



T.C.
KONYA TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ



DERİN ÖĞRENME TEKNİKLERİNİ
KULLANARAK OTOMATİK TÜBERKÜLOZ
TEŞHİSİ

Pike MSONDA

YÜKSEK LİSANS
BİLGİSAYAR MÜHENDİSLİĞİ

Ağustos-2020
KONYA
Her Hakkı Saklıdır

TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.



Pike MSONDA

ÖZET

YÜKSEK LİSANS

DERİN ÖĞRENME TEKNİKLERİNİ KULLANARAK OTOMATİK TÜBERKÜLOZ TEŞHİSİ

Pike MSONDA

Konya Teknik Üniversitesi
Lisansüstü Eğitim Enstitüsü
Bilgisayar Mühendisliği

Danışman: Dr. Öğr. Üyesi Sait Ali UYMAZ
2. Danışman: Uzm. Dr. Seda SOĞUKPINAR KARAAĞAÇ

2020,52 Sayfa

Jüri

Dr. Öğr. Üyesi Sait Ali UYMAZ
Dr. Öğr. Üyesi Yusuf UZUN
Dr. Öğr. Üyesi Alper KILIÇ

Son yıllarda, makine öğrenimi tekniklerini kullanan otomatik teşhis, araştırmaların odak noktası olmuştur. Sınıflandırıcıların, belirli bir görevi eğitilmiş bir meslek kadar iyi yerine getirebilme yeteneği, birçok uygulamaya kapı açar. *Mycobacterium Tuberculosis (TB)*, hastalığı hızlı bir şekilde teşhis edip tedavi edebilen zayıf sağlık sistemi altyapısı nedeniyle gelişmekte olan ülkelerin çoğunu rahatsız eden ölümcül bir hastalıktır. Dünya Sağlık Örgütü (WHO), yeni enfeksiyonlarda ve ölümlerde önemli azalma için 2030 ve 2035 yıllarını kilometre taşları olarak belirledi. WHO, TB'nin doğru bir şekilde teşhis edilmesini ve endemik olarak yok edilmesini yavaşlatan faktörleri iyi eğitilmiş profesyonellerin bulunmamasına ve yetersiz veya kırılabilir halk sağlığı sistemlerine bağlamaktadır. Evrişimli sinir ağları (CNN'ler), bilgisayarlı görü alanında, yani görüntü tanıma ve algılama alanında dikkate değer bir başarı göstermektedir. Bu nedenle, CNN'nin radyoloji ile birleşen görüntü sınıflandırmasındaki başarısı, bu yöntemi potansiyel TB hastalarının Göğüs Röntgeni (CXR) görüntülerini sınıflandırmak ve hızlı tanı koymak için mükemmel bir aday haline getiriyor. Bu çalışmada, iki kamuya açık veri seti kullanılarak eğitilen üç tür CNN ve Konya Eğitim ve Araştırma Hastanesi'nden toplanan yeni bir veri setiyle oluşturulan CNN tanımlanmaktadır. Ayrıca, CNN mimarilerine, uzaysal kutular kullanılarak sağlam özellik havuzlama yeteneği ile evrişimli sinir ağlarını donatan bir metodoloji olan Uzamsal Piramit Havuzlama (SPP) adlı ekstra bir katman entegre edildi. Sonuçlarımız, otomatik bir sistemin, akciğer tüberkülozunu teşhis etmede bir radyolog profesyonelinin üzerinde doğruluk oranına sahip olduğunu göstermiştir.

Anahtar Kelimeler: Derin Öğrenme, Evrişimli Sinir Ağı, Tüberküloz, Uzamsal Piramit Havuzlama.

ABSTRACT

MS THESIS

AUTOMATED DIAGNOSIS OF TUBERCULOSIS USING DEEP LEARNING TECHNIQUES

Pike MSONDA

Konya Technical University
Institute of Graduate Studies
Department of Computer Engineering

Advisor: Asst. Prof. Dr. Sait Ali UYMAZ
2. Advisor: Dr. Seda SOĞUKPINAR KARAAĞAÇ

2020, 52 Pages

Jury

Assist. Prof. Dr. Sait Ali UYMAZ
Assist. Prof. Dr. Yusuf UZUN
Assist. Prof. Dr. Alper KILIÇ

In recent decades, automatic diagnosis using machine-learning techniques have been the focus of research. The ability of classifiers to be able to perform a specific task as good as a trained profession opens the door to a lot of applications. *Mycobacterium Tuberculosis (TB)* is a deadly disease that plagues most developing countries due to weak health system infrastructure that can be able to quickly diagnose and treat the disease. The World Health Organisation (WHO) has set years 2030 and 2035 as milestones for significant reduction in new infections and deaths. The WHO reports that lack of well-trained professionals to accurately diagnose TB and insufficient or fragile public health systems which are mostly overwhelmed are the major factors that have slowed the eradication of the TB endemic. Convolutional neural networks (CNNs) have demonstrated remarkable success in the field of computer vision i.e. image recognition and detection. Consequently, common methodology for detecting TB is through radiology combined with previous success CNN have achieved in image classification makes them the perfect candidate to classify Chest X-Ray (CXR) images of potential TB patients. In this study, we propose three types of CNN trained using two public datasets and another which was collected from Konya Education and Research Hospital, Konya, Turkey. Also, the CNN architectures were integrated an extra layer called Spatial Pyramid Pooling (SPP) a methodology that equips convolutional neural networks with the ability for robust feature pooling by using spatial bins. Our results indicate a huge potential for an automated system to diagnose tuberculosis with accuracies above a radiologist professional.

Keywords: Convolutional Neural Network, Deep Learning, Tuberculosis, Spatial Pyramid Pooling.

ÖNSÖZ

Teknolojik ilerlemenin en büyük teşviklerinden biri, sağlık hizmetlerini daha iyi ve daha güvenilir bir şekilde yer almasıdır. Artan netcentric toplumu, varlıklar arasındaki daha derin korelasyonu ortaya çıkaran veri kaynağını sağlar. Bu motivasyonla birlikte, bu rapor insan uzmanlarına yakın veya daha iyi doğrulukla hastalıkları otomatik olarak teşhis etmeye dayanmaktadır. Spesifik olarak, TB, gelişmekte olan ülkelerin çoğunda, sağlık tesislerinin yanı sıra profesyonel (iyi eğitilmiş) sağlık personelinin bulunmamasından kaynaklanan sıkıntıya neden olan bir hastalıktır. Bu sorunun aşikar teknolojik çözümü, TB'yi çok az denetlemeden veya hiç denetlemeden otomatik olarak teşhis edebilen bir araç (yazılım veya donanım) kullanmaktır. Makine öğrenimindeki gelişmeler, konveksiyonel makine öğrenme algoritmasından daha iyi veri varlıkları arasında ilişki bulma kapasitesine sahip olan derin sinir ağlarının (DNN) yükselişini sağlamıştır. DNN'ler, itiraz tanıma, konuşma tanıma ve doğal dil işlemenin başarılı bir şekilde uygulanmasıyla kanıtlanmış çok umut verici algoritmalarlardır.

Bu çalışmanın gerçekleştirilmesinde, değerli bilgilerini benimle paylaşan, kendisine ne zaman danışsam bana kıymetli zamanını ayırıp, sabırla ve büyük bir ilgiyle bana faydalı olabilmek için elinden gelenden fazlasını sunan, her sorun yaşadığımda yanına çekinmeden gidebildiğim, güler yüzünü ve samimiyetini benden esirgemeyen ve gelecekteki mesleki hayatımda da bana verdiği değerli bilgilerden, danışman hoca statüsünü hakkıyla yerine getiren Dr. Öğr.Üyesi Sait Ali UYMAZ'a ve Uzman Dr. Seda SOĞUKPINAR KARAAĞAC'a teşekkürü bir borç biliyor ve şükranlarımı sunuyorum.

Teşekkürlerim az kalacağı diğer üniversite hocalarımdan da bana üniversite hayatım boyunca kazandırdıkları her şey için hepsine teker teker teşekkürlerimi sunuyorum ve benden hiçbir zaman desteğini esirgemeyen bu hayattaki en büyük şansım olan aileme de sonsuz teşekkür ederim.

Pike MSONDA
KONYA-2020

İÇİNDEKİLER

ÖZET	ii
ABSTRACT.....	iii
ÖNSÖZ	iv
İÇİNDEKİLER	v
SİMGELER VE KISALTMALAR	vii
1. GİRİŞ	1
2. KAYNAK ARAŞTIRMASI	4
3. MATERYAL VE YÖNTEM.....	11
3.1 Derin Öğrenme (DL)	11
3.1.1 Kısıtlı Boltzmann makinesi (RBM)	12
3.1.2 Otomatik kodlayıcı (AE)	13
3.1.3 Derin İnanç Ağı (DBN)	14
3.1.4 Yinelene Sinir Ağı (RNN)	15
3.1.5. Evrişimsel Sinir Ağları (CNN'ler)	16
3.1.1. Evrişim (Convolution) Katmanı	16
3.1.2 Aktivasyon fonksiyonları (AFs)	17
3.1.1.1 Sigmoid.....	18
3.1.1.2 Hyperbolic Tangent Function (Tanh)	18
3.1.1.3 Softmax.....	19
3.1.1.4 Rectified Linear Unit (ReLU) Function.....	19
3.1.2 Ortaklama (Pooling) Katmanı.....	20
3.1.3 Tam Bağlantılı (Fully Connected) Katmanı	22
3.2 Derin Evrişimsel Sinir Ağları (DCNN)	24
3.2.1 AlexNet.....	24
3.2.2 GoogLeNet (InceptionV1).....	25
3.2.3 ResNet.....	27
3.3 Veri Çoğaltma.....	28
3.4 Uzamsal Piramit Havuzlama (SPP)	29
4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA.....	31
4.1. Veriseti.....	32
4.1.1 Halka Açık Verisetleri	32
4.1.2 Konya Eğitim Araştırma Hastanesi (KERH) Veriseti	33
4.3 Veri ön işleme ve büyütme	34
4.3.1 Yeniden boyutlandırma.....	35
4.3.2 Rastgele Kırpma	35

4.3.3 Yatay ve dikey çevirme	35
4.3.4 Rastgele döndürme	36
4.3.5 Kontrast sınırlı uyarlanabilir histogram eşitleme (CLAHE).....	36
5. SONUÇLAR VE ÖNERİLER	38
5.1 Sonuçlar	38
5.2 Araştırma Bulguları	43
5.3 Öneriler	43
KAYNAKLAR	45
ÖZGEÇMİŞ	51



SİMGELER VE KISALTMALAR

Kısaltmalar

CDSS	– Klinik Karar Destek Sistemi
CNN	– Evrişim Sinir Ağı
KERH	– Konya Eğitim Araştırma Hastanesi
CXR	– Göğüs Röntgeni Görüntüleri
DCNN	– Derin Evrişimsel Sinir Ağları
HIV	– İnsan Bağışıklık Eksikliği Virüsü
ILSVRC	– ImageNet Büyük Ölçekli Görsel Tanıma Yarışması
SGD	– Olasılıksal Dereceli Azalma
SPP	– Uzamsal Piramit Havuzlama.
SVM	– Destekçi Vektör Makinesi
TB	– Tüberküloz.
WHO	– Dünya Sağlık Örgütü
NN	– Sinir ağı
DBN	– Derin İnanç Ağı
RBM	– Kısıtlı Boltzmann makinesi
AE	– Otomatik kodlayıcı
CADx	– Bilgisayar Destekli Tanı
AF	– Aktivasyon fonksiyon
DL	– Derin Öğrenme
RNN	– Yinelenen Sinir Ağı
GPU	– Grafik İşleme Birimi
CPU	– Bilgisayar işlem birimi
CLAHE	– Kontrast sınırlı uyarlanabilir histogram eşitleme

1. GİRİŞ

Tüberküloz (TB), çoğunlukla endemik olarak görülen ölümcül sonuçlara neden olabilen tehlikeli bir hastalıktır. Bilimsel olarak *Mycobacterium tuberculosis* adı verilen bir patojenin neden olduğu TB, genellikle gelişmekte olan ülkelerdeki görülmektedir (World Health, 2018). Küresel olarak tüberküloz ölüm oranı 2000 yılından bu yana yılda yaklaşık %3 ve toplamda %42 azalmış olup, bu düşüş oranı tanı konan ve tedavi edilen hasta sayısındaki önemli ilerlemeyi yansıtmaktadır. Ayrıca, bu durum tüberkülozun yoksulluğa bağlı itici güçlerinin azalması ve ekonomilerin büyümesi ile de ortaya çıkmıştır. Örneğin, Fildişi Sahili, Etiyopya, Vietnam ve Zimbabve, 2000-2017 yılları arasında tüberküloz ölüm oranında yıllık ortalama %6'dan fazla düşüş kaydedilmiştir (Reid ve ark., 2019). Gelişmekte olan ülkeler sağlık sistemi zayıflıkları nedeniyle bu ölümcül hastalığın en büyük mağdurlarıdır. Bu da yeni tıbbi araçlar geliştirmeye yönelik araştırmalara yatırım yapılmaması, bireysel hastaların farklı ihtiyaçlarını karşılamayan basitleştirilmiş, tek bedene uyan yaklaşımların uygulanması, HIV (Human Immunodeficiency Virus) koenfeksiyonu ve ilaç direncinin yayılması gibi biyolojik faktörler ve gizli tüberküloz enfeksiyonunun büyük ve kalıcı etkisine bağlıdır. (Reid ve ark., 2019; World Health, 2018).

Ayrıca tüberküloz, potansiyel riskli gruplarda öngörülemeyen orantısız bir etkiye sahip olabilmektedir. Lancet Sağlık Yatırım Komisyonu 14, 2018 Astana Herkes İçin Sağlık Konferansı için hazırlanan bir raporda, çocuk ölümleri, anne ölümleri ve HIV de dahil olmak üzere diğer önemli sonuçlara ilişkin ilerleme bağlamında tüberküloza karşı ilerlemeyi değerlendirmiştir. Komisyon, 2000 yılından bu yana çocuk ölümleri ve HIV ölümlerindeki düşüş oranlarının azaldığını ve hala arttığı sonucuna varmıştır (Reid ve ark., 2019).

Ayrıca komisyon, 2010 yılında anne ölüm ve tüberküloza karşı ilerlemenin önemli ölçüde yavaşladığını bildirdi (Organization, 2013; World Health, 2018). Yüksek HIV oranlarının birincil bir sonucu olarak, gelişmekte olan ülkelerdeki insanların TB'ye yakalanma olasılığı daha yüksektir. Birkaç TB türü arasında, pulmoner TB en çok endişe duyulan tutulum şeklidir (Abebe, Bonga ve Kebede, 2019).

Bu tür TB, esas olarak vücudun pulmoner bölgesini tutmaktadır. Pulmoner TB hastalarını teşhis etmenin en yaygın ve etkili yollarından biri göğüs radyografileridir (CXR). Dünya Sağlık Örgütü (WHO) tarafından 2017 yılında 1,3 milyon HIV negatif insanın sadece ek 300 bin HIV pozitif insanla birlikte TB' den dolayı öldüğü tahmini,

TB'nin ölümcüllüğünü yansıtmaktadır (World Health, 2018). TB ile enfekte olan insan sayısını azaltma çabaları artmaktadır, ancak gelişmekte olan ülkelerde uzman klinik bakım eksikliği bu girişimlerin etkinliğini azaltmaktadır. Çeşitli TB türlerinin varlığı tıbbi olarak tanı ve tedavide farklı stratejiler gerektirir. Akciğer Tüberkülozu, en çok görülen ve en fazla komplikasyonlara neden olan alt tipi olup bu çalışmanın temelini oluşturmaktadır. Bu tip çoğunlukla göğüs boşluğunu daha çok akciğerleri etkiler, bu da çoğu durumda bu tür TB ile ilişkili birçok semptom arasında uzun süreli öksürük, göğüs ağrıları, yorgunluk ve ateş ile sonuçlanır. WHO tarafından belirtildiği gibi (World Health, 2018), HIV ile yaşayan insanların HIV'in vücudun bağışıklık sistemi üzerindeki olumsuz etkileri nedeniyle TB'ye yakalanma olasılığı daha yüksektir (Abebe ve ark., 2019).

Bir CXR görüntüsü, vücuttaki organların eşleştirilmesinin anlık görüntüsüdür. Tüberküloz için uzmanlar, akciğerlerde, TB'ye neden olan bakteri ile eşanlamlı olan boşluk infiltrasyonu seviyesini inceleyerek bir hastada TB varlığını tespit edebilirler (Candemir ve ark., 2014; Lakhani ve Sundaram, 2017). Doğru test yöntemleri mevcut olmakla birlikte, gelişmekte olan ülkelerde finansal olarak sürdürülebilir değildir. CXR'lerin kullanımı, görüntü sınıflandırma için derin öğrenme modellerinin potansiyelini gerçekleştirmek için mükemmel bir veri kaynağı sunmaktadır. Derin öğrenme teknolojilerinin yükselişi, bilgisayar donanımı ve yazılımının ilerlemesi ile artmıştır. Son yıllarda, Grafik İşlem Birimlerinin (GPU) ve Bilgisayar İşlem Birimlerinin (CPU) hesaplama gücünün artması, bilgisayar görme, doğal dil işleme ve ses tanıma konularındaki araştırmaları ileriye taşımıştır (McBee ve ark., 2018b; McCoppin ve Rizki, 2014). Neyse ki, TB iyileştirilebilir bir hastalıktır ve en önemlisi önlenabilir bir hastalıktır. 2000-2007 yılları arasında erken teşhis ve tedavi ile 54 milyon hayat ölümden kurtulmuştur (World Health, 2018). Bu istatistik bu araştırmanın amacını körükler, TB'li kişileri hızlı bir şekilde teşhis edebilirsek, onları hızlı bir şekilde tedavi edebilir ve böylece daha fazla hayat kurtarabiliriz. Akciğer görüntülerini üreten Göğüs Radyografisi, TB tanısında kullanılan yöntemlerden biridir. Sunulan bu problem radyografik görüntüler içerdiğinden, CNN modelleri çözümde en etkili yöntemlerdir (Affonso, Rossi, Vieira ve de Carvalho, 2017). CNN, belirli bir görüntü veri kümesinde, ilgili oldukları düşünülen özellikleri doğrudan tanımlar ve ayıklar.

Derin evrişimli sinir ağları (DCNN'ler) modelleri, standart CNN modellerinden sadece bir adım ötededir. Amaç, bir Radyoloğun elde edeceği tanıya hemen hemen aynı veya daha fazla doğruluk oranı sağlamaktır. Daha geniş bir Klinik Karar Destek

Sistemine (CDSS) entegre edilirse, bu modeller özellikle sayısını azaltabilir. Bu çalışma DCNN kullanarak otomatik tanılamaya odaklanmıştır. CNN kavramı Zaman Gecikmeli Sinir Ağlarından (TDNN) alınmıştır. TDNN' de, ağırlıklar ağ genelinde geçici olarak paylaşılır, bu hesaplama karmaşıklığını azaltmaya yardımcı olur (W. Liu ve ark., 2017). Normal NN' lerde bulunan genel matris çarpımı konvülsiyon ile değiştirilir, bu doğrudan ağırlık sayısının azaltılmasına ve sonuç olarak genel karmaşıklığın azaltılmasına katkıda bulunur. Bu nedenle, CNN, videolar gibi görüntülerin olduğu gibi ızgara benzeri veri topolojisiyle uğraşırken dikkate değer bir performans göstermiştir. Bunları diğer derin öğrenme mimarilerinden ayıran bir diğer özellik de ham girdi ve görüntüleri özellik çıkarma ve seçme olmadan doğrudan ağa aktarma yeteneğidir. Buna ek olarak, CNN, başarılı bir şekilde hiyerarşik katmanlar oluşturabildiği için, derin bir öğrenme mimarisini düzgün bir şekilde uygulayan ilk mimaridir (Alex Krizhevsky, Ilya Sutskever ve Geoffrey E Hinton, 2012a; W. Liu ve ark., 2017).

Kısacası CNN, özel olarak düzenlenmiş verilerle çok iyi çalışan güçlü bir derin öğrenme mimarisi olarak görülebilir, yapısı nedeniyle ağırlık hesaplayabileceği parametre sayısını azaltır, böylece performansını katlanarak artırır. CNN'nin başarısı, el yazısı tanıma, yüz tanıma, davranış tanıma, konuşma tanıma, görüntü sınıflandırma ve çok daha fazlasının başarılı bir şekilde uygulanmasına yol açmıştır. Bu çalışma, bir hastanın TB olup olmadığını belirlemek için bir model oluşturmak üzere görüntüleri sınıflandırmadaki DCNN' nin gücünden yararlanır. Başlangıçta DCNN, birçok hesaplama kaynağının kullanılmasını gerektirir. Özel GPU tabanlı çerçeveler, eğitim süresini haftalardan bir güne verimli bir şekilde azaltarak bu sorunu hafifletmiştir. Bu teknolojiler, DCNN' yi görüntü tanıma için kullanılacak fiili araç haline getirmiştir (Litjens ve ark., 2017).

Bu tez kapsamında literatürde iyi bilinen 3 farklı DCNN mimarisi; AlexNet, InceptionV1 olarak da adlandırılabilen GoogLeNet ve son olarak bir Artık Ağ (ResNet) uygulanmıştır. Sonuçlar çok tatmin edicidir ve hasta teşhisinden elde edilen sonuçların doğruluğunu arttırmıştır.


2. KAYNAK ARAŞTIRMASI

Yapay zeka araştırmalarındaki hızlı gelişme; daha derinlemesine öğrenme, karmaşık tahmin modellerini, örneğin birçok gizli üniteye sahip çok katmanlı sinir ağlarını öğrenmek için kullanılabilecek tek bir yöntem yerine öğrenme algoritmalarının bir kombinasyonunu içeren makine öğreniminde yeni bir öğrenme paradigmasını temsil eder (LeCun, Bengio ve Hinton, 2015). Derin öğrenme yöntemleri birkaç uygulama problemine başarıyla uygulanmıştır. Örneğin, bir derin öğrenme yöntemi, %0,21 hata oranı ile MNIST veri kümesinin el yazısı basamaklarının sınıflandırılması için rekor kırmıştır (Wan, Zeiler, Zhang, Cun ve Fergus, 2013).

Görüntü analizi ve konuşma tanıma alanında son dönemdeki önemli çalışmaların sonuçları, bu alanda büyük bir ilgi yaratmıştır. Bu durum büyük veri sağlayan diğer birçok alandaki uygulamalar için de mümkün olduğunu göstermiştir. İş Zekası (BI) ile birlikte sürekli büyüyen Finansal Teknoloji (Fintech), Robotik, Makine çevirisi otomasyonun sınırlarını zorlamıştır. Aynı şekilde, tıp ve sağlık sektörü de aynı motivasyon ile süreçleri otomatik hale getirme dürtüsünü almıştır. Sonuç olarak, herkese açık bir veri setinin kullanılabilirliği nedeniyle, aynı motivasyon, daha önce sunulan çalışmaların yöntemsel olarak iyileştirilmesi olarak ortaya çıkan bu çalışmaya taşınmıştır (Ravi ve ark., 2016).

Derin öğrenme, çoklu işleme katmanlarından oluşan hesaplama modellerinin, birden fazla soyutlama seviyesine sahip verilerin temsillerini öğrenmesini sağlar. Bu yetenek, bilginin ve uzman deneyiminin teknik olarak önemli olduğu tıp alanında bilgisayar destekli yardımcı karar verme sistemi için kullanılabilir. Böylece, bu kabiliyeti sergileme girişimi (Liang, Zhang, Huang ve Hu, 2014) tarafından sunulmaktadır. Derin model, insanın düşünme yapısını simüle edebilir ve özellik gösterimi ile öğrenmeyi birleşik bir modelde birleştirebilir. Evrimsel derin inanç ağlarının değiştirilmiş bir versiyonu, büyük ölçekli veri setleri için etkili bir eğitim yöntemi olarak kullanılır. İki farklı veri seti ile test edilmiştir: ilki HIS sisteminden alınan hipertansiyon üzerine bir veri kümesi ve ikincisi manuel olarak dönüştürülmüş bir elektronik tıbbi kayıt (EMR) veri tabanından Çin tıbbi tanı ve tedavi reçetesi üzerine bir veri kümesidir (Liang ve ark., 2014). (Ravi ve ark., 2017), bu tez raporunda temelini oluşturan tıbbi görüntü analizinin kapsamlı bir incelemesini sunmaktadır.

Tıbbi görüntüleme ile ilgili problemleri çözmeye derin öğrenme tekniklerinin potansiyelini araştırırlar. İdeal olarak, bilgisayar yardımı ile kayıt, tespit, bölümlendirme ve son olarak teşhis yeteneği bir mikroskop altına konulur ve daha iyi sonuçlar elde etmek için iyileştirmenin gerekli olduğu alanların detaylandırılması sağlanır (Shen, Wu ve Suk, 2017).



Şekil 2.1: CNN radyografideki özelliklerin saptanması (Shen ve ark., 2017).

Şekil 2.1’de CNN modellerinin hastalıkları radyografik verilerden nasıl tespit edebildiğini göstermektedir. CADx (Bilgisayar Destekli Tanı), görüntü tabanlı bilgilerden bir hastalığın değerlendirilmesiyle ilgili bölümlendirme veya algılamadan ikinci bir katman işlevselliği sağlar. CADx’in başlıca uygulamaları, malign lezyonlardan malign ayrımını ve bir veya daha fazla görüntüden belirli hastalıkların tanımlanmasını içerir. Geleneksel olarak, çoğu CADx sistemi, alan uzmanları tarafından tasarlanmış özellikleri kullanmak üzere geliştirilmiştir (Shen ve ark., 2017).

2016 yılında Hwang, Kim, Jeong ve Kim (2016a) tarafından tam tüberküloz CXR’lerle eğitilmiş 6 katmanlı bir CNN mimarisi sunulmuştur. Ortaya çıkan sonuçlar, Eğri Altındaki Alan (AUC) kriterlerine göre 0.96, 0.93 ve 0.88 arasında değişen değerlerle mükemmel sonuçlardır (Hwang ve ark., 2016a). Jaeger ve ark. (2013) ilk veri setinde 0.783 ve ikinci veri setinde 0.840 hassasiyetle otomatik tanı sistemini önermektedir. Elde edilen sonuçlar, grafik kesimi ve son olarak sınıflandırmak için Destek Vektör Makineleri kullanılarak (SVM) akciğer segmentasyonundan elde edilmiştir.

Ayrıca, 2017 yılında Radiology.org tarafından yayınlanan ve Lakhani ve Sundaram (2017) tarafından yazılan bir rapor tüberkülozu teşhis etmek için bir otomasyon kullanılmasını önermektedir. Çalışmada 2 modelden elde edilen bir dizi sonuç sunmuşlardır; AlexNet ve GoogLeNet. Her biri önceden eğitilmiş model sonuçlarının yanı sıra eğitimsiz (önceden eğitilmemiş) model sonuçlarından oluşur. Bunun da ötesinde, AlexNet ve GoogLeNet' ten elde edilen olasılık puanlarının ağırlıklı ortalamalarının yarısını kullanan bir topluluk modeli önermişlerdir. GoogLeNet, AlexNet ve Ensemble modellerden sırasıyla 0,953, 0,933 ve 0,960 sonuçlar elde etmişlerdir (Lakhani ve Sundaram, 2017).

Benzer şekilde, Rajpurkar ve ark. (2017) tarafından sunulan çalışmada olduğu gibi CXR görüntüleri Pnömoni saptamasında da kullanılabilir. Radyologların ortalamasından daha yüksek bir F1 skoru üreten 121 katmanlı bir DCNN tasarlanmıştır. Son olarak, (Cao ve ark., 2016) derin öğrenme ve mobil sağlık teknolojilerini harmanlayarak yoksul toplumlarda tüberküloz teşhisini iyileştirmeyi amaçlamaktadır (Cao ve ark., 2016; Rajpurkar ve ark., 2017).

Derin öğrenmenin gücü, belirli problemleri büyük etki ile çözmek için kullanılabileceğini göstermiştir. Derin öğrenme algoritmaları Faust, Hagiwara, Hong, Lih ve Acharya (2018) tarafından sunulduğu gibi tüberkülozun otomatik teşhisini gerçekleştirmek için kullanılmıştır. Bu raporda, ortalama %94,88 doğruluk üreten sinir ağını optimize etmek için genetik algoritma kullanılmıştır. Açıkçası, derin öğrenme çözümleri sadece tüberküloz ile ilgili problemleri çözmekle kalmaz. Daha önceki bir araştırma, Alzheimer hastalığının (AD) sınıflandırılmasında büyük kazanımlar olduğunu göstermektedir (S. Liu ve ark., 2014). ADNI veri kümesini kullanarak da benzer bir çalışma yürütülmüş, önerilen yöntemin AD, MCI ve MCI dönüştürücü tanısı için sırasıyla %95.9, %85.0 ve %75.8 doğru olduğunu gösteren deneyler gerçekleştirilmiştir (Suk ve Shen, 2013). Bu araştırma, makine öğrenmesi algoritmalarını derin öğrenme teknikleriyle karşılaştırmaktadır. Bu amaç ile , AD ve prodromal aşaması Hafif Bilişsel Bozukluk (MCI) tanısına yardımcı olmak için otomatik kodlayıcıları ve bir Softmax çıktı katmanını modellemişlerdir (S. Liu ve ark., 2014).

Derin öğrenme tekniklerinin ürettiği kalıcı ve güvenilir sonuçlardan ve özellikle ilgi çeken radyografik verilerle ilgili sorunlardan daha fazla ilham alınmaktadır. En az 433 görüntüden oluşan veri kümesiyle (Bar, Diamant, Wolf ve Greenspan, 2015) farklı patolojiler için 0.87-0.94 (AUC) elde edilen bir çalışma sunmaktadır (Bar ve ark.,

2015). Bu çalışma, tıbbi olmayan büyük bir görüntü veritabanı olan ImageNet ile derin öğrenmenin, genel tıbbi görüntü tanıma görevleri için henüz kullanıma sunulmamış olan etki alanına özgü gösterimlerin yerine iyi bir alternatif olabileceğini gösteren türünün ilk örneğidir (Bar ve ark., 2015).

2015 yılında Lopes ve Valiati (2017) tüberküloz tespiti için bir özellik çıkarıcıya önceden hazırlanmış bir CNN kullanmaya çalışmıştır. Elde edilen sonuçlar, tıbbi görüntü özelliği çıkarıcılar olarak önceden eğitilmiş evrimsel ağların potansiyelini gösteren yayınlanmış çalışmalarla rekabetçidir. Bu sonuca varmak için birkaç CNN mimarisi kullanılmıştır; ImageNet kullanılarak önceden eğitilmiş GoogLeNet, VggNet ve ResNet. ResNet 227 x 227 x3 kullanırken, 224 x 224 x 3 boyutu hem Google Net hem de VggNet için kullanılmıştır (Lopes ve Valiati, 2017). GoogLeNet, iki veri kümesi arasında (0.782, 0.823) (0.725, 0.837) ve ResNet (0.804, 0.811) hassasiyetiyle en iyi sonuçları vermiştir.

Evrışimli sinir ağları (CNN'ler), görüntü ve videoları içeren problemler için en uygun yöntemlerdir (W. Liu ve ark., 2017; McBee ve ark., 2018a). DSÖ'nün 2030 yılına kadar TB'yi tamamen yok etme girişimleri doğrultusunda, bilgisayar destekli tanı bu hedefe ulaşmada yardımcı olan yöntemlerden biridir. Bu çalışmada, radyolojide kullanılan yaygın yöntemlerden biri olan Göğüs Röntgenlerini (CXR) kullanarak TB'den etkilenen TBC hastalarını sınıflandırmada DCNN' yi kullanan bir metodoloji sunulmaktadır. CXR' ler, göğüste, yani akciğerlere ve kalbe iç vücut organlarının anlık görüntülerini oluşturmaya yardımcı olan kontrollü bir iyonizasyon dozunun sonucudur. Ancak bu CXR' ler, TB tanısı koymanın en yaygın yollarından birini sağlar; bu görüntüleri genellikle doğru bir şekilde okuyabilmek için eğitilmiş bir uzman gerektirir. Bu çalışmada kullanılan verilerin bir kısmı üzerinde, eğitilmiş bir uzmanın bile yaklaşık %84 doğruluk elde edebildiği belirtilmiştir. CXR görüntülerini sınıflandırmak için makine öğrenme algoritmalarının denemeleri, Destek Vektör Makinesi (SVM) gibi algoritmalarla oldukça iyi performans gösteren umut verici sonuçlar üretmiştir. Bu özel durumda veriler, özellikleri SVM' ye beslemeden önce grafik kesme algoritması kullanılarak bölümlere ayrılmıştır (Jaeger, Karargyris, ve ark., 2014a). Klinik verilerin X-ışını tabanlı bilgisayar destekli tespit girişimi ile birlikte kombinasyonu, (0.84, 0.74, 0.72) 'nin çalışma karakteristik eğrisi açısından çarpıcı sonuçlar vermiştir (Melendez ve ark., 2016). Araştırmacılar, yaklaşık 392 hasta içeren bir hasta veri tabanı üzerinde deney yaparak, her hasta ve ilişkili CXR ile ilgili klinik bilgileri çıkardılar. CAD

kullanarak CXRs özellikleri, en iyi özellikler sıralanır ve daha sonra çoklu öğrenen füzyonuna verilir, sınıflandırma yapan CXR' leri okunur (Melendez ve ark., 2016).

Benzer şekilde, klinik görevlilere karşı CAD4TB (TB için bilgisayar destekli) arasında bir karşılaştırma çalışması, çok sayıda TBC kurbanı olan ülkelerden biri olan Zambiya, Lusaka' da yapılmıştır (Maduskar ve ark., 2013). Çalışma, sonuçlarını CAD4TB'nin 0 ile 100 arasında bir anormallik skoru hesapladığı 161 kişiden almaktadır. Dört klinik memuru da 161 kişiyi puanlamıştır (Maduskar ve ark., 2013). Mevcut 161 hasta arasında 97'si bakteriyel TB için pozitif ve 120 hastada anormal CXR vardır. Bu çalışma, elde edilen CAD4TB sisteminin, klinik görevlileri tarafından skorlanan 0,65-0,75 aralığında 0.73'lük bir EAA puanlaması ile sonuçları eğitilmiş bir klinik memuru ile karşılaştırdığına işaret etmektedir (Maduskar ve ark., 2013).

Ayrıca makine öğrenimi alanında, Shenzhen Hastanesi, Çin (Jaeger, Candemir, ve ark., 2014) ve Montgomery County'den (MC) bir kamu veri kümesinde bir sınıflandırıcı olarak bir Destek Vektör Makinesi (SVM) kullanılarak otomatik TB taraması gerçekleştirmiştir (Candemir ve ark., 2014). Birincisi, akciğerler, segmentasyon sonuçlarının özellik hesaplamasından ve son olarak SVM tarafından sınıflandırıldığı Graf Kesim Tabanlı ortak bir yöntemle segmentlere ayrılır (Candemir ve ark., 2014; Jaeger, Karargyris, ve ark., 2014a). Otomatik TB teşhisi amacına benzer şekilde CNN, mikroskopik balgam smear görüntülerinden TB basilini tespit etmek için kullanılmıştır. Bu yaklaşım % 86,76 F-skor elde etmiştir (Panicker, Kalmady, Rajan ve Sabu, 2018).

Birkaç araştırmada CNN, görüntüler ve videolar da dahil olmak üzere ızgara benzeri veriler üzerinde dikkate değer bir performans göstermiştir. CNN kullanmanın bir avantajı, özellik çıkarmanın yanı sıra ağırlıklarla aktarılabilirlik kabiliyetine ihtiyaç duymaması, CNN'yi CXR' lerden otomatik tüberküloz teşhisine yaklaşmak için mükemmel bir algoritma yapar (W. Liu ve ark., 2017). Hem mobil hem de uzaktan artan hesaplama kapasitesi, tıbbi sağlık kaynaklarının yetersiz olduğu bölgelerde TB tanısını hızlandırmak için en iyi fırsatı sunar (Alcantara ve ark., 2017). Sağlık hizmetlerinde mobil bilgisayar kullanımı (m-Health) temel motivasyon olarak, bir DCNN, TB tanı taleplerinin işlendiği bir uç noktaya yerleştirilir (Alcantara ve ark., 2017). Bu yaklaşım, göğüs radyografisini özellikle TB hakkında hızlandırmak için kötü kaynak alanlarındaki çabalara büyük ölçüde yardımcı olabilecek kapasiteye sahiptir. Yaklaşımımızın aksine, TB' yi otomatik olarak teşhis etmek için kullanılabilecek başka yöntemler olduğunu belirtmek gerekir. Bu yöntemde, 22 mikroskopik balgam smear

görüntülerinden tüberküloz basili tespit etmek için CNN kullanır. 32 (3 x 3) filtrelili 2 evrişimli katman, 128 (3 x 3) ile 3 evrişimsel katman ve 128 filtrelili 1 evrişimsel katmandan oluşan bir CNN mimarisi kullanarak 0.9713 duyarlılık, 0.784 kesinlik ve 0.8676 F-skor değerleri elde edilmiştir (Panicker ve ark., 2018). Daha yakın tarihli bir başka araştırma, Kore Tüberküloz Enstitüsü (KIT), 138 Ulusal Sağlık Enstitüsü (NIH), ABD ve Shenzhen Hastanesi'nden, Çin 662 görüntüden elde edilen toplam 10.848 CXR'de önceden eğitilmiş bir AlexNet mimarisi kullanarak bu soruna çözüm üretmişlerdir. AlexNet, 2012 ImageNet Large Scale Visual Recognition Yarışma' da (ILSVR) büyük ün kazanan ünlü bir DCNN mimarisidir. Bu mimariyi kullanarak, araştırma KIT, NIH ve Shenzhen veri kümelerinde sırasıyla 0.964, 0.88 ve 0.93 AUC sunar (Hwang, Kim, Jeong ve Kim, 2016b).

Mekansal Piramit Havuzu (SPP), sınıflandırma yapmak için tam bağlı katman tarafından uygulanan sabit uzunluktaki verilerin CNN'ye beslenmesi gereksinimini dengelemek için geliştirilmiştir. SPP, evrişimsel katmanlardan veri ve havuz özelliklerinin toplamalarını tekil bir büyüklükte hesapladıkları ve sonuç olarak sabit bir boyuta dönüştürme ihtiyacını azaltan tamamen bağlı katmandan önce yer alır. Bu yetenek, CNN'yi değişken boyutlarda girdi alma yeteneğiyle donatır. Bu yeteneğin ötesinde, SPP, CNN mimarilerini farklı ölçeklerin kıvrımlı özelliklerine erişme yeteneği ile donatır ve bu da görüntü sınıflandırmasına yardımcı olur (He, Zhang, Ren ve Sun, 2015). SPP ile önemli deneyler (Zhu, Mao, Zhu, Li ve Yang, 2016) tarafından yapılmış ve araştırmalarında SPP ile donatılmış sahne metni algılama CNN modeli için bir metin tanımlayıcı önermişlerdir. Deneyleri, ICDAR 2011 ve 2013 veri kümelerinde, farklı görüntü ölçekleri kullanılarak modelin eğitimine izin vermek için herhangi bir kırpma ve eğilme olmadan gerçekleştirilmiştir. Önerilen tanımlayıcı modelleri F-değerlendirme sonuçlarında diğer ilgili çalışmalardan yaklaşık %2 artış görülmüştür (Zhu ve ark., 2016). Yüksek çözünürlüklü görüntülerden araç algılamada DCNN çok ölçekli SPP ile kullanılmıştır. Eğitilen veri kümesi ne kırpıcı ne de eğrilmiş veya gerilmiştir, aksine DCNN modelinin sağlamlığına ek olarak farklı ölçeklerdeki görüntülerden özellikler çıkarılır (Qu, Zhang ve Sun, 2017). SPP' li DCNN, diğer geleneksel algoritmaların yanı sıra normal bir DCNN' den daha iyi performans göstermiştir. Recall oranı (RR) %95 olarak verildiğinde, tespit doğruluğu, sadece %80,5'e ulaşan ve False alarm oranı (FAR) %19.8'de olan genel bir DCNN' ye kıyasla %92,9 doğruluğa ulaşmıştır (Qu ve ark., 2017).

Han, Zhong, Cao ve Zhang (2017) yüksek uzamsal çözünürlüklü (HSR) uzaktan

algılama görüntü veri setinde önceden eğitilmiş AlexNet ile SPP kullanmıştır. SPP' nin değişken görüntü ölçekleri üzerinde eğitim alma yeteneğine bakılmaksızın, USGS Ulusal Harita Kentsel Alan Görüntüleri koleksiyonundaki tüm görüntüler, SIRI-WHU' nun Google görüntü veri kümesi, WHU-RS veri kümesi 227x227 olarak yeniden boyutlandırılmıştır. Sonuçlar, SPP ile önceden eğitilmiş AlexNet' in genel olarak önceden eğitilmiş AlexNet' ten $95,95 \pm 1,01$ daha yüksek bir doğruluk elde ettiğini göstermektedir (Han ve ark., 2017).

Bu tezin ilerleyen bölümlerinde çeşitli DCNN mimarilerini ve özelliklerini tartışacağız. Modellerimizi herkese açık veri kümeleri ve kendimizin elde ettiği bir veri kümesi üzerinde eğitirken kullandığımız veri artırma teknikleri sunulacaktır. SPP' nin TB'nin sınıflandırılmasıyla ilgili olarak DCNN üzerindeki etkilerini de tartışıyoruz.



3. MATERYAL VE YÖNTEM

Bu bölümde, CNN'yi çevreleyen kavramlar kısaca tanıtılmaktadır ve önerilen çözümlerde kullanılan üç popüler DCNN mimarisi açıklanmaktadır. CNN'ler, CXR kullanarak tüberküloz tanısını içeren bu özel sınıflandırma problemi için doğal bir seçimdir. Bunun nedeni bilgisayar görme görevlerindeki olağanüstü başarılarıdır. Bu başarı, güçlü Grafik İşlem Birimlerinde (GPU) sıkıştırılan işlem gücünün artması ve kullanılabilirliği ile karşılanmaktadır. CNN'in görüntülerden özellikleri otomatik olarak ayıklama özelliği, onları görüntü tabanlı bilgisayar destekli tanı (CADx) için güçlü bir yöntem haline getirir.

3.1 Derin Öğrenme (DL)

Son yıllarda, desen tanıma, doğal dil işleme (NLP) gibi alanlarda Makine öğrenme algoritmaları gelişinden bu yana, özellik çıkarımı ve dönüşümü için olduğu kadar model analizi ve sınıflandırması için doğrusal olmayan bilgi işlemenin birden çok katmanından yararlanan DL modellerinin bu zorlukların üstesinden geldiği gösterilmiştir. Odak noktası, zaten mevcut verilere ve tahminlere dayanarak, bilgisayarları belirleyici olarak programlamanın Konvansiyonel yöntemini terk eden, ancak bunun yerine kullanılan veriler hakkında çok az bilgi gerektiren veya hiç bilgi gerektirmeyen çözümler üreten sorunları çözmek için daha iyi yollar bulmaktır (W. Liu ve ark., 2017). Algoritmaları, verilen veriyi anlama ve hesaplanan olasılıklara dayalı karar verme yeteneği ile güçlendirmek harika sonuçlar vermiştir ve yeni bir olasılıklar dünyasına açılan bir kapı olarak görülmüştür. Bilgisayarla Görme, endüstriyel otomasyon, otonom araçlar ve karakter tanıma kullanım alanlarından sadece bazılarıdır.

Makine öğrenme algoritmalarının insan-yapay zekasını (AI) geliştirmeye yardımcı olduğu gösterilebilir, ancak insan seviyesinde bilgi işlemedeki eksiklikleri de bilinmektedir. Yüksek performansa rağmen, makine öğrenimi algoritmaları hala tatmin edici seviyenin gerisinde kalmaktadır. Bu nedenle Derin Öğrenme, makine öğrenmesi algoritmasının yetersizliklerini çözmek için geliştirilmiştir. Derin öğrenme kavramı, Sinir Ağlarına (NN' ler) dayanmaktadır; en azından kavramsal olarak insan beyinde bulunan bir nöronun işlevlerini taklit eden bir nöromorfik çalışmanın sonucudur. NN' lerin veya YSA' ların (Yapay Sinir Ağları) kullanımı, eğitim verileriyle birlikte kullanıldığında yüksek bir doğruluk sağlayabilir, ancak gerçek test verileri


kullanıldığında doğruluk genellikle düşer (Zhang, Yang, Chen ve Li, 2018). Bunun nedeni, NN' lerin geri yayılmasında kullanılan gradyan iniş algoritmasından kaynaklanıyor olabilir, genellikle yerel optimumda sıkışıp kalır ve bu durum bu aşırı uyuma neden olur.

Hinton tarafından 2006 yılında bir atılım yaparak, ağıın ilk eğitimi için denetimsiz bir öğretmen gibi izleyen “layer-wise-greedy” adında bir öğrenme önermiştir (Hinton, Osindero ve Teh, 2006). Bu fikir, daha sonra bugün gördüğümüz derin öğrenme kavramlarını doğurdu. Derin öğrenmenin ulaşmaya çalıştığı şey, bilgi birimlerinin katmanlarını (çoğunlukla hiyerarşik) düzenlemek ve ilk katmanda bulunan verilerin özelliklerini, iyi tahminler yapmak için verilerin ince ayarlandığı sonraki katmanlara aktarmaktır. Çoğu durumda derin öğrenme, Derin Ağların bir uzantısı olarak görülebilir (derin öğrenmenin mimarisini oluştururlar). Derin Ağlar, basit terimlerle, Derin Öğrenme çözümlerinin bloklarını oluşturmak için temel mimariyi sağlayan çok daha fazla katmana sahip NN' lerdir. Otomatik kodlayıcılar (AE' ler), Derin İnanç Ağları (DBN' ler), Evrimsel Sinir Ağları (CNN'ler) ve Sınırlandırılmış Boltzmann Makineleri (RBM' ler), Tekrarlayan Sinir Ağları (RNN' ler) gibi Derin Öğrenme mimarileri oluşturmanın temeli bu bölümde kısaca gözden geçirilmiştir. Bunların arasında, bu tezde deney için de kullanılan CNN'ler çoğu görüntü tanıma, sınıflandırma ve algılama görevi için sıklıkla kullanılan algoritmalar haline gelmiştir.

3.1.1 Kısıtlı Boltzmann makinesi (RBM)

RBM' yi anlamak, DBN' yi anlamak için temel bir arka plan sağlar. Adından da anlaşılacağı gibi bir RBM, BM'nin (Boltzmann Makinesi) bir çeşididir. Bunların en önemli özelliği, belirli bir girdinin dahili veri temsilini istatistiksel olarak öğrenebilen YSA modellerini stokastik olarak oluşturmaktır (Li ve ark., 2016). RBM' ler, Şekil 3.1 gösterildiği gibi, ilk katmanda görünür stokastik girdi ve sonraki katmanlarda stokastik gözlemlenebilir birimler içeren Markov alanlarına dayanmaktadır.

Bir RBM eğitimi, bir Gibbs örnekleyicileri kullanarak bir katmandaki rastgele bir durumu başlatmayı içerir. Bir katmandaki tüm birimler başlatıldığında, kalan katmanlar güncellenecektir (W. Liu ve ark., 2017). Bu güncelleme, denge dağılımına ulaşılan kadar devam edecektir. Gradyan bazlı kontrastlı diverjans (CD) algoritması kullanıldığında eğitim sürecinin daha verimli olacağı unutulmamalıdır.




Şekil 3.1: RBM'lerin şematik diyagramı (W. Liu ve ark., 2017).

3.1.2 Otomatik kodlayıcı (AE)

Otomatik ilişkilendirici olarak da bilinen bir otomatik kodlayıcı, boyutlarını küçültmek amacıyla bir veri kümesini programlı olarak kodlamak için kullanılan, denetimsiz bir öğrenme algoritması tabanlı NN' lerdir. Basit bir ifadeyle, AE, verileri orijinal değerlere geri dönüştürülebilen bir dizi soyut değere (anahtarlara) dönüştüreceklerdir (Weng, Lu, Tan ve Zhou, 2016). AE' ler, dönüşüm sırasında kimlik işlevine yaklaşımları, yayılma sırasında sürekli olarak yararlı özellikleri çıkarabilmeleri ve yararsız bilgileri filtrelemeleri nedeniyle gereklidir (Gehring, Miao, Metze ve Waibel, 2013).

Otomatik kodlayıcılar, dönüşüm yapılmadan önce hiçbir ön bilgi bilinmediğinden denetim olmaksızın eğitilir. Ayrıca, x boyutunun h 'den daha küçük olduğu durumda, bir kodlayıcı veri sıkıştırma görevini gerçekleştirir. Birkaç otomatik kodlayıcı birleştirildiğinde, girdinin hiyerarşik özelliklerini öğrenebilen bir derin öğrenme mimarisi (modeli) oluşturulabilir. Şekil 3.2, bir otomatik kodlayıcı örneğini göstermektedir. Yığınlanmış otomatik kodlayıcıyı eğitme süreci, aşağıdan yukarıya, katman katman halinde denetimsiz ön eğitimle başlar. Bu işlem, tüm gizli katmanlar eğitilene kadar devam eder ve tüm gizli katmanlar başlangıç değerleriyle başlatılır (Weng ve ark., 2016; Zhang ve ark., 2018).



Şekil 3.2: AE'lerin Şematik Diyagramı (W. Liu ve ark., 2017).


3.1.3 Derin İnanç Ağı (DBN)

DBN' ye benzer şekilde, AE, veri özelliklerini öğrenmek için ilk aşamada denetimsiz öğrenmeyi kullanır ve ardından ince ayar aşamasında, AE verileri dönüştürmek veya kodlamak için denetimli öğrenmeyi kullanır. Şekil 3.3, AE işlemlerini göstermeye çalışır.

Bir DBN, iki bitişik RBM' den oluşan bir koleksiyondan oluşmaktadır. Her bir RBM' nin görünür katmanı, önceki RBM' nin gizli katmanına bağlanır ve üstteki iki katman yönsüzdür. Bu düzenleme, üstten alınan bilginin alt katmanlara geri yayılmasına izin verir. DBN' deki eğitim, ön eğitim ve ince ayar içeren RBM' lerden biraz farklıdır (Hinton ve ark., 2006). Ön eğitim, bir DBN' yi eğitmenin en etkili aşamasıdır. Bu aşama, başlangıçta verilen verilerden alınan eğitim ağırlıklarını içerir. Ortaya çıkan ağırlıklar genellikle küresel optimuma daha yakındır ve oradan ağırlık eğitimi, gözetimsiz bir Şekil 3.3 düzey bir şekilde gerçekleştirilir. Öte yandan ince ayar, denetimli eğitim gerçekleştirmek ve yeni ayarlamaları yukarıdan aşağıya doğru yaymak için alt katmanlardan çıkarılan bilgileri kullanır (Hinton ve ark., 2006; Hinton ve Salakhutdinov, 2006).

DBN' ler, denetimsiz bir stratejiyle açgözlü bir katmandan katmana ön eğitim gerçekleştirir ve ince ayar, etiketli örnek ve üstte ek bir Softmax katmanı gözetimi altında gerçekleştirir. RBM Gibbs Örneklemesini kullanarak parametreyi eğitmektedir.


Bu eğitim, görünür katmandaki her birimin yanı sıra gizli katmandaki her bir birimin koşullu olasılığının hesaplanmasını içerir. DBN' ler, görüntü sınıflandırma ve akustik modellemede yaygın olarak uygulanmıştır (Hinton ve ark., 2006).



Şekil 3.3: Derin İnanç Ağı (W. Liu ve ark., 2017)

3.1.4 Yinelenen Sinir Ağı (RNN)

RNN en genel sıralı öğrenme modellerinden biridir ve yukarıda tartışılan diğer modellerden farklıdır. En çok, zaman serisi verileriyle uğraşmak için uygundur, örn. (bir dilde bir cümle) (Hermanto, Adji ve Setiawan, 2015). Örnek olarak alınan cümlede, her çalışma bir öncekiyle sıralı olarak ilişkilendirilecek şekilde düzenlenir. Yukarıda tartışılan modellerde, her kelime daha sonra tek bir girdi olarak alınır ve böylece iki veya üç kelime arasında var olan bağlantıyı kaybederler (Hochreiter ve Schmidhuber, 1997). Bunun tersine, RNN' lerde zaman serisi verileri, önceki girişin elde edilmesiyle işlenir, ardından Şekil 3.4 gösterildiği gibi diğer nöronlarla bağlantı kurmak için bir yön döngüsü gerçekleştirilir:



Şekil 2.4: Yinelenen Sinir Ağı (Zhang ve ark., 2018).

3.1.5. Evrişimsel Sinir Ağları (CNN'ler)

CNN, eğitim sırasında giriş verilerinden temel özellikleri çıkaran ve belirli problem alanlarında insan hassasiyetine yakın tahminler yapan bir katman yığını kullanan derin öğrenme algoritmalarıdır. Derin öğrenme algoritmaları, daha iyi bir şekilde yerine getirdikleri görevleri öğrenmelerine yardımcı olmak için karmaşık mimariler kullanır. Derin öğrenmenin ortaya çıkışına 2006 yılında (Hinton ve ark., 2006) öncülük etmiştir. Derin öğrenme ağında, her katman gözetimsiz bir şekilde eğitilir ve daha sonra her katmanın çıktısı bir sonraki katmanlara geçirilir. Temelde, CNN'nin 3 ana katmanı vardır. Bu katmanlar evrişim katmanı, ortaklama katmanı ve son olarak tam bağlantı katmanıdır.


3.1.1. Evrişim (Convolution) Katmanı

Evrişim katmanı, CNN'nin ilk katmanıdır. Bir görüntüden belirli özellikleri çıkarmayı amaçlayan bir çekirdek veya filtre bileşimi kullanarak $H \times W$ nin bir giriş görüntüsünün kıvrılmasını içerir. H , yüksekliği ve W görüntünün genişliğini temsil eder. Bu katmanda, kullanılan filtrelere bağlı olarak görüntünün temel özelliklerini temsil eden bir çıktı üretmek için dönüşümler kullanılır (Dumoulin ve Visin, 2016). Giriş görüntüsü 1, 3 veya 4 değerlerini alabilen bir boyut veya D boyuta sahip olabilir. Boyut 1 olduğunda, görüntü gri tonlamalı bir görüntü olarak temsil edilir, boyut 3 olduğunda görüntü pikselleri GB'nin ana renkleri kullanılarak temsil edilir ve son olarak boyut 4 olduğunda görüntü pikseli, birincil renkler ve opaklığı göstermek için kullanılan ekstra alfa kanalıdır. Görüntünün boyutlarının (kanalının) da kullanılan filtreye yansıtılması gerektiğine dikkat etmek önemlidir. Bu nedenle, $a \times a$ boyutundaki

filtrelerin bir K çekirdeği, giriş görüntüsü ile kıvrılırsa, her filtre, belirli bir konumdaki görüntünün belirli bir özelliğini temsil edecektir (Abiyev ve Ma'aitah, 2018; Gu ve ark., 2018). Şekil 3.5, evrişimsel bir katmanın nasıl görüldüğünün kavramsal bir temsidir. Bir özellik haritası elde edildikten sonra, özellik öğrenme sırasında doğrusal olmama özelliğini etkinleştirmek için doğrusal olmayan bir etkinleştirme fonksiyonuna uygulanır. CNN için ortak aktivasyon fonksiyonları Tanh, Sigmoid ve ReLU' dur. Ortaya çıkan özellik haritasını hesaplamak için $l - th$ evrişimsel katman F_j^l özellik Z_i^l , şu şekilde hesaplanabilir:

$$Z_i^l = B_i^l \sum_{j=1}^{a_i^{(l-1)}} K_{i,j}^{(l-1)} \cdot F_j^l \cdot W_i^l \quad (3.1)$$

Burada W_i^l , $i - th$ filtrenin ağırlık vektörüdür. $K_{i,j}^{(l-1)}$ önceki katmanların ($l - 1$) özelliklerini l katmanının F_j^l özelliği. Z_i^l , l katmanının hesaplanan özelliklerini saklayan vektördür. Denklem 3.1 kullanılarak ilk evrişimsel katmanın ($l = 0$) giriş görüntülerindeki özellikleri $Z_i^0 = X_i$ olarak alır.



Şekil 3.5: Temel bir evrişim katmanı.

3.1.2 Aktivasyon fonksiyonları (AFs)

Aktivasyon fonksiyonları (AF) CNN'de önemli rol oynamaktadır ve bugün derin modellerin başarısını arttırmıştır. Bunun nedeni, doymuş versiyonlarla karşılaştırıldığında, derin model öğrenmeye olan faydasıdır. Bir yandan, doymuş versiyonları kullanırken gradyanların kaybolma eğiliminde olacağı probleminin

üstesinden gelmeye yardımcı olurlar (Nwankpa, Ijomah, Gachagan ve Marshall, 2018; Samatin Njikam ve Zhao, 2016). Öte yandan, hızlanan model öğrenmeye katkıda bulunurlar. Aktivasyon fonksiyonu, temsil ettiği fonksiyona bağlı olarak doğrusal veya doğrusal olmayan, sınır tanıma ve çıkışlarının nesne tanıma ve sınıflandırmadan farklı alanlarda kontrol edilmesi için kullanılır (Nwankpa ve ark., 2018). Yaygın olarak kullanılan aktivasyon işlevleri 3.1.1.1- 3.1.1.4 bölümünde verilmiştir.

3.1.1.1 Sigmoid

Sigmoid AF literatürde lojistik fonksiyon veya ezme fonksiyonu olarak adlandırılabilir. Sigmoid fonksiyon üzerinde yapılan çalışmalar, CNN algoritmalarında kullanılan sigmoid AF' nin üç varyantını üretmiştir. Sigmoid, çoğunlukla ileri beslemeli sinir ağlarında kullanılan doğrusal olmayan bir AF' dir (Qian, Liu, Liu, Wu ve Wong, 2018; Samatin Njikam ve Zhao, 2016). Gerçek girdi değerleri için tanımlanmış, her yerde pozitif türevler ve bir dereceye kadar pürüzsüzlük ile sınırlı türevlenebilir bir gerçek fonksiyondur. Denklem 3.2 Sigmoid işlevi verilmektedir:

$$f(x) = \left(\frac{1}{1+exp^{-x}} \right) \quad (3.2)$$

Sigmoid işlevi, CNN mimarilerinin çıktı katmanlarında görünür ve olasılık tabanlı çıktıyı tahmin etmek için kullanılır. İkili sınıflandırma problemlerinde, lojistik regresyon görevlerinin yanı sıra diğer sinir ağı alanlarını modellemekte başarıyla uygulanmıştır. Sigmoid fonksiyonların en önemli avantajları, anlaşılması kolay olması ve çoğunlukla sığ ağlarda kullanılmasıdır (Nwankpa ve ark., 2018).

3.1.1.2 Hyperbolic Tangent Function (Tanh)

Hiperbolik tanjant fonksiyonu, CNN'de kullanılan başka bir AF türüdür ve CNN algoritmalarında kullanılan bazı çeşitleri bulunmaktadır. Tanh fonksiyonu olarak bilinen hiperbolik tanjant fonksiyonu, aralığı -1 ile 1 arasında olan daha pürüzsüz sıfır merkezli bir fonksiyondur (Lau ve Lim, 2017; Qian ve ark., 2018). Tanh fonksiyonu Denklem 3.3 te şu şekilde sunulur:

$$f(x) = \left(\frac{e^x - e^{-x}}{e^x + e^{-x}} \right) \quad (3.3)$$

Tanh fonksiyonu, çok katmanlı sinir ağları için daha iyi eğitim performansı sağlaması nedeniyle sigmoid fonksiyonuna kıyasla tercih edilen fonksiyon haline gelmiştir. Bununla birlikte, tanh fonksiyonu, sigmoid işlevlerinden kaynaklanan kaybolan gradyan sorununu da çözmemiştir. Fonksiyonun sağladığı temel avantaj, sıfır merkezli çıktı üretmesi ve böylece geri yayılma işlemine yardımcı olmasıdır (Nwankpa ve ark., 2018).

3.1.1.3 Softmax

Softmax fonksiyonu, sinirsel hesaplamada kullanılan başka bir aktivasyon fonksiyonudur. Gerçek sayıların bir vektöründen, olasılık dağılımını hesaplamak için kullanılır. Softmax fonksiyonu, olasılıkların toplamı 1'e eşit olan, 0 ile 1 arasında bir değer aralığı olan bir çıktı üretir (Samatin Njikam ve Zhao, 2016). Softmax fonksiyonu Denklem 3.4 kullanılarak hesaplanır:

$$f(x_i) = \frac{\exp(x_i)}{\sum_j \exp(x_j)} \quad (3.4)$$

Softmax fonksiyonu, her sınıfın olasılıklarını döndürdüğü çok sınıflı modellerde kullanılır ve hedef sınıf en yüksek olasılığa sahiptir. Softmax fonksiyonu çoğunlukla, kullanıldığı derin öğrenme mimarilerinin neredeyse tüm çıktı katmanlarında görülür.

3.1.1.4 Rectified Linear Unit (ReLU) Function

Rectified Linear Unit (ReLU) aktivasyon fonksiyonu, Nair ve Hinton (2010) tarafından önerilmiştir ve bugüne kadarki son teknoloji ürünü sonuçları olan derin öğrenme uygulamaları içinde en yaygın kullanılan aktivasyon fonksiyonu olmuştur. Sigmoid ve tanh aktivasyon fonksiyonlarına kıyasla, derin öğrenmede daha iyi performans ve genelleme sunar (Nwankpa ve ark., 2018; Qian ve ark., 2018). ReLU neredeyse doğrusal bir işlevi temsil eder ve bu nedenle degrade iniş yöntemi ile optimize edilmelerini kolaylaştıran doğrusal modellerin özelliklerini korur.

$$f(x) = \begin{cases} x & \text{if } x \geq 0 \\ 0 & \text{else,} \end{cases} \quad (3.5)$$

Burada $f(x)$ 'in verilen özelliklerin olasılık dağılımı olduğu ReLU fonksiyonudur.


$$A_i^l = \max(Z_i^l, 0) \quad (3.6)$$

$$A_i^l = Y(F_i^l) \quad (3.7)$$

Sinir ağının eğitimine yardımcı olmak ve doğrusal aktivasyon fonksiyonlarının kullanılmasıyla ortaya çıkabilecek doygunluğu önlemek için özelliklere doğrusal olmayan aktivasyon fonksiyonları uygulanır (Gulcehre, Moczulski, Denil ve Bengio, 2016). Denklem 3.7 'te, A_i^l , Z_i^l özelliğindeki doğrusal olmayan aktivasyonu temsil eder. CNN'de yaygın olarak bir ReLU aktivasyon fonksiyonu kullanılır. ReLU'daki Denklem 3.6 maksimum çalışma, karşılaştırmalı fonksiyonlardan daha hızlı çalışmasını sağlar ve aktivasyona biraz gürültü ekler. Bu durum ağın eğitimini optimize etmeye yardımcı olur.

3.1.2 Ortaklama (Pooling) Katman


Alt örnekleme katmanı olarak da adlandırılan bu katmanın amacı, evrişimden üretilen özelliklerin boyutsallığını azaltmaktır. Ortaklama, görüntüyü eşzamanlı olarak sıkıştırmayı ve aynı zamanda evrişimle vurgulanan özellikleri korumayı amaçlar. Ortaklama katmanları genellikle iki evrişimli katman arasına yerleştirilir (Gu ve ark., 2018). Böylece, önceki evrişimsel katmanın çıkışından elde edilen özellik haritası, ortaklama katmanında ortaya çıkan özellik haritasına bağlanır. Sonuç olarak, ortaklama katmanı ağın parametrelerinin azaltılmasına ve sinir ağının hesaplama maliyetinin düşürülmesine katkıda bulunur. Unutmamak gerekir ki, bu azaltma görüntünün önemli özelliklerini engellemez.



Şekil 3.6: Maksimum ortaklama işleminin bir temsili.

Maksimum ortaklama en yaygın havuzlama türüdür, bu ortaklama türünde, özellik haritasından maksimum değeri seçerek indirger. Bu, önceki evrimsel katman özelliklerinin maksimum değerlerine sahip yeni bir özellik haritasının oluşturulmasına yol açar. Şekil 3.6, maksimum ortaklamanın kavramsal olarak nasıl çalıştığını göstermektedir.

Diğer bir yaygın ortaklama türü, ortalama ortaklama olarak adlandırılır. Her özellik haritasından maksimum değer almak yerine ortalama ortaklama ile ortalama değeri kullanılır. Ortalama ortaklama, bir bloğun veya ortaklamanın "daha az önemli" öğeleri hakkında çok fazla bilgi tutması açısından Maksimum Ortaklamadan farklıdır. Maksimum Ortaklama, maksimum değeri seçerek onları atarken, Ortalama ortaklama, onları Şekil 3.7'te gösterildiği gibi karıştırır.




Şekil 3.7: CNN'de ortalama ortaklama işlemi.

3.1.3 Tam Bağlantılı (Fully Connected) Katmanı

Bir sinir ağının son katmanı, düzenli katmanlardan veya bir Softmax aktivasyonu kullanan bir çıkış katmanı olan gizli nöronlardan oluşan bir katmandan oluşur (Denklem 3.8). Bu katman, şekil 3.8'te gösterilen bir dizi evrişimsel ve ortaklama katmanından sonra gelir. Bu katman, CNN'nin ayıklanan özelliklerden tahminler yaptığı yerdir.

$$y_i^l = f(z_i^l) \quad (3.8)$$


Burada y_i^l gizli nöronlar z_i^l den girdi alan Softmax fonksiyonunun çıktısıdır (ağ tahmini). CNN eğitimi Stochastic Gradient Descent (SGD) ve son zamanlarda Adam Optimizer gibi bir optimizasyon algoritma kullanılarak yapılır (Gu ve ark., 2018; Gulcehre ve ark., 2016; Ruder, 2016; Zinkevich, Weimer, Li ve Smola, 2010).



Şekil 3.8: CNN'de gösterilen temel, tam bağlantılı bir katman.

Stokastik gradyan iniş (SGD) algoritması sert bir basitleştirmedir. Degradeyi her bir yinelemede hesaplamak yerine, degrade rastgele seçilen tek örnek temelinde hesaplanır. Stokastik süreç, her bir yinelemede rastgele seçilen örneklerle bağlıdır, bu da gürültü üretir, ancak sonuçta beklentilere göre işlevin en düşük noktasına ulaşır. Stokastik algoritmanın önceki yinelemeler sırasında hangi örneklerin ziyaret edildiğini hatırlaması gerekmediğinden, konuşlandırılmış bir sistemde anında örnekleri işleyebilir. Böyle bir durumda, stokastik gradyan inişi beklenen riski doğrudan optimize eder, çünkü örnekler rastgele gerçek gerçeği dağılımından alınmıştır (Bottou, 2012).

Ayrıca, derin öğrenmedeki en son trendleri takip eden Adam optimizyer, özellikle derin sinir ağlarını eğitmek için tasarlanmış son derece uyarlanabilir bir öğrenme oranı optimizasyon algoritmasıdır. Algoritmalar, her bir parametre için bireysel öğrenme oranlarını bulmak için uyarlanabilir öğrenme oranları yöntemlerinin gücünü kullanır. Adam, RMSprop ve Stokastik Degrade İnişin momentum ile birleşimi olarak görülebilir. RMSprop gibi öğrenme hızını ölçeklemek için kare degradeleri kullanır ve momentumlu SGD gibi degradenin kendisi yerine degradenin hareketli ortalamasını kullanarak momentumdan yararlanır (Kingma ve Ba, 2014). Son olarak, şekil 3.9, bir CNN'nin tüm katmanlarının bir araya getirilmesini göstermektedir.



Şekil 3.9 Bir CNN algoritmasının tüm katmanları. (Alom ve ark.)

Bir CNN mimarisi, birkaç evrimsel ve ortaklama katmanı bloğundan oluştuğunda, buna DCNN denir. DCNN, belirli problem alanları için sorunu etkin bir şekilde çözmelerini sağlamak için genellikle en iyi şekilde yığılmış katmanlara sahiptir. Tezin bu bölümünde yöntemimizde kullandığımız CNN mimarilerinin türleri incelenmiş ve sunulan sonuçları elde etmek için kullanılan metodolojiler açıklanmıştır. Bu tezde anlatılan sorunu çözmek için, bir CXR görüntüsünde bulunan bilgileri öğrenebilecek ve öğrenilen bilgileri olumlu ve olumsuz vakaları sınıflandırmak için kullanabilecek bir dizi araç kullanılmıştır. Makine Öğreniminde, öğrenilecek bilgilere özellikler denir. Bilgisayarların hesaplama gücünün artması, konveksiyon metodolojisinin birçok özelliği öğrenmeyi içeren karmaşık problemleri çözmede eksik olduğu için makine öğrenmeyi yeni boyutlara itmiştir. Derin İnanç Ağlarının icadı sayesinde daha güçlü ve güvenilir bir metodoloji ortaya çıkmıştır. Derin Öğrenme,

konuşma tanıma, nesne tanıma, örüntü tanıma ve doğal dil işleme gibi birçok gerçek dünya sorunuyla mücadele etmek için bir dizi çözüm sunar (Litjens ve ark., 2017).

Bunları diğer derin öğrenme mimarilerinden ayıran bir diğer özellik de, ham girdi ve görüntüleri özellik çıkarma ve seçme olmadan doğrudan ağa aktarma yeteneğidir. CNN, derin bir öğrenme mimarisini düzgün bir şekilde uygulayan ilk mimaridir çünkü başarılı bir şekilde hiyerarşik katmanlar oluşturabilirler. Kısacası CNN, özel olarak düzenlenmiş verilerle çok iyi çalışan güçlü bir derin öğrenme mimarisi olarak görülebilir, yapısı nedeniyle ağın hesaplayabileceği parametre sayısını azaltır, böylece performansı katlanarak artar. CNN'nin başarısı, el yazısı tanıma, yüz tanıma, davranış tanıma, konuşma tanıma, görüntü sınıflandırma ve çok daha fazlasının başarıyla uygulanmasına yol açmıştır (Alex Krizhevsky, Ilya Sutskever ve Geoffrey E. Hinton, 2012b).

Bir CNN genellikle üç ana süreçten geçer: seyrek etkileşim, parametre paylaşımı, eşdeğer gösterim. Seyrek etkileşim, çekirdeği girdilerden daha küçük yaparak veri azaltmanın yapıldığı yerdir. Parametre paylaşımına gelince, her bir konumda ayrı parametreler (ağırlıklar) öğrenmek yerine, ağın yalnızca bir setini öğrenmesi gerektiğini belirtir. Parametre paylaşımı, girişteki herhangi bir değişikliğin çıktıya da yansıtılmasını sağlayan eşdeğerlik ile tamamlanır. (Krizhevsky ve ark., 2012b).


3.2 Derin Evrimsel Sinir Ağları (DCNN)

Bu bölümde, bilgisayarla görme alanında dikkate değer bir başarı elde eden ünlü CNN mimarilerini keşfedeceğiz. Daha önce açıklandığı gibi, DCNN, belirli bir görüntü sınıflandırması, algılama veya tanıma problemi elde etmek için özel olarak bir araya getirilmiş bir CNN katmanları yığınıdır. DCNN, CNN algoritmalarında derin öğrenme tekniklerinin uygulanmasını temsil eder. Bu tezde aşağıdaki modeller kullanılmaktadır:

3.2.1 AlexNet

ImageNet, çeşitli görüntülerden oluşan büyük bir depo ve yıllar boyunca CNN mimarilerinin verimliliğini ölçmede kullanılan birincil veri kaynağı olarak hizmet vermiştir. ImageNet 1,2 milyondan fazla yüksek çözünürlüklü görüntü içermektedir. ImageNet, CNN mimarisini aşamalı olarak iyileştirmek için bir zorluk olarak

barındırılmaktadır. 2012 ImageNet yarışmasının kazananlarından biri Alex Krizhevsky ve ark. Tarafından geliştirilen ve sunulan AlexNet'tir. AlexNet, Tanh'ın aksine kıvrımlı katmanlarında ReLU aktivasyonlarını kullanmayı tercih etmiştir. Bu karar, derin öğrenme modellerinin eğitimi için gerekli olan verilere doğrusallık katmanın yanı sıra hızını kat kat artırır. Dropout oranı, ortaklama büyüklüğü 3 olan 0,5'te tutulur. Bu mimari, bahsedildiği gibi ReLU aktivasyonu ile 5 evrişimli katmandan oluşur; ağa giriş çalışmasında (Krizhevsky ve ark., 2012b) açıklandığı gibi 224 x 224 x 3 boyutuna ayarlanır. Evrişimsel katmanları takiben, son olarak çıkış katmanına yol açan 2 tam bağlı katman vardır. Tamamen bağlı katman, bir dizi nöron veya her biri 4096 olan gizli birimlerden oluşmaktadır. Çıktı katmanı, sınıflandırmayı gerçekleştiren bir Softmax işlevine yol açan 1000 gizli birimden oluşur (Jaeger, Karargyris, ve ark., 2014b; Krizhevsky ve ark., 2012b). Şekil 3.10, Alexnet'in iki aşamalı mimarisini göstermektedir.




Şekil 3.10: İki aşamalı AlexNet mimarisi

3.2.2 GoogLeNet (InceptionV1)


ILSVRC 2014 yarışmasının galibi GoogLeNet, InceptionV1 olarak da bilinir. Bu mimari, AlexNet'ten çok daha yüksek olan 22 katmandan oluşmaktadır ve bu da onu çok derin bir mimari haline getirmektedir. Bu mimarinin sabit girdi boyutu 224 x 224'tür ve AlexNet'e benzer doğrusallık yaratmak için ReLU aktivasyonunu kullanır (Szegedy ve ark., 2015). Mimari tasarım, evrişimsel ağların optimal yerel seyrek yapısını bularak bir insan nörolojik sisteminin nasıl çalıştığını tekrarlamayı amaçlamaktadır. Bu nedenle, bu mimari, evrişimsel katmanların ardından

normalleştirme ve maksimum ortaklama izlendiği standart CNN tasarımını takip etmemektedir. Bunun yerine, bir dizi başlangıç modülü filtre öğrenmesine ve boyutsallığın azaltılmasına katkıda bulunmaktadır. GoogLeNet'in en önemli özelliklerinden biri, seyrek bağlantılı mimari kavramını güçlendiren Inception Katmanlarının piyasaya sürülmesidir. Başlangıç katmanı, farklı çekirdek boyutlarına sahip çeşitli evrişimli katmanların birleşmesidir.

Şekil 3.11, Şekil 3.12'te sunulduğu gibi geliştirilmiş olan başlangıç katmanı konseptini göstermektedir. İlk ve son konsept arasındaki en büyük fark, 1 x 1 evrişimsel çekirdeklerin eklenmesidir. Bu çekirdekler, özellik haritaları daha fazla hesaplama gerektiren katmanlara beslenmeden önce, genellikle boyut küçültmeden sorumludur.



Şekil 3.11: Inception Modülü (Native)



Şekil 3.12: İndirgenme Konvolüsyonlu 1x1 katmanlara sahip Inception Modülü

GoogLeNet, hesaplama açısından verimli bir ağıdır, bu nedenle düşük hesaplama özellikli makinelerde bile çalışabilir. 3 x 3 ve 5 x 5 kıvrımları olan yaklaşık 5 giriş modülünden oluşur. Katmanları azaltmak için 1 x 1 kıvrımlar kullanılır, başlangıç modülleri doğrusallık için ReLU da kullanır. Bu mimari 224 x 224 boyutunda sabittir ve başlangıç modülleri ve arada maksimum havuzlama katmanları kullanımı ile birlikte, toplam 7M eğitilebilir parametre sayısı ile, AlexNet ve VGGNet gibi sırasıyla 62M ve 138M'ye sahip mimarilerin altına düşer.


3.2.3 ResNet

Genellikle 152'den fazla katmandan oluşan Artık Ağ'ın (ResNet), 34, 50 ve 101 katmanlar içeren diğer versiyonları da sunulmuştur (He, Zhang, Ren ve Sun, 2016). Bu mimari 2015 ILSVRC yarışmasında zirveye çıkmıştır ve insan hassasiyetine yaklaşık doğruluğa ulaşmıştır (Targ, Almeida ve Lyman, 2016). Artık Ağlar kavramı, evrimsel ağlarla derinleştiginizde ortaya çıkan sorunu çözmeye çalışır ve bazı bilgiler kaybolur. Her katmandaki giriş bilgilerini bir sonraki katmana taşımak için bir dizi artık fonksiyon kullanılır (He ve ark., 2016). Daha derinlere inildikçe, modeller daha doğru hale gelir, ancak daha derin ağların doygun bir doğruluğa sahip olması nedeniyle bu senaryo her zaman böyle değildir, bu da birkaç katman boyunca sürekli olarak bozulmaya başlar ve daha yüksek bir eğitim hatasına neden olur. Bozunma problemi olarak da bilinen bu davranış, artık öğrenme uygulamasıyla çözülür (He ve ark., 2016).

Artık Öğrenme, artık fonksiyona açıkça yaklaşarak katmanlar üzerindeki haritalamayı yeniden biçimlendirerek normal yığılmış evrimsel katmanlar tarafından üretilen bir haritanın yeniden yönlendirilmesini amaçlamaktadır. Bu, doğrusal olmayan çoklu katmanların asimptotik olarak karmaşık fonksiyonları yaklaşık olarak tahmin edebileceği varsayımı altındadır ki, bu kalan fonksiyonları asimptotik olarak yani yaklaşık olarak tahmin edebildikleri varsayımına eşdeğerdir (Denklem 3.9 ve 3.10) (He ve ark., 2016). Özünde, artık öğrenme aşağıdaki gibi ifade edilebilir:

$$F(x) = H(x) - x \quad (3.9)$$

$$H(x) = F(x) + x \quad (3.10)$$



Şekil 3.13: Artık Öğrenme

Burada $H(x)$, istiflenmiş katmanların eşlemesidir.

Bir sonraki eğitim katmanına önceden eğitilmiş ağırlıkları sağlayarak, bu eğitime ilişkin daha fazla bilgi içeren katmanları destekleme Şekil 3.13’de gösterdiği gibi gerçekleştirir. Artık Ağlar, genel işlevselliklerinde Tekrarlayan Sinir Ağlarına çok benzerdir. ResNet 224x224x3 boyutlarında girişe sahiptir. Yapısına bağlı olarak, tamamen bağlı bir katmanla 34, 50 ve 101 katmana sahip olabilir (He ve ark., 2016).

3.3 Veri Çoğaltma

Derin öğrenme algoritmaları, verilen genelleme problemlerini çözmeye çalışır. Etkili bir şekilde genelleme yapabilmek için, farklı sınıflarla ilgili özelliklerin yeterince sunulmasını gerektirir (Wong, Gatt, Stamatescu ve McDonnell, 2016). Yeterli veri mevcut olsa bile, bir modele çok fazla kolay örnek verilirse, kolayca aşırı öğrenme gerçekleşebilir. Çoğu durumda veri büyütme iki nedenden dolayı yapılır. İlki, modelde aşırı öğrenme olmaması için ve ikincisi, verilerin yeterli olmadığı durumlarda veri kümesini çoğaltmak için. Bu, derin bir öğrenme modeline daha fazla değişken veri eklemenin performansı artıracığı fikrinin sonucudur. Veri büyütme rotasyonları, rastgele kırpma, rastgele yeniden boyutlandırma, yansıtma, renk değiştirme, kontrast gibi geometrik dönüşümlerden geçmeyi ve hatta bazen gürültü eklemeyi içerir.

Veri artırımı üç ana teknikte kategorize edilebilir; geleneksel görüntü dönüşümleri (temel görüntü manipülasyonları), Üretken Çekişmeli Ağlar (GAN) ve öğrenme artışlarıdır. Görüntü manipülasyonu ile veri artırımı, öncelikle görüntünün boyutunu, yönünü veya şeklini değiştirmeyi içeren en temel büyütme türüdür. Çevirme (yatay veya dikey), renk kanalını değiştirme, bir görüntüden belirli bir boyuttaki bir yamayı seçmeyi içeren kırpma, döndürmeler, çeviriler bu büyütme teknikleri altındaki

tekniklerden sadece birkaçıdır (Perez ve Wang, 2017; Shorten ve Khoshgoftaar, 2019). GAN tabanlı veri artırımı, temel özellikleri (özellikleri) korurken verilerden yapay bir örnek oluşturan bir model içerir. GAN modellerinin uygulanması, veri kümesinden önemli özelliklerin doğru bir şekilde alınmasına yardımcı olan rakip eğitimi nedeniyle sınıflandırma modellerinde büyük başarı ile sonuçlanmıştır.

Son olarak, veri artırma için öğrenme teknikleri, bir katmanın tek bir görüntü ile aynı boyutta döndürüldüğü yerden iki görüntü ile bir ağı beslemeyi içerir. Ortaya çıkan katman ayrı bir görüntü olarak kabul edilir. Orijinal görüntü ile birlikte sınıflandırma için başka bir ağda kullanılır. Bu çalışmada sadece görüntü manipülasyonu büyütme teknikleri uygulanmaktadır.

3.4 Uzamsal Piramit Havuzlama (SPP)


SPP (He ve ark., 2015) tarafından 2015 yılında sabit girdi görüntü boyutunun gerekliliğini ortadan kaldırmak için önerilen bir metodolojidir. Genellikle CNN mimarisi giriş katmanları, esasen tamamen bağlı katmanlar nedeniyle sabit bir giriş görüntü boyutuna izin verecek şekilde tasarlanmıştır. Tamamen bağlı katmanlar, elde edilen özellik boyutlarının sınırlı tanımını gerektirir. CNN mimarilerinin, sınıflandırma için özelliklerin doğru hesaplanmasını sağlamak üzere bir girdi boyutu kısıtlaması ile ayarlandığı akılda tutulmaktadır.

Bu yaklaşım ImageNet, COCO veri kümesi, CIFAR ve daha pek çok farklı veri setinde aynı sonuçları ortaya koymuştur. Bu yaklaşımın sınırlaması, değişken boyutlara sahip bir veri kümesiyle uğraşırken, sınıflandırma için temel özelliklerin kaybolmasına neden olabilmesidir. İdeal olarak, SPP kullanırken, evrişimli katmanlar değişmez, yine de yapılandırma çekirdek boyutlarını korurlar, ancak farklı boyutlardaki girdileri kabul edecek şekilde ayarlanırlar. Evrişimsel katmanlar boyuttan bağımsız olarak yine de özellikler çıkaracağından, özellikler görüntülerden çıkarılır.

Tamamen bağlı katmanlardaki belirli özelliklerin ihtiyacını karşılamak için, tam bağlı katmandan önceki son ortaklama katmanı veya evrişimsel katman, mekansal piramit ortaklama katmanı ile değiştirilir. Bu katman, her filtrenin tüm çıkarılan özelliklerini, girdi görüntü boyutuyla orantılı olarak farklı boyutlarda uzaysal kutularda toplar (Gu ve ark., 2018). Bu işlem, özelliklerin görüntünün daha ince seviyesinden

daha kaba seviyelerine kadar filtrelerine göre gruplandığı kelimeler çantası modeliyle eşanlamlıdır. Sabit bir uzunluk, çok seviyeli birleştirme pencereleri önceden ayarlamadan modelleri eğitme yeteneği, nesnenin algılanması için görüntünün daha sağlam özelliklerinin bir araya getirilmesine izin verir ve son olarak farklı ölçeklerde özellikleri bir araya getirme yeteneği, CNN'yi bir SPP katmanı ile donatmanın avantajlarından bazılarıdır.

Örneğin, bir CNN'nin son katmanı 256 özellik eşlemesine sahiptir, (1 x 2 x 4) uzamsal bölmelerinden sonraki SPP katmanı, her bir özellik haritasını farklı bölmelere dayalı olarak bir araya getirir. 1 değerinin ilk bölmesi gri renkte, ikincisi 4 değeri yeşil ve sonuncusu mavi olarak Şekil 3.14'da gösterildiği gibi harita özelliklerini bir araya getirecektir.



Şekil 3.14: Uzamsal Piramit Ortaklama yapısı

4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA

Bu bölümde, tez kapsamında kullanılan CXR tüberküloz veri setleri ve DCNN modelleri verilmektedir. Üç DCNN modeli, ayrı ayrı açıklanan üç veri kümesi kullanılarak eğitildi. Ayrıca tüm mimarilerde düzenli bir ortaklama katmanı yerine SPP eklenmiştir. Bu nedenle, SPP kullanılarak eğitilmiş modeller, sonuçlar bölümünde kolay tanımlama için bir "SPP" ile açıklanmıştır. Doğal olarak, bu tür yalın veri kümeleri göz önüne alındığında, aşırı büyütme azaltmak ve modeli gerçek dünya verilerindeki küçük değişikliklere karşı daha sağlam hale getirmek için veri büyütme teknikleri kullanılabilir.

DCNN' nin otomatik özellik çıkarımı, çok az veri ön işleminin yapılmasını sağlar. Tüm veri kümeleri için önce görüntüler 256 x 256 olarak yeniden boyutlandırılmış, sonra rastgele AlexNet, AlexNet-SPP, GoogLeNet, GoogLeNet-SPP, ResNet50 ve ResNet50-SPP için görüntüler 227 x 227 ve 224 x 224 boyutlarına kırpılmıştır. Belleği korumak için çalışan 90, 180, 270 derecelik açılarda görüntüler yatay olarak çevrilmiş ve rastgele döndürülmüştür. CXR' lerin kontrastını yükseltmek için Contrast Limited Adaptive Histogram Equalization (CLAHE) kullanılmıştır.

Modeller, 8GB'lık özel bir belleğe sahip bir NVidia GeForce RTX 2070 üzerinde çalıştırılmıştır. Değerlendirme ölçütü olarak geçerlilik doğruluğu kullanılmıştır. Tüm örnekler eğitim ve test için %75-%25 olarak ayrılmıştır. Her bir veri kümesi için sırasıyla en büyük fraksiyon, 103, 496, 274 adet veri eğitime ve geri kalan 35, 166, 91, veri kümesi 1, veri kümesi 2 ve veri kümesi 3 için modelin doğrulanması için kullanılmıştır.

0.001 ile 0.00001 arasında değişen öğrenme oranlarına sahip 120 iterasyon için tüm modelleri yürütmüştür. Ağların geri yayılma işlemi sırasında küresel optimizasyon için bir SGD ile 8'lik bir toplu iş boyutu kullanılmıştır.

Tüm modellerimizde, çok seviyeli ortaklama pencereleri kullanılmıştır, (1 x 1, 2 x 2, 3 x 3 ve 6 x 6) olarak adlandırılabilir yaklaşık 50 kutu kullanılmıştır (He ve ark., 2015). He ve ark. (2015) tarafından gözlemlendiği gibi çok seviyeli, sağlam bir ortaklama oluşturmayı sağlar ve modelin doğruluk kazanımlarına yardımcı olur. Bu çalışmada benzer bir yaklaşım kullanılmış ve sonuçlarda sunulduğu gibi her modelde gözle görülür bir kazanç kaydedildi.


4.1. Veri seti

Bu bölümde, önerdiğimiz çözümün eğitiminde ve testlerinde kullanılan veri kümeleri açıklanmaktadır. Veri setleri halka açık veri kümelerinden ve Konya Eğitim Araştırma Hastanesi'nden (KERH) alınan CXR görüntülerinden oluşturulan özel bir veri kümesinden oluşmaktadır. Çizelge 4.4, bu çalışmada kullanılan veri kümelerinin bir özetini sunmaktadır.

4.1.1 Halka Açık Veri setleri

Bu tez kapsamında üç veri kümesi üzerinde DCNN' de SPP kullanımının performansı değerlendirilmiştir. Genel kullanıma açık büyük veri kümelerinin eksikliğinin bu tür araştırmalarda durgunluğun bir nedeni olduğunu belirtmek önemlidir. Kullanılan iki veri kümesi herkese açık olarak erişilebilir durumdadır; bunlardan biri Ulusal Tıp Kütüphanesi, Maryland, ABD tarafından oluşturulmuştur. Bu veri seti Montgomery, County, Maryland, ABD'deki Sağlık ve İnsan Hizmetleri Departmanı'nın işbirliğinin bir sonucudur. Veri seti ön göğüs bölgesini gösteren toplam 138 görüntüden oluşur. Görüntülerin 80'i normal vakalar olarak sınıflandırılırken, geri kalan 58 vaka anormaldir (TB' li CXR' ler). Her CXR, 12 bit gri tonlamalı görüntüler olarak PNG' ye (Portable Network Graphics) aktarılmıştır. Her görüntünün çözünürlüğü $4,020 \times 4,892$ ile $4,892 \times 4,020$ piksel arasındadır (Çizelge 4.1) (Candemir ve ark., 2014; Jaeger, Candemir, ve ark., 2014).

Çizelge 4.1: Montgomery Veri setine ait CXR görüntü örnekleri

Normal (Sağlıklı) Vaka	Anormal (TB'li) Vaka
	

İkinci veri seti Guangdong Tıp Fakültesi, Shenzhen, Çin Halk Hastanesi'nden alınmıştır. Shenzhen, Çin'den elde edilen veriler 336 anormal (tüberkülozlu) ve 326 normal CXR' den oluşur. Phillips DR Dijital Diagnost sistemi, bir ay boyunca tüm görüntüleri toplamak için kullanılan birincil araçtır. Bu veri seti, PNG formatında, 12 bit gri tonlamalı ve 3000×3000 piksel görüntülere sahiptir (Çizelge 4.2) (Jaeger, Candemir, ve ark., 2014).

Çizelge 4.2: Shenzhen Veri setine ait CXR görüntü örnekleri

Normal (Sağlıklı) Vaka	Anormal (TB' li) Vaka
	


4.1.2 Konya Eğitim Araştırma Hastanesi (KERH) Veri seti

İki halka açık veri setlerine ek olarak, Radyografi Bölümü ile işbirliği içinde Konya Eğitim Araştırma Hastanesi'nden elde edilen görüntülerden yeni bir veri seti oluşturulmuştur. Her biri 4000×4000 piksel çözünürlüğe sahip tüm görüntüleri toplamak için bir Samsung DR Digital Diagnost sistemi kullanılmıştır.

Örnekler, DICOM, JPG, BITMAP ve PNG gibi farklı formatlarda veri toplamamıza olanak tanıyan PACS (Resim Arşivleme İletişim Sistemi) adı verilen bir Görüntü Arşivleme ve İletişim Sistemi kullanılarak toplanmıştır. Tüm resimler PNG formatında çıkarılmıştır. Daha önce herhangi bir tedavi almayan yeni teşhis edilmiş ARB (Aside Dayanıklı Basil) pozitif (balgam örneğinde saptanan) tüberküloz hastalarının göğüs radyografileri retrospektif olarak taranmıştır. Verilerin toplanması eğitimli Radyolog profesyonelinin gözetimi altında gerçekleştirilmiştir. Bu set 206 normal ve 159 anormal CXR' ye sahip vakalardan oluşmaktadır. Bu veri kümesinden CXR örnekleri Çizelge 4.3'de görülebilir.

İnsan katılımcıları içeren çalışmalarda gerçekleştirilen tüm prosedürler, kurumsal veya ulusal araştırma komitesinin etik standartlarına ve 1964 Helsinki Deklarasyonu'na ve daha sonraki değişikliklerine veya karşılaştırılabilir etik standartlara uygun olmuştur. Çalışma Selçuk Üniversitesi Tıp Fakültesi Klinik Araştırmalar Etik Kurulu tarafından onaylanmıştır (Konya: No: 2019/240).

Çizelge 4.3: Shenzhen Veri setine ait CXR görüntü örnekleri



Çizelge 4.4: Veri seti Özetleri

Name	Montgomery	Shenzhen	KERH
Source	Montgomery County, USA	Shenzhen, China	Konya, Turkey
Format	.PNG	.PNG	.PNG
Normal	80	336	206
Abnormal	58	326	159
Total	138	662	365

4.2 Veri ön işleme ve büyütme

Derin öğrenme algoritmaları, eğitim için büyük verilere ihtiyaç duyar. Özellikle, nesne tespiti için CNN, eğitim için çok fazla görüntü gerektirir (Jeong, Park ve Ha, 2018). Web tarayıcısı ile internetten eğitim görüntüleri almak mümkündür. Ancak çoğu durumda, tarayıcı tarafından toplanan görüntüler genellikle rafine edilmez. Bu nedenle, elde edilen model, beslendiği veriler uygun olmadığından etkili bir şekilde eğitilmeyebilir. Etkili eğitimi sağlamak için, algoritmanın iyi rafine edilmiş veriler

üzerinde eğitim almasını sağlamak için veri ön işleme yöntemleri kullanılır. Konuyu ilgilendiren en yaygın görüntü ön işleme yöntemlerinden biri, yeniden boyutlandırma, çarpıtma, kırpma, yansıtma ve geliştirme içerir.

4.2.1 Yeniden boyutlandırma

Yeniden boyutlandırma, bir görüntünün orijinal boyutundan tercih edilen başka bir boyuta küçültülmesini içerir. Yeniden boyutlandırmanın nedenlerinden biri, CNN giriş katmanının (çoğu zaman sabit bir giriş gerektiren) gereksinimlerini karşılamaktır. Yeniden boyutlandırmanın ikinci nedeni, eğitimden önce görüntünün boyutunu azaltmaktır. Bir görüntüyü yeniden boyutlandırma işlemi, belirli bir piksel boyutundaki bir görüntüyü alır ve aynı görüntüyü belirli bir boyutla döndürür. Görüntü dikdörtgen ise, genellikle bir görüntünün 256 x 256 boyutuna indirgenmesi önerilir. Değilse, daha kısa taraf 256 olarak yeniden boyutlandırılır, ardından 256 x 256 kırpma yaması alınır. Deneylerimizde, benzer prosedürler izlenmiştir, görüntülerin çoğu dikdörtgen olduğundan, her görüntüyü doğrudan 256 x 256 olarak yeniden boyutlandırılmıştır.

4.2.2 Rastgele Kırpma

Rastgele kırpma, orijinal görüntünün rastgele bir alt kümesini oluşturan bir veri büyütme tekniğidir. Bu, modelin daha iyi genellemesine yardımcı olur, çünkü modellerin öğrenmesini istenen ilgi alanı / nesneler görüntüde her zaman tam olarak görünmüyor veya eğitim verilerinde aynı ölçekte bulunmuyor. Bu teknik, tüm senaryolar için uygun olmasa da deneylerde yeni görüntüler oluşturmak için rastgele kırpma kullanılmaktadır. Daha önce belirtildiği gibi, tüm görüntüler 256 x 256 olarak yeniden boyutlandırılmıştır. Yeniden boyutlandırmadan sonra, her bir görüntüyü rastgele 3 kez kırparak, tek bir görüntüden 224 x 224 yama halinde kırpılmış 3 ayrı görüntü oluşturulmuştur.

4.2.3 Yatay ve dikey çevirme

Veri artırımına ortak bir yaklaşım, tren zamanı veri artırımıdır. Tren zamanı veri artırmada, hafızada çeşitli büyütme teknikleri (görüntü çevirme, döndürme, yansıma ve döndürme gibi) uygulanır ve eğitim için modele verilir. Bu yaklaşım avantajlıdır, çünkü

gerçekleştirilen tüm işlemler bellekte yapılır ve diske kaydedilmez. Her görüntüyü yatay ve dikey olarak çevirerek tren-zaman artırımı yapılmıştır.

4.2.4 Rastgele döndürme


Döndürme, belirli bir görüntünün sabit noktada dönüştürüldüğü bir görüntü dönüştürme tekniğidir (dönme merkezi olarak adlandırılır). Rastgele döndürme, 0 ila 360 arasında belirli bir derece kullanarak görüntüyü rastgele döndürmeyi amaçlamaktadır. Her görüntünün 90, 180 ve 270 derece arasında rastgele döndürüldüğü tren zamanı büyütme ile rastgele döndürme kullanılmıştır.

4.2.5 Kontrast sınırlı uyarlanabilir histogram eşitleme (CLAHE)

Histogram eşitleme, küresel olarak kontrastı iyileştirme yöntemidir. Bu süreç, küresel olarak görüntü boyunca dağıtılan yoğunluk ayarlamasıdır. Herhangi bir gri skala görüntüsü (x) ele alındığında, n_i be gri seviye i oluşum sayısı ve görüntü (x) seviye i pikselinin oluşma olasılığı fonksiyonu şöyledir:

$$p_x(i) = p(x = i) = \frac{n_i}{n}, 0 \leq i < L \quad (4.1)$$

Kontrast sınırlı uyarlamalı eşitleme, uyarlanabilir histogram eşitlemesinin değiştirilmiş bir parçasıdır. Bu yöntemde geliştirme işlevi tüm komşu piksellere uygulanır ve dönüştürme işlevi türetilir. Bu çalışmada, algoritma ön plana uygulanır ve görüntüyü sınırlar, şekil 4.1'de gösterilen adımları kullanarak CXR görüntülerinin kontrastını artırır (Yadav, Maheshwari ve Agarwal, 2014).



Şekil 4.1: Genel CLAHE algoritma adımlar

5. SONUÇLAR VE ÖNERİLER

5.1 Sonuçlar

Bu çalışmada, esas olarak Mekansal Piramit Havuzlaması (SPP) kullanılarak CXR'lerden alınan tüberkülozun sınıflandırılmasına odaklanılmıştır. Bunu başarmak için, son evrimsel katman ile tam bağlı katmanın başlangıcı arasında yaygın olarak kullanılan ortaklama katmanı yerine bir SPP katmanı ile üç DCCN yerleştirilmiştir. Sonuçlar sunulurken, benzer araştırmalara katkıda bulunan diğer yöntemlerin sonuçları araştırıp karşılaştırılmıştır.

Çizelge 5.1: Halka açık veri setlerinde SPP'li ve SPP'siz modellerin deneysel sonuçları.

Model	Dataset	Without SPP	With SPP
AlexNet	Montgomery	0.94	0.97
GoogLeNet		0.97	0.97
ResNet50		0.99	0.97
AlexNet	Shenzhen	0.95	0.95
GoogLeNet		0.97	0.98
ResNet50		0.95	0.96

Çizelge 5.1'teki doğrulama doğruluğu sonuçları modellerin halka açık veri kümelerindeki performansını gösterir. Çizelge 5.2 KERH veri kümesinden elde edilen doğrulama doğruluğu sonuçlarını gösterir. Ayrıca, Çizelge 5.3 – 5.5, tüm veri kümelerinde eğitimsiz AlexNet, AlexNet-SPP GoogLeNet, GoogLeNet-SPP, ResNet50 ve ResNet50-SPP için hata matrisleridir.

Çizelge 5.2: KERH veri kümesinde SPP ve SPP'siz sonuçlar.

Model	Dataset	Without SPP	With SPP
AlexNet	KERH	0.99	0.99
GoogLeNet		1.0	1.0
ResNet50		0.98	0.99

Çizelge 5.3: Montgomery veri kümesinde SPP' li ve SPP' siz üç model için Hata Matrisi.

	Montgomery		Predicated	
			Negative	Positive
Actual	AlexNet	Negatif	57	3
		Pozitif	3	41
	AlexNet-SPP	Negatif	58	2
		Pozitif	1	43
	GoogleNet	Negatif	58	2
		Pozitif	3	43
	GoogleNet-SPP	Negatif	57	3
		Pozitif	0	44
	ResNet50	Negatif	60	0
		Pozitif	1	43
	ResNet50-SPP	Negatif	59	1
		Pozitif	2	42

Çizelge 5.4: Shenzhen veri kümesinde SPP' li ve SPP' siz üç model için Hata Matrisi.

	Shenzhen		Predicated	
			Negative	Positive
Actual	AlexNet	Negatif	234	8
		Pozitif	15	240
	AlexNet-SPP	Negatif	226	16
		Pozitif	8	247
	GoogleNet	Negatif	228	14
		Pozitif	2	253
	GoogleNet-SPP	Negatif	238	4
		Pozitif	7	248
	ResNet50	Negatif	229	13
		Pozitif	10	245
	ResNet50-SPP	Negatif	232	10
		Pozitif	10	245

Çizelge 5.5: KERH veri kümesinde SPP' li ve SPP' siz üç model için Hata Matrisi

	KERH		Predicated	
			Negative	Positive
Actual	AlexNet	Negatif	163	1
		Pozitif	3	106
	AlexNet-SPP	Negatif	163	1
		Pozitif	3	106
	GoogleNet	Negatif	164	0
		Pozitif	0	109
	GoogleNet-SPP	Negatif	164	0
		Pozitif	0	109
	ResNet50	Negatif	164	0
		Pozitif	6	103
	ResNet50-SPP	Negatif	163	1
		Pozitif	3	106

Ayrıca, Çizelge 5.6 ve 5.7, KERH veri setinde SPP' siz ve SPP' li modellerin özgünlük (specificity), kesinlik (precision), duyarlılık (recall) ve F-değerlendirme (F-measure) açısından performansını sunmaktadır. Aşağıdaki sınıflandırma sonuçları bir hata matrisi biçiminde verildiğinde, recall Denklem 4.1, precision Denklem 4.2, specificity Denklem 4.3 ve F değerlendirme Denklem 4.4 Denklem kullanılarak hesaplanabilir.

$$Recall = \frac{TP}{TP + FN} \quad (4.1)$$

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

$$Specificity = \frac{TN}{TN + FP} \quad (4.3)$$

$$F\ Measure = \frac{(Precision * Recall)}{(Precision + Recall)} \quad (4.4)$$

TP, FP, TN, FN, sırasıyla bir modelin öngörüsünün gerçek pozitif, yanlış pozitif, gerçek negatif ve yanlış negatifini temsil etmektedir.

Çizelge 5.6: Tüm veri kümelerinde SPP modelleri olmadan recall, precision, specificity ve F değeri.

Model	Dataset	Recall (Sensitivity)	Precision	Specificity	F Measure
AlexNet	Montgomery	0.93	0.93	0.95	0.93
GoogLeNet		0.97	0.95	0.96	0.96
ResNet50		0.97	1.0	1.0	0.98
AlexNet	Shenzhen	0.94	0.96	0.96	0.95
GoogLeNet		0.99	0.94	0.94	0.96
ResNet50		0.96	0.94	0.94	0.95
AlexNet	KERH	0.97	0.99	0.99	0.98
GoogLeNet		1.0	1.0	1.0	1.0
ResNet50		0.94	1.0	1.0	0.97


Çizelge 5.7: Tüm veri kümelerinde SPP modelleri olan recall, precision, specificity ve F değeri.

Model	Dataset	Recall (Sensitivity)	Precision	Specificity	F Measure
AlexNet-SPP	Montgomery	0.97	0.95	0.96	0.96
GoogLeNet-SPP		1.0	0.93	0.95	0.96
ResNet50-SPP		0.95	0.97	0.98	0.96
AlexNet-SPP	Shenzhen	0.96	0.93	0.93	0.95
GoogLeNet-SPP		0.97	0.98	0.98	0.97
ResNet50-SPP		0.96	0.96	0.95	0.96
AlexNet-SPP	KERH	0.97	0.99	0.99	0.98
GoogLeNet-SPP		1.0	1.0	1.0	1.0
ResNet50-SPP		0.97	0.99	0.99	0.98

Alıcı işletim karakteristiği (ROC) eğrileri, ikili bir sınıflandırıcının tahmin yeteneğini nitelemek için kullanılır. Tablo 5.8, verilen tüm veri kümelerindeki tüm

modeller için Roc eğrilerini göstermektedir. Tabloda ayrıca ROC eğrisi skorunun altındaki alan gösterilmektedir.

Çizelge 5.8: Tüm modeller için Roc grafikleri.



5.2 Araştırma Bulguları

Modellerimizin sonuçları, SPP ile uygulandığında tüm modellerde doğrulukta hafif bir artış olduğunu göstermektedir. Bu gelişmeyi belirlemek için, doğrulama doğruluğu kullanılmıştır. Resmi, 3 kez rastgele kırparak hem doğrulama hem de eğitim seti verileri yapay olarak arttırılmıştır. Gözlemlendiği gibi, eğitimsiz bir AlexNet-SPP, Montgomery, Shenzhen ve KERH veri kümesinde önemli bir artış sağlamıştır veya aynı doğrulama doğruluğunu elde etmiştir. Bu çalışmada incelediğimiz diğer yöntemlerle karşılaştırıldığında, AlexNet-SPP diğer modellerle denk performans veya biraz daha iyi performans göstermiştir. Montgomery üzerinde eğitilmiş eğitimsiz GoogLeNet ve ResNet50, (He ve ark., 2015) aynı boyutta SPP ile eğitilmiş bir veri kümesinde bile doğruluğu arttırmaktadır. Küçük bir veri kümesi nedeniyle, modelin önemli ölçüde fazla uyduğunu da not edebiliriz. Bunu azaltmak için, ResNet50 dışında bırakmanın yanı sıra düzenleme olarak çeşitli büyütme yöntemleri uygulanmıştır. Daha fazla bilgi için, her bir veri setindeki her modelin eğrisinin altındaki alan Çizelge 5.8'de hesaplanmıştır. AUC açısından performans veri kümeleri arasında farklılık gösterir, ancak eğitimsiz GoogLeNet ve GoogLeNet-SPP ortalama olarak tüm veri kümelerinde çok iyi performans gösterir, GoogLeNet Montgomery, Shenzhen ve KERH'de sırasıyla 0.98, 0.93, 1.0 elde eder. SPP sürüm puanları ve 0.93, 0.98 ve 1.0 AUC, neredeyse benzer şekilde Montgomery veri kümesi için kaydedilir.

KERH' nin veri kümesinde eğitimsiz modellerin kullanılmasından elde edilen sonuçlar, diğer veri kümelerine kıyasla daha iyi sonuçlar ortaya koymaktadır. AlexNet, SPP olmadan dikkat çekici bir 0.94 ve SPP ile 0.95 elde eder. ResNet50, SPP olmadan 0.93 ve SPP ile 0.94 ile AlexNet' e benzer bir performans gösterir. En çarpıcı sonuç, eğitimsiz GoogLeNet ve GoogLeNet-SPP' de sırasıyla 0.97 ve 0.98 doğrulama doğruluğuyla elde edilir.

5.3 Öneriler

Bu tezde, Mekansal Piramit Havuzlamasının CXR kullanarak tüberküloz üzerinde otomatik tanı üzerinde nasıl bir etkisi olduğu gösterilmiştir. Hepsi CNN modelleri olduğu için 6 modeli sıfırdan eğitilmiştir. Çok fazla ön işlem yapmadan görüntülerden özellikleri otomatik olarak çıkarma yeteneğine sahiptirler. Giriş görüntüleri yeniden boyutlandırılmış ve rastgele 3 kez kırılmıştır (veri kümelerini

yapay olarak arttırmanın bir yolu olarak). Mekansal Piramit Birleştirme oldukça yeni tanıtılmış bir metodolojidir ve görüntüleyici algılanması ve sınıflandırılmasının düşünülmesini değerlendirmektedir (Yue, Mao ve Li, 2016).

Bu tezde görüldüğü gibi, tüm modeller temel eğitimsiz modellerden doğruluk artışı görmüştür. Bu nedenle, CNN' in akciğer tüberkülozu tanısına yardımcı olmak için daha iyi ve sağlam bir model yetiştirmek için SPP ile güçlendirilebileceği sonucuna vardık. SPP ile eğitim, her model için sabit bir mimariye yeniden boyutlandırmadan farklı boyutlara sahip modellerin eğitilmesine yardımcı olabilir. Gelecekteki iyileştirmeler için, DCNN' nin büyük veri kümelerinde daha iyi çalıştığı gözlemlendiğinden daha büyük bir veri kümesinde SPP ile ince ayar yapmak planlanmıştır. Ayrıca, farklı aktivasyon yöntemlerini, yani Mish kullanarak ve ReLU ile karşılaştırılması hedeflenmiştir (Misra, 2019).

KAYNAKLAR

- Abebe, G., Bonga, Z., ve Kebede, W., 2019, Treatment outcomes and associated factors in tuberculosis patients at Jimma University Medical Center: A 5-year retrospective study. *International journal of mycobacteriology*, 8(1), 35.
- Abiyev, R. H., ve Ma'aitah, M. K. S., 2018, Deep Convolutional Neural Networks for Chest Diseases Detection. *Journal of Healthcare Engineering*, 2018, 4168538. doi:10.1155/2018/4168538
- Affonso, C., Rossi, A. L. D., Vieira, F. H. A., ve de Carvalho, A. C. P. d. L. F., 2017, Deep learning for biological image classification. *Expert Systems with Applications*, 85, 114-122. doi:<https://doi.org/10.1016/j.eswa.2017.05.039>
- Alcantara, M. F., Cao, Y., Liu, C., Liu, B., Brunette, M., Zhang, N., Sun, T., Zhang, P., Chen, Q., Li, Y., Morocho Albarracin, C., Peinado, J., Sanchez Garavito, E., Lecca Garcia, L., ve Curioso, W. H., 2017, Improving tuberculosis diagnostics using deep learning and mobile health technologies among resource-poor communities in Perú. *Smart Health*, 1-2, 66-76. doi:<https://doi.org/10.1016/j.smhl.2017.04.003>
- Alom, M., Taha, T., Yakopcic, C., Westberg, S., Hasan, M., Van Esesn, B., ve Asari, V., The history began from AlexNet: A comprehensive survey on deep learning approaches. arXiv 2018. *arXiv preprint arXiv:1803.01164*.
- Bar, Y., Diamant, I., Wolf, L., ve Greenspan, H., 2015, *Deep learning with non-medical training used for chest pathology identification*. Paper presented at the Medical Imaging 2015: Computer-Aided Diagnosis.
- Bottou, L., 2012. Stochastic gradient descent tricks, In *Neural networks: Tricks of the trade* (pp. 421-436): Springer.
- Candemir, S., Jaeger, S., Palaniappan, K., Musco, J. P., Singh, R. K., Xue, Z., Karargyris, A., Antani, S., Thoma, G., ve McDonald, C. J., 2014, Lung segmentation in chest radiographs using anatomical atlases with nonrigid registration. *IEEE transactions on medical imaging*, 33(2), 577-590.
- Cao, Y., Liu, C., Liu, B., Brunette, M. J., Zhang, N., Sun, T., Zhang, P., Peinado, J., Garavito, E. S., ve Garcia, L. L., 2016, *Improving tuberculosis diagnostics using deep learning and mobile health technologies among resource-poor and marginalized communities*. Paper presented at the 2016 IEEE First International Conference on Connected Health: Applications, Systems and Engineering Technologies (CHASE).
- Dumoulin, V., ve Visin, F., 2016, A guide to convolution arithmetic for deep learning. *arXiv preprint arXiv:1603.07285*.

- Faust, O., Hagiwara, Y., Hong, T. J., Lih, O. S., ve Acharya, U. R., 2018, Deep learning for healthcare applications based on physiological signals: A review. *Computer Methods and Programs in Biomedicine*, 161, 1-13. doi:<https://doi.org/10.1016/j.cmpb.2018.04.005>
- Gehring, J., Miao, Y., Metze, F., ve Waibel, A., 2013, *Extracting deep bottleneck features using stacked auto-encoders*. Paper presented at the 2013 IEEE international conference on acoustics, speech and signal processing.
- Gu, J., Wang, Z., Kuen, J., Ma, L., Shahroudy, A., Shuai, B., Liu, T., Wang, X., Wang, G., Cai, J., ve Chen, T., 2018, Recent advances in convolutional neural networks. *Pattern Recognition*, 77, 354-377. doi:<https://doi.org/10.1016/j.patcog.2017.10.013>
- Gulcehre, C., Moczulski, M., Denil, M., ve Bengio, Y., 2016, *Noisy activation functions*. Paper presented at the International conference on machine learning.
- Han, X., Zhong, Y., Cao, L., ve Zhang, L., 2017, Pre-trained AlexNet architecture with pyramid pooling and supervision for high spatial resolution remote sensing image scene classification. *Remote Sensing*, 9(8), 848.
- He, K., Zhang, X., Ren, S., ve Sun, J., 2015, Spatial pyramid pooling in deep convolutional networks for visual recognition. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 37(9), 1904-1916.
- He, K., Zhang, X., Ren, S., ve Sun, J., 2016, *Deep residual learning for image recognition*. Paper presented at the Proceedings of the IEEE conference on computer vision and pattern recognition.
- Hermanto, A., Adj, T. B., ve Setiawan, N. A., 2015, *Recurrent neural network language model for english-indonesian machine translation: Experimental study*. Paper presented at the 2015 International Conference on Science in Information Technology (ICSITech).
- Hinton, G. E., Osindero, S., ve Teh, Y.-W., 2006, A fast learning algorithm for deep belief nets. *Neural computation*, 18(7), 1527-1554.
- Hinton, G. E., ve Salakhutdinov, R. R., 2006, Reducing the dimensionality of data with neural networks. *science*, 313(5786), 504-507.
- Hochreiter, S., ve Schmidhuber, J., 1997, Long short-term memory. *Neural computation*, 9(8), 1735-1780.
- Hwang, S., Kim, H.-E., Jeong, J., ve Kim, H.-J., 2016a, *A novel approach for tuberculosis screening based on deep convolutional neural networks*. Paper presented at the Medical Imaging 2016: Computer-Aided Diagnosis.
- Hwang, S., Kim, H.-E., Jeong, J., ve Kim, H.-J., 2016b, *A novel approach for tuberculosis screening based on deep convolutional neural networks* (Vol. 9785): SPIE.

- Jaeger, S., Candemir, S., Antani, S., Wáng, Y.-X. J., Lu, P.-X., ve Thoma, G., 2014, Two public chest X-ray datasets for computer-aided screening of pulmonary diseases. *Quantitative imaging in medicine and surgery*, 4(6), 475.
- Jaeger, S., Karargyris, A., Candemir, S., Folio, L., Siegelman, J., Callaghan, F., Xue, Z., Palaniappan, K., Singh, R. K., ve Antani, S., 2013, Automatic tuberculosis screening using chest radiographs. *IEEE transactions on medical imaging*, 33(2), 233-245.
- Jaeger, S., Karargyris, A., Candemir, S., Folio, L., Siegelman, J., Callaghan, F. M., Xue, Z., Palaniappan, K., Singh, R. K., ve Antani, S. K., 2014a, Automatic tuberculosis screening using chest radiographs. *IEEE Trans. Med. Imaging*, 33(2), 233-245.
- Jaeger, S., Karargyris, A., Candemir, S., Folio, L., Siegelman, J., Callaghan, F. M., Xue, Z., Palaniappan, K., Singh, R. K., ve Antani, S. K., 2014b, Automatic tuberculosis screening using chest radiographs. *IEEE Trans. Med. Imaging*, 33(2), 233-245 %!
- Automatic tuberculosis screening using chest radiographs.
- Jeong, H., Park, K., ve Ha, Y., 2018, 15-17 Jan. 2018, *Image Preprocessing for Efficient Training of YOLO Deep Learning Networks*. Paper presented at the 2018 IEEE International Conference on Big Data and Smart Computing (BigComp).
- Kingma, D. P., ve Ba, J., 2014, Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*.
- Krizhevsky, A., Sutskever, I., ve Hinton, G. E., 2012a, *Imagenet classification with deep convolutional neural networks*. Paper presented at the Advances in neural information processing systems.
- Krizhevsky, A., Sutskever, I., ve Hinton, G. E., 2012b, *Imagenet classification with deep convolutional neural networks*.
- Lakhani, P., ve Sundaram, B., 2017, Deep learning at chest radiography: automated classification of pulmonary tuberculosis by using convolutional neural networks. *Radiology*, 284(2), 574-582.
- Lau, M. M., ve Lim, K. H., 2017, 1-3 April 2017, *Investigation of activation functions in deep belief network*. Paper presented at the 2017 2nd International Conference on Control and Robotics Engineering (ICCRE).
- LeCun, Y., Bengio, Y., ve Hinton, G., 2015, Deep learning. *nature*, 521(7553), 436-444.
- Li, G., Deng, L., Xu, Y., Wen, C., Wang, W., Pei, J., ve Shi, L., 2016, Temperature based restricted boltzmann machines. *Scientific Reports*, 6, 19133.
- Liang, Z., Zhang, G., Huang, J. X., ve Hu, Q. V., 2014, *Deep learning for healthcare decision making with EMRs*. Paper presented at the Bioinformatics and Biomedicine (BIBM), 2014 IEEE International Conference on.

- Litjens, G., Kooi, T., Bejnordi, B. E., Setio, A. A. A., Ciompi, F., Ghafoorian, M., Van Der Laak, J. A., Van Ginneken, B., ve Sánchez, C. I., 2017, A survey on deep learning in medical image analysis. *Medical image analysis*, 42, 60-88.
- Liu, S., Liu, S., Cai, W., Pujol, S., Kikinis, R., ve Feng, D., 2014, *Early diagnosis of Alzheimer's disease with deep learning*. Paper presented at the Biomedical Imaging (ISBI), 2014 IEEE 11th International Symposium on.
- Liu, W., Wang, Z., Liu, X., Zeng, N., Liu, Y., ve Alsaadi, F. E., 2017, A survey of deep neural network architectures and their applications. *Neurocomputing*, 234, 11-26. doi:<https://doi.org/10.1016/j.neucom.2016.12.038>
- Lopes, U., ve Valiati, J. F., 2017, Pre-trained convolutional neural networks as feature extractors for tuberculosis detection. *Computers in Biology and Medicine*, 89, 135-143.
- Maduskar, P., Muyoyeta, M., Ayles, H., Hogeweg, L., Peters-Bax, L., ve van Ginneken, B., 2013, Detection of tuberculosis using digital chest radiography: automated reading vs. interpretation by clinical officers. *The International Journal of Tuberculosis and Lung Disease*, 17(12), 1613-1620. doi:10.5588/ijtld.13.0325
- McBee, M. P., Awan, O. A., Colucci, A. T., Ghobadi, C. W., Kadom, N., Kansagra, A. P., Tridandapani, S., ve Auffermann, W. F., 2018a, Deep Learning in Radiology. *Academic Radiology*, 25(11), 1472-1480. doi:<https://doi.org/10.1016/j.acra.2018.02.018>
- McBee, M. P., Awan, O. A., Colucci, A. T., Ghobadi, C. W., Kadom, N., Kansagra, A. P., Tridandapani, S., ve Auffermann, W. F., 2018b, Deep Learning in Radiology. *Academic Radiology*, 25(11), 1472-1480 %1478 2018/1411/1401/ %! Deep Learning in Radiology %@ 1076-6332. doi:<https://doi.org/10.1016/j.acra.2018.02.018>
- McCoppin, R., ve Rizki, M., 2014, *Deep learning for image classification*.
- Melendez, J., Sánchez, C. I., Philipsen, R. H. H. M., Maduskar, P., Dawson, R., Theron, G., Dheda, K., ve van Ginneken, B., 2016, An automated tuberculosis screening strategy combining X-ray-based computer-aided detection and clinical information. *Scientific Reports*, 6(1), 25265. doi:10.1038/srep25265
- Misra, D., 2019, Mish: A Self Regularized Non-Monotonic Neural Activation Function. *arXiv preprint arXiv:1908.08681*.
- Nair, V., ve Hinton, G. E., 2010, *Rectified linear units improve restricted boltzmann machines*. Paper presented at the ICML.
- Nwankpa, C., Ijomah, W., Gachagan, A., ve Marshall, S., 2018, Activation functions: Comparison of trends in practice and research for deep learning. *arXiv preprint arXiv:1811.03378*.

- Organization, W. H., 2013, *Global tuberculosis report 2013*: World Health Organization.
- Panicker, R. O., Kalmady, K. S., Rajan, J., ve Sabu, M. K., 2018, Automatic detection of tuberculosis bacilli from microscopic sputum smear images using deep learning methods. *Biocybernetics and Biomedical Engineering*, 38(3), 691-699. doi:<https://doi.org/10.1016/j.bbe.2018.05.007>
- Perez, L., ve Wang, J., 2017, The effectiveness of data augmentation in image classification using deep learning. *arXiv preprint arXiv:1712.04621*.
- Qian, S., Liu, H., Liu, C., Wu, S., ve Wong, H. S., 2018, Adaptive activation functions in convolutional neural networks. *Neurocomputing*, 272, 204-212. doi:<https://doi.org/10.1016/j.neucom.2017.06.070>
- Qu, T., Zhang, Q., ve Sun, S., 2017, Vehicle detection from high-resolution aerial images using spatial pyramid pooling-based deep convolutional neural networks. *Multimedia Tools and Applications*, 76(20), 21651-21663. doi:10.1007/s11042-016-4043-5
- Rajpurkar, P., Irvin, J., Zhu, K., Yang, B., Mehta, H., Duan, T., Ding, D., Bagul, A., Langlotz, C., ve Shpanskaya, K., 2017, Chexnet: Radiologist-level pneumonia detection on chest x-rays with deep learning. *arXiv preprint arXiv:1711.05225*.
- Ravi, D., Wong, C., Deligianni, F., Berthelot, M., Andreu-Perez, J., Lo, B., ve Yang, G.-Z., 2016, Deep learning for health informatics. *IEEE journal of biomedical and health informatics*, 21(1), 4-21.
- Reid, M. J., Arinaminpathy, N., Bloom, A., Bloom, B. R., Boehme, C., Chaisson, R., Chin, D. P., Churchyard, G., Cox, H., ve Ditiu, L., 2019, Building a tuberculosis-free world: The Lancet Commission on tuberculosis. *The Lancet*, 393(10178), 1331-1384.
- Ruder, S., 2016, An overview of gradient descent optimization algorithms. *arXiv preprint arXiv:1609.04747*.
- Samatin Njikam, A. N., ve Zhao, H., 2016, A novel activation function for multilayer feed-forward neural networks. *Applied Intelligence*, 45(1), 75-82. doi:10.1007/s10489-015-0744-0
- Shen, D., Wu, G., ve Suk, H.-I., 2017, Deep learning in medical image analysis. *Annual review of biomedical engineering*, 19, 221-248.
- Shorten, C., ve Khoshgoftaar, T. M., 2019, A survey on Image Data Augmentation for Deep Learning. *Journal of Big Data*, 6(1), 60. doi:10.1186/s40537-019-0197-0
- Suk, H.-I., ve Shen, D., 2013, *Deep Learning-Based Feature Representation for AD/MCI Classification*, Berlin, Heidelberg.
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., ve Rabinovich, A., 2015, *Going deeper with convolutions*. Paper

- presented at the Proceedings of the IEEE conference on computer vision and pattern recognition.
- Targ, S., Almeida, D., ve Lyman, K., 2016, Resnet in resnet: Generalizing residual architectures. *arXiv preprint arXiv:1603.08029*.
- Wan, L., Zeiler, M., Zhang, S., Cun, Y. L., ve Fergus, R. (2013). *Regularization of Neural Networks using DropConnect*. Paper presented at the Proceedings of the 30th International Conference on Machine Learning, Proceedings of Machine Learning Research. <http://proceedings.mlr.press>
- Weng, R., Lu, J., Tan, Y.-P., ve Zhou, J., 2016, Learning cascaded deep auto-encoder networks for face alignment. *IEEE Transactions on Multimedia*, 18(10), 2066-2078.
- Wong, S. C., Gatt, A., Stamatescu, V., ve McDonnell, M. D., 2016, Understanding data augmentation for classification: when to warp? *arXiv preprint arXiv:1609.08764*.
- World Health, O., 2018, *Global tuberculosis report 2018*. Geneva: World Health Organization.
- Yadav, G., Maheshwari, S., ve Agarwal, A., 2014, 24-27 Sept. 2014, *Contrast limited adaptive histogram equalization based enhancement for real time video system*. Paper presented at the 2014 International Conference on Advances in Computing, Communications and Informatics (ICACCI).
- Yue, J., Mao, S., ve Li, M., 2016, A deep learning framework for hyperspectral image classification using spatial pyramid pooling. *Remote Sensing Letters*, 7(9), 875-884.
- Zhang, Q., Yang, L. T., Chen, Z., ve Li, P., 2018, A survey on deep learning for big data. *Information Fusion*, 42, 146-157. doi:<https://doi.org/10.1016/j.inffus.2017.10.006>
- Zhu, R., Mao, X., Zhu, Q., Li, N., ve Yang, Y., 2016, 25-28 Sept. 2016, *Text detection based on convolutional neural networks with spatial pyramid pooling*. Paper presented at the 2016 IEEE International Conference on Image Processing (ICIP).
- Zinkevich, M., Weimer, M., Li, L., ve Smola, A. J., 2010, *Parallelized stochastic gradient descent*. Paper presented at the Advances in neural information processing systems.

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı : Pike MSONDA
Uyruğu : Malawi
Doğum Yeri ve Tarihi : 04-04-1994
Telefon : +90 537 372 28 34
Faks :
E-Posta : pike.msonda@gmail.com

EĞİTİM

Derece	Adı	İlçe	İl	Bitirme Yılı
Lise :	Malamulo Secondary School	Thekerani	Thyolo,	2009
Üniversite :	DMI. ST. John the Baptist University	Mangochi	Mangochi	2015
Yüksek Lisans :	Konya Teknik Üniversitesi	Selçuklu	Konya	

İŞ DENEYİMLERİ

Yıl	Kurum	Görevi
2015	NITEL (National Integrated Technologies Limited)	Yazılım geliştirici
2016	Baobab Health Trust	Yazılım geliştirici

UZMANLIK ALANI

Yapay Zekâ

YABANCI DİLLER

İngilizce ve Türkçe

YAYINLAR

Msonda P. and Uymaz S.A., “Automated Diagnosis of Tuberculosis using Deep Learning Techniques”, *International Conference on Advanced Technologies, Computer Engineering and Science (ICATCES 2019)*, 2019, pp. 58-62. (Yüksek Lisans tezinden hazırlanmıştır).