

ÇUKUROVA ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

**Akciğer Kanserinin CT Görüntülerinden Teşhisi İçin
Differansiyel Konvolüsyonel Yapay Sinir Ağı Tabanlı Görüntü
Tanıma Yazılımı Geliştirilmesi**

Emran DURSUNOV

Biyomedikal Mühendisliği Anabilim Dalı

Eylül, 2025

ÇUKUROVA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YÜKSEK LİSANS TEZ ONAYI

**Akciğer Kanserinin CT Görüntülerinden Teşhisi İçin
Differansiyel Konvolüsyonel Yapay Sinir Ağı Tabanlı Görüntü
Tanıma Yazılımı Geliştirilmesi**

Emran DURSUNOV

Biyomedikal Mühendisliği Anabilim Dalı

Bu Yüksek Lisans Tezi 19/09/2025 Tarihinde Aşağıdaki Jüri Üyeleri Tarafından
Değerlendirilmiş ve Oy Birliği / Oy Çokluğu ile Kabul Edilmiştir.

Jüri : Prof. Dr. Mutlu AVCI (Danışman)
: Dr.Öğr.Üyesi Mustafa İSTANBULLU
: Dr.Öğr.Üyesi Abdurrahman Özgür POLAT

**Bu Tez Fen Bilimleri Enstitüsü, Biyomedikal mühendisliği Anabilim Dalında
Hazırlanmıştır.**

Tez No:

Prof. Dr. Sadık DİNÇER
Enstitü Müdürü

Not: Bu tezde kullanılan özgün ve başka kaynaktan yapılan bildirişlerin, çizelge ve fotoğrafların kaynak
gösterilmeden kullanımı, 5846 sayılı Fikir ve Sanat Eserleri Kanunundaki hükümlere tabidir.

İÇİNDEKİLER

ÖZ	V
ABSTRACT	VI
TEŞEKKÜR	VII
ÇİZELGELER DİZİNİ	VIII
ŞEKİLLER DİZİNİ	IX
SİMGELER VE KISALTMALAR	X
1. GİRİŞ	1
1.1. Akciğer nodülü tespitindeki hatalar	2
1.2. Akciğer nodülü görüntülemeye CAD	3
1.3. Bilgisayar Tomografisinde Akciğer Nodülü	5
1.4. Bilgisayarlı tomografi akciğer görüntü işleme	6
1.5. Pulmoner nodülün bilgisayarlı tanısı	6
1.6. Tezin Amacı	8
1.7. Sinir Ağları	8
2. ÖNCEKİ ÇALIŞMALAR	13
3. MATERYAL VE METOT	19
3.1. Çalışmada kullanılan kütüphaneler	19
3.1.1. Pytorch	19
3.1.2. OpenCV	19
3.1.3. NumPy	20
3.1.4. Glob	20
3.1.5. Scikit-learn	20
3.1.6. Matplotlib	20
3.2. Değerlendirme Metrikleri	21
3.3. LIDC-IDRI veri seti	21
3.4. Evrişimsel Sinir Ağı	23
3.4.1. Konvolüsyonel Katman	23
3.4.2. Aktivasyon Katmanı	25
3.4.3. Havuzlama Katmanı	25
3.4.4. Tam Bağlantılı Katman	26
3.4.5. Evrişimsel Sinir Ağı'nın Eğitimi	27
3.5. Softmax	27
3.5.1. Veri artırımı	27
3.5.2. DropOut	27
3.5.3. DropConnect	28

3.6. Diferansiyel Konvolüsyonel Sinir Ağı.....	28
3.7. Diferansiyel konvolüsyon	31
3.8. Birikimli geri yayılım algoritması.....	33
4. BULGULAR VE TARTIŞMA	35
4.1. SoftMax kullanılan Geriye Yayılımlı Diferansiyel CNN sonuçları.....	42
5. SONUÇLAR VE ÖNERİLER	43
KAYNAKLAR	45
ÖZGEÇMİŞ	51
EKLER.....	52



**Akciğer Kanserinin CT Görüntülerinden Teşhisi İçin
Diferansiyel Konvolüsyonel Yapay Sinir Ağı Tabanlı
Görüntü Tanıma Yazılımı Geliştirilmesi**

Emran DURSUNOV

Danışman: Prof. Dr. Mutlu AVCI

Biyomedikal Mühendisliği Anabilim Dalı

ÖZ

Akciğer kanseri dünyada ölüm oranını artıran önemli nedenlerden biridir, çünkü her yıl diğer kanser türlerine kıyasla akciğer kanseri nedeniyle çok sayıda ölüm gerçekleştiği görülmektedir. Eğer ilk aşamada tespit edilir ve tanımlanırsa, çok sayıda hastanın hayatta kalma oranı artırılabilir. Bu nedenle, uygun ve anlık bir sonuç elde etmek için, tıbbi görüntü işleme alanında makine öğreniminin son tekniklerini kullanarak sınıflandırmanın doğruluğunu artırılabilir.

Bu çalışmada, Diferansiyel Konvolüsyon olarak adlandırılan yeni bir konvolüsyon tekniği ve güncellenmiş hata geri yayılım algoritması kullanılmaktadır. DCNN yönsel aktivasyon farklılıklarını içeren özellik haritalarını bir sonraki katmana aktarmayı amaçlamaktadır. Bu uygulama, konvolüsyonlu özelliklerin özellik haritası üzerinde nasıl değiştiği fikrini dikkate almaktadır. Bu özellik, filtre sayısını değiştirmeden sınıflandırma performansını artırmaktadır. Anormal ve normal bilgisayar tomografi (BT) görüntüleri de dahil olmak üzere farklı akciğer kanseri türlerini sınıflandırmak için diferansiyel konvolüsyonel sinir ağı modeli önermektedir. Bu modelin performansını test etmek ve eğitmek için, anormal ve normal görüntüleri içeren 1.000 akciğer bilgisayarlı tomografi (BT) görüntüsünden oluşan bir veri kümesi kullanılmıştır. Deneysel sonuçlar, önerilen modelin %96,25'lik bir doğruluğa ulaştığını göstermiştir. Bu çalışmada, önerilen diferansiyel CNN modelinin akciğer kanserinin otomatik sınıflandırılmasını kolaylaştırmak için kullanılabileceğini göstermektedir.

Anahtar Kelimeler: Makine Öğrenmesi, Diferansiyel CNN, Görüntü İşleme, Akciğer Kanseri Tespiti.

Development Of Differential Convolutional Neural Network Based Image Recognition Software For Diagnosis Of Lung Cancer From CT Images

Emran DURSUNOV

Advisor: Prof. Dr. Mutlu AVCI

Department of Biomedical Engineering

ABSTRACT

Lung cancer is one of the major causes of mortality in the world, as there are more deaths each year from lung cancer than from any other type of cancer. If detected and identified at the initial stage, the survival rate of a large number of patients can be increased. Therefore, it can improve the accuracy of classification using the latest techniques of machine learning in the field of medical image processing in order to achieve a convenient and instantaneous result.

In this work, we use a new convolution technique called Differential Convolution and an updated error back propagation algorithm. DCNN aims to transfer feature maps containing directional activation differences to the next layer. This implementation takes into account the idea of how convolved features change over the feature map. This feature improves the classification performance without changing the number of filters. proposes a differential convolutional neural network model to classify different types of lung cancer, including abnormal and normal computer tomography (CT) images. To train and test the performance of this model, a dataset of 1,000 lung computed tomography (CT) images including abnormal and normal images is used. Experimental results show that the proposed model achieves an accuracy of 97.25%. This study shows that the proposed differential CNN model can be used to facilitate automatic classification of lung cancer.

Keywords: Machine Learning, Differential CNN, Image Processing, Lung Cancer Detection.

TEŞEKKÜR

Bu araştırma için beni yönlendiren, karşılaştığım zorlukları bilgi, tecrübesi ile aşmamda yardımcı olan ve tez konumu bulmamda bana yardımını esirgemeyen değerli Danışman Hocam Prof.Dr. Mutlu AVCI ve yazılım geliştirme aşamasında katkılarda bulunan Dr. Öğr. Üyesi Mehmet SARIGÜL 'e teşekkürlerimi sunarım.



ÇİZELGELER DİZİNİ

Çizelge 1. Akciğer kanseri BT görüntülerini sınıflandırma için oluşturulan CNN model özeti.....	37
Çizelge 2. Akciğer kanseri BT görüntülerini sınıflandırma için oluşturulan	38
Çizelge 3. Farklı modellerin sonuçlarının önerdiğimiz diferansiyel derin-CNN modeli ile karşılaştırılması.....	41
Çizelge 4. Uygulanan derin öğrenme modelleri.....	41
Çizelge 5. Literatürdeki diğer çalışmalar ile karşılaştırma tablosu	41
Çizelge 6. SoftMax kullanılan BP ve DCNN ile Diferansiyel CNN sonuçlarının karşılaştırılması.....	42



ŞEKİLLER DİZİNİ

Şekil 1. Yaygın akciğer kanseri türleri (ASC, 2017)	2
Şekil 2. CAD Sistemi. Bir akciğer nodülünün CAD işaretli göğüs BT görüntüleri. (Masahito,2013)	4
Şekil 3. 64 yaşında bir kadına ait akciğer BT taraması (Armato, 2015). (a) kesitlerin alınma yönü. (b) bir normal kesit. (c) sağ üst kısmında malign bir nodül içeren bir anormal kesit.....	5
Şekil 4. BT taramasından malign pulmoner nodülü tespit etmek için tipik bir CAD sistemi. (a) nodül tespitinde evre 1'e genel bakış. (a) akciğer hastalığı sınıflandırmasında 2. aşamaya genel bakış (Colin Jacobs, 2014).....	7
Şekil 5. Üç giriş düğümüne sahip yapay nöronun matematiksel modeli, x_0 , x_1	9
Şekil 6. İki nöronlu bir giriş katmanı, üç nöronlu bir gizli katman ve tek nöronlu bir çıkış katmanından oluşan 3 katmanlı bir yapay sinir ağı.	10
Şekil 7 . Farklı katman sayılarında sınıflandırma performansı.	11
Şekil 8. İş akış diyagramı	19
Şekil 9. LIDC-IDRI veri setinden bir BT görüntüsü üzerinde neoplazm etiketleme örneği.....	22
Şekil 10. Kırpılmış görüntünün yerel bölgesindeki özellikleri çıkarmak için bir konvolüsyonel katman örneği. Konvolüsyonel katman, 2×2 boyutunda bir filtre ve bir çıktı özellik haritasından oluşur. (Nielsen, 2015; Sankar vd., 2016).....	24
Şekil 11. Maksimum havuzlama işlemine bir örnek. 2 adımlı 2×2 filtre 4 giriş alır ve maksimum değeri koruyarak aşağı örnekleme gerçekleştirir. (Nielsen, 2015).....	26
Şekil 12. Dropout Tekniği.....	28
Şekil 13. Sabit filtreler	29
Şekil 14 Differentail CNN yapısı.....	30
Şekil 15. Diferansiyel konvolüsyon işlemi. (Sarigül, 2019)	32
Şekil 16. Orijinal görüntü Sol Üst: Orijinal görüntü; Sol Alt: Geleneksel özellik haritası; Diğerleri: Diferansiyel özellik haritaları. (Sarigül, 2019).....	32
Şekil 17. Önerilen Differential CNN model için doğruluk oranı	36
Şekil 18.Önerilen Differential CNN model için kayıp oranı.....	38
Şekil 19. Diferansiyel Evrişimli Sinir Ağlarının Mimarisi	39
Şekil 20. CNN model için doğruluk oranı.....	40
Şekil 21.CNN model için kayıp oranı	40

SİMGELER VE KISALTMALAR


ANN	: Artificial Neural Network
DCNN	: Differential Convolution Neural Network
BT	: Bilgisayarlı Tomografi
CAD	: Bilgisayar Destekli Tespit
CNN	: Convolution Neural Network
MÖ	: Makine Öğrenmesi
MR	: Magnetik Rezonans Görüntüleme
DNN	: Deep Neural Network (Derin Sinir Ağı)
IDRI	: Lung Image Database Consortium



1. GİRİŞ

Akciğer kanseri dünyada en sık görülen kanser hastalığı haline gelmektedir. Amerikan Kanser Derneği tarafından yayınlanan istatistiksel verilere göre (ASC, 2017), akciğer kanseri kanserden ölümlerin önde gelen nedenidir. Erken teşhis ve tanı, kanserde hayatta kalma oranını artırmanın anlamlı bir yoludur. Akciğer kanseri teşhisi alanında, akciğer kanseri olduğundan şüphelenilen bir hastaya, düşük maliyeti ve kolay çekilebilir olması nedeniyle ilk olarak akciğer röntgeni çekilmesi önerilmektedir. Akciğer kanseri, anormal kitleler olarak tanımlanan pulmoner nodülden kaynaklanır. Akciğer içindeki doku. Pulmoner nodül röntgen görüntüsüne yansıdığına, kitle sağlıklı dokulara kıyasla farklı yoğunluk alanlarına sahiptir. Radyolog, yoğunluk alanındaki değişimi fark ederek akciğer kanserinin yerini bulabilir. Ancak, bir göğüs röntgeni akciğerin 2 boyutlu bir projeksiyonudur ve pulmoner nodülün boyutu genellikle 10 mm'den azdır. Bu nedenle, radyoloğun nodülün türünü (yani iyi huylu veya kötü huylu) ve daha ileri bir tıbbi tedavi uygulamak için nodülün tam yerini doğrulaması zordur. Radyolog göğüs röntgeninde herhangi bir şüpheli bulgu fark ederse, tanıyı kesinleştirmek için daha ileri bir bilgisayarlı tomografi (BT) incelemesi önerilir. (Christian, 2014)

Akciğer kanseri olarak adlandırılan akciğer karsinomu, dünya çapında en çok etkilenen ve en yüksek kanserli ölüm oranına neden olan kanserdir. Akciğer kanseri, bir veya her iki akciğerde başlayan anormal hücrelerin kontrolsüz kitlesel büyümesinden kaynaklanır. Kanser hücreleri hızla bölünür ve dokuları etkilemeden tümör oluşumuyla sonuçlanır. Kanser hücrelerinin ilerleyen büyümesi tümörleri oluşturur ve akciğerlerin normal işleyişini engeller. İki türü var olan akciğer kanseri: küçük hücreli akciğer kanseri ve küçük hücreli olmayan akciğer kanseri. Küçük hücreli olmayan akciğer kanseri hastalarının sayısı küçük hücreli akciğer kanseri hastalarından daha fazladır. Küçük hücreli akciğer kanserleri nöroendokrin sistemde gelişir ve bu da hızla yayılan nöroendokrin tümörlere neden olur. Buna karşılık, küçük hücreli olmayan akciğer kanserinin akciğerde bulunan kanser hücrelerinin konumuna bağlı olarak üç ana tipi vardır - Adenokarsinom, skuamöz hücreli karsinom, büyük hücreli karsinom. Küçük hücreli olmayan akciğer kanseri benzer tedaviye sahiptir ve zamanla yanıt verir. Bunlar arasında adenokarsinomlar şekilde gösterildiği gibi en sık görülen türdür ve akciğer kanserlerinin %40'ını esas olarak akciğerin mukus tabakasında, %30'unu hava yollarında, akciğerin orta kısmında ve %15'ini küçük hücreli karsinom gibi çok hızlı yayılarak etkileyen ve akciğerin herhangi bir yerinde yuvarlak şekilde ortaya çıkan skuamöz hücreli karsinom oluşturur (David Silver,2016). Şekil 1, ortaya çıkan kanser türlerini göstermektedir.



Şekil 1. Yaygın akciğer kanseri türleri (ASC, 2017)

Bu kanserler hızla beyin, lenf düğümleri, kemik gibi diğer organlara yayılır ve vücudun önemli bölümlerinde ölüme yol açar. Kanser yaklaşık %57'si tanı anında göğsün ötesine yayılır.

(Sebastian,2016) İlk aşamalarda kanser lenf düğümlerine yayılır, ancak genellikle metastaz halinde göğüs içinde kalır, ancak böbrekler, kemikler, karaciğer gibi diğer uzak bölgelere yayılabilir. Bu nedenle tanı sırasında erken bir taramada görülebilen kanserli akciğer nodüllerinin öngörülmesi ile yayılma önlenir.

1.1. Akciğer nodülü tespitindeki hatalar

Günlük radyolojik raporlamaların yaklaşık %4'ü tanı hataları içermektedir.(Pinsky, 2004) Sonuç olarak, anormal radyolojik çalışmaların %30'u gözden kaçmaktadır. Tanı hatası, eksik tanı (tanı konulmaması), yanlış tanı (doğru tanıdan farklı bir tanı) veya gecikmiş tanı olarak tanımlanmıştır. Bu hatalar, hasta ölümünün ve önemli, büyük ve küçük kalıcı hasarların ana nedenlerinden biri olarak kabul edilmektedir.(Tehrani, 2013)

(Kundel, 1999) üç tür hata tanımlamıştır: gözlemcinin lezyon alanını tespit edemediği tarama hatası; gözlemcinin lezyon alanını tespit ettiği, ancak lezyonu ayırt edemediği tanıma hatası; ve kötü huylu bir lezyonun iyi huylu bir lezyon veya normal bir yapı olarak yanlış yorumlanması olan karar verme hatası. Bu üç hata türü birlikte gözlemci hatasının bir parçasını oluşturur. Sistemle ilgili hatalar ve bilişsel faktörler de tanısal hatayı incelerken dikkate alınmaya değerdir. Sistemle ilgili hatalar, teknik ve ekipman arızalarına ek olarak sağlık politikaları, prosedürleri, ekip çalışması ve iletişimle ilgili sorunları içerir. (Graber, 2005) tarafından tanımlandığı üzere, bilişsel hatalar ya doktorun teşhis becerilerinin veya hastanın durumu hakkındaki bilgisinin yetersiz olmasını içeren hatalı bilgidir, ya hastaların testlerinden, muayenelerinden veya görüşmelerinden veri toplamada sorun yaşandığında hatalı veri toplamadan, ya da yanlış bilgi işleme anlamına gelen hatalı sentezden (teşhisle ilgili olan

hastayla ilgili bilgilerin dikkate alınmaması gibi) kaynaklanmaktadır. Ayrıca, artan iş yükü, hasta beklentileri, gözlemcinin uyanıklık düzeyi ve yorgunluk gibi koşullar da tanı hatalarının artmasına katkıda bulunmaktadır. Graber ve arkadaşları tarafından yapılan bir çalışmada, tanı hatalarının neredeyse yarısı sistemle ilgili ve bilişsel faktörlerin bir kombinasyonundan, %19'u yalnızca sistemle ilgili faktörlerden ve %28'i yalnızca bilişsel faktörlerden kaynaklanmıştır.(Shaoqing,2015)

BT raporlamasının özellikle hataya açık olduğu görülmekle birlikte, BT'deki hataları tanımlayan çok az çalışma bulunmaktadır. Belgelenen hataların %88'i görüntü yorumlama sırasında (bilişsel hata) meydana gelmektedir ve hataların çoğu yanlış negatif bulgulardır. Bu durum, son yıllarda gerçekleştirilen BT prosedürlerinin artan hacmi, tek bir BT incelemesi için oluşturulan büyük görüntü setleri, radyoloğun raporlamayı gerçekleştirmesi için mevcut olan sınırlı zaman ve radyoloğun BT teknolojilerindeki yeni gelişmeler hakkında güncel ve uygun eğitim almamasından kaynaklanıyor olabilir. (Creadie,2013) 222 hastada 256 hatayı incelerken çeşitli BT incelemeleriyle ilgili hataların %62'sini bildirmiştir. Literatürde sunulduğu gibi, BT ile atlanan akciğer kanseri vakalarının sayısallaştırılması, muhtemelen yapılan çok sayıda rutin BT incelemesi arasında atlanan vakaların tanınmasındaki zorluk nedeniyle sınırlıdır. (Kakinuma, 2018) BT taramasında 22 kanserden yedisinin gözden kaçtığını bildirmiştir ve Li ve arkadaşları tarafından yapılan daha yeni bir çalışmada (Pugatch, 2008) kanserden 32'si BT incelemelerinde gözden kaçmıştır. NLST'de, LDCT tarama kolunda akciğer kanserlerinin %6,2'si atlanmıştır. Literatürde göğüs BT'si için akciğer nodülü saptama oranlarında önemli farklılıklar bildirilmiştir. Saptamadaki hassasiyet, teknik faktörlere (kesit kalınlığı) ek olarak nodül özelliklerine (boyut, şekil, kenarlar, yoğunluk, konum, komşu yapılarla ilişki) bağlıdır. Küçük çap genellikle gözden kaçan akciğer nodülleri ile daha yakından ilişkilidir. Bu durum, radyologlar tarafından çift okuma için pozitif prediktif değer için tüm nodül boyutları için %35,2'den >50 mm boyutundaki nodüller için %76,1'e yükseldiği (Mohammadi,2019) yapılan bir çalışmada gösterilmiştir.


1.2. Akciğer nodülü görüntüleme CAD

Radyolojide çift okumanın hataları azalttığı ve tanısal duyarlılığı artırdığı bildirilmiştir, ancak zaman alan bir prosedür olarak kabul edilir ve iki radyolog kullanıldığında daha yüksek bir yorumlama maliyetine neden olur; ayrıca daha nitelikli radyologların çalışmasını gerektirir. Bu nedenle her görüntü için çift okuma yapmak mümkün olmayabilir.(John Duchi, 2020)

CAD gibi yazılım teknolojileri, radyologların gözden kaçan akciğer nodüllerinin oranını azaltmalarına, çift okumadan daha verimli bir şekilde ve daha düşük maliyetlerle yardımcı olma potansiyeline sahiptir; ancak, iyi huylu veya nodül olmayan yapıların dahil edilmesinden kaynaklanan yüksek yanlış pozitiflik oranı önemli bir endişe kaynağıdır. 1980'lerin sonlarında, akciğer nodülü tespiti için ilk CAD sistemleri ortaya çıktı, ancak bu ilk girişimler, o dönemde mevcut olan sınırlı hesaplama kaynakları ve yetersiz gelişmiş görüntü işleme teknikleri nedeniyle çok başarılı olamadı. CAD sistemlerinin amacı, radyologlara akciğer nodüllerinin tespitinde yardımcı olmak ve her tarama için gereken okuma süresini azaltmaktır. Okuma süresi, CAD eşzamanlı okuyucu olarak kullanıldığında,

okumanın önce tek başına radyologlar tarafından, ardından CAD ile ayrı ayrı yapılmasına kıyasla önemli ölçüde kısalmıştır. (Sebastian,2016)

Çoğu CAD sisteminin nasıl çalıştığına dair genel bir kavram olarak, beş ana adımda özetlenebilir: edinme (tıbbi görüntülerin elde edilmesi), ön işleme (kaliteyi iyileştirmek ve işleme algoritmalarının hassasiyetini ve doğruluğunu artırmak için uygulanan teknikler), segmentasyon (işlevi, çalışma bölgesini radyografik görüntülerdeki diğer organlardan ve dokulardan ayırmaktır), nodül tespiti (görüntüdeki pulmoner nodüllerin varlığını belirlemek ve konumlarını işaretlemek) ve yanlış pozitiflerin ortadan kaldırılması, ancak, CAD sistemi geliştiricilerinin kendi özel CAD sistemlerinin nasıl çalıştığı hakkında çok az bilgi verdiğini belirtmek gerekir.(Masahito,2013) Şekil 2'de bir göğüs BT görüntüsü üzerinde bir nodülü işaretleyen bir CAD sisteminin görüntüsü gösterilmektedir.



Şekil 2. CAD Sistemi. Bir akciğer nodülünün CAD işaretli göğüs BT görüntüleri. (Masahito,2013)

CAD klinik ortamda bir fark yaratma potansiyeline sahiptir; bir akciğer nodülünü otomatik olarak tespit edebilir ve BT görüntülerinde bu nodülün iki boyutlu ve hacimsel ölçümlerini hesaplayabilir. Bu ölçümler kullanılarak nodülün büyümesi değerlendirilerek zaman içindeki ilerlemesi takip edilebilir. Klinik iş akışı açısından avantajı, radyologların her vaka için harcadığı değerli zamandan tasarruf etmek ve nodül takibi için daha tekrarlanabilir sonuçlar üretmektir. Buna ek olarak, radyologların enerjisi daha verimli bir şekilde görüntü yorumlamaya odaklanır, ancak CAD sistemi kantitatif araçlarının klinik bir iş istasyonuna entegre edilmesinin zor olduğu kanıtlanmıştır ve henüz bu verimli bir şekilde uygulanmamıştır.(Mohammadi,2019)


CAD, göğüs BT incelemelerinde akciğer nodülü saptama hassasiyetini önemli ölçüde artırmıştır; ayrıca, çeşitli çalışmalar göğüs BT'sinde CAD uygulamasının radyologlar tarafından

başlangıçta gözden kaçırılan akciğer nodüllerini saptamada da yararlı olduğunu ortaya koymuştur. Bu durum, dört CAD sisteminin radyologlar tarafından saptanmadan bir yıl önce BT incelemelerinde solid nodül olarak ortaya çıkan 50 akciğer kanseri üzerinde test edildiği yakın tarihli bir çalışmada gösterilmiştir. Kanserlerin radyologlar tarafından atlandığı dönemde, CAD sistemleri akciğer kanserlerinin %70'ine kadarını tespit etmiştir. (Masahito,2013)

1.3. Bilgisayar Tomografisinde Akciğer Nodülü

Bilgisayarlı Tomografi (BT) taraması, pulmoner nodülleri tespit etmedeki yüksek hassasiyeti nedeniyle radyologlar tarafından yaygın olarak kullanılmaktadır. Diğer göğüs radyografisi yöntemlerine kıyasla daha yüksek bir tespit oranı gösterir ve bu nedenle akciğer kanseri mortalitesini azaltmada yardımcı olur. Göğüs röntgeni sorununu aşmak için BT tarayıcı, çeşitli açılarla birçok X-ışını ölçümü gerçekleştirerek hastanın akciğerini analiz eder ve akciğerin kesitsel görüntülerini üretir. Taranan BT görüntülerini bir araya getiren radyolog, hastanın akciğerini 3 boyutlu uzayda inceler. X-ışını görüntüsünün aksine, BT görüntüleri radyoloğun anormal ve normal dokular arasındaki desenleri ayırt etmesine yardımcı olan gelişmiş bir ölçüme sahiptir. (Masahito,2013)

Tamamlanmış bir BT taraması gerçekleştirmek için, BT tarayıcısı hastanın başından ayaklarına doğru aksiyal eksen boyunca yavaşça kayar. Şekil 3(a)'da gösterildiği gibi, bir BT taraması akciğerin üstünden başlayıp altına kadar uzanan bir dizi kesit görüntüsü oluşturur. BT tarayıcısından alınan her bir kesit görüntüye dilim adı verilir. Şekil 3(b) ve Şekil 3(c) sırasıyla akciğer kanseri olan 64 yaşındaki bir kadın hastadan farklı aksiyal pozisyonlarda alınan iki farklı kesiti göstermektedir.




Şekil 3. 64 yaşında bir kadına ait akciğer BT taraması (Armato, 2015). (a) kesitlerin alınma yönü. (b) bir normal kesit. (c) sağ üst kısmında malign bir nodül içeren bir anormal kesit.

1.4. Bilgisayarlı tomografi akciğer görüntü işleme

BT taraması, farklı doku yoğunlukları arasındaki X-ışını zayıflama farklarının ölçülmesi ve sofistike bilgisayar işlemleriyle elde edilen eşit çözünürlükte bir dizi iki boyutlu görüntüdür. İncelenen nesne gentry açıklığının içinde yer aldığından, elde edilen görüntü kare şeklinde olmasına rağmen, yalnızca çizilen dairenin içinde yararlı bilgiler içerir. Başka bir kesit oluşturulduktan sonra, nesne yeni bir kesit oluşturmak için gentry boyunca sabit bir mesafede hareket ettirilir. Böylece, tüm iki boyutlu dilim görüntüleri serisi tek bir üç boyutlu görüntü oluşturur.(Hui Chen, 2010)

Bir nesnenin iç yapısını analiz ederken, nesnenin ilgilenilen bölgelerine işaretler uygulamak oldukça yaygındır. Uygulanan işaretler, nesneyi araştırmacının ilgilendiği ve ilgilenmediği alanlara ayırmaya (bölmeye) olanak tanır. Eksenel dilimlere ayrıştırılmış ve işaretler uygulanmış hacimsel bir BT görüntüsünün bir örneği Şekil 4'de gösterilmektedir.



Şekil 4. Bilgisayarlı tomografi görüntüsünün hacimsel yerleşimigöğüs kafesi.(Hui Chen, 2010)


1.5. Pulmoner nodülün bilgisayarlı tanısı

Pratikte, BT taramaları pulmoner nodül tespitinde yüksek duyarlılığa sahip olsa da, bir radyolog için nodülün iyi huylu mu yoksa kötü huylu mu olduğunu belirlemek hala kolay değildir. Hasta sayısı çok fazla olduğunda, radyoloğun tanı koymasına zaman almaktadır. Seminer niteliğindeki Ulusal Akciğer Tarama Çalışması (The National Lung Screening Trial Research Team, 2011) düşük doz BT taramalarıyla akciğer kanserinden ölüm oranının %20 azaldığını bildirmiştir. Bununla birlikte, pozitif düşük doz BT taramalarının oranı %24,2 iken, pozitif taramaların toplam %96,4'ünde yanlış pozitiflik görülmüştür, yanlış pozitif tanı gereksiz takip muayenelerine yol açarak tanıyı geciktirecek ve artan radyasyon maruziyeti hastaya daha fazla zarar verecektir.

Bilgisayar Destekli Tespit (CAD) sistemleri, bir radyoloğun vaka incelemesi sırasında aradığı şüpheli özellikleri tanımlayarak gözlemsel gözden kaçmaları azaltmak için geliştirilmiştir. CAD sistemi radyologların teşhis doğruluğunu artırdığından, CAD sistemi ön teşhis için iyi bir seçim haline dönüşmektedir (Colin Jacobs, 2014)

Akciğer BT taraması için tipik bir CAD sistemi iki aşamadan oluşur: 1) nodül tespiti ve 2) akciğer hastalığı sınıflandırması. İlk aşama, şüpheli nodül adaylarını vurgulayan endişe verici alanların

işaretlenmesini ifade eder. İşaretleri oluşturmak için, çift eşik metrikleri veya morfoloji işlemleri gibi görüntü işleme metodolojileri aracılığıyla genel yaklaşımlar uygulanır (Christian, 2014). Bununla birlikte, CAD sistemleri tarafından üretilen işaretler genellikle yüksek hassasiyet ve yanlış pozitif oranlara sahiptir (Hui Chen, 2010). Bu nedenle, ikinci aşama, klinik tanısal karar verme yeteneği sağlarken, işaretli endişe alanları için yanlış pozitif oranları azaltmayı amaçlamaktadır. Genellikle, işaretli endişe alanlarından özellikler çıkarılır ve nodül sınıflandırması için makine öğrenimi şemaları kullanılır (Russell, 2010). Şekil 5'te pulmoner nodüllerin teşhisinde klinik radyologlara yardımcı olacak tamamlanmış bir CAD sistemi gösterilmektedir.



Şekil 4. BT taramasından malign pulmoner nodülü tespit etmek için tipik bir CAD sistemi. (a) nodül tespitiinde evre 1'e genel bakış. (a) akciğer hastalığı sınıflandırmasında 2. aşamaya genel bakış (Colin Jacobs, 2014)

Pulmoner nodülün malignite derecelendirmesine ilişkin bir bilgisayar destekli tanı aracı, CAD sisteminin ikinci aşamasına aittir ve iyi huylu ve kötü huylu vakalar arasındaki nodül tiplerini ayırt ederek yanlış pozitif oranını azaltmaya odaklanır. Pulmoner nodüller çok çeşitli şekil ve boyutlara sahip olmanın yanı sıra iyi huylu ve kötü huylu desenler arasında yüksek görsel benzerlikler vardır, bu nedenle nodüllerin şekilleri veya boyutları gibi düşük seviyeli metinsel olmayan özelliklerin analizi her zaman umut verici bir teşhis performansı sağlayamaz. Pulmoner nodül tespiti için ilk geliştirilen CAD sistemi, pulmoner nodülün düşük seviyeli özelliklerini daha yüksek boyutlu alanlarda tanımlamak için geleneksel görüntüleme işleme yöntemlerini uygulamıştır (Maryellen L., 2003). Ancak bu özellikler, düşük ayırt edici güç nedeniyle yeni nodül paternleri ortaya çıktığında sınırlı genellemelere sahipti (Mizuho Nishio, 2017).

Son yıllarda derin öğrenme, görüntü sınıflandırma, nesne algılama, görüntü segmentasyonu ve doğal dil işleme alanlarında büyük başarılar elde etmiştir. Bu alanların çoğunda derin öğrenme, insan performansına yakın bir performans elde edebilmektedir (David Silver, 2016). Görüntü sınıflandırması yapmak için en popüler derin öğrenme mimarisi olan evrişimli sinir ağı (CNN), yüksek seviyeli ayırt

edici özellikler çıkarma yeteneğine sahiptir. Pulmoner nodül tespiti için klinik kullanıma ek olarak, CNN nodül segmentasyonu veya nodül hacmi gibi herhangi bir ek bilgi olmadan yama tabanlı ham görüntüyü kullanır ve CNN herhangi bir ek özellik çıkarıcı veya sınıflandırıcı olmadan denetimli bir şekilde otomatik olarak uçtan uca eğitilir. Bu nedenle, CNN'in CAD sistemlerinin performansını artırmada yardımcı olması beklenmektedir. Daha yüksek teşhis doğruluğu elde etmek amacıyla tıp alanında derin öğrenmeden yararlanmak için birçok araştırma çalışması yapılmıştır (Wang X., 2014).

1.6. Tezin Amacı


Bu tez, BT taramasında kötü huylu pulmoner nodül teşhisi için diferansiyel konvolüsyonel sinir ağı (DCNN) tabanlı bir CAD sistemi tasarlamayı amaçlamaktadır. Tasarlanan DCNN, ek segmentasyona ihtiyaç duymadan ham giriş görüntüsüne dayanarak pulmoner nodülleri iyi huylu veya kötü huylu olarak ayırt edebilmektedir. Bu tezin amacına ulaşmak için, tasarlanan DCNN pulmoner nodül sınıflandırma görevi için dikkatlice uyarlanmıştır: 1) filtre boyutu, alıcı alan ve optimize edici dahil olmak üzere optimum hiper parametrelerin araştırılması. 2) Dengesiz eğitim veri setinin performans etkisinin araştırılması. 3) DCNN ve diğer yaygın olan CNN mimarilerinin sınıflandırma performansının karşılaştırılması. (Karen, 2014)

1.7. Sinir Ağları

Yapay sinir sistemi, insan beyninin boyut ve karmaşıklık açısından karşılaştırılabilir bir modelle taklit edilmesine yönelik güçlü bir ilgiyi beraberinde getirmektedir. Yapay sinir ağı (ANN) başlangıçta biyolojik sinir sistemi üzerindeki neokorteksi modellemekle ilgilenmiştir, ancak son zamanlarda ses tanıma, bilgisayar görüşü, robotik kontrol ve veri madenciliği gibi makine öğrenimi görevlerine uygulanmıştır. Derin sinir ağı (DNN) geliştirilmiş bir ANN modelidir ve verileri insan performansı kadar doğru tahmin edebilmektedir. DNN modeli, tipik ANN'dan daha fazla katmandan oluşur; böylece DNN, verilerdeki üst düzey soyutlamayı çıkarabilir (Wang, 2014). CNN, görüntü özelliklerini çıkarmak için konvolüsyon işlemlerini kullanan bir DNN türüdür. CNN 1990'ların başında tanıtıldığından beri (LeCun, 1989), ImageNet (Deng, 2009) ölçütünde etkileyici görüntü tanıma göstermiştir. ResNet (Kaiming, 2015) 1000 farklı sınıf içeren ImageNet veritabanından 1,2 milyon yüksek çözünürlüklü görüntüyü %3,57 hata oranı ile sınıflandırmıştır.

Göz yoluyla bir nesneyi gördüğümüzde, gözümüzdeki ışık reseptörleri optik sinir yoluyla biyolojik akım gönderir. Beynimizdeki nöronlar bu biyolojik akımı işler ve gözün ne gördüğünü bize bildirir. Şekil 6'de üç giriş düğümünden oluşan ve ikili bir çıkış üreten en basit yapay nöron gösterilmektedir.

Bilgisayar, görsel sistemin insandan farklı temsillerine sahip olduğundan, görüntüyü piksellerle görüntü desenleri oluşturarak algılar. Şekil 6'de, üç görüntü pikseli (x_0 , x_1 ve x_2) sinaps akımı oluşturmak için benzersiz sinaps yollarından geçmektedir. Her sinaps yolu, giriş pikseli ile çarpımsal olarak etkileşime giren öğrenilebilir bir ağırlık (w_0 , w_1 ve w_2) içerir.



Şekil 5. Üç giriş düğümüne sahip yapay nöronun matematiksel modeli, x_0 , x_1 ve x_2 .

Gözümüz bir nesneye odaklandığında, etrafımızdaki diğer nesneleri otomatik olarak göz ardı eder. Muhtemelen öğrenilebilir ağırlıklar, ilgili görüntü modellerine yönelik sinaps akımlarını kontrol eder. Örneğin, negatif ağırlıklar ayarlanarak, ilgisiz görüntü desenlerini görmezden gelmek için inhibitör (negatif) sinaps akımları oluşturulur. Giriş düğümleri ilgili görüntü desenlerinden oluştuğunda, uyarıcı (pozitif) sinaps akımları üretilir. Modelin son aşamasında, nöron tüm sinaps akımlarını alır ve toplar. Toplanan değer belirli bir eşiği aşarsa, nöron tetiklenir. Yapay nöronun çıktısı matematiksel olarak şu şekilde ifade edilebilir:


$$y = f(\sum x_i w_i + b) \quad (1)$$

x_i girişi, w_i girişine karşılık gelen ağırlık, b bias ve f aktivasyon fonksiyonudur. Bias, aktivasyon fonksiyonundan önce toplanan sabit bir parametredir. Bias fikri, biasın sınıflandırıcı kümesinin veriye doğru bir şekilde uymasını sağlamasıdır (Ian Goodfellow, 2016). Örneğin, girişlerin tamamı sıfırsa, öğrenilebilir ağırlıklar değişse de nöronun bir çıkışı tetiklenemez. Bununla birlikte, çoğu tıbbi görüntü gri ölçekli olarak saklanır. Gri ölçekli bir görüntünün temsilinde, sıfır yoğunluğa sahip bir piksel siyah renge karşılık gelir. Bu nedenle, önyargı ekleyerek, tüm giriş pikselleri sıfır olsa bile nöron tetiklenebilir.

Yapay nöronlardan oluşan bir koleksiyon ANN'nın katmanlarını oluşturur. Bir önceki katmandaki nöronlar, sinaps yolları aracılığıyla bir sonraki katmandaki her bir nöronla tam bağlantılar kurar. Tipik bir ANN, nöronların boyutunun girdi özelliklerinin sayısı ile eşleştiği bir girdi katmanından oluşur ve farklı sınıfların puanlarını üretmek için kullanılan bir çıktı katmanına sahiptir. Özellik çıkarma işlemini gerçekleştirmek için giriş katmanı ile çıkış katmanı arasında bir veya iki gizli

katman kullanılır (Sun-Chong Wang, 2003). DNN'nin mimarisi, daha derin ve daha yoğun gizli katmanlarla entegre edilmesinden esinlenmiştir. DNN, ANN'ya kıyasla daha karmaşık sinaps yolları oluşturduğundan, öğrenilebilir ağırlıkların artan kapasitesi daha iyi öğrenme yetenekleri sağlar, böylece DNN daha yüksek seviye soyutlamada daha fazla özellik çıkarabilir. Şekil 6, iki giriş özelliği (x_0 ve x_1) alan ve gizli katmanda üç nöronun (h_0 , h_1 ve h_2) oluşan basit bir ANN'yı göstermektedir. Böyle bir 3 katmanlı ANN yapısı tek bir sınıf puanı (y) üretebilmektedir. Örneğin, akciğer kanserine yakalanma riski ailedeki akciğer kanseri geçmişine ve sigara içme geçmişine bağlı olabilir (Annette, 2013). Riski ANN aracılığıyla değerlendirmek için, 3 katmanlı ANN hasta geçmişlerini iki giriş özelliği olarak çıkarır ve akciğer kanserine yakalanma riski için skor çıktısı verir.


Giriş özelliklerini çıkarma yeteneği, nöronların katmanlar halinde organize edilmesi ve gizli katmanın giriş özelliklerini çıkarmak için kullanmasıdır. Şekil 6'da, gizli katman her iki girdi özelliğine ilişkin üç özellik çıkarmaktadır.



Şekil 6. İki nöronlu bir giriş katmanı, üç nöronlu bir gizli katman ve tek nöronlu bir çıkış katmanından oluşan 3 katmanlı bir yapay sinir ağı.

Çıkarılan özellikler, sinaps yollarının hiçbirinin birbiriyle ilişkili olmaması nedeniyle ilişkisizdir, ancak sinaps yolları iki giriş özelliğinden gizli katmandaki her nörona tam bağlantılar oluşturur, bu nedenle çıkarılan özellikler her iki giriş özelliğiyle ilişkilidir. Ardından, gizli katmandaki nöronlar çıkarılan özellikleri sinaps yolları aracılığıyla çıkış nöronuna iletir.

Çıkış katmanına ulaşmadan önce daha fazla aşama (gizli katmanlar) yayarak, böyle bir ANN yapısı DNN olarak ifade edilebilir. Deneysel olarak, ANN'ya kıyasla daha derin gizli katmanlar kullanan DNN, özellik çıkarımı için daha fazla temsil gücüne ve özellik öğrenimi için daha iyi genellemeye sahiptir (Ian Goodfellow, 2016). Şekil 7, her bir gizli katmanın derinliğinin ve genişliğinin artırılmasının, deney verilerinin toplandığı test doğruluğunu artırdığını göstermektedir.



Şekil 7 . Farklı katman sayılarında sınıflandırma performansı.

Daha derin gizli katmanlar sinaps yollarının sayısını statik olarak artırdığından, daha derin gizli katmanlar artan öğrenilebilir parametreler yoluyla daha fazla özellik çıkarır. Örneğin, Şekil 8'de gösterilen 3 katmanlı ANN, giriş özelliklerini çıkarmak için 4 nöron kullanır ve toplam 13 öğrenilebilir parametre için ek 4 önyargı parametresi ile 9 öğrenilebilir ağırlık parametresinden oluşan 9 sinaps yolu oluşturur. İki kat nöron boyutuna sahip iki gizli katman daha ekleyerek, yeni mimari orijinal 3 katmanlı ANN kıyasla 36 daha fazla sinaps yolu ve 12 daha fazla önyargı parametresi oluşturan 16 nöron içerir. Öğrenilebilir parametrelerin toplam sayısı yaklaşık 7 kat artmıştır. Dolayısıyla, gizli katmanların eklenmesi ve genişletilmesi öğrenilebilir parametrelerin sayısını önemli ölçüde artırdığı için DNN istatistiksel açıdan ANN'dan daha iyi performans göstermektedir. (Ian Goodfellow, 2016).



2. ÖNCEKİ ÇALIŞMALAR

Çin'den Lei Fan ve araştırmacı grubu (2017) CAD akciğer kanseri tespiti için derin öğrenme algoritmasını kullanmıştır. Bu makalede, akciğerlerin BT taramaları üzerinde görüntü işleme uygulanmamıştır. Görüntüler doğrudan iki konvolüsyonel katman, iki maksimum havuzlama katmanı, bir tam bağlı katman ve bir çıkış katmanından oluşan konvolüsyonel sinir ağına girdi olarak beslenmektedir. Doğrultulmuş doğrusal birim (ReLU), konvolüsyonel ve maksimum havuzlama katmanları arasında uygulanır. Sistem %67,7'lik bir genel doğruluk sağlamaktadır. Destek vektör makinelerinin aynı sayıda giriş örneğinde 3D evrimsel sinir ağından daha düşük sınıflandırma doğruluğuna sahip olduğu sonucuna varılmıştır.

Bijaya Kumar Hatuwal ve Himal Chand Thapa (2020) iyi huylu doku, adenokarsinom ve skuamöz hücreli karsinomu tanımlamak için üç gizli katman, bir giriş katmanı ve bir tam bağlı katmanın bulunduğu derin bir CNN modeli oluşturdu. Araştırmalarında 0,1'lik bir bırakma değeri ve maksimum havuzlama kullanılmıştır. “Adam” optimize edicisini kullanmışlar ve sonunda eğitimde %96,11 ve doğrulamada %97,2 doğruluk elde etmişlerdir.

Muayed AL-Huseiny ve arkadaşları (2021) BT görüntülerini kullanarak kötü huylu akciğer nodüllerini tespit etmek için transfer öğrenme tabanlı bir derin sinir ağı (DNN) kullanma yaklaşımını önermişlerdir. Görüntülerden ROI'yi (İlgi Bölgesi) bulmak için hızlı bir ön işleme tekniği uygulamışlardır. Bu çalışmada, GoogLeNet DNN kullanılmış ve veri kümeleri için modifiye edilmiştir. Sonuçta %94,38'lik bir doğruluk elde edilmiştir.

Agarwal (2021) çalışmalarında Alexnet CNN kullanan bir akciğer kanseri tespit sistemini tanımlamıştır. Bu çalışma, konvolüsyon sinir ağı ve AlexNet tabanlı bir model yardımıyla sadece kötü huylu ve iyi huylu akciğer tümörleri arasında ayırım yapmıştır. AlexNet'in 25 katmandan (227x227x3 ölçeğinde) oluştuğu belirtilmelidir. SGDM optimizasyon modeli ve 0.0003 başlangıç öğrenme oranı kullanılmıştır. Kodu çalıştırmak için MATLAB 2021a yazılımı kullanılmış ve önerilen yöntem sonunda %96 doğruluk elde edilmiştir.

Ying Su ve arkadaşları (2021) çalışmalarında daha hızlı R-CNN kullanarak akciğer nodüllerini tespit etmek için bir yaklaşım önermişlerdir. LIDC-IDRI veri kümesi üzerinde deneyler yapmışlardır. Öğrenme oranı olarak 0.001 ve adım boyutu olarak 70000 kullanmışlardır. Zayıflama katsayısı, bırakma oranı ve yığın boyutu sırasıyla 0,1, 0,5 ve 64 idi. Araştırmacılar optimize edilmiş ve geliştirilmiş Faster R-CNN yöntemi ile %91,2 doğruluk elde etmişlerdir.

Mehedi Masud ve arkadaşları (2021) çalışmalarında, histopatolojik görüntülerini analiz ederek 5 farklı kolon ve akciğer dokusu türü arasında ayırım yapan bir sınıflandırma çerçevesi önermiştir. Bu 5 sınıfın 2'si iyi huylu, 3'ü ise kötü huyludur. Veri kümesine toplam 25000 resim dahil edilmiştir. Yazarlar, görüntülerden özellik çıkarımı için DFT ve DWT tekniklerini kullanmışlardır. Daha sonra kanser dokularını %96,33 doğrulukla tanımlamak için CNN tabanlı bir teknik kullanmışlardır. Satvik Garg ve arkadaşları, önceden eğitilmiş çeşitli CNN modellerinin sonuçlarını gösteren başka bir araştırma yürütmüştür.

M. Saric (2019) çalışmalarında, iki CNN mimarisi - ResNet ve VGG16 kullanarak akciğer dokularının WSI'sında (Tüm Slayt Görüntüleri) akciğer malignitelerini tespit etmek için otomatik bir sistem önerdi. Hedef, görüntü yamalarını normal ve tümör hücreleri olarak tanımlamaktır. Yazarlar optimize edici olarak SGD kullanmışlardır. Kayıp fonksiyonu olarak ikili çapraz entropi atanmış ve 0.0001'lik bir öğrenme oranı seçilmiştir. Sonuç olarak, VGG16'nın (%75,41) yama seviyesi doğruluğu açısından ResNet'ten (%72,05) daha iyi performans gösterdiği gözlemlenmiştir.

Albert Chon ve arkadaşları (2017) çalışmalarında, akciğer kanseri tespiti için Googlenet tabanlı bir 3D CNN modeli sunmuştur. Veri kümesi, yazarların 1261,420 ve 420 eğitim, doğrulama ve test kümesi boyutlarına böldüğü 2101 hasta için etiketli veriler içeriyordu. Eğitim sırasında her konvolüsyon ve başlangıç katmanından sonra 0,3 olasılıkla bir bırakma kullanılmıştır. Yazarlar 0.0001 öğrenme oranına sahip “Adam” optimize edicisini kullanmışlardır. Önerilen modelin 0,757 AUC puanı ile %75,1 doğruluk elde ettiği görülmüştür.

Hiba Mzough ve arkadaşları (2020) tüm hacimsel T1-Gado manyetik rezonans (MR) sekansları ile düşük dereceli glioma (LGG) ve yüksek dereceli glioma (HGG) olarak glioma beyin tümörü sınıflandırması için etkili ve tam otomatik bir derin çok ölçekli üç boyutlu sinir ağı (3D CNN) modeli sunmuşlardır. Geliştirdikleri model, hem yerel hem de küresel bağlamsal bilgileri azaltılmış ağırlıklarla birleştirme potansiyeline sahiptir. Heterojenliği kontrol etmek için yoğunluk normalizasyonuna ve MRG verilerinin uyarlanabilir kontrast geliştirmesine dayalı bir ön işleme tekniği önermişlerdir. Ayrıca, böyle bir derin 3D ağı başarılı bir şekilde eğitmek için bir veri artırma tekniği kullanmışlardır. Çalışmalarında, önerilen ön işleme ve veri artırımının sınıflandırma doğruluğu üzerindeki etkisini incelemişlerdir. İyi bilinen kıyaslama ölçütü (Brats, 2018) üzerinden yapılan nicel değerlendirmeler, önerdikleri mimarinin, 2D CNN varyantına kıyasla LG ve HG gliomları arasında ayırım yapmak için en özel özellik haritasını oluşturduğunu doğrulamaktadır. Önerdikleri model, diğer modellerden daha iyi performans gösteren iyi sonuçlar sunmaktadır. Son zamanlarda denetlenen ve denetlenmeyen son teknoloji model, doğrulama veri kümesini kullanarak %96,49'luk genel bir doğruluk elde etmiştir.

Abhishta Bhandari ve arkadaşları (2022) MR beyin görüntülerini kullanarak beyin tümörü segmentasyonu için otomatik bir segmentasyon modeli önermiştir. Nöronların (düğümmler olarak adlandırılır) ve sinapsların (bağlantılar) biyolojik süreci üzerine makine öğrenimi boru hattı yöntemleri olan konvolüsyonel sinir ağları (CNN'ler) gibi yaklaşımlar literatürde ilgi görmüştür. CNN'lerin beyin tümörlerini sınıflandırmadaki rolünü, ilk olarak CNN'lere eğitici bir bakış atarak ve sınıflandırma için örnek bir boru hattını düzenlemek için bir literatür araştırması yaparak araştırıyorlar. Ardından, yeni bir alan olan radyonik alanından geçerek CNN'leri kullanarak geleceği araştırıyorlar. Bu, tedaviye yanıt ve hayatta kalma gibi klinik sonuçları tahmin etmek için beyin tümörlerinin sinyal yoğunluğu şekli ve dokusu gibi nicel özelliklerini inceler. Linmin Pei beyin tümörü sınıflandırması ve yapısal çok modlu manyetik rezonans görüntülerine (mM- RI) dayalı genel sabitlik tahmini için bir derin öğrenme yöntemi önermiştir. İlk olarak, tümör sınıflandırması yapmak için radyoloji mMRI görüntü alt bölgelerindeki tümör alanı belirsizliğini dikkate alan 3B bağlam farkındalı bir derin öğrenme

önermişlerdir. Daha sonra, tümör alt tipine ulaşmak için tümör sınıflandırmasında düzenli bir 3B evrişimli sinir ağına (CNN) başvururlar. Derin öğrenme ve makine öğrenmesinin hibrit bir yöntemini kullanarak sağkalım tahmini gerçekleştiriyorlar. Önerilen yaklaşımları tümör segmentasyonu ve genel sağkalım tahmini için Multimodal Brain Tumor Segmentation Challenge 2019 (BraTS 2019) veri setine ve tümör sınıflandırması için Computational Precision Medicine database Radiology-Pathology (CPMRadPath) Challenge on Brain Tumor Classification 2019 veri setine uygulamışlardır. Modelin performans değerlendirmesi çok ünlü ölçütler olan MSE, doğruluk ve zar genel değerleri kullanılarak yapılmıştır. Önerilen modelin sonuçları sağlam bir segmentasyon sağlıyor ve sınıflandırma sonuçları test adımıda ikinci sırada yer alıyor.

Ahmet Çınar ve arkadaşları (2023 MR görüntülerini kullanarak beyin tümörü sınıflandırması için hibrit bir yöntem önermişlerdir. Resnet50 mimarisine dayalı CNN modelini kullanmışlardır. Resnet50 modelinin son katmanlarını çıkarmışlar ve sekiz katman eklemişlerdir. Modelleri mükemmel doğruluk elde etti. Sonuçlar GoogleNet, Alexnet, Resnet50, Densenet201 ve InceptionV3 modelleri ile elde edilmiştir. Mesut Tog̃ açar beyin tümörü sınıflandırması için “BrainMRNet” adında yeni bir konvolüsyon sinir ağı modeli önermektedir. Mimari, dikkat modülleri ve bir artık ağı ile hiperaktif bir sütun tekniği üzerine inşa edilmiştir - modelleri BrainMRNet'te ön işleme ile başlar. Daha sonra, her görüntü için artırma tekniklerine dayalı dikkat modeline aktarılır. Model, MR görüntüsünün önemli bir alanını seçerek bunu konvolüsyon sinir ağı katmanlarına aktarmıştır. Konvolüsyon katmanlarındaki temel tekniğe dayanan BrainMRNet modeli hiperaktif bir sütundur. Beyin modelinin her katmanından çıkarılan özellik, son katmanın yönteme dayalı dizi yapısı tarafından tutulur. Amaç, dizide tutulan özellikler arasından en büyük ve en verimli özellikleri seçmektir. BrainMRNet modeli ile elde edilen sınıflandırma başarısı %96,05'tir.

Fatih Özyurt ve arkadaşları (2021) nötrosofi birlikte evrim sinir ağı (NS-CNN) kullanarak hibrit bir modele dayalı bir çalışma sunmuşlardır. Amaç, beyin görüntülerinden tümör alanını iyi huylu ve kötü huylu olarak sınıflandırmaktır. İlk aşamada, MR görüntüleri neutrosophy set-expert maximum fuzzy-sure entropy (NS-EMFSE) yöntemi kullanılarak bölütlenmiştir. Sınıflandırma aşamasında bölütlenmiş beyin görüntülerini kullanarak destek vektör makinesi (SVM) ve k-en yakın komşular (KNN) sınıflandırıcılarını kullanarak CNN elde etmişler ve sınıflandırmışlardır. Modelin değerlendirmesi, 80 iyi huylu tümör ve 80 kötü huylu tümör üzerinde 5 katlı çapraz doğrulamaya dayanmaktadır. Modelin sonucu, CNN özelliklerinin farklı sınıflandırıcılarla mükemmel bir performans sergilediğini göstermektedir. Javaria Amina ve diğerleri beyin tümörü sınıflandırması için konvolüsyonel sinir ağı kullanarak MRI dizilerinin DWT füzyonuna dayalı bir model oluşturmuştur. Çalışma, dört MRG dizisinin yapısal ve doku bilgileri (T1C, T1, FLAIR ve T2) arasında bir hibrit önerdi. Ayrık dalgacık dönüşümünün (DWT) Daubechies dalgacık çekirdeği ile birleştirilmesi, tek bir MRG dizisine kıyasla daha bilgilendirici bir tümör alanı veren füzyon işlemi için kullanılır. Ardından, gürültüyü gidermek için kısmi difüzyon filtresi (PDDF) uygulamışlardır. Tümörlü veya tümörsüz alanları sınıflandırmak için önerilen model konvolüsyonel sinir ağını (CNN) beslemek için bir eşikleme yöntemi kullandılar.

Pim Moeskops ve arkadaşları (2022) bir konvolüsyon sinir ağı kullanarak MR beyin görüntülerinin sınıflandırılması için otomatik bir model önermişlerdir. Her bir vokselle ilgili çok ölçekli bilgi elde etmek için çoklu yama boyutları ve çoklu konvolüsyon çekirdek boyutları kullanmışlardır. Yaklaşım açık özelliklere bağlı değildir, ancak eğitim verilerini kullanarak sınıflandırma için önemli bilgileri tanımayı öğrenir. Yaklaşım, aksiyal T1 ağırlıklı ve T2 ağırlıklı görüntüleri içeren beş farklı veri kümesi kullanarak modeli doğrulamak için yalnızca tek bir anatomik MR görüntüsü istemektedir. Model, her veri seti için ortalama zar katsayısı genel bölütlenmiş doku sınıfları kullanılarak değerlendirilmiştir. Jamshid Sourati ve diğerleri ilk kez CNN'ler için Fisher bilgisine (FI) dayalı yeni bir aktif öğrenme yöntemi önermiştir. Gradyanları hesaplamak için verimli geri yayılım yaklaşımı ve yeni bir düşük boyutlu FI yaklaşımı, çok sayıda parametreye sahip CNN'ler için FI hesaplamamızı sağladı. Beyin çıkarımı için önerilen yaklaşımı, evrensel aktif öğrenme ve aktif yarı otomatik segmentasyon olmak üzere iki farklı öğrenme türünde yama bazlı segmentasyon CNN modeli ile değerlendirmişlerdir. İki senaryoda, bir veri setinin etiketlenmiş eğitim konularına dayalı bir başlangıç modeli elde edildi. Amaç, hedef denek(ler)i etkin bir şekilde gerçekleştiren bir model oluşturmak için yeni örneklerin küçük bir alt kümesini parlatmaktır.

Benjamin Thyreau ve arkadaşları (2019) MR beyin görüntüleri için konvolüsyonel sinir ağları (ConvNets) kullanarak bir kortikal parselasyon yaklaşımı geliştirmiştir. Yüzey analizlerinden elde edilen bilgiyi otomatik olarak daha basit hacim verileri üzerinde hemen uygulanabilir bir şeye aktaran bir makine öğrenimi yaklaşımı. Bir ConvNets modelini, yüzey yaklaşımından elde edilen parselasyonu yinelemek için çift MRI kohortlarının kortikal şeritlerinden oluşan büyük bir veri seti üzerinde eğitiyorlar. Modeli daha geniş bir bağlamda uygulanabilir hale getirmek için görünmeyen segmentasyonlara genelleştirmeye zorladılar. Model, görünmeyen kohortların görünmeyen verileri üzerinde tahmin edilmiştir. Yaklaşımın öğrenme sırasındaki davranışını tanımladılar. Büyük bir eğitim veritabanı, büyütme ve çift kontrast gereksinimi için destek sağlamaya başvuran veritabanının kendisine olan güvenini ölçtüler. Genel olarak, ConvNets yaklaşımı MR görüntülerini hızlı ve doğru bir şekilde bölütlemek için etkili bir yöntem sağlar.

Jude Hemanth ve arkadaşları (2021) modifiye edilmiş derin konvolüsyon sinir ağı (DCNN) kullanarak anormal bir tümörü sınıflandırmak için bir model önermiştir. Onların bakış açısı, geleneksel DCNN'nin hesaplama karmaşıklığını azaltmayı hedeflemektedir. Parametre değişikliklerinin sayısını azaltmak için eğitim modelinde olumlu değişiklikler mükemmeldir. Tam bağlı katmandaki ağırlık değiştirme işlemi, önerilen değiştirilmiş yöntemde tamamen atılmıştır. Durum içinde, bu tam bağlı katmanın ağırlıklarını keşfetmek için basit bir görev süreci kullanılır. Böylece, önerilen yöntemde hesaplama karmaşıklığı güvenli bir şekilde en aza indirilmiştir. Değiştirilmiş DCNN, manyetik rezonans beyin görüntülerini keşfetmek için kullanılmıştır. Modelin performansı mükemmel doğruluk göstermiştir.

XinyuZhou ve diğerleri (2019) beyin tümörü segmentasyonu için daha az GPU bellek tüketimi ve hesaplama karmaşıklığına sahip verimli 3D artık sinir ağı (ERV-Net) kullanan bir model önermiştir. ERV-Net'in hesaplamada verimli olduğu düşünüldüğünde. İlk olarak, kullanılan ShuffleNetV2, ERV-


Net'in verimliliğini geliştirmek ve GPU belleğini azaltmak için bir kodlayıcıdır, daha sonra bozulmayı önlemek için kod çözücü artık bloklarla (Res-kod çözücü) girerler. Ağ yakınsaması ve veri dengesizliği sorunlarını çözmek için, zar kaybı ve çapraz entropi kaybından oluşan bir füzyon kaybı fonksiyonu geliştirdiler. Daha sonra, ERV-Net'in kaba segmentasyon çıktısını iyileştirmek için özlü ve sağlam bir ön-son yaklaşım önerdiler. Modellerini değerlendirmek için çok modlu beyin tümörü segmentasyon yarışması 2018'in (BRATS 2018) veri setini kullandılar ve ERV-Net'in tümörleri geliştirmek için %81,8, 91,21 ve 86,62 zar ve 2,70, 3,88 ve 6,79 mm Hausdorff mesafeleri ile en iyi performansı elde ettiğini gösterdiler.

Muhammad Attique Khan ve arkadaşları (2022) beyin tümörü sınıflandırması için derin öğrenme tabanlı otomatik bir çoklu model sınıflandırma yaklaşımı önermiştir. Amaçladıkları model beş aşamadan oluşmaktadır. İlk olarak, kenar histogramı eşitleme ve ayrık kosinüs dönüşümüne (DCT) dayalı doğrusal kontrast gerdirmeyi kullanmışlardır. İkinci olarak, derin öğrenme özellik çıkarımı gerçekleştirmişlerdir. Transfer öğrenimi kullanarak, özellik çıkarımı için VGG16 ve VGG19 olmak üzere önceden eğitilmiş iki konvolüsyonel sinir ağı (CNN) modeli kullanılmıştır. Üçüncü olarak, en iyi seçilen özellikler için aşırı öğrenme makinesi (ELM) ile korentropi tabanlı bir ortak öğrenme yöntemi uyguladılar. Dördüncü olarak, sağlam kovaryant özellikleri sınıflandırma için kısmi en küçük kareye (PLS) dayalı tek bir matriste birleştirdiler ve birleştirilmiş matris ELM'ye beslendi. Önerilen model BRATS veritabanı kullanılarak doğrulanmış ve %97,8'lik en iyi doğruluğa ulaşılmıştır. Bu çalışma mevcut yaklaşım tarafından motive edilmiştir. Bu yaklaşımda, beyin tümörü sınıflandırması için derin öğrenme kullanan çok modlu sınıflandırma kullanılmıştır. Bu çalışmada önerilen yöntem, beyin tümörü sınıflandırması için bir diferansiyel derin sinir ağı kullanmıştır.



3. MATERYAL VE METOT

Python yazılım dili hem görsel işleme hem de makine öğrenimi uygulamaları için zengin kütüphanelere sahiptir. Bu araştırmada Python dili için Colab yazılım geliştirme platformu kullanılmıştır. Şekil 9'de önerilen tasarıma ait iş akış şeması gösterilmektedir.



Şekil 8. İş akış diyagramı

3.1. Çalışmada kullanılan kütüphaneler

Akciğer kanseri tespiti için işlemleri gerçekleştirebilmek için hazırlanan yazılımda Python programlama dilindeki Opencv, Numpy, Glob, Scikit-learn, Matplotlib, Pytorch, kütüphaneleri kullanılmıştır.

3.1.1. Pytorch

Pytorch, sinir ağlarını basit bir şekilde oluşturmanın ve verimli bir şekilde eğitmenin bir yolunu sunar, bu da Pytorch'un araştırmalarda kullanılan en popüler çerçeve haline gelmesine yol açmıştır. Sektördeki kullanıcı tabanı da popülerliğini artırmaya devam ediyor.

Pytorch'un temel yapı taşı, bir dizi veya matris gibi olan tensördür. Bu tensörler, modellerin girdi ve çıktıların yanı sıra parametrelerini de kodlar. Pytorch, modelleri hızlı bir şekilde prototiplemek için sinir ağlarını tanımlamak için birçok kullanışlı yapı taşı sağlar. Eğitim süreci, otomatik farklılaştırma için C'de uygulanan ve yürütmeyi hızlı hale getiren autograd kütüphanesini kullanır.

3.1.2. OpenCV

OpenCV (Open Source Computer Vision Library) açık kaynak kodlu bir bilgisayarla görme ve makine öğrenimi yazılım kütüphanesidir. OpenCV, bilgisayarla görme uygulamaları için ortak bir altyapı sağlamak ve ticari ürünlerde makine algısının kullanımını hızlandırmak için inşa edilmiştir. Apache 2 lisanslı bir ürün olan OpenCV, işletmelerin kodu kullanmasını ve değiştirmesini kolaylaştırır.

3.1.3. NumPy

NumPy, Python'da bilimsel hesaplama için temel pakettir. Çok boyutlu bir dizi nesnesi, çeşitli türetilmiş nesneler (maskelenmiş diziler ve matrisler gibi) ve matematiksel, mantıksal, şekil manipülasyonu, sıralama, seçme, ayırık Fourier dönüşümleri, temel doğrusal cebir, temel istatistiksel işlemler, rastgele simülasyon ve çok daha fazlası dahil olmak üzere diziler üzerinde hızlı işlemler için çeşitli rutinler sağlayan bir Python kütüphanesidir.

3.1.4. Glob

glob modülü sıklıkla OS modülü ile birlikte dosya okuma ve yazma, dizin oluşturma ve kaldırma gibi dosya ile ilgili görevleri yerine getirmek için kullanılır. Çok büyük hacimli verilerle çalışırken veya kalıplara dayalı karmaşık dosya işlemleri gerçekleştirirken glob modülü kullanışlı olur.

Dosya adlarını kalıplarla eşleştirmenin yanı sıra, bu modül dosya yollarını filtrelemek ve değiştirmek için bir dizi yararlı işlev içerir. Örneğin, glob.glob fonksiyonu belirli bir kalıpla eşleşen tüm dosyaların bir listesini döndürürken, glob.iglob fonksiyonu eşleşen dosyalar üzerinde bellek açısından daha verimli bir yöntemle yineleme yapar.

3.1.5. Scikit-learn

Scikit-learn, çapraz doğrulama yöntemiyle beğeni toplamaktadır. Yukarı yönde, eğitim ve test veritabanlarını çok basit bir şekilde oluşturma imkanı sağlar. Ardından, bir ızgara arama mekanizması aracılığıyla çapraz doğrulama, beklenen tahminlere en yakın model parametrelerini bulmayı mümkün kılar. Süreç, test tabanının örnekleme ardışık iterasyonlarla öğrenme tabanı ile karşılaştırarak ayarlar (aşağıdaki şemaya bakın). Amaç, eşikler açısından doğru ayarı elde etmektir, örneğin dolandırıcılık tespiti açısından %2'yi aşmamak.

Scikit-learn'in bir diğer güçlü noktası olan kütüphane, öğrenme aşamalarından önce veri setlerinin ön işlemlerini kontrol etmek için bir dizi yöntem içerir. Bunların çıkarılması, temizlenmesi, biçimlendirilmesi ve etiketlenmesini yönetir. Ancak Pandas ile sınırlı bir entegrasyon sunuyor. Bu hassas hazırlık aşamasında, Scikit-learn'in yerel olarak yaptığı gibi verilerin matrisler yerine tablolar şeklinde işlenmesine izin veren bir kütüphane.

3.1.6. Matplotlib

Python'daki Matplotlib, veri görselleştirme için en popüler ve güçlü kütüphanelerden biridir. Verileri oldukça iyi bir şekilde çizebilen çeşitli önceden oluşturulmuş işlevler sunar. Dağılım grafiği, Çubuk grafik, Pasta grafiği, XY grafiği, yığılmış grafik, 3B grafik ve diğerleri gibi çok çeşitli çizim seçenekleri sunar. Ayrı olarak yüklenmesi gereken üçüncü taraf bir kütüphanedir. Matplotlib doğrusal ve doğrusal olmayan çizim için kullanılabilir ve desteklerini 2D'nin ötesine genişletir.

3.2. Değerlendirme Metrikleri

Önerilen modelin verimliliğini değerlendirmek için, karşılaştırma amacıyla, klasik ve modern olanlar arasında dört makine öğrenimi yöntemi modelinden yararlandık. Önerilen diferansiyel CNN modeli ile diğer modeller arasındaki Sınıflandırma performansını değerlendirmek için dört farklı performans ölçütü kullanılmıştır; doğruluk, kesinlik, geri çağırma ve F1-scoru. Doğruluk, bir veri kümesindeki tüm örnekler arasında doğru sınıflandırılan örneklerin oranıdır. Doğruluk değeri (14)'de görülebilir; burada t doğru sınıflandırılmış örnek sayısı ve n veri kümesindeki örnek sayısıdır.

$$Acc = \frac{t}{n} \quad (14)$$

Kesinlik, bir sınıftaki tüm örnekler arasında doğru sınıflandırılan örneklerin oranıdır. C sınıfının hassasiyet değeri, P_c , şöyle olabilir (15)'te görülen n_c , c sınıfındaki örneklerin toplam sayısı ve t_c , c sınıfındaki doğru sınıflandırılmış örneklerin sayısıdır.

$$P_c = \frac{t_c}{n_c} \quad (15)$$

Geri çağırma, ilgili sınıfta sınıflandırılan tüm örnekler arasında doğru sınıflandırılan örneklerin oranıdır. Geri çağırma değeri k_c , c sınıfına ait olarak sınıflandırılan örneklerin toplam sayısı ve t_c , c sınıfta doğru sınıflandırılan örneklerin sayısı olmak üzere (16)'te gösterilmiştir.

$$R_c = \frac{t_c}{k_c} \quad (16)$$

F1-scoru, kesinlik ve geri çağırma ölçütlerinin bir kombinasyonudur. C sınıfının F1-scoru (17)'te gösterilmiştir; burada P_c c sınıfının kesinliği ve R_c c sınıfının geri çağırmasıdır.

$$F_c = \frac{2*(P_c*R_c)}{P_c+R_c} \quad (17)$$

Bir sınıflandırma deneyinin hassasiyet, geri çağırma ve F1-scor değerleri, veri kümesindeki tüm sınıflar için tüm hassasiyet, geri çağırma ve F1-scor değerlerinin ortalaması alınarak hesaplanır.

Precision, recall ve F1-score, farklı sınıflar için farklı sayıda örnek içeren veri kümeleri için daha doğru değerler verebilir. Bu nedenle ilk deney setinde bu dört farklı performans ölçütü için değerler verilmiştir.

3.3. LIDC-IDRI veri seti

LIDC-IDRI (Lung Image Database Consortium - Image Database Resource Initiative) veri seti (Armato, 2011), akciğer kanserinin teşhisi ve taranması için etiketlenmiş malignitelerle birlikte göğüs


bilgisayarlı tomografi görüntülerinden oluşmaktadır. Bu bir açık Bilgisayar destekli akciğer kanseri teşhis tekniklerinin geliştirilmesi, eğitimi ve değerlendirilmesi için kamu-özel sektör işbirliğiyle oluşturulan uluslararası kaynak Ulusal Kanser Enstitüsü, Ulusal Sağlık Enstitüleri Vakfı ve ABD Gıda ve İlaç İdaresi tarafından kurulan bir kamu-özel sektör ortaklığı.

Yedi akademik merkez ve sekiz tıbbi görüntüleme şirketi, 1.018 bilgisayarlı tomografi çalışması içeren bu veri setini oluşturmak için işbirliği yapmıştır. Her bir çalışma aşağıdaki bölgelerin bilgisayarlı tomografi görüntülerini içermektedir ve iki aşamalı görüntü açıklama sürecinin sonuçlarını kaydeden bağlantılı bir XML dosyası, dört deneyimli torasik radyolog tarafından gerçekleştirilmiştir. İlk kör inceleme aşamasında, her radyolog bağımsız olarak her bir BT taramasını bağımsız olarak incelemiş ve üç kategoriden birine ait nodul işaretlemiştir:

1. “düğümler ≥ 3 mm”,
2. “düğümler < 3 mm”,
3. “ ≥ 3 mm düğüm yok”.

Daha sonraki kör inceleme aşamasında, her radyolog bağımsız olarak kendi sonuçlarını diğer üç radyologun anonimleştirilmiş sonuçlarıyla birlikte gözden geçirerek son kararı vermiştir. Bu sürecin amacı, radyologlar arasında zorunlu bir fikir birliği gerektirmeden her BT görüntüsündeki tüm maligniteleri mümkün olduğunca doğru bir şekilde tanımlamaktır.

Bu nedenle, LIDC-IDRI veri kümesindeki her BT incelemesi, birkaç radyologdan gelen malignitelerin bir işaretlemesine sahiptir. Derin öğrenme modellerini eğitmek ve test etmek için veri elde etmek amacıyla, tüm işaretlemelerin %50 konsensüsünü hesaplayarak elde edilebilecek yalnızca bir işaretlemenin kullanılması gerekir. (Armato, 2011) Bir kesit BT incelemesinde birden fazla radyolog tarafından işaretlenen bir malign tümör örneği ve %50 fikir birliği Şekil 11'da gösterilmektedir.



Şekil 9. LIDC-IDRI veri setinden bir BT görüntüsü üzerinde neoplazm etiketleme örneği

3.4. Evrişimsel Sinir Ağı

Derin yapıların güçlü temsil kabiliyetine sahip Evrişimli Sinir Ağları(CNN), birçok araştırma alanında giderek artan bir popüleriteye sahiptir. Evrişimsel Sinir Ağlarının mevcut benzer yapay sinir ağlarına göre temel farkı, evrişimsel kısmın dahil edilmesidir. Bu ekleme, yapay sinir ağlarının performansını doğrudan artırmaktadır. Bu gerçek, birçok farklı evrişimsel model ve tekniğin geliştirilmesine yol açmıştır. Lecun tarafından önerilen konvolüsyonel Sinir Ağları (Lecun vd., 1998) patern tanıma alanında en başarılı yöntemlerden biri haline gelmiştir. Bu yapılarda, giriş görüntüsü üzerinden görsel özelliklerin çıkarılması için yerel olarak eğitilmiş filtreler kullanılır. Havuzlama ile boyutu küçültülen özellik haritaları işlemi bir sonraki konvolüsyonun giriş görüntüleridir. Bu işlem derin özellikler çıkarılana kadar devam eder. Bu adımlardan sonra, genellikle bir sınıflandırıcı tarafından bu özellikler üzerinde bir karar verilir (Ravi vd., 2017). Derin konvolüsyonel sinir ağı genel olarak konvolüsyonel katmanlar, havuzlama katmanları ve tam bağlantılı bir ağ içeren bir yapıya işaret eder (Nielsen, 2015). Bu yapıda, konvolüsyon işlemleri özellik çıkarımı için kullanılırken, tam bağlı ağ bu özellikler üzerinde bir sınıflandırıcıdır. Tam bağlantılı kısım, sınıflandırma amacıyla bir SoftMax çıktı katmanı ile sonuçlanabilir. Bu katmanlarla oluşturulan AlexNex, OverFeat, GoogLeNet gibi birçok popüler ağ yapısı vardır. Bu yapıları eğitirken karşılaşılan en büyük sorunlardan biri aşırı uyumdur. Aşırı uyumu önlemek için geliştirilen bazı teknikler veri artırımı, DropOut ve DropConnect'tir.

ConvNet, görüntünün yerel uzamsal bölgesi içindeki özellikleri çıkarmak için konvolüsyon işlemini kullanan özel bir CNN türüdür. Gizli katmanlar arasında tam bağlantılar kurmak yerine, ConvNet gizli nöronları yerel bilgileri “görmeye” ve bunları üst düzey özellik oluşturmak için birleştirmeye zorlar. Farklı özellikler genellikle çeşitli yerel bölgelerde ortaya çıkar çünkü komşu pikseller uzaktaki piksellerden daha ilişkilidir. Bu nedenle ConvNet, görüntü sınıflandırmada muazzam bir başarı elde etmek için bir yerel özellik dedektörleri koleksiyonu kullanır. ConvNet, giriş görüntülerini piksel değerlerinden sınıf puanlarına dönüştürmek için bir dizi katman oluşturur. Genel ConvNet dört farklı katman türüne sahiptir: konvolüsyonel katman, aktivasyon katmanı, havuzlama katmanı ve tam bağlantılı katman.

3.4.1. Konvolüsyonel Katman


Konvolüsyon katmanı, karmaşık fonksiyonların giriş görüntüsüne uygulanmasına izin veren bir dizi sabit boyutlu filtreye sahip bir yapıdır (Ravi vd., 2017). Bu işlem, yerel olarak eğitilmiş filtrelerin görüntü üzerinde kaydırılmasıyla gerçekleştirilir. Bu işlem sırasında her filtre görüntü boyunca aynı ağırlık ve yanlılık değerlerine sahiptir. Buna ağırlık paylaşım mekanizması denir ve bu mekanizma tüm görüntü üzerinde aynı özelliği temsil etme yeteneği sağlar (Chandrakumar ve Kathirvel, 2016; Ravi vd., 2017; Sankar vd., 2016). Bir nöronun yerel alıcı alanı, nöronun bir önceki katmanda bağlı olduğu alanı temsil eder. Alıcı alanın boyutu filtrelerin boyutuna göre belirlenir. m ve n giriş görüntüsünün boyutu ve çekirdeğin boyutu olsun, i görüntüyü temsil etsin, w ve b sırasıyla

filtrenin ağırlık ve bias değerleridir. Çıktı $o_{o,o}$ Eşitlik (2)'deki gibi hesaplanabilir, burada f aktivasyon fonksiyonudur. Bu süreçte aktivasyon fonksiyonu olarak ReLu veya sigmoid kullanılabilir (Nielsen, 2015; Sankar vd., 2016). ReLu aktivasyon fonksiyonunun davranışı Eşitlik (3)'de de görülebilir.

$$o_{o,o} = f \quad (2)$$

$$F(x) = \begin{cases} x & x > 0 \\ 0 & \text{else} \end{cases} \quad (3)$$

Konvolüsyonel katman öğrenilebilir filtre kümelerini benimser. Her filtre, genişliği ve yüksekliği ile birlikte filtre boyutuna bağlı olarak, sabit ölçekli uzamsal alan içinde giriş hacminin tam derinliğini konvolize eder. ANN'lar gibi giriş hacmindeki tüm nöronlardan çıkış nöronuna tam bağlantı kurmak yerine, evrimsel katmanın bağlantısı giriş hacminin yerel bölgelerinde özellik çıkarımına ilham verir. Öte yandan, bir dizi filtre kümesi, her filtrenin çıkış derinliği nedeniyle belirli bir yerel bölgeden çıkarılan örtüşen özellikler üretir. Bu tür örtüşen özellikler, belirli yerel bölgenin çeşitli temsillerini sunar. Bu nedenle, evrişim katmanının çıktısı bir grup özellik haritası üretir ve her özellik haritası giriş hacminden farklı yerel bölgelere karşılık gelir. (Ravi vd., 2017)



Şekil 10. Kırpılmış görüntünün yerel bölgesindeki özellikleri çıkarmak için bir konvolüsyonel katman örneği. Konvolüsyonel katman, 2×2 boyutunda bir filtre ve bir çıktı özellik haritasından oluşur. (Nielsen, 2015; Sankar vd., 2016)

Şekil 12, konvolüsyon filtresini 3×3 boyutundaki uzamsal matris boyunca kaydırarak kırpılmış görüntü için bir konvolüsyon işlemini göstermektedir. Bir konvolüsyonel katman için, gizli nöronlar her bir özellik haritasında organize edilir. DNN bağlantı şemasının aksine (Şekil 12'de atıfta bulunulduğu gibi), konvolüsyonel katmandaki her gizli nöron, giriş özelliklerinin belirli bir yerel

bölgesine bağlantı kurar. Örneğin, Şekil 3.3'teki özellik haritası, özellik haritasının 2×2 matrisini oluşturmak için 4 gizli nörondan oluşur ve özellik haritasındaki her bir matris elemanı her bir gizli nöronun çıkışı temsil eder. 2×2 filtrenin çevrilmeden konvolüsyonlanmasıyla, giriş özelliklerinin vurgu alanı, özellik haritasında -55'e eşit olan benzersiz bir özelliğe çıkarılır. Dolayısıyla, 2×2 boyutundaki giriş özelliklerinin yerel bir bölgesi, özellik haritasında bir özelliğe karşılık gelir. Genel olarak, her bir gizli nöronun çıkışı Denklem 3 olarak ifade edilebilir. (Ravi vd., 2017)

Özellik haritasının i satır ve j sütunundaki y özelliğini çıkarmak için, $m \times n$ boyutundaki w filtresinin ağırlıkları, i satır ve j sütunundan $(i + m)$ satır ve $(j + n)$ sütununa kadar giriş özellikleri x üzerinde nokta üretimi gerçekleştirirken, nokta çarpımının sonucu yanlılık terimi b 'yi ekler.

Konvolüsyonel katmanın özellik çıkarma şeması ANN'daki ileri beslemeli yayılımdan esinlenmiş olsa da (Denklem 2'de atıfta bulunulduğu gibi), öğrenilebilir parametreler önemli ölçüde azaltılır çünkü tek bir özellik haritası aynı filtrenin konvolüsyonuyla oluşturulur, böylece her gizli nöron aynı filtreden öğrenilebilir parametreleri paylaşır. Dolayısıyla, ConvNet'in öğrenilebilir parametreleri paylaşması nedeniyle aşırı uyum sağlama şansı daha azdır. Dahası, ConvNet parametrelerin paylaşımından faydalanır. Mümkün olduğunca çok özellik çıkarmak için daha yoğun bir gizli katmana güvenmek yerine, konvolüsyonel katman, bir dizi filtreyi (filtre kümeleri) istifleyerek yerel uzamsal bölge içindeki değişmez ilişkileri öğrenirken eğitilmiş modelin giriş gürültülerine uymasını önler. (Nielsen, 2015; Sankar vd., 2016)


3.4.2. Aktivasyon Katmanı

Konvolüsyonel katmanı genellikle bir aktivasyon katmanı takip eder. Aktivasyon katmanı, öğrenilen özellikleri çıkarmak yerine, eğitim aşamasında yakınsamayı hızlandırmak amacıyla ConvNets'e doğrusal olmayan özellikler eklemek için kullanılır. Büyük miktarda veri ve yüksek performanslı paralel hesaplama çözümleri, daha iyi sınıflandırma sonuçları elde etmek için ConvNets'i daha fazla evrimsel katman entegre etmeye teşvik etse de, uzun eğitim süresi hala önemli bir endişe kaynağıdır. Çoğu modern ConvNets mimarisi, benzer performansı korurken eğitim süresini azaltmak için aktivasyon katmanı kullanmıştır. Tipik aktivasyon katmanı sigmoid fonksiyonu, tanh fonksiyonu veya ReLU aracılığıyla doğrusal olmayan bir yapı üretir. (Sankar vd., 2016)

3.4.3. Havuzlama Katmanı

Havuzlama işlemi, konvolüsyon ve aktivasyon fonksiyonundan geçen özellik haritalarına uygulanır. Bu, giriş özellik haritalarının özeti olan daha küçük özellik haritalarının üretilmesini sağlar. Havuzlama işlemi bir pencere kaydırılarak gerçekleştirilir. Seçilen işlemi uygulamak için görüntü üzerinde. İyi bilinen havuzlama işlemleri maksimum, ortalama ve L2 havuzlamadır. Ortalama havuzlama giriş değerlerinin ortalamasını alırken, maksimum havuzlama maksimum değeri baştan sona geçirir ve L2 havuzlama ise girişlerin L2 normunu hesaplar (Nielsen, 2015). Havuzlama işleminin sağladığı en büyük avantajlar görüntü boyutunun küçültülmesi ve görsel özelliklerin görüntü üzerinde bağımsız olarak çıkarılmasıdır (Nielsen, 2015; Sankar vd., 2016).

Her bir özellik haritasının uzamsal boyutluluğunu azaltmak için ardışık evrimsel katmanlar arasına bir havuzlama katmanı eklemek yaygındır. ANN'da kullanılan tam bağlantı yapısı, yüksek çözünürlüklü girdi ölçeğini eşleştirmek için çok sayıda ağırlık parametresi gerektirir ve bu da genellikle aşırı uyuma yol açar. Ayrıca, evrimsel katman hala belirli gereksiz bilgiler üretme şansına sahiptir çünkü yerel bölge hala tam bağlantı kurmaktadır. Bu nedenle, havuzlama katmanı temel bilgileri korur ve aşırı uyum şansını azaltır. Genel havuzlama işlemleri, giriş değerlerini maksimum veya ortalama değerle değiştirerek maksimum havuzlama veya ortalama havuzlamadır.



Şekil 11. Maksimum havuzlama işlemine bir örnek. 2 adımlı 2×2 filtre 4 giriş alır ve maksimum değeri koruyarak aşağı örnekleme gerçekleştirir. (Nielsen, 2015)

Şekil 13'de, giriş özellik haritasını aşağı örnekleyen bir maksimum havuzlama katmanını göstermektedir. 4×4 boyutundaki özellik haritası, 2×2 boyutunda ve 2 adımlı havuzlama filtresi içinde maksimum değer tutularak havuzlanır. Komşu özelliklerin maksimum değerini tutarak, ConvNet'in ileri besleme yolu daha az fazlalığa sahip olur ve maksimum aktivasyona sahip yol da korunur. (Nielsen, 2015)

3.4.4. Tam Bağlantılı Katman

Konvolüsyon ve havuzlama katmanlarından sonra veriler tek boyutlu bir vektöre dönüştürülür. Bu vektör tam bağlı ağırlık girdisi olacaktır. Tam bağlantılı yapı bir veya daha fazla gizli katman içerebilir. Her nöron, bağlantı ağırlıklarını bir önceki katmandan gelen verilerle çarpar ve bir yanlılık değeri ekler. Hesaplanan değer bir sonraki katmana iletilmeden önce aktivasyon fonksiyonundan geçer. Bu katmandaki bir nöron tarafından yapılan hesaplamalar Eşitlik (4)'te görülebilir. (Nielsen, 2015)

$$f c_1 = f(b + \sum_{q=1}^m w_{1,q} * o_q) \quad (4)$$

Burada f aktivasyon fonksiyonu, w ağırlık vektörü, o q . nöronun giriş vektörü ve b ise bias değeridir.

Tam bağlantılı katman, önceki havuzlama katmanına tam bağlantılar kurar. Tam bağlantılı katman, sınıflandırma yapan ANN ile benzer bir yapıya sahiptir. Son tam bağlantılı katmandan sonra, SoftMax fonksiyonu aracılığıyla çıktı vektörlerini normalleştirmek yaygındır. SoftMax şu şekilde tanımlanabilir:

$$y_i \frac{e^{y_i}}{\sum e^{y_i}} \quad (5)$$

Burada SoftMax fonksiyonu i nöronundaki çıktı vektörünü üstel bir fonksiyon aracılığıyla sıfır ile bir arasında bir değere bastırır. Daha sonra, i nöronundaki bastırılmış çıktı vektörünü katmandaki tüm bastırılmış çıktı vektörlerinin toplamına bölerek, i nöronundaki normalleştirilmiş çıktı vektörü oluşturulur ve y olarak adlandırılır. Normalleştirilmiş çıktı vektörü, tüm olası kategoriler arasındaki olasılık dağılımını temsil eder. (Nielsen, 2015)

3.4.5. Evrimsel Sinir Ağının Eğitimi

ConvNet'in eğitimi, konvolüsyonel katmanlar ve tam bağlantılı katmanlardaki öğrenilebilir parametrelerin optimize edilmesine karşılık gelir, böylece eğitilen model eğitim verilerine uyar. ConvNet'in çıktısı SoftMax fonksiyonu aracılığıyla sınıfların olasılıksal dağılımını ürettiğinden, belirli bir sınıfa ait olan girdi özellikleri, iyi eğitilmiş modeli ileri beslemeli olarak yayarak büyük olasılıkla en yüksek olasılığa sahiptir. ConvNet'in standart bir optimizasyon yöntemi, kayıp fonksiyonunun kayıplarını en aza indirmektir.

3.5. Softmax

Softmax aktivasyon fonksiyonu, lojistik regresyonun çok sınıflı uyarlanmış bir versiyonudur. Genellikle sınıflandırma amacıyla çıktı katmanında kullanılır. Eşitlik (6)'teki gibi tanımlanır (Nielsen, 2015).

$$class_j = \frac{\exp(sf_j)}{\sum_q \exp(sf_q)} \quad (6)$$


3.5.1. Veri artırımı

Veri artırımı, yapay olarak örnek sayısının artırılmasıdır. Bu işlem, sinir ağı eğitiminde aşırı uyum durumunu önlemek için gerçekleştirilir. Görüntünün boyutunun, yönünün, aydınlatma koşulunun değiştirilmesi veri artırımına örnek işlemlerdir. Yapay olarak üretilen bu veriler de eğitim veri kümesine dahil edilir. Bu da daha genel özellik çıkarma kabiliyetine yol açar (Krizhevsky vd., 2012).

3.5.2. DropOut

DropOut ezberlemeden kaçınmak için kullanılan tekniklerden biridir. Bu yöntemde, ağdaki rastgele seçilen bazı nöronların aktivasyonu eğitim sırasında sıfır olarak alınır. Seçilen nöronlar

eğitimin her iterasyonunda değiştirilir. Bu yöntemle öğrenme süreci daha güvenilir hale gelir ve aşırı uyum azaltılır (Srivastava, Hinton, Krizhevsky, Sutskever ve Salakhutdinov, 2014).



Şekil 12. Dropout Tekniği

3.5.3. DropConnect

DropConnect, DropOut'a benzer bir teknik olup aşırı uyumu önlemek için geliştirilmiştir. DropOut tekniğinde seçilen nöronların aktivasyonları sıfır olarak alınırken, DropConnect tekniğinde rastgele seçilen ağırlık değerleri sıfır olarak ayarlanır. Bu işlem ağıın genelleme performansını artırmakta ve ezberlemeyi önlemektedir (Wan, Zeiler, Zhang, Le Cun, & Fergus, 2013).

3.6. Diferansiyel Konvolüsyonel Sinir Ağı

Bu bölümde, önerilen Diferansiyel Konvolüsyon tekniğinin arkasındaki fikir, uygulama ve eğitim algoritmasının detayları verilmiştir. Diferansiyel konvolüsyon tekniğini kullanan CNN yapıları Diferansiyel CNN'ler olarak adlandırılır. Bir nöronun ve komşularının aktivasyonları arasındaki değişiklikleri dikkate alırlar ve güncellenmiş geri yayılım algoritması uygularlar. Önerilen teknik bir tak ve çalıştır modülü olarak düşünülebileceğinden, tüm konvolüsyonel yapılara uygulanabilir.

Algoritma 1. DCNN eğitim algoritması

Girdi: eğitim verisi t , test_verisi, sınıf sayısı N **Çıktılar:** sınıf

Gerekirse önceden eğitilmiş sinir ağına ince ayar işlemi uygulayın.

tüm eğitim görüntülerini önceden eğitilmiş ağıdan geçirin, tüm özellikleri oluşturun

tüm özellikleri $[-1,+1]$ aralığında normalleştirin

her sınıfı i için

ith sınıfına ait eğitim verilerini bulmak, tpi

her özelliği k için

ortalama değeri hesaplayın, M_i^k ve standart sapma, V_i^k için son

maksimum ve minimum standart sapmayı V_{maxi} ve V_{mini} bulun

maksimum olan $maxftr$ 'nin indisini bulun

σ 'yi standart sapma eşiklemesine göre hesaplayın ve

eğitim verilerinin yumuşatma parametresi tpi

$$\sigma = \begin{cases} \ln \sum_{k=1}^m |V_i^k - M_i^k| \\ \frac{1}{2} (V_{max} - V_{min}) \end{cases}$$

için son

konvolüsyonel parça ağırlıklarını rastgele başlatma

test verilerindeki toplam_hata azalırken

her bir eğitim görüntüsü için; $imgm$

$imgm$ 'yi evrişimsel kısımdan geçirin ve özellikleri hesaplayın her desen düğümü

için;

düğüm özellikleri ile oluşturulan özellikler arasındaki Öklid mesafesini hesaplamak

özellikler, $dist(i)$

σ_j ile RBF aktivasyon fonksiyonunu, $r(j)$ uygulayın

her sınıf için; i sapma etkisi terimini hesaplar,

$d(j,i) = e^{(y(j,i) - y_{max}) * y(j, i)}$

normalleştirme katmanını nöronlarının değerlerini hesaplar; $c = \frac{u}{D}$

için son

için son

ile her bir çıkış nöronunun hatası hesaplanır.

$e = (y(i) - c(i))$


hatayı konvolüsyonel katmanlar aracılığıyla geri yayar

için son

end while

1	-1	1	1	0	0	1
		-1	0	-1	-1	0

Şekil 13. Sabit filtreler



Şekil 14 Differentail CNN yapısı

3.7. Diferansiyel konvolüsyon

Giriş görüntüsü üzerinde bir dizi filtrenin kaydırılmasıyla gerçekleştirilen konvolüsyon işlemi, derin öğrenme yapılarının temel unsurudur. Giriş görüntüsü üzerindeki görsel örüntülerin çıkarılmasını sağlar. Dolayısıyla, yapı ne kadar çok özellik haritası üretirse, sınıflandırıcı o kadar çok özellik elde eder.

Önerilen konvolüsyon tekniğinin arkasındaki fikir, bir piksel ve komşuları arasındaki yön değişikliklerinin dikkate alınmasıdır. Diferansiyel konvolüsyon, ek değişim miktarı hesaplamaları ile bir pikselin ve komşularının desen yönelimini analiz eder. Matematiksel farklılaştırmada olduğu gibi piksellerin aktivasyonları arasındaki fark hesaplanarak sıralı değişimler dikkate alınır. Görüntüler farklı frekanslara sahip dalgaların süperpozisyonu şeklinde değerlendirilirken, ek bir ardışık diferansiyel hesaplama standart konvolüsyonun örüntü yönlendirme yeteneğini geliştirmelidir. Bu gerçek, önerilen yöntemin bir fark sinyali ekleme haritası ile güçlendirilmiş gelişmiş bir konvolüsyon yaklaşımı içermesine yol açmaktadır. Bu ek fark haritaları, önceden tanımlanmış sabit filtreler uygulanarak geleneksel konvolüsyon ile üretilen özellik haritasından üretilir. Sabit filtreler Şekil 1'de gösterilmektedir. Bu filtrelerin her biri bir yöndeki farkları hesaplamak için kullanılır. Sonuç olarak, her yön için sinyal farklılıklarını içeren ek özellik haritaları üretilir. (Sarigül, 2019)

Geleneksel konvolüsyon ile oluşturulan özellik haritası g_1 ve ek dört harita g_2 , g_3 , g_4 ve g_5 olsun. Bu haritaların nöronlarının değerleri (7)-(10)'de verildiği gibi hesaplanır. Eğer g_1 'in boyutu $M \times N$ ise, g_2 , g_3 , g_4 ve g_5 ek özellik haritalarının boyutu sırasıyla $(M-1) \times N$, $M \times (N-1)$, $(M-1) \times (N-1)$ ve $(M-1) \times (N-1)$ olacaktır. Oluşturulan bu ek özellik haritaları sıfırlarla genişletilir ve Şekil 16'de gösterildiği gibi ilk özellik haritasının boyutuna getirilir. Ayrıca bu işlemle filtrenin alıcı alanı iki eksen boyunca birer birim büyütülmüş olur. Diferansiyel özellik haritalarının örnekleri Şekil 4'te verilmiştir.

$$g_{2,i,j} = g_{1,i,j} - g_{1,i+1,j} \quad (7)$$

$$g_{3,i,j} = g_{1,i,j} - g_{1,i,j+1} \quad (8)$$


$$g_{4,i,j} = g_{1,i,j} - g_{1,i+1,j+1} \quad (9)$$

$$g_{5,i,j} = g_{1,i+1,j} - g_{1,i,j+1} \quad (10)$$


Geleneksel yöntemle üretilen ilk özellik haritasından sonra diferansiyel konvolüsyon yöntemi, önceden tanımlanmış sabit filtrelerle ek konvolüsyon işlemleri gerçekleştirir. Diferansiyel konvolüsyonda kullanılan ön tanımlı filtreler, görüntüler üzerindeki kenar ve köşe gibi temel yapıların tespitinde de kullanışlıdır. Kullanılan filtreler Hücreli Sinir Ağı gibi diğer sinir ağı yapılarında da başarıyla kullanılmıştır (Chua ve Yang, 1988).

Diferansiyel konvolüsyonun avantajlarından biri, tek bir konvolüsyonel katmanın derinliğinin artırılmasının, konvolüsyonel katman sayısını artırmadan daha fazla özellik elde edilmesini

sağlamasıdır. Ne kadar çok özellik haritası üretilirse, bir sonraki katmanda o kadar çok parametre ortaya çıkar. Bu bir dezavantaj gibi görünse de, diferansiyel konvolüsyon katmanının eğitilebilir yeni bir parametre eklemekten başka bir konvolüsyon gerçekleştirdiği göz önünde bulundurulmalıdır. (Sarigül, 2019)



Şekil 15. Diferansiyel konvolüsyon işlemi. (Sarigül, 2019)



Şekil 16. Orijinal görüntü Sol Üst: Orijinal görüntü; Sol Alt: Geleneksel özellik haritası; Diğerleri: Diferansiyel özellik haritaları. (Sarigül, 2019)

3.8. Birikimli geri yayılım algoritması

Yeni özellik haritaları ile diferansiyel konvolüsyon, geri yayılım algoritmasında bir iyileştirme gerektirir. Geri yayılım sırasında, hatalar her bir özellik haritasına ters yönde iletilir. Her bir ekstra özellik haritasındaki hatalar, karşılık gelen sabit değerli filtre ağırlıkları ile çarpılır ve ilk özellik haritasının karşılık gelen hatalarına eklenir. Hesaplanan bu hata matrisi ilgili filtrenin eğitimi için kullanılır ve geriye doğru yayılır.

İlk haritaya iletilen hata h_1 ; üretilen ekstra haritalara iletilen hatalar h_2, h_3, h_4, h_5 ; hata matrisinin elemanları E ; ve haritaların boyutu $M \times N$ olsun. İlgili filtre için hata hesaplamaları aşağıda verilmiştir (11)-(13).

$$E_{i,j} = h_{1,i,j} - h_{2,i,j-1} + h_{2,i,j} - h_{3,i-1,j} + h_{3,i,j} - h_{4,i-1,j-1} + h_{4,i,j} - h_{5,i-1,j} \quad (11)$$

Burada $i > 1, j > 1, i < M$ ve $j < N$. Eşitlik (11)'da görüldüğü gibi, ne köşedeki ne de kenarlardaki nöronlar tüm komşu nöronlardan hata beslemesi alır. Haritanın köşe nöronları Eşitlik (11)'daki gibi 3 komşu nöronlardan hata beslemesi alır. (Sarigül, 2019)

$$E_{i,j} = \begin{cases} h_{1,i,j} + h_{2,i,j} + h_{3,i,j} + h_{4,i,j} & i = 1, j = 1 \\ h_{1,i,j} - h_{2,i,j-1} + h_{3,i,j} + h_{5,i,j-1} & i = 1, j = N \\ h_{1,i,j} - h_{2,i,j-1} + h_{3,i-1,j} + h_{4,i,j-1} & i = M, j = 1 \end{cases} \quad (12)$$

Haritanın kenar nöronlarına yayılacak hatalar (13)'deki gibi hesaplanır. Kenar nöronlar 5 komşu nöronlardan hata beslemesi alır.

$$E_{i,j} = \begin{cases} h_{1,i,j} + h_{2,i,j} + h_{3,i,j} + h_{4,i,j} & i = 1, 1 < j < N \\ h_{1,i,j} - h_{2,i,j-1} + h_{3,i,j} + h_{5,i,j-1} & i = M, 1 < j < N \\ h_{1,i,j} - h_{2,i,j-1} + h_{3,i-1,j} + h_{4,i,j-1} & 1 < i < M, j = 1 \end{cases} \quad (13)$$



4. BULGULAR VE TARTIŞMA

Test aşamasında, önerilen tekniğin uyarlanabilirliğini ve etkinliğini göstermek için iki farklı deney seti uygulanmıştır. İlk deney setinde sınıflandırma performansının değerlendirilmesi amaçlanmıştır. İkinci deney setinde ise önerilen teknik alternatif konvolüsyon teknikleri ile karşılaştırılmıştır. Doğruluk değerleri dikkate alınarak performans iyileştirmeleri gözlemlenmiştir.


CNN, edinilen özellikleri temsil etmede güçlü bir avantaja sahip olsa da, derin yapı ve denetimli öğrenme, eğitim verisi miktarı sınırlı olduğunda, birçok tıbbi durumda olduğu gibi, sınırlı veri durumunda, diferansiyel CNN'deki çok sayıda parametre aşırı uyuma yol açabileceğinden aşırı verimi ortaya çıkarabilir.

Bu çalışmada, giriş BT görüntülerini anormal (Akciğer kanseri: evet) veya normal (Akciğer kanseri: hayır) olarak sınıflandırmak için bir diferansiyel CNN modeli kullanılmıştır. Şekil 4a, anormal BT akciğer kanseri veri kümesinin önerilen modelimize göre sınıflandırılmasını temsil etmektedir; sonuçlar, modelin doğruluğu korurken büyük verileri sınıflandırma yeteneğini göstermektedir. Diferansiyel CNN modeline dayalı olarak normal BT akciğer görüntülerinin sınıflandırılmasını açıklamaktadır; sonuçlar, önerilen modelin BT akciğer görüntülerinin büyük verilerini sınıflandırmadaki etkinliğini göstermiştir.

İlk deney setinde, sonuçlar Diferansiyel Evrişim kullanılan modelin tüm veri kümeleri için herhangi bir ölçümde daha iyi performans sağladığını göstermiştir. Doğruluk için %96.25'a varan bir performans artışı elde etmiştir. Kesinlik için %94,47'ye varan bir performans artışı elde edilmiştir.

Bu çalışmada model, her biri kendi kategorisine ait 250 örnekten oluşan kanser pozitif ve kanser olmayan görüntülerden oluşan 500 ile 50 epok ve 32 parti boyutu için eğitilmiştir. Başlangıçta model, %96.35 doğruluk ve %95 doğrulama doğruluğu elde eden DCNN mimarisi ile eğitilmiştir. Aşağıdaki şekillerde eğitim ve doğrulamanın doğruluk ve kayıp grafikleri gösterilmektedir.

Diferansiyel CNN'nin orijinal özellik haritaları önceden ayarlanmış filtre ile dönüştürüldüğünden dahası, diferansiyel özellik haritaları çeşitli yönlerdeki varyasyonları kaydeder, bu da temel tapınak görüntüsünü tanımlamak ve görüntülerin daha doğru sınıflandırılmasını sağlamak için diferansiyel derin CNN'in performansını artırır. Buradan, sınıflandırma doğruluğu diferansiyel derin CNN modeli kullanılarak geliştirilmiştir.




Şekil 17. Önerilen Differential CNN model için doğruluk oranı

Şekil 19. gösterilen doğruluk ve Şekil 20. kayıp eğrileri, veri setlerinin öğrenme performansını değerlendirmek için kullanılan standart indekslerdir. Şekil 16, diferansiyel derin-CNN modelinin doğruluk değerini temsil etmektedir (eğitim ve test adımları). Grafik, önerilen modelin etkinliğini göstermektedir. Diferansiyel derin-CNN modeli tarafından elde edilen doğruluk değeri 0,9625'tir.

Çizelge 1. Akciğer kanseri BT görüntülerini sınıflandırma için oluşturulan CNN model özeti

Layer (type:depth-idx)	Output Shape	Param #
Convnet	[32, 1]	
--		
Sequential: 1-1	[32, 12800]	--
└─Conv2d: 2-1	[32, 64, 248, 248]	640
└─BatchNorm2d: 2-2	[32, 64, 248, 248]	128
└─ReLU: 2-3	[32, 64, 248, 248]	--
└─MaxPool2d: 2-4	[32, 64, 124, 124]	--
└─Conv2d: 2-5	[32, 128, 122, 122]	73,856
└─BatchNorm2d: 2-6	[32, 128, 122, 122]	256
└─ReLU: 2-7	[32, 128, 122, 122]	--
└─MaxPool2d: 2-8	[32, 128, 61, 61]	--
└─Conv2d: 2-9	[32, 256, 59, 59]	295,168
└─BatchNorm2d: 2-10	[32, 256, 59, 59]	512
└─ReLU: 2-11	[32, 256, 59, 59]	--
└─MaxPool2d: 2-12	[32, 256, 29, 29]	--
└─Conv2d: 2-13	[32, 512, 27, 27]	1,180,160
└─BatchNorm2d: 2-14	[32, 512, 27, 27]	1,024
└─ReLU: 2-15	[32, 512, 27, 27]	--
└─MaxPool2d: 2-16	[32, 512, 13, 13]	--
└─Conv2d: 2-17	[32, 512, 11, 11]	2,359,808
└─BatchNorm2d: 2-18	[32, 512, 11, 11]	1,024
└─ReLU: 2-19	[32, 512, 11, 11]	--
└─MaxPool2d: 2-20	[32, 512, 5, 5]	--
└─Flatten: 2-21	[32, 12800]	--
Sequential: 1-2	[32, 1]	--
└─Dropout: 2-22	[32, 12800]	--
└─Linear: 2-23	[32, 512]	
6,554,112		
└─ReLU: 2-24	[32, 512]	--
└─Dropout: 2-25	[32, 512]	--
└─Linear: 2-26	[32, 256]	131,328
└─ReLU: 2-27	[32, 256]	--
└─Linear: 2-28	[32, 128]	32,896
└─ReLU: 2-29	[32, 128]	--
└─Linear: 2-30	[32, 1]	129
Total params: 10,631,041		
Trainable params: 10,631,041		



Şekil 18.Önerilen Differential CNN model için kayıp oranı


Çizelge 2. Akciğer kanseri BT görüntülerini sınıflandırma için oluşturulan

Differential CNN model özeti


Layer (type:depth-idx)	Output Shape	Param #
SampleNet	[1, 1]	--
└Conv2d: 1-1	[1, 64, 250, 250]	640
└DiffConv: 1-2	[1, 320, 250, 250]	--
└Sequential: 1-3	[1, 128000]	--
└└Conv2d: 2-1	[1, 640, 248, 248]	
1,843,840		
└└└BatchNorm2d: 2-2	[1, 640, 248, 248]	1,280
└└└ReLU: 2-3	[1, 640, 248, 248]	--
└└└MaxPool2d: 2-4	[1, 640, 124, 124]	--
└└└Conv2d: 2-5	[1, 1280, 122, 122]	
7,374,080		
└└└BatchNorm2d: 2-6	[1, 1280, 122, 122]	2,560
└└└ReLU: 2-7	[1, 1280, 122, 122]	--
└└└MaxPool2d: 2-8	[1, 1280, 61, 61]	--
└└└Conv2d: 2-9	[1, 2560, 59, 59]	
29,493,760		
└└└BatchNorm2d: 2-10	[1, 2560, 59, 59]	5,120
└└└ReLU: 2-11	[1, 2560, 59, 59]	--
└└└MaxPool2d: 2-12	[1, 2560, 29, 29]	--
└└└Conv2d: 2-13	[1, 5120, 27, 27]	
117,969,920		
└└└BatchNorm2d: 2-14	[1, 5120, 27, 27]	10,240

└─ReLU: 2-15	[1, 5120, 27, 27]	--
└─MaxPool2d: 2-16	[1, 5120, 13, 13]	--
└─Conv2d: 2-17	[1, 5120, 11, 11]	
235,934,720		
└─BatchNorm2d: 2-18	[1, 5120, 11, 11]	10,240
└─ReLU: 2-19	[1, 5120, 11, 11]	--
└─MaxPool2d: 2-20	[1, 5120, 5, 5]	--
└─Flatten: 2-21	[1, 128000]	--
─Sequential: 1-4	[1, 1]	--
└─Linear: 2-22	[1, 5120]	
655,365,120		
└─ReLU: 2-23	[1, 5120]	--
└─Linear: 2-24	[1, 2560]	
13,109,760		
└─ReLU: 2-25	[1, 2560]	--
└─Linear: 2-26	[1, 1280]	
3,278,080		
└─ReLU: 2-27	[1, 1280]	--
└─Linear: 2-28	[1, 640]	819,840
└─ReLU: 2-29	[1, 640]	--
└─Linear: 2-30	[1, 320]	205,120
└─ReLU: 2-31	[1, 320]	--
└─Linear: 2-32	[1, 1]	321


Total params: 1,065,424,641
Trainable params: 1,065,424,64



Şekil 19. Differansiyel Evrişimli Sınır Ağlarının Mimarisi



Şekil 20. CNN model için doğruluk oranı



Şekil 21.CNN model için kayıp oranı

Çizelge 3. Farklı modellerin sonuçlarının önerdiğimiz diferansiyel derin-CNN modeli ile karşılaştırılması.

Model	Accuracy %	Sensitivity %	Precision %
KNN	78	46	72.11
CNN-SVM	95.62	-	92.12
CNN	95.5	95.07	94.81
M-CNN	95.4	95	95.7
Alex_Net	87.66	84.38	93.1
Google-Net	89.66	84.85	96.55
VGG-16	84.48	81.25	89.66
LunCTNet	94.5	95	92.3
Proposed differential CNN	96.25	94.89	97.22

Çizelge 3'te, bir test ve eğitim veritabanı üzerinde diferansiyel bir derin-CNN modelinin doğruluk, duyarlılık, özgüllük, kesinlik ve F-skorunun, önceki modellere kıyasla önemli ölçüde üstün olan %96,25, 94,89 ve 97.22'lik en iyi sonuçları elde ettiğini görebiliriz.

Çizelge 4. Uygulanan derin öğrenme modelleri

Derin Öğrenme Modelleri	Parametre Sayısı	Eğitim Süresi	Doğruluk Oranları
CNN Modeli	10,631,041	3 saat 10 dakika	% 92.22
Differential CNN Modeli	1,065,424,641	5 saat 15 dakika	% 96.35

Çizelge 5. Literatürdeki diğer çalışmalar ile karşılaştırma tablosu

Veri seti	Derin Öğrenme Modeli	Metot	Doğruluk oranı	Kaynak
LIDC & IDRI	CNN	DNN	82.10	Gruetzemacher(2016)
LIDC & IDRI	CNN	DNN, SAE	84.15	Song (2017)
ILD	CNN	LeNet, AlexNet, VGG	85.61	Anthimopoulos (2016)
Data Science ve Kaggle	CNN	U-net	86.60	Alakwaa(2017)
LUNA 16	CNN	CNN	92.22	CNN
LUNA 16	Differential CNN	Differential CNN	96.35	Önerilen modelde elde edilen sonuç

Diferansiyel derin-CNN modelinin performansı, önceki model ile değerlendirilmiştir. Yukarıda bahsedilen deneysel sonuçların gözlemlenmesiyle, önerilen tekniğin performansının önceki

yaklaşımlara kıyasla daha iyi olduğu görülmüş ve bu da önerilen modelin uygulanabilirliğini ortaya koymuştur.

Bu çalışmada, deneysel sonuçların geçerliliğine yönelik tartışmak için, Çizelge 3 ve 5'te gösterildiği gibi, farklı derin öğrenme teknikleri kullanarak akciğer kanseri sınıflandırması alanında yayınlanan son referansları kullandık. Sonuçlarımızın doğrulanması, beş değer kullanılarak önerilen diferansiyel derin-CNN modeli ile bir simülasyonda mevcut modeller arasında bir karşılaştırmaya dayanmaktadır. Önerilen modelin UTMC büyük verilerini Şekil 16'de gösterildiği gibi yüksek doğruluk ve çok düşük kayıpla doğrulama yeteneği, sonuçların geçerliliğinin açık bir kanıtıdır.

4.1. SoftMax kullanılan Geriye Yayılımlı Diferansiyel CNN sonuçları

Birikimli geriye yayılım yöntemi sınıflandırma performansını arttırmakla birlikte bazı sorunlara da yol açmıştır. Komşulardan iletilen tüm hataların ana özellik haritasından gelen hata ile toplanması eğitimde kullanılacak hata değerini arttırmıştır. Bu nedenle öğrenme oranının belirlenmesi daha sorunlu hale gelmiştir. Ayrıca, ana özellik haritasından gelen hatanın toplam hata içindeki oranı çok küçüktür ve bu hatanın etkisi sınırlıdır. Bu sorunların üstesinden gelebilmek için SoftMax fonksiyonu kullanılarak komşuluk hataları sınırlandırılmıştır. Bu süreçte SoftMax oranları eğitimin ileri geçişinde hesaplanan aktivasyon farkları kullanılarak belirlenmiştir. Bu işlem daha büyük yapılar ve veri kümeleri için daha doğru bir eğitim sağlamış ve performansı da artırmıştır.

SoftMax kullanılan geri yayılımlı Diferansiyel CNN, hassasiyet, geri çağırma ve F1-skoru için %11,41 ve %5,92'ye varan ek bir görelî performans artışı sağlamıştır. Dolayısıyla, geleneksel yöntemle kıyasla toplam görelî performans artışı hassasiyet, geri çağırma ve F1-skoru için %89,41'e kadar çıkmaktadır. Ortalama görelî performans artışı kesinlik, geri çağırma ve F1-skoru için sırasıyla %20,53 ve %23,16 olmuştur. Görüldüğü üzere, SoftMax kullanılan geriye yayılma yöntemi Diferansiyel CNN'in performansını önemli ölçüde artırmıştır.

Çizelge 6. SoftMax kullanılan BP ve DCNN ile Diferansiyel CNN sonuçlarının karşılaştırılması

Dataset Name	Differential CNN with Accumulative BP			DCNN		
	P	R	F1	P	R	F1
LUNGc	88.75	80.468	89.392	81.666	77.606	74.248
Luna16	78.088	80.936	79.242	78.460	70.250	69.340

5. SONUÇLAR VE ÖNERİLER

Derin öğrenme yapılarının yüksek temsil yeteneği onları popüler hale getirmiştir. Bu yetenek konvolüsyon işleminin bir sonucudur. Konvolüsyon işlemi, eğitilebilir filtrelerin görüntü üzerinde kaydırılması ve aktivasyon değerlerinin hesaplanmasıyla özellik haritalarının çıkarılmasına dayanır. Bu özellik haritaları görüntü üzerindeki çeşitli örüntülerin tanınmasını sağlar. Derin öğrenme yapılarının popülerliği, yeni konvolüsyonel modellerin ve tekniklerin geliştirilmesine yol açmıştır.

Bu çalışmada, akciğer kanseri tespiti için yeni bir konvolüsyon tekniği, diferansiyel konvolüsyon ve geliştirilmiş bir geri yayılım algoritması önerilmektedir. Diferansiyel konvolüsyon, bir piksel ve komşuları arasındaki yön değişikliklerini dikkate alır. Diferansiyel konvolüsyon, bir piksel ve komşuları arasındaki yönsel değişim miktarlarını hesaplayarak piksellerin örüntü yönelimini çıkarır. Matematiksel farklılaştırmada olduğu gibi, değişim miktarı hesaplamaları, piksellerin aktivasyonları arasındaki farkı hesaplayarak sıralı değişiklikleri dikkate alır. Görüntüler farklı frekanslara sahip dalgaların süperpozisyonu olarak tanımlanabildiğinden, diferansiyel konvolüsyon sinyal değişikliklerini temsil eden yeni özellik haritaları oluşturur. Bu haritalar, sınıflandırma problemleri için değerli bilgiler olan örüntüler üzerindeki büyük farklılıkların tespit edilmesini sağlar. Diferansiyel konvolüsyon, geleneksel konvolüsyon ile üretilen özellik haritası üzerinde önceden tanımlanmış sabit filtrelerle 4 ek konvolüsyon işlemi gerçekleştirerek bu haritaları sağlar. Diferansiyel konvolüsyonun kolay uygulanması, tekniği tüm konvolüsyonel yapılar için uyarlanabilir hale getirir. Diferansiyel konvolüsyonu uyarlayan yapılar, hata geri yayılım algoritmasında bir güncelleme gerektirir. Bu nedenle, komşu aktivasyonlar üzerinde birikimli bir hata sağlayan geliştirilmiş bir geri yayılım algoritması önerilmiştir. Bu yöntemde, nöronlar komşuluk aktivasyonları aracılığıyla ek olarak hata bilgisi edinir. Kısaca, önerilen teknik hem ileri hem de geri geçişlerde komşuluk aktivasyonlarını kullanmaktadır. İleri geçişte sinyal değişikliklerini temsil ederken, geri geçişte hata bilgisini iletir.

Bu tez çalışmasında, diferansiyel konvolüsyon tekniği iki farklı deney seti üzerinde test edilerek performansı gösterilmiştir. İlk deney setinde geleneksel bir CNN yapısı diferansiyel konvolüsyon ile donatılmış ve performans artışı 2 farklı akciğer BT görüntüsü veri seti üzerinde ölçülmüştür. İkinci deneyde ise Diferansiyel CNN, farklı geleneksel CNN yapıları ve diğer konvolüsyon teknikleri olan Tiled CNN, Dilated CNN ile karşılaştırılmıştır.

İlk deney setinde önerilen teknik doğruluk değerini %96,29'a kadar yükseltmiştir. İkinci deney setinde Diferansiyel CNN karşılaştırılan tüm evrimsel yapılardan daha iyi performans göstermiştir. Diferansiyel CNN, LUNA16 ve LUNGc veri kümelerini kullanarak en yakın performans gösteren modelden %4,33 ve %2,93 daha yüksek performans değerleri sağlamıştır. Diferansiyel konvolüsyon uyarlamalı NIN modelinin aynı veri kümeleri için doğruluk değerleri

%92,44 ve %82,65 olmuştur. Bu sonuçlar, diferansiyel konvolüsyon tekniğinin akciğer kanseri tespiti için etkinliğini ve uyarlanabilirliğini göstermektedir.

Sonuç olarak, önerilen tekniğin yenilikleri ve verimlilikleri aşağıdaki gibi özetlenebilir. Örüntü yönelimini çıkarmak için değerli bir oluşum olan piksel aktivasyonu arasındaki yön değişim miktarını korur, filtre sayısını artırmadan özellik haritalarının sayısını artırır ve komşuluk aktivasyonları yoluyla hata beslemeleri sağlar. Ayrıca, tüm CNN yapılarına kolayca uyarlanabilir, performansta artış sağlar ve akciğer kanseri tespiti için mükemmel bir çözüm olabilecek daha hızlı hata minimizasyonu sağlar.



KAYNAKLAR

- Afkham, H. M., Targhi, A. T., Eklundh, J. O., & Pronobis, A. (2008). Hayvan sınıflandırması için ortak görsel kelime dağarcığı. Örüntü tanıma üzerine 19. uluslararası konferans, 2008. ICPR 2008 (pp. 1-4). IEEE.
- Armato III, Lubomir Samuel G. and Hadjiiski, Georgia D. ve Karen Drukke Tourassi, Maryellen L. Giger, Feng Li, George Redmond, Keyvan Farahan, Justin S. Kirby, ve Laurence P. Clarke. (2025) Spieaapmnci akciğer nodülü sınıflandırma mücadelesi veri seti/
- Abhishta Bhandari ve arkadaşları (2022) Katı akciğer nodül yoğunluğu histogramlarının basıklık ve çarpıklık değerlendirmeleri: BT'de malign ve benign nodüllerin ayrımı. Japanese Journal of Radiology, 32(1):14-21.
- Beck, A., & Teboulle, M. (2025). Doğrusal ters problemler için hızlı bir iteratif büzölme-eşikleme algoritması. SIAM Journal on Imaging Sciences, 2(1), 183-202.
- Bradley Efron. (1993) Bootstrap'e giriş. Monographs on statistics and applied probability (Series); 57. Chapman ve Hall, New York.
- Diederik P. Kingma ve Jimmy Ba. (2024) Adam: Stokastik optimizasyon için bir yöntem. CoRR, abs/1412.6980
- Christian, T., & Kathirvel, R. (2014). Derin öğrenme mimarisi kullanarak diyabetik retinopatinin sınıflandırılması. Uluslararası Mühendislik Araştırmaları Dergisi & Technology (IJERT), 5(6), 19-24.
- Chua, L. O., & Yang, L. (1988). Hücrel sinir ağırları: Uygulamalar. IEEE Transactions on Circuits and Systems, 35(10), 1273-1290.
- Charles X. Ling ve Chenghui Li. (1998) Doğrudan pazarlama için veri madenciliği: Problemler ve çözümler. Proceedings of the Fourth International Conference on Knowledge Discovery and Data Mining, KDD'98, sayfa 73-79. AAAI Press/
- Creadie, Thijs Kooi, Babak Ehteshami Bejnordi, Arnaud Arindra Adiyoso Setio, Francesco Ciompi, Mohsen Ghafoorian, Jeroen A.W.M. van der Laak, Bram van Ginneken ve Clara I. Snchez. (2013) Tıbbi görüntü analizinde derin öğrenme üzerine bir araştırma. Tıbbi Görüntü Analizi, 42:60-88.
- Christopher M. Bishop. (2006) Örüntü Tanıma ve Makine Öğrenimi (Bilgi Bilimi ve İstatistik). Springer-Verlag New York, Inc, Secaucus, NJ, ABD.
- David Silver, G. E. (2016). Konuşma tanıma, hesaplamalı kimya ve doğal dil metin işleme problemlerine derin öğrenme yaklaşımları (Doktora tezi), Toronto Üniversitesi Bilgisayar Bilimleri Yüksek Lisans Bölümü.
- Diederik P. Kingma ve Jimmy Ba. (2014) Adam: Stokastik optimizasyon için bir yöntem. CoRR, abs/1412.6980.

- Deng, J., Dong, W., Socher, R., Li, L. J., Li, K., & Fei-Fei, L. (2009). Imagenet: Büyük ölçekli bir hiyerarşik görüntü veritabanı. IEEE konferansında, Bilgisayarla görme ve örüntü tanıma, 2009. CVPR. 2009 (s. 248-255). IEEE.
- Masahito, Atsuto Maki ve Maciej A. Mazurowski. (2013) Konvolüsyonel sinir ağlarında sınıf dengesizliği problemi üzerine sistematik bir çalışma. CoRR, abs/1710.05381/
- Ellison, D.W. 2016 Dünya Sağlık Örgütü Merkezi Sinir Sistemi Tümörleri Sınıflandırması: Bir özet. Acta Neuropathol. 2016, 131, 803-820.
- Goodenberger, M.L.; Jenkins, R.B. Yetişkin gliomasının genetiği. Kanser Genetiği. 2012, 205, 613-621.
- Y. Bar, I. Diamant, L. Wolf, S. Lieberman, E. Konen ve H. Greenspan. (2015) Tıbbi olmayan eğitim ile derin öğrenme kullanarak göğüs patolojisi tespiti. In 2015 IEEE 12th International Symposium on Biomedical Imaging (ISBI), pages 294-297/
- He, K., Zhang, X., Ren, S., & Sun, J. (2023). Görüntü tanıma için derin artık öğrenme. Bilgisayarla görme ve örüntü tanıma üzerine IEEE konferansı bildirilerinde. (s. 770-778).
- Hui Chen, Yan Xu, Yujing Ma ve Binrong Ma. (2010) BT görüntülerinde akciğer nodüllerinin ayrımı için sinir ağı topluluğu tabanlı bilgisayar destekli tanı: Klinik değerlendirme. Academic Radiology, 17(5):595-602/
- Krizhevsky, A., & Hinton, G. (2025). Küçük görüntülerden çoklu özellik katmanları öğrenme: Teknik rapor, Citeseer.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). Derin evrişimli sinir ağları ile görüntü sınıflandırması. Sinirsel bilgi işleme sistemlerindeki gelişmeler içinde (s. 1097-1105).
- Lazebnik, S., Schmid, C., & Ponce, J. (2004). Nesne tanıma için yarı yerel afin parçalar. İngiliz Yapay Görme Konferansı (BMVC'04) içinde (s. 779-788). İngiliz Makine Görme Derneği (BMVA).
- Lazebnik, S., Schmid, C., & Ponce, J. (2005). Parça tabanlı doku ve nesne tanıma için bir maksimum entropi çerçevesi. Onuncu IEEE uluslararası konferansında: Cilt 1, Bilgisayarla görme, 2005. ICCV 2005 (s. 832-838). IEEE.
- LeCun, Y., Boser, B. E., Denker, J. S., Henderson, D., Howard, R. E., Hubbard, W. E. ve diğerleri (1990). Geri yayılım ağı ile el yazısı rakam tanıma. Sinirsel bilgi işleme sistemlerindeki gelişmeler içinde (s. 396-404).
- Lecun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998). Belge tanıma uygulanan gradyan tabanlı öğrenme. Proceedings of the IEEE, 86(11), 2278-2324.
- Lin, M., Chen, Q., & Yan, S. (2013). Ağ içinde ağ. (s. 1-10). arXiv ön baskı arXiv:13124400.
- Mohammadi, (2019) A. MRI Görüntülerine ve Kaba Tümör Sınırlarına Dayalı Beyin Tümörü Sınıflandırması için Kapsül Ağları. ICASSP 2019-2019 IEEE Uluslararası Akustik, Konuşma ve Sinyal İşleme Konferansı (ICASSP) Bildirilerinde, Brighton, İngiltere,; s. 1368-1372.

- Muayed AL-Huseiny ve arkadaşları (2025) Döşenmiş konvolüsyonel sinir ağları. Sinirsel bilgi işleme sistemlerindeki gelişmeler içinde (s. 1279-1287).
- Nielsen, M. A. (2015). Sinir ağları ve derin öğrenme. Determination Press.
- Pinsky, M. E., & Zisserman, A. (2004). Çiçek sınıflandırması için görsel bir sözcük dağılımı. IEEE Bilgisayar Topluluğu konferansında: Cilt 2, Bilgisayarla görme ve örüntü tanıma (s. 1447-1454). IEEE.
- Pugatch, A. Castellino. (2008) Bilgisayar destekli algılama (cad): genel bir bakış. Cancer Imaging, 5(1):1719.
- Ravi, D., Wong, C., Deligianni, F., Berthelot, M., Andreu-Perez, J., Lo, B. ve diğerleri (2022). Sağlık bilimi için derin öğrenme. IEEE Journal of Biomedical and Health Informatics, 21(1), 4-21.
- Russell, O., Deng, J., Su, H., Krause, J., Satheesh, S., Ma, S., ve diğerleri (2010). Imagenet büyük ölçekli görsel tanıma yarışması. International Journal of Computer Vision (IJCV), 115(3), 211-252. <http://dx.doi.org/10.1007/s11263-015-0816-y>.
- Samuel G. Armato, Karen Drukker, Feng Li, Lubomir Hadjiiski, Georgia D. Tourassi, Justin S. Kirby, Laurence P. Clarke, Roger M. Engelmann, Maryellen L. Giger, George Redmond ve Keyvan Farahani. (2016) Bilgisayarlı akciğer nodülü sınıflandırması için Lungx mücadelesi. Journal of Medical Imaging, 3:3-9.
- Sebastian, B., Farhadi, A., & Elgammal, A. (2016). Öznitelik tabanlı muhakeme ile nesne merkezli anormallik tespiti. IEEE bilgisayarla görme ve örüntü tanıma konferansı bildirilerinde. (s. 787-794).
- Shaoqing, M., Batri, K., & Partvathi, R. (2015). Derin konvolüsyon sinir ağları kullanarak en erken diyabetik retinopati sınıflandırması. International Journal of Advanced Engineering Technology, 2(1), 460-470.
- Seeland, M., Rzanny, M., Alaqraa, N., Wäldchen, J., & Mäder, P. (2017). Çiçek görüntüleri kullanılarak bitki türlerinin sınıflandırılması yerel özellik temsillerinin karşılaştırmalı bir çalışması. PloS One, 12(2), e0170629.
- Sermanet, P., Eigen, D., Zhang, X., Mathieu, M., Fergus, R., & LeCun, Y. (2013). Overfeat: Konvolüsyonel ağlar kullanarak entegre tanıma, lokalizasyon ve tespit. (s. 1-16). arXiv ön baskı arXiv:1312.6229.
- Simonyan, K., & Zisserman, A. (2014). Büyük ölçekli görüntü tanıma için çok derin evrişimli ağlar. arXiv ön baskı arXiv:1409.1556.
- Söderkvist, O. (2001). İsveç ağaçlarından yaprakların bilgisayarla görme sınıflandırması. Yüksek Lisans Tezi.
- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. (2014). Bırakma: Sinir ağlarının aşırı uyum sağlamasını önlemenin basit bir yolu. Makine Öğrenimi Araştırmaları Dergisi, 15(1), 1929-1958.

- Zhaowei Cai, Quanfu Fan, Rogerio Schmidt Feris ve Nuno Vasconcelos. (2017) Hızlı nesne tespiti için birleşik çok ölçekli derin evrişimli sinir ağı. CoRR, abs/1607.07155.
- Tehrani, W. Dong, R. Socher, L. J. Li, Kai Li ve Li Fei-Fei. (2013) Imagenet: Büyük ölçekli bir hiyerarşik görüntü veritabanı. İçinde 2009 IEEE Bilgisayarla Görme ve Örüntü Tanıma Konferansı, sayfa 248-255.
- John Duchi, Elad Hazan ve Yoram Singer. (2020) Çevrimiçi öğrenme ve stokastik optimizasyon için uyarlanabilir subgradient yöntemleri. Journal of Machine Learning Research, 12:2121-2159.
- Maryellen L. Giger, Kyongtae T. Bae, ve Heber Macmahon. (2014) Bilgisayarlı tomografi görüntülerinde pulmoner nodüllerin bilgisayarlı tespiti. Investigative Radiology, 29(4):459465.
- Ian Goodfellow, Yoshua Bengio ve Aaron Courville. (2016) Derin Öğrenme. MIT Press.
- Jerzy W. Grzymala-Busse, Linda K. Goodwin, Witold J. Grzymala-Busse ve Xinqun Zheng. (2014) Değişen kural gücüne dayalı dengesiz veri kümelerine bir yaklaşım. Kaba-Nöral Hesaplama içinde: Techniques for Computing with Words içinde.
- Graber, Li Yijing, Jennifer Shang, Gu Mingyun, Huang Yuanyue ve Gong Bing. (2005) Sınıf-dengesiz verilerden öğrenme: Yöntem ve uygulamaların gözden geçirilmesi. Expert Systems with Applications, 73:220-239.
- Ying Su ve arkadaşları (2021) Çoklu atlas segmentasyonu için rastgele yerel ikili örüntü tabanlı etiket öğrenimi. Proc.SPIE, 9413:8.
- Kundel, Xiangyu Zhang, Shaoqing Ren ve Jian Sun. (1999) Görsel tanıma için derin evrişimli ağlarda uzamsal piramit havuzlama. CoRR, abs/1406.4729.
- Kaiming He, Xiangyu Zhang, Shaoqing Ren ve Jian Sun. Görüntü tanıma için derin artık öğrenme. CoRR, abs/1512.03385, 2015.
- Kakinuma, Hua, Che-Hao Hsu, Shintami Chusnul Hidayati, Wen-Huang Cheng ve Yu- Jen Chen. Bilgisayarlı tomografi görüntülerinde akciğer nodüllerinin derin öğrenme tekniği ile bilgisayar destekli sınıflandırılması. Onco Targets Ther, 8:2015-2022, Ağustos 2013.
- Nathalie Japkowicz ve Shaju Stephen(2021) Sınıf dengesizliği sorunu: Sistematik bir çalışma. Intell. Data Anal., 6(5):429-449
- K. Jarrett, K. Kavukcuoglu, M. Ranzato ve Y. LeCun. Nesne tanıma için en iyi çok aşamalı mimari nedir? İçinde 2009 IEEE 12. Uluslararası Bilgisayarla Görme Konferansı, sayfa 2146-2153, Eylül 2009.
- Yangqing Jia, Evan Shelhamer, Jeff Donahue, Sergey Karayev, Jonathan Long, Ross Girshick, Sergio Guadarrama ve Trevor Darrell. Caffe: Convolutional architecture for fast feature embedding. arXiv ön baskı arXiv:1408.5093, 2014.
- Yann Lecun, Yoshua Bengio ve Geoffrey Hinton. Derin öğrenme. Nature, 521(7553):436-444, Mayıs 2015.

- Q. Li, W. Cai, X. Wang, Y. Zhou, D. D. Feng ve M. Chen. (2022)Konvolüsyonel sinir ağı ile tıbbi görüntü sınıflandırması. 13th International Conference on Control Automation Robotics Vision (ICARCV), sayfa 844-848.
- Wei Li, Peng Cao, Dazhe Zhao ve Junbo Wang.(2021) Bilgisayarlı tomografi görüntüleri üzerinde derin evrişimli sinir ağları ile pulmoner nodül sınıflandırması. Comput Math Methods Med, 2016:6215085.





ÖZGEÇMİŞ

Emran DURSUNOV, İlk ve Orta öğrenimini Bişkek’te tamamladı. 2017 yılında başladığı Kırgız Devlet Teknik Üniversitesi’nde Biyomedikal Mühendisliği Lisans Bölümü’nü 2021 yılında tamamladı. 2022 yılında Çukurova Üniversitesi Biyomedikal Mühendisliği Bölümünde Yüksek Lisans öğrenimini başladı.





EKLER

EK-A Önerilen Differential CNN yazılım şekli

```
class DiffConv(nn.Module):

    def __init__(self):
        super(DiffConv, self).__init__()

    def forward(self, x):
        sizeofin = x.size()

        ins = sizeofin[0]
        n = sizeofin[1]
        sx = sizeofin[2]
        sy = sizeofin[3]

        self.output = torch.zeros(ins,n*5,sx,sy)
        self.signInputs = torch.zeros(ins,n*5,sx,sy)
        for i in range(0,ins):
            oM = 0
            oN = n

            self.output[i,oM:oN,0:sx,0:sy]= x[i].clone()

            oM = n
            oN = 2*n

            #area = self.output[i,oM:oN,0:sx-1,0:sy]
            self.output[i,oM:oN,0:sx-1,0:sy] = self.output[i,oM:oN,0:sx-1,0:sy].
add(x[i,0:n,0:sx-1,0:sy])
            self.output[i,oM:oN,0:sx-1,0:sy] = self.output[i,oM:oN,0:sx-1,0:sy].
add(-x[i,0:n,1:sx,0:sy])

            oM = 2*n
            oN = 3*n

            #area = ptr[oM:oN,0:sx,0:sy-1]
            self.output[i,oM:oN,0:sx,0:sy-1]=self.output[i,oM:oN,0:sx,0:sy-1].
add(x[i,0:n,0:sx,0:sy-1])
            self.output[i,oM:oN,0:sx,0:sy-1]=self.output[i,oM:oN,0:sx,0:sy-1].
add(-x[i,0:n,0:sx,1:sy])

            oM = 3*n
            oN = 4*n

            #area = ptr[oM:oN,0:sx-1,0:sy-1]
            self.output[i,oM:oN,0:sx-1,0:sy-1]=self.output[i,oM:oN,0:sx-1,0:sy-1].
add(x[i,0:n,0:sx-1,0:sy-1])
            self.output[i,oM:oN,0:sx-1,0:sy-1]=self.output[i,oM:oN,0:sx-1,0:sy-1].
add(-x[i,0:n,1:sx,1:sy])

            oM = 4*n
            oN = 5*n

            #area = ptr[oM:oN,0:sx-1,0:sy-1]
            self.output[i,oM:oN,0:sx-1,0:sy-1]=self.output[i,oM:oN,0:sx-1,0:sy-1].
add(x[i,0:n,1:sx,0:sy-1])
            self.output[i,oM:oN,0:sx-1,0:sy-1]=self.output[i,oM:oN,0:sx-1,0:sy-1].
add(-x[i,0:n,0:sx-1,1:sy])

            oM = n
            oN = 5*n

            self.output[0:ins,oM:oN,:, :] = self.output[0:ins,oM:oN].abs()

        return self.output
```

```
!pip install torchinfo
import os
import glob
import sklearn
```

```

from sklearn.model_selection import train_test_split
import PIL
import numpy as np
import matplotlib.pyplot as plt
import torch
import torch.nn as nn
from torchinfo import summary
import torch.optim as optim
from IPython.display import Image
from torch.utils.data import DataLoader, Dataset
from torchvision.datasets import ImageFolder
from torchvision.transforms import transforms
import cv2

device = torch.device("cuda" if torch.cuda.is_available() else "cpu")
random_seed = 124 #Set Random Seed for reproducibility
np.random.seed(random_seed)
torch.manual_seed(random_seed)
torch.backends.cudnn.deterministic = True
path = '/content/drive/MyDrive/kaggle.api/' # Hem pozitif hem de negatif görüntüler için dosya bağlantılarını çıkarın
ve veri kümesini eğitim, doğrulama ve test kümelerine ayırın
pos_files = glob.glob(os.path.join(path, "/positive lung cancer", '*..*'))
neg_files = glob.glob(os.path.join(path, "/negative lung cancer", '*..*'))
images = pos_files + neg_files
labels = np.array([1]*len(pos_files)+[0]*len(neg_files))
images_tv, images_test, y_tv, y_test = train_test_split(images, labels, shuffle=True,
test_size=0.2, random_state=123)
images_train, images_val, y_train, y_val = train_test_split(images_tv, y_tv, shuffle=True,
test_size=0.25, random_state=123)
num_pos, num_neg = len(pos_files), len(neg_files)
im = [cv2.imread(images_train[i]) for i in range(6)]

```

Dataset Class

class CT_Dataset(Dataset):

```

def __init__(self, img_path, img_labels, img_transforms=None, grayscale=True):
    self.img_path = img_path
    self.img_labels = torch.Tensor(img_labels)
    if (img_transforms is None) & (grayscale == True):
        self.transforms = transforms.Compose([transforms.Grayscale(),
                                              transforms.Resize((250, 250)),
                                              transforms.ToTensor()])

    elif grayscale == False:
        self.transforms = transforms.Compose([transforms.Resize((250, 250)),
                                              transforms.ToTensor()])

    else:
        self.transforms = img_transforms
def __getitem__(self, index):
    # load image
    cur_path = self.img_path[index]
    cur_img = PIL.Image.open(cur_path).convert('RGB')
    cur_img = self.transforms(cur_img)
    return cur_img, self.img_labels[index]
def __len__(self):
    return len(self.img_path)
class Convnet(nn.Module):

    def __init__(self, dropout=0.5):
        super(Convnet, self).__init__()
        import torch
import torch.nn as nn
import torch.nn.functional as F
# define CNN mode
class Convnet(nn.Module):
    def __init__(self, dropout=0.5):
        super(Convnet, self).__init__()
        self.conv1 = nn.Conv2d(1, 64, 3, stride=1, padding=1)
        self.diff_conv = DiffConv()
        self.convnet = nn.Sequential(

```

```

# input (num_batch, 1, 80, 250)
nn.Conv2d(in_channels=320, out_channels=320, kernel_size=3), # (num_batch, 64, 248,
248)
nn.BatchNorm2d(320),
nn.ReLU(),
nn.MaxPool2d(kernel_size=2), # (num_batch, 64, 124, 124)
nn.Flatten() # (num_batch, 1600)
)
self.classifier = nn.Sequential(
    # Dropout before first linear layer since it has a large number of trainable parameters
    nn.Linear(in_features= 8000, out_features=320),
    nn.ReLU(),
    nn.Linear(in_features=320, out_features=160),
    nn.ReLU(),
    nn.Linear(in_features=160, out_features=80),
    nn.ReLU(),
    nn.Linear(in_features=80, out_features=1)
)
def forward(self, x):
    x = self.conv1(x) # A standard convolution
    x = self.diff_conv(x)
    x = self.convnet(x)
    x = self.classifier(x)
    return x

```