90.

- Kumari, L. R., Bokkolla, P., Syeeda, S. F., Gudala, S. P. ve Dasandla, M., 2021. Detection of Pneumonia Using Deep Learning. 2021 5th International Conference on Trends in Electronics and Informatics (ICOEI), 3-5 Haziran 2021, Tirunelveli, Hindistan, s. 1272-1279.
- Kuş, Z., 2019. Mikrokanonikal Optimizasyon Algoritması ile Konvolüsyonel Sinir Ağlarında Hiper Parametrelerin Optimize Edilmesi. Yüksek Lisans Tezi, Fatih Sultan Mehmet Vakıf Üniversitesi Lisansüstü Eğitim Enstitüsü, 99s.
- LeCun, Y., Boser, B., Denker, J. S., Henderson, D., Howard, R. E., Hubbard, W. ve Jackel, L. D., 1989. Backpropagation Applied To Handwritten Zip Code Recognition. Neural Computation, 1(4), 541-551.
- Lee, C.-S., Wang, M.-H., Yen, S.-J., Wei, T.-H., Wu, I.-C., Chou, P.-C., ... Yan, T. H., 2016. Human vs. Computer Go: Review And Prospect. IEEE Computational Intelligence Magazine, 11(3), 67-72.
- Lichenstein, R., Suggs, A. H. ve Campbell, J., 2003. Pediatric Pneumonia. Emergency Medicine Clinics, 21(2), 437-451.
- Margolis, P. ve Gadomski, A., 1998. Does This Infant Have Pneumonia? Jama, 279(4), 308-313.
- Matsuki, Y., Nakamura, K., Watanabe, H., Aoki, T., Nakata, H., Katsuragawa, S. ve Doi, K., 2002. Usefulness Of An Artificial Neural Network For Differentiating Benign From Malignant Pulmonary Nodules On High-Resolution CT: Evaluation with Receiver Operating Characteristic Analysis. American Journal of Roentgenology, 178(3), 657-663.
- Mooney P., 2018. Chest X-Ray Images (Pneumonia). <https://www.kaggle.com/paultimothymooney/chest-xray-pneumonia>.
- Murphy, K. P., 2012. Machine Learning: A Probabilistic Perspective. MIT Press. ISBN: 978- 0-262-01802-9, Cambridge, 1054s.
- Naskinova, I., 2021. On Convolutional Neural Networks for Chest X-ray Classification. IOP Conference Series: Materials Science and Engineering, 4-6 Kasım 2020, Yambol, Bulgaristan, s. 1-8.
- Neuman, M. I., Monuteaux, M. C., Scully, K. J. ve Bachur, R. G., 2011. Prediction Of Pneumonia In A Pediatric Emergency Department. Pediatrics, 128(2), 246-253.
- Nino, G., Zember, J., Sanchez-Jacob, R., Gutierrez, M. J., Sharma, K. ve Linguraru, M. G., 2021. Pediatric Lung Imaging Features Of COVID-19: A Systematic Review and Meta-Analysis. Pediatric Pulmonology, 56(1), 252-263.
- O'Shea, K. ve Nash, R., 2015. An Introduction To Convolutional Neural Networks. <https://arxiv.org/pdf/1511.08458.pdf>.
- Özkan, İ. ve Ülker, E., 2017. Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri. Gaziosmanpaşa Bilimsel Araştırma Dergisi, 6(3), 85-104.

- Özlü, T., Bülbül, Y., Alataş, F., Arseven, O., Coşkun, A. Ş., Çilli, A., ... diğerleri, 2009. Türk Toraks Derneği Erişkinlerde Toplumda Gelişen Pnömoni Tanı ve Tedavi Uzlaş Raporu. Türk Toraks Dergisi, 10(9), 1-16.
- Parveen, N. ve Sathik, M. M., 2011. Detection of Pneumonia In Chest X-Ray Images. Journal of X-ray Science and Technology, 19(4), 423-428.
- Punn, N. S. ve Agarwal, S., 2021. Automated Diagnosis of COVID-19 With Limited Posteroanterior Chest X-Ray Images Using Fine-Tuned Deep Neural Networks. Applied Intelligence, 51(5), 2689-2702.
- Qian, N., 1999. On The Momentum Term In Gradient Descent Learning Algorithms. Neural Networks, 12(1), 145-151.
- Rahman, T., Chowdhury, M. E. H., Khandakar, A., Islam, K. R., Islam, K. F., Mahbub, Z. B., ... Kashem, S., 2020. Transfer Learning With Deep Convolutional Neural Network (CNN) for Pneumonia Detection Using Chest X-ray. Applied Sciences, 10(9), 3233.
- Rand, T., 1997. A Radiologic Approach to Diseases of The Chest. European Journal of Radiology, 3(25), 251-252.
- Raoof, S., Feigin, D., Sung, A., Raoof, S., Irugulpati, L. ve Rosenow, E. C., 2012. Interpretation of Plain Chest Roentgenogram. Chest, 141(2), 545-558.
- Ruder, S., 2016. An Overview of Gradient Descent Optimization Algorithms. <https://arxiv.org/pdf/1609.04747.pdf>.
- Sandal, Ö. S., Ceylan, G., Sarı, F., İşgüder, R., Devrim, İ. ve Ağın, H., 2016. Çocuk Yoğun Bakımda Yatan Hastalarda Toraks Patolojilerinin Tanısında Akciğer Grafisi ve Bilgisayarlı Toraks Tomografisinin Karşılaştırılması. Journal of Pediatric Emergency and Intensive Care Medicine, 3, 131-134.
- Schmidhuber, J., 2015. Deep Learning In Neural Networks: An Overview. Neural networks, 61, 85-117.
- Setiawan, W. ve Damayanti, F., 2020. Layers Modification of Convolutional Neural Network for Pneumonia Detection. Journal of Physics: Conference Series, 1477, 052055.
- Sousa, R. T., Marques, O., Soares, F. A. A., Sene Jr, I. I., de Oliveira, L. L. ve Spoto, E. S., 2013. Comparative Performance Analysis of Machine Learning Classifiers In Detection of Childhood Pneumonia Using Chest Radiographs. Procedia Computer Science, 18, 2579-2582.
- Şeker, A., DiRi, B. ve Balık, H. H., 2017. Derin Öğrenme Yöntemleri ve Uygulamaları Hakkında Bir İnceleme. Gazi Mühendislik Bilimleri Dergisi, 18.
- Şen, N. ve Özhan, M. H. (Ed.), 2017. Pnömoni. Türkiye Solunum Araştırmaları Derneği TÜSAD, ISBN: 978-605-4899-58-6, e-kitap, 224s.

- Tanaka, N., Matsumoto, T., Kuramitsu, T., Nakaki, H., Ito, K., Uchisako, H., ... Yamakawa, K., 1996. High Resolution CT Findings In Community-Acquired Pneumonia. Journal of Computer Assisted Tomography, 20(4), 600-608.
- Toğaçar, M., Ergen, B. ve Sertkaya, M. E., 2019. Zatürre Hastalığının Derin Öğrenme Modeli ile Tespiti. Fırat Üniversitesi Mühendislik Bilimleri Dergisi, 31(1), 223-230.
- Toikka, P., Virkki, R., Mertsola, J., Ashorn, P., Eskola, J. ve Ruuskanen, O., 1999. Bacteremic Pneumococcal Pneumonia In Children. Clinical Infectious Diseases, 29(3), 568-572.
- URL-1, <https://www.ncbi.nlm.nih.gov/books/NBK536940>. 21 Kasım 2020.
- URL-2, <https://www.who.int/news-room/fact-sheets/detail/pneumonia>. 06 Şubat 2021.
- URL-3, <https://www.lung.org/lung-health-diseases/lung-disease-lookup/pneumonia/symptoms-and-diagnosis>. 23 Ekim 2020.
- URL-4, <https://toraks.org.tr/site/resources/aegrotationes/p/5>. 29 Mayıs 2021.
- Varshni, D., Thakral, K., Agarwal, L., Nijhawan, R. ve Mittal, A., 2019. Pneumonia detection using CNN based feature extraction. 2019 IEEE International Conference on Electrical, Computer and Communication Technologies, 20-22 Şubat 2019, Coimbatore, Hindistan, s. 1-7.
- World Health Organization, 2001. Standardization of Interpretation of Chest Radiographs For The Diagnosis of Pneumonia In Children. No. WHO/V&B/01.35.
- Zeiler, M. D., 2012. Adadelta: An Adaptive Learning Rate Method. <https://arxiv.org/pdf/1212.5701.pdf>.
- Zubair, S., 2020. An Efficient Method to Predict Pneumonia from Chest X-Rays Using Deep Learning Approach. The Importance of Health Informatics in Public Health During A Pandemic, 272, 457.

ÖZGEÇMİŞ

Gazipaşa İlköğretim okulunda ilk ve ortaokulu tamamladı. 2001-2005 yılları arasında Ali Fuat Kadirbeyoğlu Anadolu Lisesi'nde öğrenimini tamamladı. 2005- 2009 yılları arasında Karabük Teknik Eğitim Fakültesi'nde Bilgisayar Öğretmenliği bölümünü tamamladı. 2017- 2019 yılları arasında Karadeniz Teknik Üniversitesi Bilgisayar Mühendisliği bölümünü bitirdi. 2019 yılında Gümüşhane Üniversitesi Biyoteknoloji Ana Bilim Dalı'nda Yüksek Lisans eğitime başladı. Halen Gümüşhane İl Milli Eğitim Müdürlüğü'nde Fatih Projesi İl Koordinatörlüğü görevini sürdürüyor.

