

T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

AĞIZ KANSERİ TANISINDA YAPAY SİNİR
AĞLARININ KULLANIMI

Betül SÜREN

YÜKSEK LİSANS TEZİ
Matematik Anabilim Dalı
Matematik Programı

Danışman
Doç. Dr. Mutlu AKAR

Haziran, 2024

T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

AĞIZ KANSERİ TANISINDA YAPAY SİNİR AĞLARININ
KULLANIMI

Betül SÜREN tarafından hazırlanan tez çalışması 25.06.2024 tarihinde aşağıdaki jüri tarafından Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Matematik Anabilim Dalı Matematik Programı **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Doç. Dr. Mutlu AKAR
Yıldız Teknik Üniversitesi
Danışman

Jüri Üyeleri

Doç. Dr. Mutlu AKAR, Danışman
Yıldız Teknik Üniversitesi

Doç. Dr. Muttalip ÖZAVŞAR, Üye
Yıldız Teknik Üniversitesi

Dr. Öğr. Üyesi Fatih TEMİZ, Üye
Üsküdar Üniversitesi

Danışmanım Doç. Dr. Mutlu AKAR sorumluluğunda tarafımda hazırlanan "Ağız Kanseri Tanısında Yapay Sinir Ağlarının Kullanımı" başlıklı çalışmada veri toplama ve veri kullanımında gerekli yasal izinleri aldığımı, diğer kaynaklardan aldığım bilgileri ana metin ve referanslarda eksiksiz gösterdiğimi, araştırma verilerine ve sonuçlarına ilişkin çarpıtma ve/veya sahtecilik yapmadığımı, çalışmam süresince bilimsel araştırma ve etik ilkelerine uygun davrandığımı beyan ederim. Beyanımın aksinin ispatı halinde her türlü yasal sonucu kabul ederim.

Betül SÜREN



Bu çalışma, Yıldız Teknik Üniversitesi Bilimsel Araştırma Proje Koordinatörlüğü'nün FYL-2024-6104 numaralı projesi ile desteklenmiştir.

Aileme



TEŐEKKÜR

Tez sürecimde beni deęerli bilgi ve deneyimleriyle yönlendiren, tez danışmanım Doç. Dr. Mutlu AKAR'a içtenlikle teşekkür ederim. Eğitim hayatım boyunca her zaman maddi ve manevi destekleri ile yanımda olan, hedeflerime giden yolda beni cesaretlendiren sevgili anneme, babama ve kardeşlerime teşekkür ederim.

Bu çalışmada TÜBİTAK Bilim İnsanı Destek Programları Başkanlığı (BİDEB) 2211-Yurt İçi Lisansüstü Burs Programı kapsamında destek alınmıştır.

Betül SÜREN

İÇİNDEKİLER

TEŞEKKÜR	v
KISALTMA LİSTESİ	viii
ŞEKİL LİSTESİ	x
TABLO LİSTESİ	xi
ÖZET	xii
ABSTRACT	xiv
1 GİRİŞ	1
1.1 Motivasyon	1
1.2 Katkılar	1
1.3 Taslak	2
2 AĞIZ KANSERİ GENEL BİLGİLER	3
2.1 Ağız Kanserinin Epidemiyolojisi	3
2.2 Risk Faktörleri	5
2.3 Erken Teşhisin Önemi	5
2.4 Teşhis ve Tedavi Yaklaşımları	6
2.5 Literatür Taraması	6
3 TEMEL BİLGİLER	9
3.1 Yapay Zeka Nedir?	9
3.2 Makine Öğrenimi Nedir?	10
3.2.1 Denetimli Öğrenme	10
3.2.2 Denetimsiz Öğrenme	11
3.2.3 Yarı Denetimli Öğrenme	11
3.2.4 Pekiştirmeli Öğrenme	12
3.3 Yapay Sinir Ağı Nedir?	12
3.4 Derin Öğrenme Nedir?	14
3.4.1 Derin Öğrenme Modelleri	15
3.4.2 Evrişimli Sinir Ağı	17

4 MALZEME VE YÖNTEM	29
4.1 Veri Seti	29
4.2 Önerilen Modeller	32
4.2.1 ResNet	32
4.2.2 DenseNet Mimarisi	34
4.3 Performans Metrikleri	38
4.4 Sonuçlar	40
5 SONUÇ	45
KAYNAKÇA	47
TEZDEN ÜRETİLMİŞ YAYINLAR	60



KISALTMA LİSTESİ

AC	Accuracy (Doğruluk)
Adam	Adaptive Moment Estimation (Uyarlanabilir Moment Tahmini)
ANN	Artificial Neural Network (Yapay Sinir Ağları)
BBK	Baş ve Boyun Kanseri
BN	Batch Normalization (Toplu Normalizasyon)
CLAHE	Contrast Limited Adaptive Histogram Equalization (Sınırlı Kontrastlı Uyarlamalı Histogram Eşitleme)
CNN	Convolutional Neural Network (Evrışimli Sinir Ağı)
DenseNet	Densely Connected Convolutional Networks (Yoğun Evrişimli Ağ)
F	F1-score (F1-skör)
FN	False Negative (Yanlış Negatif)
FP	False Positive (Yanlış Pozitif)
HPV	Human Papillomavirus (İnsan Papilloma Virüsü)
LSTM	Long Short-Term Memory (Uzun Kısa Süreli Bellek)
OSCC	Oral Squamous Cell Carcinoma (Oral Skuamöz Hücreli Karsinom)
PR	Precision (Kesinlik)
RBM	Restricted Boltzmann Machine (Kısıtlanmış Boltzmann Makinesi)
RE	Recall (Duyarlılık)
ReLU	Rectified Linear Unit (Düzeltilmiş Doğrusal Ünite)
ResNet	Residual Network (Artık Bağlantılı Ağ)
RNN	Recurrent Neural Network (Tekrarlayan Sinir Ağı)
SGD	Stochastic Gradient Descent (Stokastik Gradyan İnişi)
SP	Specificity (Özgüllük)
TN	True Negative (Doğru Negatif)

TP

True Positive (Doğru Pozitif)



ŞEKİL LİSTESİ

Şekil 3.1	Yapay zeka ve alt kümeleri	9
Şekil 3.2	Denetimli öğrenme şeması	11
Şekil 3.3	Yapay sinir ağı modeli	13
Şekil 3.4	Derin sinir ağı modeli	14
Şekil 3.5	Kısıtlı Boltzmann Makinesi modeli	17
Şekil 3.6	Evrişimli sinir ağı mimarisi (sınıflandırma problemi için)	17
Şekil 3.7	Bilgisayarda bir görüntünün karşılığı	18
Şekil 3.8	4x4 giriş görüntüsüne 3x3 filtre uygulanması örneği	19
Şekil 3.9	Sıfır dolgu ekleme örneği	20
Şekil 3.10	2x2 boyutunda filtre ile adım sayısı 2 seçilerek yapılan havuzlama işlemi örneği	22
Şekil 3.11	Aktivasyon fonksiyonunun genel yapısı	23
Şekil 3.12	ReLU aktivasyon fonksiyonunun grafiği	24
Şekil 4.1	Orijinal görüntü (normal) & CLAHE (normal)	29
Şekil 4.2	Orijinal görüntü (OSCC) & CLAHE (OSCC)	29
Şekil 4.3	Eğitim ve test veri kümesindeki eleman sayısının yüzdeler dağılımı	31
Şekil 4.4	Artık öğrenme	32
Şekil 4.5	ResNet mimarisi	33
Şekil 4.6	Yoğun bağlantı yapısı	35
Şekil 4.7	DenseNet mimarisi	35

TABLO LİSTESİ

Tablo 4.1	Karmaşıklık matrisi	38
Tablo 4.2	Doğruluk değeri	41
Tablo 4.3	Kesinlik değeri	41
Tablo 4.4	Duyarlılık değeri	41
Tablo 4.5	F1-skor	42
Tablo 4.6	Özgüllük değeri	42
Tablo 4.7	Doğruluk değeri	42
Tablo 4.8	Kesinlik değeri	43
Tablo 4.9	Duyarlılık değeri	43
Tablo 4.10	F1-skor	43
Tablo 4.11	Özgüllük değeri	44
Tablo 5.1	Önceki çalışmalarla bulguları karşılaştırma. (Adam optimizasyonu için önerilen modeller)	45
Tablo 5.2	Önceki çalışmalarla bulguları karşılaştırma. (Stokastik Gradyan Azalma - SGD optimizasyonu için önerilen modeller)	46

Ağız Kanseri Tanısında Yapay Sinir Ağlarının Kullanımı

Betül SÜREN

Matematik Anabilim Dalı

Matematik Programı

Yüksek Lisans Tezi

Danışman: Doç. Dr. Mutlu AKAR

Kanser, küresel anlamda ölüm nedenleri arasında ikinci sırada yer almaktadır ve kanser vakaları her yıl hızla artmaktadır. Özellikle baş ve boyun bölgesinde ortaya çıkan kanser vakaları, sıklıkla karşılaşılan türler arasında yer almakta olup, bu kapsamda en yaygın görülen tür, ağız kanseridir. Ağız kanseri her yıl yaklaşık olarak 177 bin ölüme sebep olmaktadır.

Oral skuamöz hücreli karsinom (OSCC), ağız kanserinin en yaygın türüdür ve yaklaşık %90'ını oluşturur. OSCC teşhisinde, genellikle biyopsi yöntemi tercih edilir. Ancak, birçok hastanın biyopsiye karşı çekinceleri olduğundan, teşhis genellikle hastalığın ileri bir aşamasında konulur ve bu durum sağ kalım oranlarını olumsuz etkiler. Bu nedenle, hastalar tarafından tercih edilebilir, hızlı, güvenli ve düşük maliyetli sistemler geliştirmeye olan ilgi ve ihtiyaç artmaktadır. Bu bağlamda, bu çalışmada, OSCC teşhisi için derin sinir ağlarının güçlü mimarileri kullanılarak bir sınıflandırma gerçekleştirilmiştir. En etkili sonucu veren model ve hiperparametreleri seçerek, hızlı ve güvenilir bir sınıflandırma işlemi yapmak hedeflenmektedir.

Kullanılan veri seti, Kaggle platformundan temin edilmiştir. Bu veri seti, normal ve OSCC olmak üzere iki farklı sınıfa ayrılmıştır. Görüntülerin detaylarını ve kontrastını artırmak amacıyla CLAHE yöntemi uygulanmıştır. Ardından, veri ön işleme gerçekleştirilmiştir. Sonrasında ResNet mimarisinin ResNet101 ve ResNet152 varyasyonları kullanılarak bir sınıflandırma yapılmıştır. Sınıflandırma iki farklı optimizasyon algoritması ve 5 farklı dönem sayısı (epoch) için yapılarak

uygun optimizasyon algoritması ve dönem sayısı belirlenmiştir. Ardından benzer işlemler DenseNet mimarisinin DenseNet169 ve DenseNet201 varyasyonları ile yapılmıştır. Sonuç olarak Adam optimizasyonu kullanıldığında en yüksek doğruluk değerini %95.28 ile DenseNet169 mimarisi vermiştir. SGD optimizasyonu için ise en yüksek doğruluk değerini DenseNet201 mimarisi %97.01 olarak vermiştir.

Anahtar Kelimeler: Ağız kanseri, derin öğrenme, OSCC, ResNet, DenseNet.



ABSTRACT

The Use of Artificial Neural Networks in Oral Cancer Diagnosis

Betül SÜREN

Department of Mathematics

Master of Science Thesis

Supervisor: Assoc. Prof. Dr. Mutlu AKAR

Cancer ranks as the second leading cause of death worldwide , and cancer cases are rapidly increasing each year. Head and neck cancers are among the most frequently encountered types, with the most common type in this category being oral cancer. Oral cancer is responsible for an estimated 177,000 deaths annually.

Oral squamous cell carcinoma (OSCC) is the most common type of oral cancer, accounting for approximately %90 of cases. Biopsy is commonly preferred for diagnosing OSCC. However, because many patients have reservations about biopsies, the diagnosis is often made at an advanced stage of the disease, which negatively affects survival rates. Consequently, there is a growing interest and demand for the development of patient-preferred, rapid, safe, and cost-effective systems. In this study, a classification process was conducted for OSCC diagnosis using advanced deep neural network architectures. The aim is to achieve a fast and reliable classification process by selecting the most effective model and hyperparameters.

The dataset used was obtained from the Kaggle platform. To improve image clarity and contrast, the CLAHE method was utilized. Subsequently, data preprocessing was performed. Following that, a classification was conducted using variations of the ResNet architecture, namely ResNet101 and ResNet152. Classification was performed using two different optimization algorithms and for 5 different numbers of epochs, determining the appropriate optimization algorithm and number of epochs. Subsequently, similar procedures were performed using different variations

of the DenseNet architecture, such as DenseNet169 and DenseNet201. As a result, the DenseNet169 architecture provided the highest accuracy of %95.28 when Adam optimization was used. For SGD optimization, the DenseNet201 architecture yielded the highest accuracy at %97.01.

Keywords: Oral cancer, deep learning, OSCC, ResNet, DenseNet.



1.1 Motivasyon

Kanser vakalarındaki hızlı artış, erken teşhisin önemini bir kez daha hatırlatmış ve bu anlamda hızlı sonuçlar verebilen güvenilir sistemlerin geliştirilmesine yol açmıştır. Baş ve boyun kanserleri arasında yer alan ve en yaygın türü olan ağız kanseri, her yıl yaklaşık olarak 177.000 ölüme ve 350.000 yeni vakaya sebep olmaktadır. Ayrıca en yaygın ağız kanseri türü de Oral skuamöz hücreli karsinom (OSCC)'dir ve ağız kanserinin yaklaşık %90'ını oluşturmaktadır. Ağız kanseri teşhisinde kullanılan yöntemlerden biyopsi, özgünlük ve hassasiyet açısından belirsizdir ve birçok hasta tarafından maliyet vb. sebeplerle tercih edilmemektedir. Bu da erken teşhisin önüne geçmektedir. Dolayısıyla hem hızlı sonuçlar verebilen hem güvenilir hem de düşük maliyetli sistemlere ihtiyaç duyulmaktadır. Bu anlamda önerilen tanı yöntemleri ise yapay sinir ağları (ANN) aracılığıyla risk faktörlerinin değerlendirilmesi, laboratuvar testlerinin gerçekleştirilmesi ve lezyonların analiz edilmesidir. Buradan yola çıkarak bu çalışmada evrişimli sinir ağları yardımıyla Oral skuamöz hücreli karsinom (OSCC) görüntüleri üzerinde bir sınıflandırma yaparak hızlı ve düşük maliyetli teşhis yapabilmek hedeflenmektedir.

1.2 Katkılar

Evrişimli sinir ağları, sınıflandırma problemlerinde oldukça başarılı sonuçlar verdiği için bu çalışmada tercih edilmiştir. Evrişimli sinir ağlarından alınan iki farklı mimari bu anlamda değerlendirilmiş ve bu mimariler içerisinde iki farklı katmana sahip varyasyonları seçilerek kullanılan mimariler kendi içinde de değerlendirilmiştir. Ayrıca farklı hiperparametreler kullanarak hiperparametrelerin sonuca etkisi de araştırılmıştır. Bu çalışmada evrişimli sinir ağlarından ResNet ve DenseNet mimarileri ile çalışılmıştır. Resnet mimarisinin katman sayısına göre iki farklı varyasyonu olan ResNet101 ve Resnet152 alınmış, DenseNet mimarisinden de katman sayısına göre iki farklı varyasyonu olan DenseNet169 ve DenseNet201

alınmıştır. Toplam dört model kullanılmış ve bu dört model farklı iki optimizasyon algoritması ve 5 farklı dönem sayısı değeri için değerlendirilmiştir. Böylelikle katman sayısının, mimarinin yapısının, optimizasyon algoritmasının ve dönem sayısının sonuca etkisi değerlendirilmiştir. Bu değerlendirme sonuçlarının ileride yapılması amaçlanan çalışmalar için fikir olabileceği düşünülmektedir.

1.3 Taslak

Tezin ikinci bölümünde kanserin tanımından ve öneminden bahsedildikten sonra ağız kanserinin tanımı, vaka sayıları ile ilgili istatistikleri, risk faktörleri ve erken teşhisin önemi anlatılmıştır. Daha sonra teşhis ve tedavi yöntemlerinden bahsedilerek erken teşhis için geliştirilmesi istenen sistemlere olan ihtiyaç anlatılmıştır. Bölümün sonunda da bu anlamda yapılan çalışmalardan bahsedilmiştir.

Üçüncü bölümde yapay zeka, makine öğrenimi ve makine öğrenimi yöntemleri verildikten sonra yapay sinir ağları anlatılmıştır. Daha sonra derin öğrenme ve derin öğrenme modelleri verilerek adım adım evrişimli sinir ağlarına giriş yapılmıştır. Bu bölümde evrişimli sinir ağlarının nasıl çalıştığı detaylı olarak anlatılmıştır ve sonrasında evrişimli sinir ağları için önem taşıyan aktivasyon fonksiyonları, kayıp fonksiyonları ve optimizasyon algoritmaları verilmiştir. Ayrıca temel tanımlardan, öğrenme oranı tanımı, dönem sayısı tanımı ve parti boyutu (batch size) tanımı da verilerek bölüm bitirilmiştir.

Dördüncü bölümde öncelikle çalışmada kullanılan veri setinden ve veri setine uygulanan ön işlemlerden bahsedilmiştir. Ardından bu veri seti üzerinde kullanılan mimariler ve modeller açıklanmıştır. Daha sonra sonuçları değerlendirmek için kullanılan performans metrikleri ve sonuçlar verilmiştir.

Beşinci bölümde kullanılan modellerden ve hiperparametrelerden elde edilen en iyi sonuçlar, performans metriklerine göre verilmiş ve daha önceki çalışmalarla karşılaştırılmıştır. Son olarak da çalışmanın sonuçları değerlendirilerek bölüm bitirilmiştir.

2 AĞIZ KANSERİ GENEL BİLGİLER

2.1 Ağız Kanserinin Epidemiyolojisi

Kanser, normal doku hücrelerinde meydana gelen kontolsüz bölünme ve çoğalma sonucu oluşmaktadır [1]. Küresel anlamda 2018 yılında gerçekleşen ölümlerin 9,6 milyonu kanser kaynaklıdır [2]. Dünya genelinde 15 yıl içerisinde kanser oranının iki kattan daha fazla artabileceği düşünülmektedir [3]. Yine Küresel anlamda kanser, ölüm nedenleri içerisinde ikinci sıradadır ve günümüzde önemli bir sağlık problemidir. Kanser vakalarındaki bu hızlı artış 2030 yılına kadar böyle devam ederse kanserin ölüm nedenleri içerisinde ilk sırayı alacağı düşünülmektedir [4]. Ayrıca artışın bu şekilde devam etmesi halinde 2008 verilerine göre 2030 yılında yeni vaka sayısında %75 artış olabileceği de düşünülmektedir [2].

Her yıl yaklaşık olarak 630.000 kişiye baş ve boyun kanseri (BBK) tanısı koyulmaktadır [5, 6]. Baş ve boyun kanserleri; ağız boşluğu, dudak, tükürük bezleri, orofarenks, nazofarenks, tonsil, burun paranzal sinüs, hipofarenks ve orta kulak kanserlerini kapsar [7]. Ağız kanserleri ise, ağız ve yutak kanserleri arasında yer alır ve ağızda başlar [8].

Ağız kanseri, dünya çapında her yıl yaklaşık olarak 177.000 ölüme ve 350.000 yeni vakaya sebep olmaktadır ve en yaygın karşılaşılan kanser türleri arasında on birinci sırada yer almaktadır [5, 9]. Ağız kanserinin küresel insidansının üçte ikisinden fazlası düşük veya orta gelirli ülkelerde meydana gelmiştir [10]. Ayrıca, küresel anlamda ve orta gelirli ülkelerde yüksek riske sahip kanser türleri içinde altıncı sırada yer almaktadır [11].

Ağız kanseri, ağız boşluğu ve tüm alt bölgeleri, dudak ve orafarenks kanserlerini kapsamaktadır [12]. Ağız boşluğu dişleri, dudakları, dişetlerini, dudak ve yanakların iç bölgesini örten yanak mukozasını, dilin 2/3 ön tarafını, sert damağı ve ağız tabanını içerir. Yirmi yaş dişlerinin arka kısmı genellikle orofarenksin bir kısmı olarak kabul edilse de ağız boşluğu içinde yer alabilir. Ağız boşluğu ve orofarenks

konuşma, nefes alıp verme, çiğneme ve yutma gibi görevlere yardımcı olur. Yine bu bölgede bulunan tükürük bezleri de tükürük üretimi ile ağız nemli tutmaya ve yiyeceklerin yutulmasına yardım eder [8].

Oral skuamöz hücreli karsinom (OSCC), ağız kanserinin yaygın olarak karşılaşılan türüdür ve ağız kanserinin yaklaşık %90'ını oluşturmaktadır [13]. Ağız boşluğunda meydana gelen kanserlerin dünya sağlık örgütü tarafından sınıflandırması şu şekilde yapılmıştır [14]:

- Skuamöz hücreli karsinom,
- Verrüköz karsinoma,
- Minör tükürük bezlerinde meydana gelen tümör,
- Mukozal melanoma,
- Kaposi Sarkoması,
- Primer intraosseöz skuamöz hücreli karsinoma,
- Osteosarkoma,
- Nadir karşılaşılan malign tümörler,
- Metastatik tümörler.

Oral skuamöz hücreli karsinomlar da dahil olmak üzere mukozal karsinomlar, pozisyon, anamnez, etiyoloji ve metodoloji farklılıkları sebebiyle ayrı değerlendirilirler [15]. Ağız kanserinin genellikle karşılaşıldığı bölgeler; dudaklar, ağız tabanı, dil, diş etleri, ağız boşluğu ve çeşitli diğer bölgeleri yer almaktadır [13]. Bu lezyonlar, buldukları alanda tahribata neden olarak büyüme ve yayılma yeteneğine sahiptir [16].

Ağız kanserinin belirtileri aşağıdaki gibi sıralanabilir [8]:

- Yanakta bir kitle veya kalınlaşma,
- Çiğneme ve yutmada zorluk,
- Ağızda iyileşmeyen yara,
- Çeneyi veya dili hareket ettirmekte zorluk,
- Ağızda geçmeyen ağrı,

- Ses deęişiklikleri,
- Dilde veya aęzın dięer bir bölgesinde hissizlik,
- Boyunda bir şişlik veya kitle,
- Boęazda acıma veya boęazda sürekli bir takılma hissi,
- Kilo kaybı,
- Çenede protezin uyumunu bozan veya rahatsızlık oluşturan şişlik,
- Nefeste sürekli kötü koku,
- Diş eti, dil, bademcik veya aęız mukozasında beyaz veya kırmızı bir alanın/lezyonun olması,
- Dişlerin kaybı veya dişlerde veya çenede ağrı.

2.2 Risk Faktörleri

Orofarenks içinde gelişen karsinomlardan farklı olarak, aęız kanseri genellikle tütün ve alkol kullanımına baęlıyken, orofarenks kanserleri genellikle insan papillomavirüsü (HPV) etkisi altında oluşur [15]. Ancak son on yılda, HPV kaynaklı oral ve orofarengial kanserlerin insidansında bir artış olduğu ifade edilebilir [17–19]. Ayrıca, aęız kanseri risk faktörlerinin coęrafi bölgeye ve bölge halkının yaşam tarzı alışkanlıklarına baęlı deęiştiğini söylemek mümkündür [20]. Örneğin, Batı ülkelerde sigara içme ve alkol kullanımı önemli risk faktörleri iken, Güney Asya ve Pasifik ülkelerinde ise betel fıstığı çiğneme ve sigara kullanma önemli risk faktörleri arasındadır [21]. Özetlemek gerekirse aęız kanserinin başlıca risk faktörlerinin her türlü tütün ürünlerinin kullanılması, alkol kullanımı, kronik inflamasyon, betel fıstığı çiğneme ve HPV olduğu söylenilebilir [22–26].

2.3 Erken Teşhisin Önemi

OSCC tanısı genellikle hastalığın ileri evrelerinde yapıldığı için sağ kalım oranı düşüktür [27]. OSCC tanısı genellikle hastalığın üçüncü veya dördüncü aşamasında koyulur ve 5 yıllık sağ kalım oranının %15 ile %50 arasında olduğu söylenilebilir [28]. Ancak, teşhisin erken aşamalarda yani hastalığın ilk veya ikinci aşamalarında konulması halinde sağ kalım oranının yaklaşık olarak %80'e ulaşabileceği düşünülmektedir [29, 30].

Hastalığın teşhisinin yaklaşık olarak %50'si ileri aşamada yapılabilmektedir. Bunun nedeninin, hastaların erken aşamalarda belirgin semptomlara sahip olmaması veya hastanın ağrı, kanama ve ağız boşluğu veya boyunda kitle gibi belirgin semptomlar yaşamadan tıbbi desteğe başvurmaması ve lenfatik yayılımın gerçekleşmiş olabileceği düşünülmektedir [30]. Tanının bir aydan daha fazla gecikmesi durumunda, hastalığın ileri evrelerden birinde olması olasılığı artmaktadır [31]. Ayrıca, hastalık ilerlediği zaman ve lezyonun bulunduğu yere erişmek zor olduğunda prognoz da kötüleşmektedir [17].

2.4 Teşhis ve Tedavi Yaklaşımları

OSCC'nin teşhisinde biyobelirteçlerin kullanımı bir seçenek olabilir [32]. Bu süreçte, patolog tarafından hastadan alınan bir doku örneği ile biyopsi yapılır ve mikroskop altında değerlendirilir. Ancak, bu inceleme sadece hücre yapısı, doku dağılımı ve kanser seviyesinin görsel değerlendirmesiyle sınırlıdır [27]. Dolayısıyla, sonuçlar genellikle nitel bir değerlendirme olarak kabul edilir, özgünlük ve hassasiyet açısından belirsizlik mevcuttur. Bu nedenden dolayı ve ağız kanserinin ciddiyeti konusunda farkındalığın artmasından dolayı, güvenilir ve erken teşhis tekniklerine olan talep artmıştır [33].

Maliyet veya çeşitli farklı sebeplerden dolayı, birçok hasta biyopsiden kaçınmaktadır. Bu da, hastaların erken aşamalarda biyopsiyi geciktirmelerine veya yaptırmamalarına sebep olur ve erken teşhisin önüne geçer. Tüm bu nedenlerden dolayı, araştırmacılar daha erişilebilir tanı yöntemlerini önermişlerdir [34]. Bahsedilen tanı yöntemi, risk faktörlerinin değerlendirilmesi, laboratuvar testlerinin gerçekleştirilmesi ve lezyonların yapay sinir ağları (ANN) aracılığıyla analiz edilmesi ile ağız kanserinin teşhisini içermektedir [35].

2.5 Literatür Taraması

Bu bölümde ağız kanseri teşhisinde yapay sinir ağları kullanılarak yapılan çalışmalar özetlenmiştir.

Uthoff vd. [36] tarafından akıllı telefon tabanlı bir sinir ağı modeli önerilmiş ve %80 ile %90 arasında değişen hassasiyet, özgüllük, pozitif tahmin edici ve negatif tahmin edici değerleri elde edilmiştir. Yapılan bir başka çalışmada, Xu vd. [37], üç boyutlu evrişimli sinir ağları ile iki boyutlu evrişimli sinir ağlarını ağız kanseri teşhisi için kullanmış ve bu konuda üç boyutlu evrişimli sinir ağlarının iki boyutlu evrişimli sinir ağlarına göre daha başarılı sonuçlar verdiğini elde etmişlerdir. Gupta

vd. [38] tarafından derin öğrenme tabanlı bir, çok katmanlı sinir ağı modeli önerilmiş ve eğitim veri seti için %91.65 doğruluk, test veri seti için %89.3 doğruluk elde edilmiştir. Jeyaraj vd. [39] ise, bir bölünmüş derin evrişimli sinir ağı modeli önermişler ve 100 görüntüden oluşan bir veri seti için %91.4 sınıflandırma doğruluğu, %94 hassasiyet ve %91 özgüllük elde etmişlerdir, 500 görüntüden oluşan bir veri seti için de %94.5 doğruluk elde etmişlerdir.

Fu vd. [40] tarafından sunulan çalışmada, %98.3 AUC, %94.9 hassasiyet ve %88.7 özgüllük elde edilmiştir. Welikala vd. [41] ResNet101 algoritmasını kullandıkları bir çalışma sunmuşlar ve %78.30 eğitim doğruluğu elde etmişlerdir. Das vd. [42] sundukları çalışmada AlexNet, VGG-16, VGG-19 ve ResNet50 modellerini kullanmışlar ve bu dört model arasında en yüksek sınıflandırma doğruluğunu %92.15 ile ResNet50 modelinde elde etmişlerdir. Ayrıca, Das vd. sunmuş oldukları çalışmada kullandıkları bu dört model dışında kendi geliştirdikleri bir CNN modelini önermişler ve %97.5 doğruluk elde etmişlerdir. Chu vd. [43] SVM modelini kullanarak bir çalışma yapmış ve %70.59 eğitim doğruluğu elde etmişlerdir. Lin vd. [44] ise yaptıkları çalışmada akıllı telefon tabanlı görüntüler kullanmış ve bu görüntülere veri ön işleme uygulamışlardır, çalışmada CNN tabanlı HRnet algoritmasını kullanmışlar ve %83 hassasiyet, %96.6 özgüllük, %84.3 kesinlik ve %83.6 F1-skor değeri elde etmişlerdir.

Alhazmi vd. [45], yapay sinir ağı tabanlı tahmin modeli geliştirmişler ve veri setindeki her bir durum için yirmi dokuz değişken ele almışlardır. Hastalarla ilişkilendirilen bu yirmi dokuz değişken, modeli eğitmek için kullanılmıştır, çalışmanın sonucunda %85.71 hassasiyet, %60 özgüllük ve %78.95 doğruluk elde etmişlerdir. Shavlokhova vd. [46] tarafından sunulan bir çalışmada FCM (Ex vivo floresan konfokal mikroskopi) yöntemi kullanılmış ve aşırı uyumu önlemek için veri setine veri ön işleme uygulanmıştır, derin öğrenme modeli olarak da MobileNet algoritması kullanılmış ve %47 hassasiyet ile %96 özgüllük elde edilmiştir. Warin vd. [47] ise DenseNet-121 ve R-CNN modellerini kullanmışlar ve DenseNet-121 için %99 doğruluk, %100 hassasiyet ve %99 F1-skoru, R-CNN için %76.67 hassasiyet, %82.12 duyarlılık ve %79.31 F1-skoru elde etmişlerdir.

Jubair vd. [48], EfficientNet-B0 algoritmasını kullandıkları bir çalışma sunmuşlar ve %85 doğruluk, %84.5 özgüllük, %86.7 hassasiyet, %92.8 AUC elde etmişlerdir. Naditha B R vd. [49] ise, ResNet50 ve VGG-16 modellerinin avantajlarını birleştirdikleri bir derin öğrenme modeli önermişler ve %96.2 doğruluk, %98.14 hassasiyet, %94.23 özgüllük elde etmişlerdir. Gizem vd. [35], EfficientNet-b4, Inception-v4, DenseNet161, Ensemble ve ResNet152 modellerini kullanmışlardır. EfficientNet-b4 için 0.869 kesinlik, 0.855 duyarlılık ve 0.858 F1-skor, Inception-v4

için 0.877 kesinlik, 0.855 duyarlılık ve 0.858 F1-skor, DenseNet161 için 0.879 kesinlik, 0.841 duyarlılık ve 0.844 F1-skor, Ensemble için 0.849 kesinlik, 0.841 duyarlılık ve 0.843 F1-skor, ResNet152 için 0.826 kesinlik, 0.812 duyarlılık ve 0.811 F1-skor elde etmişlerdir.

Alkahadar vd. [50] karar ağacı modelini kullandıkları bir çalışma sunmuşlar ve %76 doğruluk elde etmişlerdir. Rahman vd. [51] transfer öğrenmeyi destekleyen bir model önermişler ve AlexNet'e dayalı bir algoritma kullanarak %90.06 eğitim doğruluğu elde etmişlerdir. Deif vd. [52] sundukları çalışmada özellik çıkarımı için VGG-16, AlexNet, ResNet50 ve Inception-V3 algoritmalarını, en iyi özellikleri seçmek için ikili parçacık sürü optimizasyonu (BPSO) algoritmasını, sınıflandırma için ise XGBoost algoritmasını kullanmışlardır ve en yüksek sınıflandırma doğruluğunu Inception-V3 ve BPSO kullanıldığında %96.3 olarak elde etmişlerdir.


Liyaneg vd. [53], MobileNet-V3 ve EfficientNet-V2 modellerini kullanmışlar ve MobileNet-V3 için duyarlılık, kesinlik ve F1-skor değerlerini %64 olarak elde etmişlerdir, EfficientNet-V2 için %64 duyarlılık, %61 kesinlik ve %62 F1-skor elde etmişlerdir. Zhou vd. [54] sınıflandırma görevi için ResNet50 modelini kullanmışlar ve %92.86 kesinlik, %91.84 duyarlılık, %92.24 F1-skor, %96.41 özgüllük, %91.86 hassasiyet ve %98.95 AUC değeri elde etmişlerdir, algılama görevi için ise YOLOV5 algoritmasını kullanmışlar ve %98.70 hassasiyet, %98.70 kesinlik, %79.51 duyarlılık, %88.07 F1-skor ve %90.89 AUC değeri elde etmişlerdir. Manikandan vd. [55], bir evrişimli sinir ağı modeli önermişler (CLAHE + GLCM + ICNN) ve %97.32 doğruluk elde etmişlerdir.

Ayrıca, erken teşhisin kritik olduğu çeşitli hastalıklar ve kanser türlerinin tespiti için daha önce farklı makine öğrenimi yöntemleri de farklı hastalıklarda tercih edilip başarılı sonuçlar elde edilmiştir [56–58]. Bu da erken teşhis anlamında makine öğrenimi ve derin öğrenme modellerinin son derece tercih edilebilir olduğunu göstermektedir.

3.1 Yapay Zeka Nedir?

Yapay zeka kavramı ilk olarak Hannover, New Hampshire, Dartmouth College'da gerçekleştirilen bir konferansta ortaya atılmıştır [59]. Yapay zeka, insana özgü anlama, geçmiş deneyimlerden öğrenme, çözüm geliştirme gibi üst düzey becerilerin bilgisayar veya bilgisayar destekli makineler tarafından yerine getirilebilmesi olarak ifade edilebilmektedir [60]. Kısacası yapay zekanın amacı zeki davranışlar sergileyebilen sistemler geliştirmektir. Yapay zekanın uygulama alanlarından bahsedilecek olursa konuşma tanıma [61, 62], görüntü işleme [63, 64], doğal dil işleme [65, 66], akıllı robotlar [67, 68], otonom araçlar [69, 70], enerji sistemleri [71, 72], sağlık [73, 74], fintech (finans teknolojisi) [75] olmak üzere pek çok kullanım alanı olduğu söylenebilir.

Yapay zeka kavramıyla birlikte akla ilk gelen kavramlar ise makine öğrenmesi ve derin öğrenmedir. Uygulama kısmında bazen birbirleri yerine de kullanılan bu kavramlar aslında temel farklılıklara sahiptirler. Makine öğrenimi yapay zekanın bir alt kümesidir ve derin öğrenme de makine öğreniminin bir alt kümesidir. Sonuç olarak her derin öğrenme uygulaması bir makine öğrenmesi uygulaması iken her makine öğrenimi uygulaması bir derin öğrenme uygulaması değildir [76]. Yapay zeka ve alt kümelerinin şeması şekil 3.1'de verilmiştir [77] :



Şekil 3.1 Yapay zeka ve alt kümeleri

3.2 Makine Öğrenimi Nedir?

Günümüzde veri artışının çok fazla olmasıyla birlikte bu verileri analiz etmeye olan ihtiyaç da artmıştır. Ayrıca veri erişilebilirliğinin yeterince fazla olması, veri sayısındaki artış ve hesaplama gücünün artması öğrenme anlamında yeni yöntemler geliştirilmesine neden olmuş ve bu da birçok bilimsel alanda çığır açıcı gelişmeleri beraberinde getirmiştir [78].

Arthur Samuel'a göre, Makine öğrenimi bilgisayarların açıkça programlanmadan öğrenme yeteneği kazandığı bir alan olarak tanımlanır [79]. Makine öğrenimi, bilgisayarların öğrenmesini sağlayan algoritmalar geliştirmekle ilgilidir. Öğrenme, verilerin istatistiksel yapılarını veya desen bulma gibi diğer yapılarını tespit etme sürecidir [80]. Makine öğrenme algoritmaları, bir görevi öğrenme sürecinde insanın öğrenme yaklaşımını temsil etmek üzere geliştirilmiştir [81].


Makine öğreniminde yaygın olarak kullanılan dört öğrenme yöntemi vardır, bunlar: denetimli öğrenim, denetimsiz öğrenim, yarı denetimli öğrenim ve pekiştirmeli öğrenimdir [82–84].

3.2.1 Denetimli Öğrenme

Denetimli öğrenme, girdi değerleri ve bunlara karşılık gelen çıkış değerleri ile beslenmiş eğitim verilerini içerir. Burada amaç girdi değerlerini çıkış değerlerine eşleyen modeli (genel kuralı) öğrenmektir, böylelikle sistem çıkış değeri belli olmayan yeni giriş değerleri için çıkış değeri tahmin edebilir [78].

Denetimli öğrenme uygulamaları, dış yardıma ihtiyacı olan uygulamalardır [79]. Genellikle sınıflandırma problemleriyle ilgilidir. Bu problemler arasında el yazısı tanıma, nesnelerin resimlerini sınıflandırma ve belge sınıflandırma gibi görevler bulunur [85].

Denetimli öğrenmenin temel adımları şöyledir: bir veri kümesi toplanır, daha sonra eğitim ve test kümesi olarak farklı kümelerine ayrılır; ardından eğitim kümesi kullanılarak hedef olan sonuç ile girdi verilerinin özellikleri arasındaki ilişkiyi anlatan model oluşturulur; son olarak modelin daha önce karşılaşmadığı test veri kümesi kullanılarak modelin performansı değerlendirilir [86]. Denetimli öğrenmenin adımlarının şeması şekil 3.2'de verilmiştir [79] :



Şekil 3.2 Denetimli öğrenme şeması

3.2.2 Denetimsiz Öğrenme

Denetimsiz öğrenme, girdi veri kümesindeki örnekler etiketsiz iken yapılan modellemedir [80]. Veri kümesindeki özellikleri keşfedip desenleri tespit etmeyi ve her bir örneği belirli kategorilere göre sınıflandırmayı hedefler [82–84]. Bu algoritma, denetimsizdir yani veri kümesinde olan veya olmayan desenleri ve özellikleri algoritmanın belirlemesi istenir, dışarıdan bilgilendirilmez [86].

Denetimsiz öğrenme algoritmaları, verideki yapıyı kendisi keşfeder ve veriden bazı özellikler öğrenir, böylelikle yeni veriyle karşılaştığında, daha önce öğrendiği özelliklerden yararlanarak yeni verinin sınıfını tanır [79].

Denetimli öğrenme ile karşılaştırılırsa; denetimsiz öğrenmede tahmin edilen bir sonuç yoktur yalnızca verideki desenler belirlenir [85].

Yaygın olarak kullanılan denetimsiz öğrenme uygulamaları kümeleme, ilişkilendirme, anormallik tespiti [82–84], sık desen tespiti ve boyut azaltmadır [78].

3.2.3 Yarı Denetimli Öğrenme

Yarı denetimli öğrenme, denetimli öğrenme ile denetimsiz öğrenmenin kombinasyonu olarak düşünülebilir [79]. Bu algoritma, uygun bir model veya sınıflandırıcı üretmek için hem etiketli hem de etiketsiz örnekleri içeren bir veri kümesi kullanır [80].

Yarı denetimli öğrenmenin denetimli öğrenme ile denetimsiz öğrenme arasında bir orta yol olduğu söylenebilir ve hem etiketli hem de etiketsiz örneklerin olduğu veri kümelerinde kullanışlıdır [84]. Genellikle örneklerin etiketlenmesi zaman alıcı veya maliyetli olduğunda tercih edilir. Tıbbi görüntüler için de oldukça kullanışlıdır. Örneğin bir doktor tıbbi görüntülerden oluşan bir veri kümesinden küçük bir alt küme alarak o kümedeki örnekleri etiketler ve bunları bir modeli eğitmek için kullanır, daha sonra oluşturulan model veri kümesindeki diğer etiketsiz örnekleri

sınıflandırmada kullanılır [86]. Sonuç olarak oluşturulan etiketli veri kümesi, teorik olarak denetimsiz modellere kıyasla daha iyi performans vermesi gereken bir model eğitimi için kullanılır [84].

3.2.4 Pekiştirmeli Öğrenme

Pekiştirmeli öğrenme, genel bir sonuç istenilen ve tek bir doğru cevabı olmayan belirli bir görev için kullanılır. Sadece veri ile değil deneme yanılma yolu ile beraber öğrenir [83, 84]. Pekiştirmeli öğrenmede algoritmanın kendi kendine öğrenmesi sağlanır [86]. Her hareket çevre üzerinde bir etkiye sebep olur ve çevre de, algoritmayı yönlendiren geri bildirimler verir [80]. Deneme yanılma ile algoritma hangi davranışın istendiğini öğrenmeye başlar ve sonunda nasıl hareket edeceğini öğrenerek başarıya ulaşır. Güçlü bir öğrenme tekniğidir ancak şu an için tıpta uygulamaları sınırlıdır [86].

3.3 Yapay Sinir Ağı Nedir?

Yapay sinir ağları, insan beyninin işleyişinden yola çıkarak geliştirilen bir hesaplama modelidir [87]. Bu model bilgi işleme açısından birbirine bağlı olan çok sayıda nöronun (düğümünden) oluşur [88]. Modelde yer alan nöronlardan oluşan kümeler işlem birimi olarak bilinir ve bu nöron kümeleri hem birbirlerine hem de diğer nöronlara bağlıdır [87].


Sistem içerisinde bulunan katmanlardaki nöronlar arasındaki bağlantılara ağı denilmektedir ve bu bağlantılar ağırlıkları temsil eder, ağırlıklar bir nöronun etkisini belirler [87]. Yapay sinir ağında bulunan bir nöron kümesi (işlem birimi); özellikler, kavramlar, harfler veya anlamlı bir takım soyutlama modelleri gibi farklı temsilleri içerebilir [89].

Yapay sinir ağı, klasik bilgi işleme teknolojilerinden çok daha farklı bir yapıya sahiptir. Geleneksel yapay zeka mantık temelli olup yapılandırılmamış bilgiyi işleme konusunda bazı noktalarda yetersiz kalırken yapay sinir ağı öz-organize olabilen, adaptif ve gerçek zamanlı öğrenebilme özelliklerine sahip paralel dağıtılmış bir sistemdir [90].

Yapay sinir ağları veri setine uyum sağlayabilmektedir. Ayrıca gürültülü ve eksik değerlere sahip veri setleri için de uygundur [91].

İlk yapay nöron modeli, 1943 yılında McCulloch ve Pitts tarafından önerilmiştir. Bu modelin sonlu sayıda nöron ve ağırlıklar ile hesaplanabilir bir işlemi

gerçekleştirebileceğini kanıtlamışlardır. Modelin giriş katmanında veri alınır ve ağırlıklı bağlantılar ile gizli katmana iletilir. Matematiksel olarak veriler işlenir ve sonucu sonraki katmanda yer alan nöronlara iletilir. Ağın çıkışı, en son katmanda yer alan nöronlar ile sağlanır [91]. Temel olarak bir yapay sinir ağının modeli şekil 3.3’de verilmiştir [92] :



Şekil 3.3 Yapay sinir ağı modeli

Bir gizli katmanda yer alan b . nöron sisteme girilen veriyi (x_a) işler ve aşağıdaki şekilde hesaplanır [93]; (a) ağırlıklı toplamın hesaplanması ve eklenmesi, (θ_b) yanılma terimi (bias) eklenmesi :

$$net_b = \sum_{a=1}^k x_a * w_{ab} + \theta_b \quad b = (1, 2, 3, \dots, n) \quad (3.1)$$

Yapay sinir ağları desen tanıma, otomatik kontrol, tahmin, değerlendirme, akıllı robot, ekonomi, biyoloji ve tıp gibi pek çok alanda başarılı sonuçlar vermiştir [94].


Yapay sinir ağları yapısal anlamda ileri beslemeli ağlar ve geri beslemeli ağlar olarak iki sınıfta incelenir. İleri beslemeli ağlar, giriş katmanından çıkış katmanına doğru bilgi akışının tek yönlü ilerlediği ağlardır [95]. Geri beslemeli ağlar ise geri beslemeli bağlantılar içerirler ve herhangi bir sinirin çıkış katmanından giriş katmanına doğru bilgi akışı vardır [96]. Ayrıca iki yapıyı birlikte içeren ağlar da mevcuttur [95]. Geri yayılım ile eğitilen ileri beslemeli ve çok katmanlı ağlar kullanışlı ve güvenilir olmalarından dolayı en çok kullanılan ağlardır [97].

3.4 Derin Öğrenme Nedir?

Derin öğrenme, veri kümesinden aldığı bilgileri kendi kendine öğrenebilen ve karmaşık işlemler yapabilen bir algoritmadır. Makine öğrenimindeki gelişmelerden yola çıkarak geliştirilmiştir. Makine öğrenimindeki özelliklerden daha gelişmiş ve hızlı özellikler derin öğrenmede sistem tarafından kendi kendine oluşturulur. Derin öğrenmede çok katmanlı sinir ağları kullanılır. Bir katmanın çıktısı diğer bir katman için girdi niteliğindedir [98]. Derin mimari yapısıyla karmaşık yapay zeka problemlerini çözebilmektedir [99].

Derin öğrenmede eğitimin amacı, her katman için en iyi ağırlık parametrelerini elde etmektir. Böylelikle basit özellikler karmaşık özellikler ile en uygun şekilde birleştirilir ve veriden en uygun temsiller sıralı olarak öğrenilebilir [100]. Yaygın olarak kullanılan eğitim yöntemi, tahmin edilen etiketler ile eğitim etiketleri (gerçek etiketler) arasındaki hatayı en aza indirmek için tüm ağırlıkları iteratif olarak güncelleyen geri yayılımdır. Geri yayılım, ağırlıkları ayarlamak gerektiğinde ne kadar ayarlanacağını öğrenmek için hesaplamaların çıkıştan girişe (geriye) doğru akışı için kullanılan bir terimdir ve bu geriye yayılım ile ileri geçişte hesaplanmış olan ara değerler yeniden verimli bir şekilde kullanılmış olur [101].

Öncelikle veri seti alınır, daha sonra her katman için çıkış hesaplanır ve elde edilen sinyaller ağ boyunca ileri doğru iletilir. Çıktı katmanında, bir kayıp fonksiyonu, tahmin edilen ile verilen etiketler arasında oluşan hatayı hesaplar [102]. Bu eğitim hatası en aza indirilmek için, geri yayılım kullanılır ve ağ boyunca hata sinyalleri geriye doğru iletilir. Böylelikle ağırlıklara göre gradyanlar hesaplanır [103]. Bu gradyanlar, ağıdaki her ağırlık için hatanın ilgili ağırlık ile ilişkisini ifade eder. Son olarak da ağırlıklar güncellenir [104]. Temel olarak bir derin sinir ağının modeli aşağıda şekil 3.4 ile verilmiştir [105] :



Şekil 3.4 Derin sinir ağı modeli

Derin sinir ağıları, bir giriş katmanı, birden fazla gizli katman ve bir çıkış katmanından oluşur. Giriş verileri için çıkış değerleri her katmanda sırayla hesaplanır. Her katman, bir önceki katmandan gelen çıkış değerlerini giriş vektörü olarak alır ve mevcut katmanda her birim için ağırlık vektörüyle çarpılarak ağırlıklı toplam elde edilir [100]. Ardından ağırlıklı toplama sigmoid, ReLU veya hiperbolik tanjant gibi doğrusal olmayan fonksiyonlardan biri uygulanır ve çıkış değeri hesaplanır [106]. Her katmanda gerçekleştirilen hesaplama, önceki katmanlardaki temsillere göre biraz daha soyut olan temsillere dönüştürülür [102].

Derin öğrenme, hesaplama anlamında oldukça yoğundur ve modellerin uygun bir süre içinde eğitilebilmesi için grafik işlemcileri (GPU'lar) ve benzer bilgisayar donanımları kullanılır [101]. Sınırlı sayıda veri ile çalışıldığında transfer öğrenme olarak bilinen bir yaklaşım ile, söz konusu problemdeki büyük veri setlerinden yararlanılarak performansı arttıracak şekilde geliştirilmiştir ve yeterli veri seti ile çalışıldığında çok daha iyi sonuçlar vermektedir [107].

Derin öğrenmenin sınıflandırma, tahmin, kontrol, görüntü sınıflandırma ve teşhis gibi pek çok kullanım alanı vardır [98].

3.4.1 Derin Öğrenme Modelleri

Farklı problemlere çözüm getirmek için geliştirilmiş farklı derin öğrenme modelleri mevcuttur. Bu modeller, içerdikleri katman sayısı, karmaşıklığı, veri seti özellikleri, kullanılan kütüphaneler ve programlama dili gibi farklı özelliklere göre birbirinden ayrılırlar. Geliştirilen derin öğrenme modelleri, endüstri, ses, tıp ve sınıflandırma gibi pek çok uygulama alanında kullanılmaktadır [108].

Yaygın olarak kullanılan derin öğrenme modellerinden bazıları şunlardır: Evrişimli Sinir Ağı (CNN), Tekrarlayan Sinir Ağı (RNN), Uzun Kısa Süreli Bellek (LSTM), Kısıtlanmış Boltzmann Makinesi (RBM), Otomatik Kodlayıcı (Auto Encoder) [108].

Aşağıda yaygın olarak kullanılan derin öğrenme modelleri kısaca açıklanmıştır. Ancak görüntü analizinde sıklıkla tercih edilmesinden [109] ve başarılı sonuçlar vermesinden dolayı bu çalışmada evrişimli sinir ağı kullanılmıştır. Burada kısaca açıklanan evrişimli sinir ağı, bir sonraki bölümde detaylı olarak açıklanmıştır.

Evrişimli Sinir Ağı (Convolutional Neural Network - CNN): Görüntü analizinde sıklıkla tercih edilen evrişimli sinir ağı, filtre tabanlı ve çok katmanlı bir derin öğrenme modelidir ve ileri beslemeli bir sinir ağı yapısına sahiptir [109].


Tekrarlayan Sinir Ağı (Recurrent Neural Network - RNN): Dil çevirirlerinde sıklıkla kullanılan bu model ardışık verilerden yararlanarak bir sonraki adımı tahmin etme sürecinden oluşur. Örnek olarak tamamlanmamış bir cümle içerisindeki kelimelerden yola çıkarak cümlenin devamının tahmin edilmesi verilebilir [110].

RNN'ler, ardışık bilginin kullanılabilmesi için geliştirilmiş döngüsel bağlantı yapılarından oluşmuşlardır. Giriş bilgileri ardışık olarak işlenir ve gizli birimlerde bulunan döngüsel bağlantılar ile bu birimlerde tekrarlayan hesaplamalar gerçekleştirilir [100]. Gizli birimler durum vektörleri olarak da adlandırılırlar ve geçmiş bilgi burada saklanır. Söz konusu girişin çıktısı, daha önceki tüm girişler dikkate alınarak ve durum vektörleri kullanılarak hesaplanır [102].

Uzun Kısa Vadeli Bellek (Long Short Term Memory - LSTM): RNN'in bir varyasyonudur [108]. LSTM, kaybolan gradyan problemini çözmek için geliştirilmiş bir modeldir [111]. RNN kısa vadeli bilgiyi hatırlayabiliyorken LSTM, uzun vadeli veriler ile çalışabilir. Önceki giriş ve durum bilgilerini saklayabilme özelliğine sahiptir. Ayrıca sahip olduğu bir kontrol mekanizması sayesinde hangi bilgileri saklayacağına otomatik karar verebilir [108]. LSTM modelinin üç kapısının olduğu söylenebilir ve bu kapılar şöyledir: birinci kapı giriş kapısıdır ve yeni bilgileri kontrol eder, ikinci kapı unutma kapısıdır ve daha önce kullanılan bilgileri siler, üçüncü kapı ise çıkış kapısıdır ve bilgileri düzenler [109, 112].

Kısıtlanmış Boltzmann Makinesi (Restricted Boltzmann Machine - RBM): Boltzmann makinesi görünür ve gizli kısım olarak iki bölümden oluşur. Sadece görünür birimler veri ile bağlanmıştır ve verinin dağılımını tanımlamada görünür birimlere yardımcı olarak gizli birimler kullanılır. RBM'de olan kısıtlama ise görünür birimler arasında ve gizli birimler arasında bağlantı olmamasıdır [111].

RBM'ler, özellik öğrenme ve sınıflandırma alanlarında kullanılabilirler. İki katmanlı bir yapıya sahiptirler. Bu katmanlar giriş ve gizli katmanlar olarak isimlendirilmişlerdir. Giriş verilerini kullanarak olasılıksal grafik modeli oluştururlar [113]. RBM'lerde gizli birimler ile görünür birimler arasındaki bağlantının kaldırılmasıyla model, çift taraflı grafik halini alır. Şekil 3.5'de RBM modeli verilmiştir [111] :




Şekil 3.5 Kısıtlı Boltzmann Makinesi modeli

Derin Otomatik Kodlayıcılar (Auto Encoder): Denetimsiz öğrenme algoritmasının kullanıldığı bir modeldir. Sınıflandırma özelliği olmayan bu modelde, giriş veri setinin boyutu daha küçük bir vektör elde edebilmek için azaltılır. Daha sonra giriş yeniden oluşturulmak için çalışılırken çıkışın, giriş veri kümesi ile aynı özelliklerde elde edilmesine çalışılır [114, 115].

3.4.2 Evrişimli Sinir Ağı

Evrişimli sinir ağı ilk kez LeCun vd. tarafından tanıtılmıştır [116]. Çok katmanlı sinir ağı yapısına sahip bir mimaridir. Şekil 3.6'da sınıflandırma modeli için evrişimli sinir ağının yapısı verilmiştir [117] :



Şekil 3.6 Evrişimli sinir ağı mimarisi (sınıflandırma problemi için)

CNN, görüntü verileri gibi ızgara desenine sahip veri kümelerinde işlemler yapabilmek üzere geliştirilmiş bir derin öğrenme modelidir [118, 119]. Görüntüler piksel değerlerinden oluşur ve bu piksel değerleri de iki boyutlu bir ızgarada saklanır [120]. Bu ızgaranın bir matris olduğu söylenebilir. Şekil 3.7'de bir görüntünün matris karşılığı verilmiştir [121] :



Şekil 3.7 Bilgisayarda bir görüntünün karşılığı

Bilgisayar herhangi bir resmi sayı dizisi şeklinde algılar. Şekil 3.7’de sağ tarafta yer alan matris, sol tarafta yer alan görüntünün piksel parlaklığına karşılık gelen 0 ile 255 arasındaki sayılardan oluşmuştur [120].

Her görüntü konumuna matris formunda ve özellik çıkartıcı olarak tanımlanmış filtreler uygulanır, bu filtreler optimize edilebilirler. Bir özellik görüntü üzerinde herhangi bir konumda ortaya çıkabileceği için bu işlem CNN’leri görüntü analizi yaparken verimli kılar [120].

Parametrelerin optimize edilmesi sürecine eğitim denilmektedir. Parametre, eğitim süreci içerisinde otomatik olarak öğrenilen değişkenleri ifade ederken Hiperparametre, eğitim süreci başlamadan ayarlanılan değişkenleri ifade eder [120].

CNN mimarisi, genellikle üç çeşit katmandan oluşur: evrişim katmanı, havuzlama katmanı ve tam bağlantılı katman [120]. Her katmanda birden fazla iki boyutlu düzlem vardır ve her düzlemde de birden fazla nöron bulunur, üç boyutlu girişin çıktısı değeri de her katmanda üç boyutludur [117].

Evrişim ve havuzlama katmanı özellik çıkarma işlemlerinde kullanılırken, tam bağlantılı katman sınıflandırma yapar [120].

Model resmi tanıdığına giriş katmanında resmin bütün detayları saklanır, üç boyutlu vektör diyagramında ilk iki boyut orijinal genişliği ve yüksekliği temsil ederken üçüncüsü yani derinlik ise resmin rengini temsil eder [117].

Evrişimli sinir ağının giriş resmi ile iyi uyum sağlayabilmesi, eğitim sırasında özellik çıkarma işlemi ile desen sınıflandırma işlemini eş zamanlı olarak gerçekleştirebilmesi ve ağırlık paylaşımı ile eğitim parametrelerinin azaltılabilmesi bu ağların görüntü işleme alanında geleneksel sinir ağlarına göre daha avantajlı

olduğunun söylenebilmesini sağlar [117].

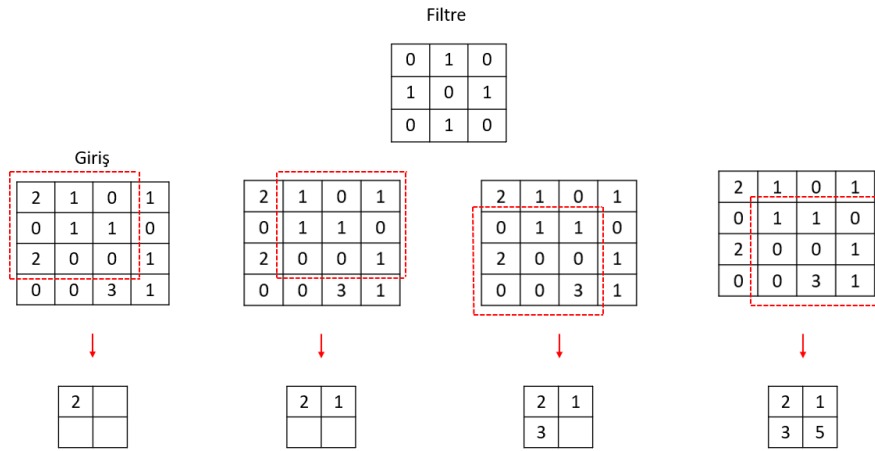
CNN'ler lezyon tespiti [122], segmentasyon [123], doğal dil işleme [124], sınıflandırma [125] ve resimleri yeniden yapılandırma [126, 127] gibi pek çok uygulama alanında kullanılmaktadır.

Evrişim Katmanı: Evrişim katmanı, ardı ardına gerçekleştirilen bir yığın matematiksel işlemde oluşur [120]. Evrişim işlemi de bu işlemlerden biridir. Evrişim katmanında amaç, girdi verilerinin özelliklerinin temsillerini öğrenmektir [128]. Yani evrişim katmanı özellik çıkarma işleminin gerçekleştiği katmandır [120].

Evrişim katmanında filtre olarak adlandırılan ve sayılardan oluşan bir matris giriş görüntüsünün piksel değerlerinden oluşan matris üzerine uygulanır [120]. Evrişim filtresi görüntü üzerinde belirli bir bölgeye odaklanmak ve bölgedeki özellikleri çıkarmak için kullanılır [128].

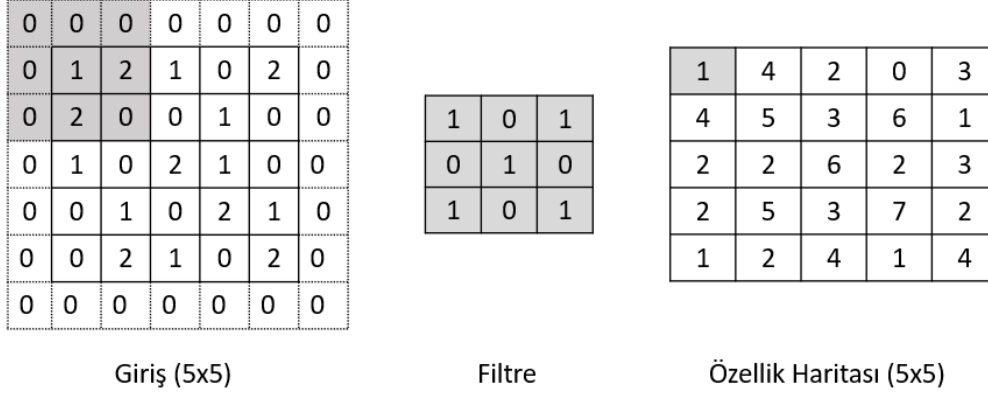
Evrişim işleminde filtre boyutu ve sayısı olmak üzere iki temel hiperparametre vardır. Filtre boyutu genellikle 3x3, 5x5, veya 7x7 olabilmekte iken filtre sayısı özellik haritalarının derinliğini belirleyen hiperparametrelerdir ve filtre sayısı keyfi olarak belirlenir [120].

Evrişim katmanının çıktısı, giriş ve filtre değerleri arasında yapılan nokta çarpımın hesaplanması sonucu elde edilir [129]. Giriş görüntüsünün elemanları ile filtrenin elemanları arasında eleman bazında bir çarpım işlemi yapılır ve karşılık gelen konumun çıktısı elde edilmiş olur [120]. Bu işlem için bir örnek şekil 3.8'de verilmiştir [130] :



Şekil 3.8 4x4 giriş görüntüsüne 3x3 filtre uygulanması örneği

Filtre matrisinin merkezi giriş görüntüsünün piksel değerlerinden oluşan matrisin en dıştaki ögesinin üzerine koyulmaz ve çıkış özellik haritası girişin genişliğini ve yüksekliğini azaltır. Filtre uygulandıktan sonra oluşan boyut farkını gidermek için sıfır dolgu adı verilen bir işlem uygulanabilir. Bu işlem giriş görüntüsünün etrafına sıfır satırları ve sütunları eklemekten oluşur. Böylece filtrenin merkezi giriş görüntüsünün en uç ögesine oturtulabilir ve boyutu korunabilir. Aşağıda şekil 3.9 ile sıfır dolgu ekleme örneği verilmiştir [120] :



Şekil 3.9 Sıfır dolgu ekleme örneği

Aynı anda birden fazla filtre kullanılarak farklı özellikler belirlenebilir [117]. Yani farklı filtreler farklı özellik çıkarıcıları olarak düşünülebilir. İki ardışık filtre konumu arasında olan mesafeye ise adım denir ve adım sayısı genellikle 1 seçilir [120].

CNN modelinde eğitim süreci, belirli bir görevi yerine getirmek için en uygun filtreleri belirlemektir. Eğitim boyunca evrişim katmanında otomatik bir şekilde öğrenilen tek parametre filtrelerdir. Filtre boyutu, sayısı, adım sayısı ve dolgu işlemi ise eğitim sürecinden önce ayarlanması gerekli olan hiperparametrelerdir [120].

Evrişim işleminde filtrenin görüntünün tüm konumları boyunca paylaşılmasıyla ağırlık paylaşımı gerçekleşmiş olur ki bu evrişimin temel özelliğidir. Evrişim işleminde gerçekleştirilen bu ağırlık paylaşımı şu özellikleri oluşturur: filtreler görüntü boyunca gezdirilirken bölgesel özellikleri öğrenir, daha büyük bir görüş alanı yakalar, öğrenilecek parametre sayısını azaltır ve böylelikle model verimliliği artar [120].

Giriş verisine filtre uygulandıktan sonra oluşan çıktıya özellik haritası denir [131] ve özellik haritası sayısı ile filtre sayısı aynıdır [117].

Evrişim katmanı birden fazla özellik haritasından oluşmaktadır. Bir özellik

haritasında her bir nöron, bir önceki katmandaki nöronların komşuluklarıyla bağlanmıştır. Yeni özellik haritalarını elde etmek için farklı birkaç filtre kullanılır. Aynı filtre kullanılarak bir özellik haritası oluşturulur [128].

Herhangi bir yeni özellik haritasını hesaplayabilmek için, önceden öğrenilen bir filtreyle giriş özellik haritaları evrişilir ve sonuçlar doğrusal olmayan bir aktivasyon fonksiyonundan geçer [128]. Evrişim doğrusal bir işlemdir [120]. CNN'de doğrusal olmayanlığı aktivasyon fonksiyonu katar [128]. Genellikle kullanılan aktivasyon fonksiyonları sigmoid, tanh ve ReLU'dur [106].

Havuzlama Katmanı: Giriş verisinin boyutunu, modeldeki parametre sayısını ve hesaplama sayısını azaltmaktadır [129]. Havuzlama katmanına alt örnekleme katmanı da denir [132]. Havuzlama katmanı, evrişim katmanları arasında olan bağlantı sayısını azaltır ve böylelikle hesaplama yükü de azalır [128]. Yani, havuzlama katmanı özellik haritalarına boyut azaltma işlemi uygular. Böylelikle küçük kayma veya bozulmalar model tarafından tanınır ve ardışık öğrenilebilir parametre sayısı da azalır [120].

Havuzlama katmanında özellik haritalarının çözünürlükleri azaltılırken özelliklerin konumdan bağımsız olarak korunması amaçlanır. Bu katmanda yer alan her özellik haritası mevcut katmandan önce gelen evrişim katmanında karşılık gelen özellik haritasıyla bağlanır. Bu sebeple havuzlama katmanı ile kendisinden önce gelen evrişim katmanı aynı sayıda özellik haritası içermektedir [128].

Havuzlama katmanının amacı boyut azaltmaktır [117]. Bu katman hesaplamaları hızlandırır ve aşırı uyumu önler [129]. Havuzlama katmanında öğrenme gerçekleşmemektedir. Filtre boyutu, adım ve dolgu hiperparametreleri bu katmanda da bulunmaktadır [120].


Havuzlama katmanı genellikle iki evrişim katmanı arasında yer alır. Daha soyut özellikleri temsil etmek için birkaç evrişim katmanı ile havuzlama katmanı bir araya getirilebilir [128]. Havuzlama işlemi genellikle ortalama havuzlama [133] ve maksimum havuzlama [134–136] olarak iki farklı şekilde yapılabilir.

Maksimum Havuzlama: Sıklıkla kullanılan havuzlama yöntemidir. Giriş özellik haritalarını bölümlere ayırır ve her bölümün maksimum değerini alır. Genellikle 2x2 boyutunda ve adım sayısı 2 seçilerek kullanılır. Özellik haritalarının boyutunda değişiklik olmaz [120].

Ortalama Havuzlama: Havuzlama yöntemlerinden bir diğeridir [137]. Bu yöntemde de derinlik değişmez. Bir önceki yöntemden farklı olarak özellik haritasında

öğelerin ortalaması alınarak oluşturulur. Bu yöntem genellikle tam bağlantılı katmanlardan önce ve bir kez uygulanır. Öğrenilebilir parametrelerin sayısının azaltılması ve CNN'in değişken boyutlarda girişleri kabul etmesinin sağlanması bu yöntemin avantajlarından [120].

Şekil 3.10'da havuzlama işlemi örneği verilmiştir [130] :



Şekil 3.10 2x2 boyutunda filtre ile adım sayısı 2 seçilerek yapılan havuzlama işlemi örneği

Yüksek seviyeli analizler yapabilmek için birkaç evrişim ve havuzlama katmanından sonra bir veya daha fazla tam bağlantılı katman eklenebilir [128].

Tam Bağlantılı Katman: Bu katmanda evrişim ve havuzlama katmanlarından alınan son çıktı özellik haritaları düzleştirilir yani vektöre dönüştürülür [120]. Tam bağlantılı katman konumsal bilgiyi saklayamaz ve önceki katmanda bulunan tüm nöronları mevcut katmanda karşılık gelen her tek nöronla bağlar [128]. Gelenksel sinir ağlarında olduğu gibi bu katmanda yer alan nöronlar da önceki katmanlarda bulunan tüm nöronlar ile tamamen bağlıdır [138].

Her girdinin her çıktıya öğrenebilen ağırlıklarla bağlı olduğu ve yoğun katmanlar olarak bilinen bir veya birden daha fazla tam bağlantılı katmana bağlanır [120]. En son kullanılan tam bağlantılı katmandan elde edilen çıktılar bir çıkış katmanına beslenir [128]. Genellikle son tam bağlantılı katmanda sınıf sayısı kadar çıktı düğümü vardır [120].


Tam bağlantılı katmanda evrişim ve havuzlama katmanları tarafından oluşturulan özellikler ağırlıklı nihai çıktılarıyla eşlenir. Her tam bağlantılı katmanın ardından ReLU gibi doğrusal olmayan bir fonksiyon gelir [120]. Tam bağlantılı katmanlar aktivasyonlardan tahminler üretmeyi amaçlar. Genellikle sınıflandırma ve regresyon uygulamalarında kullanılır [129]. Çıktıları olasılık dağılımını iyi şekillendirebildiği için softmax regresyonu sınıflandırma görevlerinde sıklıkla tercih edilir [139].

3.4.2.1 Aktivasyon Fonksiyonları

Bir görüntü verisi ile görüntü sınıfı arasındaki ilişki doğrusal değildir. Aralarındaki doğrusal olmayan bu ilişki aktivasyon fonksiyonu kullanılarak sağlanır [140].

Sinir ağlarında yer alan her nöron, bir önceki katmanda yer alan nöronların çıktılarını girdi olarak alır ve işleyerek bir sonraki katmana iletir. Böylelikle bilgi sürekli bir iletim halinde tutulur. Aktivasyon fonksiyonu ise bir sonraki nörona iletilmesi gereken bilgileri belirler [141]. Aktivasyon fonksiyonları girişi bir sayı olan, doğrusal olmayan fonksiyonlardır ve bu sayı üzerine birtakım matematiksel işlemler uygularlar [138].

Çok katmana sahip sinir ağlarında her iki katman arasında bir aktivasyon fonksiyonu bulunur. Aktivasyon fonksiyonunun genel yapısı şekil 3.11'deki gibidir [141]:



Şekil 3.11 Aktivasyon fonksiyonunun genel yapısı

Şekil 3.11'de n özellik aynı anda j . nörona giriş yapar ve burada x_i : giriş özelliği, w_{ij} : giriş özelliği ile nöron arasındaki bağlantının ağırlığı, b_j : nöronun iç durumu, y_j : nöronun çıktısı ve $f(\cdot)$: aktivasyon fonksiyonudur [142]. Yani, aktivasyon fonksiyonu ağırlıklı toplamı türetir ve bias (yanılma payı) ekleyerek gizli katmanı güçlendirir [143].

Eğer aktivasyon fonksiyonu kullanılmıyaydı mevcut katman ile öncesindeki katman arasında doğrusal bir ilişki olurdu. Bu ise gizli katmanların ağa bir etkisi olmadığı anlamına gelir. Böyle bir durumda ağ, sınırlı öğrenme yeteneğine sahip olurdu [141].

Aktivasyon fonksiyonu bir evrişimli sinir ağının performansında önemli bir artış sağlar [128]. CNN'ler farklı aktivasyon fonksiyonları kullanarak karmaşık özellikleri ifade edebilirler [141].


ReLU (Rectified Linear Unit): Evrişim katmanları için en çok tercih edilen

aktivasyon fonksiyonudur [130]. Yarı doğrusal bir fonksiyondur [106, 116]. Matematiksel formülü aşağıdaki gibidir [130]:

$$f(x) = \max(0, x) = \begin{cases} 0, & x < 0 \\ x, & x \geq 0 \end{cases} \quad (3.2)$$

ReLU, sıfırdan küçük x değerleri için sıfır, sıfırdan büyük x değerleri için x'i verir [141].

ReLU fonksiyonu öğrenmeyi hızlandıran bir fonksiyondur. ReLU'nun türevi sabittir ve x sıfırdan küçük iken türevi sıfır, x sıfırdan büyük iken türevi 1 olduğundan ideal bir yakınsama sunar. ReLU aktivasyon fonksiyonunun grafiği Şekil 3.12'de verilmiştir [141] :



Şekil 3.12 ReLU aktivasyon fonksiyonunun grafiği

Sıfırdan küçük x değerleri için gradyan sıfır olacağından geri yayılacak hata sıfır ile çarpılır, bu da önceki katmana bir hata ileilmeyeceği anlamına gelir. Burada oluşan nöronlara ölü nöron denir [141] ve ölü nöronlar sıfırlanabilir [140]. ReLU, geri yayılımı olumsuz etkilese de birçok çalışma ReLU'nun aktivasyon fonksiyonları arasında iyi çalıştığını kanıtlamıştır [128]. ReLU, ile gradyan inişinin yakınsama hızı artırılabilir [138].

Softmax: Genellikle bir CNN ağının son katmanında kullanılan [144] softmax aktivasyon fonksiyonu, ağın performansını artırmak için tercih edilir [145].

Görüntü sınıflandırma uygulamalarında da sınıflandırma yapmak için son katmanda kullanılır [143]. Katman içindeki düğümler, bir olasılık dağılımında çıktı olarak döndürülen olasılıkların yer aldığı çıkış katmanı ile ilişkilendirilir [146–149].

Softmax aktivasyon fonksiyonunun denklemini aşağıda verilmiştir [144]:

$$\alpha(c)_j = \frac{e^{c_j}}{\sum_{k=1}^K e^{c_k}} \quad (3.3)$$

3.4.2.2 Kayıp Fonksiyonları

Kayıp fonksiyonu, ağıın ürettiği çıktı tahmini ile gerçek etiketler arasında olan ilişkiyi verir [120]. Genellikle eğitim aşamasını yönlendirme amacıyla kullanılır [129].

Çok sınıflı sınıflandırma uygulamalarında genellikle tercih edilen kayıp fonksiyonu cross entropy (çapraz entropi) fonksiyonudur [120]. Gerçek dağılım ile tahmin edilen dağılım arasındaki farkı değerlendirmeye yarar. Çapraz entropi kaybına softmax kaybı da denilmektedir. Evrişimli sinir ağlarında softmax katmanı ile birlikte kullanılır [141].

Her sınıf için tahmin edilen olasılık değeri ile sınıfın gerçek değerini (0 veya 1) karşılaştırır. Tahmin edilen değer ile gerçek değer arasındaki uzaklığa bağlı ceza değeri hesaplar. Ceza değeri logaritmiktir, bu nedenle fonksiyon daha küçük uzaklıklar için daha küçük ceza puanı (örneğin, 0.1 veya 0.2) ve daha büyük uzaklıklar için daha büyük ceza puanı (örneğin, 0.9 veya 1.0) verir [141].

Çapraz entropi kaybı farklı sınıflar arasındaki marj veya aynı sınıf içerisindeki yoğunluk derecesi ile ilgilenmez, sadece sınıflandırma doğruluğu ile ilgilenir. Çapraz entropi kaybı en popüler kayıp fonksiyonudur ve genellikle ağıının sonunda softmax katmanı olan CNN modellerinde tercih edilir [141].

Çapraz entropi kaybının formülü aşağıda verilmiştir [150]:

$$\begin{aligned} L(y, P(y \setminus x)) &= -\log P(y \setminus x) \\ L(y, P(y \setminus x)) &= -\log \left(\frac{e^{f_y(x)}}{\sum_k e^{f_k(x)}} \right) \end{aligned} \quad (3.4)$$

Verilen formülde, y : giriş verisinin doğru sınıfını, $P(y \setminus x)$: giriş verisinin doğru sınıf için tahmin olasılığını, $f_y(x)$: doğru sınıf için karar fonksiyonunu, $f_k(x)$: k sınıfı için karar fonksiyonunu temsil eder [150].

3.4.2.3 Optimizasyon Algoritmaları

Eğitim sürecinde matematiksel işlemler genellikle çok fazla hesaplama gücü gerektirdiği için kayıp fonksiyonunu en aza indirmek amacıyla optimizasyon algoritmaları kullanılır. Ayrıca optimizasyon algoritmaları eğitim sürecini hızlandırmaya yarar. Yaygın olarak kullanılan optimizasyon algoritmalarından bazıları SGD, Momentum, AdaGrad, Adam vb. dir [141].

Gradyan İnişi (Gradient Descent): Gradyan inişi, yaygın olarak kullanılan bir optimizasyon algoritmasıdır; bu algoritma, öğrenilebilir parametreleri, yani çekirdekleri ve ağırlıkları, kayıp fonksiyonunu en aza indirmek için iteratif olarak günceller. Kayıp fonksiyonunun türevi, fonksiyonun en hızlı artış yönünü belirler ve her öğrenilebilir parametre, belirlenen bir öğrenme oranıyla belirli bir adımda, türevin tersi yönde güncellenir. Matematiksel olarak, gradyan, kaybın her öğrenilebilir parametreye göre kısmi türevidir ve bir parametrenin güncellenmesi şu şekilde ifade edilir [120]:

$$w := w - \alpha * \frac{\partial L}{\partial w} \quad (3.5)$$

Bu denklemde, öğrenilebilir her bir parametre w ile, öğrenme oranı α ile ve kayıp fonksiyonu L ile temsil edilmiştir. Uygulamada, öğrenme oranı, eğitim başlamadan önce belirlenmesi gereken en kritik hiperparametrelerden biridir. Ayrıca uygulama esnasında, sınırlı bellek gibi faktörlerden dolayı, parametrelerin gradyanları, eğitim veri setinin küçük parçaları olan mini partiler kullanılarak hesaplanır ve parametre güncellemelerine uygulanır. Bu yöntem mini yığın gradyan inişi olarak da bilinir ve bir hiperparametredir [120]. Bunun yanı sıra, gradyan inişi algoritması üzerinde birçok geliştirme önerilmiş ve sıkça kullanılmıştır; bu da SGD ile momentum, RMSprop ve Adam gibi yöntemleri içermektedir [137, 151, 152].

SGD (Stochastic Gradient Descent - Stokastik Gradyan İnişi): Geri yayılım algoritması parametreleri güncellemek için gradyan inişini kullanan standart eğitim tekniğidir [153]. Stokastik gradyan inişi adı, kayıp fonksiyonunun parti/küme (batch) içerisindeki ağırlıklara göre rastgele dalgalanmalarından gelir [140].

Stokastik gradyan inişi, eğitim kümesinden rastgele bir örnek seçerek gradyanları tahmin eder [154]. Seçilen bir küme, ağırlık güncellemeleri yapmak için kullanılır [140]. Bu durum daha kararlı bir yakınsama elde etmeye ve parametre güncellemesindeki varyansı azaltmaya yardımcı olur [128]. Sadece bir örnek için gradyan hesaplaması yapılacağından, her güncellemede SGD'nin oldukça az bir zamana ihtiyacı vardır [141]. Bu nedenle, SGD çevrimiçi öğrenme için son derece uygundur [155].

Yakınsama hızı, öğrenme oranı ile kontrol edilir. Başlangıçta kararlı yakınsamayı sağlayacak küçük ve sabit bir öğrenme oranı ile başlamak, sonrasında öğrenme oranını yakınsama hızı yavaşladıkça azaltmak yaygın olarak tercih edilen bir yöntemdir [128]. Ağırlık güncellemeleri için bir kümenin gradyanı ortalanan ve kullanılır [140].

Momentum: Momentum algoritmasını Qian vd. önermiştir [137]. Bu algoritma, ağırlıkları güncellemede gradyanın üstel olarak ağırlıklı ortalamasını kullanır, bu nedenle fiziksel momentumu simgeler. Bir katmandaki gradyan diğer katmandaki gradyandan çok daha büyük olduğunda, öğrenme süreci de dengesiz olabilir [141].

Düşük gradyan yönleri için momentum oluşturulurken, dik gradyan yönlerinde olan dalgalanma azaltılır [140]. Momentum algoritması katmanlar arasındaki bağlantılardaki salınımı önleyerek daha hızlı yakınsamayı sağlayabilir. Ancak, gradyan inişini kontrolsüz bir şekilde takip etmesi momentum algoritmasının bir sorunudur [141].

AdaGrad: Bir diğer optimizasyon algoritması AdaGrad algoritmasıdır [156]. AdaGrad, öğrenme hızını her parametreye göre adapte edebilen bir algoritmadır. Yani, öğrenme hızını parametreler ile uyumlu olarak ayarlayabilir [141].

Özellikle ilgili (yani sıkça güncellenen) parametreler için öğrenme hızını düşürür, nadiren güncellenen parametreler için öğrenme hızını artırır. Bu nedenle, seyrek verilerin işlenmesi için uygundur [141].

Daha önceki gradyanların kareleri toplamının karekökü ile ters orantılı olacak şekilde gradyanı ölçeklendirir. Bu durum dik yönlere göre daha büyük bir öğrenme oranına sahip olunabileceği anlamını taşır. Önceki gradyanların karelerinin toplamı zamanla arttığından öğrenme oranı sıfıra doğru düşer ve ağırlık öğrenmesi durur [140].

Öğrenme hızının manuel olarak ayarlanmasının gerekmemesi AdaGrad'ın bir avantajıdır [141]. Genellikle öğrenme hızı 0.01 olarak kullanılır [157].

Adam (Adaptive Moment Estimation): Sıkça kullanılan bir diğer optimizasyon algoritması, Adam (Adaptive Moment Estimation)'dır. Adagrad ile momentum algoritmalarını birleştirir [151]. Adam algoritmasının başarılı sonuçlar verdiği ve birçok evrişimli sinir ağı modeline uygulanabilir olduğu yapılan çalışmalardan yola çıkarak söylenebilir [158–160].

Optimizasyon algoritması seçerken dikkat edilmesi gereken noktalar: Her güncellemede doğruluk ile kayıp fonksiyonu arasında bir denge kurabilmek

için mini küme kullanılabilir. Veri dağılımı, optimizasyon algoritmalarının performansını önemli ölçüde etkiler, bu nedenle deneme yoluyla veri seti için en uygun optimizasyon algoritması seçilebilir. Çok fazla salınım veya sapma olması durumlarında öğrenme hızını düşürmek iyi bir fikir olabilir [141].

3.4.2.4 Öğrenme Oranı (Learning Rate)

Öğrenme hızını belirleyen bir parametre olan öğrenme oranı, ağı güncelleyen adımın büyüklüğünü kontrol eder. Bu parametre arttıkça, ağı ağırlıkları ve eşik değerleri daha hızlı güncellenir, ancak bu durum ağı istikrarını riske atabilir (örneğin, ağırlıkların ani değişiklikleri nedeniyle ağı yakınsaması zorlaşabilir). Diğer taraftan, öğrenme oranı azaldıkça, ağı daha kararlı olabilir ancak eğitim süreci daha uzun sürebilir ve minimuma ulaşması daha güç hale gelebilir. Derin öğrenme sürecinde, parametrelerin güncellenmesi geriye yayılım algoritmasıyla gerçekleştirilir. Geriye yayılım işlemi sırasında, güncelleme işlemi, geriye doğru türev alınarak değişimin hesaplanmasıyla gerçekleştirilir. Hesaplanan değişim değeri, öğrenme oranı parametresiyle çarpılarak elde edilir ve bu sonuç, ağırlık değerlerinden çıkarılarak yeni ağırlık değeri hesaplanır. Bu süreçte kullanılan öğrenme oranı parametresi, sabit bir değer olarak ayarlanabilir veya adım adım artan bir değere dönüştürülebilir (örneğin, belirli bir adıma kadar 0.001 ve sonrasında 0.01 gibi). Ayrıca, momentum değerine göre de değişebilir veya öğrenme sürecinde adaptif algoritmalar tarafından da otomatik olarak ayarlanabilir [161].

3.4.2.5 Dönem Sayısı (Epoch)

Model eğitilirken veri seti aşamalı olarak kullanılır, veri setinin tümü aynı anda işlenmez. Veri seti belirli parçalara ayrılır ve bu parçalar sırayla model eğitimine dahil edilir. İlk parça eğitilir, modelin performansı ölçülür, ardından geri yayılım algoritması kullanılarak ağırlıklar güncellenir. Daha sonra yeni bir eğitim veri seti ile model yeniden eğitilir ve ağırlıklar güncellenir. Bu süreç, modelin en uygun ağırlıklarını bulmak için her eğitim adımında tekrarlanır. Her bir eğitim adımı bir dönem sayısı olarak adlandırılır [161].

3.4.2.6 Parti Boyutu (Batch Size)

Parti boyutu, ağı verilen alt örneklerin sayısıdır ve bu örnekler üzerinde parametre güncellemeleri gerçekleştirilir [161].

4

MALZEME VE YÖNTEM


4.1 Veri Seti

Yapay zekanın hızla ilerlemesi ve yayılması, pek çok yaşam alanında belirgin etkilere sahiptir. Bu alanlardan belki de en önemlisi sağlık alanıdır. Makine öğrenimi ve derin öğrenme gibi yapay zeka alt disiplinleri, sağlık alanında son derece değerli çözümler sunmaktadır. Özellikle hayati öneme sahip hastalıklar için erken teşhis anlamında bu alt disiplinlerin kullanılması sundukları değerli çözümlerin başında gelmektedir. Hızlı ve güvenilir sonuçlar verdiği için makine öğrenimi ve derin öğrenme modelleri bu anlamda sıklıkla kullanılmaktadır. Bu çalışma için evrişimli sinir ağı mimarileri kullanılmış ve transfer öğrenimi destekli sınıflandırma yapılmıştır. Çalışma, Google Colab üzerinden Python programla dili kullanılarak sürdürülmüştür.

Çalışmada kullanılan veri seti Kaggle'dan elde edilmiştir ve erişime açık bir veri kümesidir [162]. Kullanılan veri setindeki görüntüler normal ve OSCC olmak üzere iki sınıfa ayrılmaktadır. Veri setindeki görüntülere kontrastı artırmak ve detayları daha belirgin hale getirmek için CLAHE (Sınırlı Kontrastlı Uyarlamalı Histogram Eşitleme) uygulanmıştır.



Şekil 4.1 Orijinal görüntü (normal) & CLAHE (normal)



Şekil 4.2 Orijinal görüntü (OSCC) & CLAHE (OSCC)

Clahe, görüntülerde kontrastı artırmak için kullanılan bir görüntü işleme tekniğidir. Bu yöntemde görüntüler alt bölgelere ayrılır ve her alt bölge için ayrı ayrı histogram eşitleme uygulanır. CLAHE'de, her piksel, dört en yakın bölgenin eşlemelerinden elde edilen sonuçların lineer bir kombinasyonu ile eşlenir. Aşırı kontrast artışı da bu yöntem ile önlenir [163]. Clahe, tıbbi görüntüler üzerinde başarılı sonuçlar üretmiştir. Bu da, bu çalışmada bu tekniğin tercih edilmesine neden olmuştur.

Toplam 5.192 görüntüden oluşan bu veri setine CLAHE uygulandıktan sonra veri kümesine normalleştirme ve boyut ayarlama işlemleri uygulanmıştır. Boyut ayarlama işlemi kullanılacak olan algoritmaların ihtiyaçlarına uygun olarak gerçekleştirilmiştir. Boyut ayarlamadan sonra veri kümesindeki her bir görüntünün boyutu 224x224 olmuştur. Ayrıca, veri setine CLAHE algoritmasının uygulanması için OpenCV kütüphanesinin createCLAHE fonksiyonu kullanılmıştır.

Veri setinde bazı değişkenlerin ortalama ve varyans değerleri diğer değişkenlerden farklı olabilir. Bu da, hatalı sonuçlara neden olabilir. Bu sebeple veri setindeki değerlere normalleştirme yapılması gerekmektedir. Ayrıca normalleştirme yapmak, karmaşıklığı önler, standartlaştırılmış sonuçlara ulaşabilmeyi sağlar, değişkenler ile standartlaştırılmış değerler arasında daha kolay karşılaştırma yapabilmeyi sağlar. Normalleştirme, veri ön işleme uygulamalarından biri olup, bir veri dönüştürme işlemidir [164].

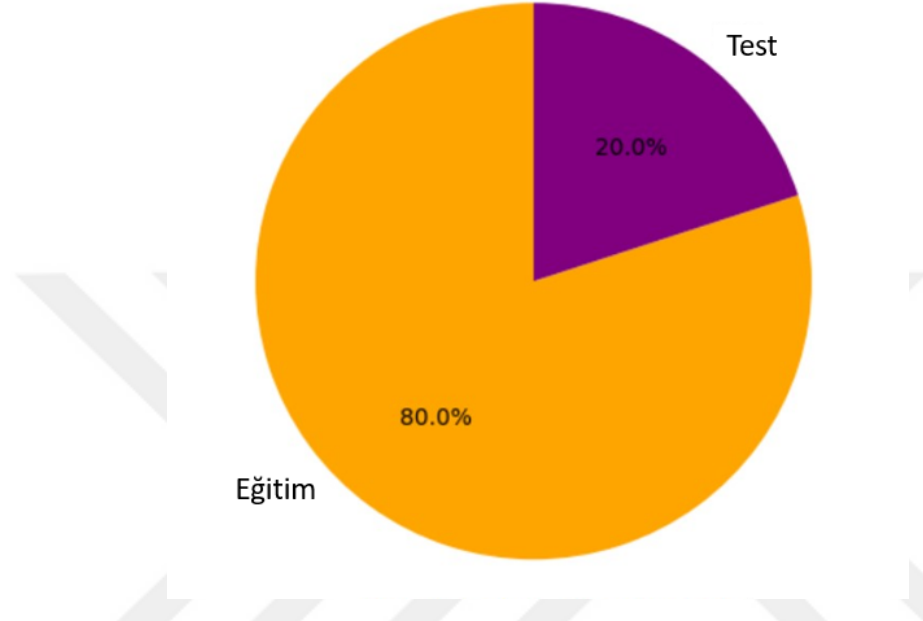
Veri setinde bazen bazı nitelik türleri, kullanılacak olan algoritma için uygun olmayabilir veya bazı durumlarda veri özellikleri belirleyici olmayabilir. Veri dönüşümü, bu gibi durumlarda uygulanan bir yöntemdir ve bu sorunları ortadan kaldırılabılır. Veri normalleştirme de bir veri dönüşümü uygulaması olup iki türlü gerçekleştirilebilir: min-max normalleştirme, Z-skor normalleştirme [164]. Bu çalışmada, Z-skor normalleştirme kullanılmıştır.

Z-skor normalleştirme, ortalama değerin değişken değerden çıkarılması ile elde edilen sonucun standart sapma değerine bölünmesi ile elde edilir. En yakın sonucu veren hesaplama yöntemi standart sapmadır. Z-skor normalleştirme, 1968 yılında Edward Altman tarafından geliştirilmiş bir istatistiksel ölçüdür. Edward Altman, New York Üniversitesi'nde Finans Bölümü Profesörüdür ve bu yöntemi iflas tahmininde bulunmak üzere geliştirmiştir. Z-skor formülü aşağıda verilmiştir [164]:

$$X' = (X - X_o)/\sigma_s \quad (4.1)$$

Burada: X' , dönüştürülen değeri; X , gözlem değerini; X_o , gözlemlerin aritmetik ortalamasını; σ_s , gözlem değerlerinin standart sapmasını temsil etmektedir [164].

Bu işlemlerin ardından veri kümesinin %80'i eğitim için, %20'si test için ayrılmıştır. Sonuçta, eğitim veri kümesi toplam 4.154 görüntüden oluşurken, test veri kümesi ise 1.038 görüntüden oluşmaktadır.



Şekil 4.3 Eğitim ve test veri kümesindeki eleman sayısının yüzdeleri dağılımı

Çalışmada, veri setinin eğitim için dört farklı CNN modeli, 2 farklı optimizasyon algoritması ve 5 farklı dönem sayısı kullanılmıştır. Her modelde, CrossEntropyLoss kayıp fonksiyonu ve 0.001 öğrenme oranı kullanılmıştır. Kayıp fonksiyonu olarak, sınıflandırma problemlerinde tahmin edilen etiketlerin gerçek etiketlerle karşılaştırılmasında başarılı sonuçlar elde ettiğinden, CrossEntropyLoss tercih edilmiştir. Sınıflandırma için 4 farklı CNN modeli seçilmiştir. Bunlar: ResNet101, ResNet152, DenseNet169 ve DenseNet201'dir. Bu modeller, öncelikle Adam (Adaptif Moment Tahmini) optimizasyon algoritması, CrossEntropyLoss kayıp fonksiyonu ve 0.001 öğrenme oranı ile eğitilmiştir. Kullanılan modeller, ImageNet ağırlıkları ile önceden eğitilmiştir. Değerlendirmeler her 10 dönem sayısında bir yapılmış ve sonuçlar 50 dönem sayısı boyunca incelenmiştir. Daha sonra, optimizasyonun etkisini araştırmak için SGD (Stokastik Gradyan İnişi) optimizasyon algoritması seçilerek benzer işlemler tekrarlanmıştır.

4.2 Önerilen Modeller

4.2.1 ResNet

ResNet mimarisi ilk olarak 2015 yılında Kaiming He vd. tarafından "Deep Residual Learning for Image Recognition" başlıklı makalede tanıtılmıştır [64] ve artıklı ağ olarak adlandırılır [165]. Bu mimari geleneksel olarak kullanılan katmanlar yerine artıklı bloklardan oluşur. Bu bloklara atlama bağlantıları dahil edilmiştir, bu da bloğun girdisini bloğun çıktısına doğrudan ekleyerek öğrenmeyi kolaylaştırır [64].


Derin ağların eğitimi, derin olmayan ağların eğitiminden daha zordur. ResNet mimarisi, derin ağların eğitimini kolaylaştırmak amacıyla geliştirilmiştir [64].

Derin evrişimli sinir ağları [139, 166], görüntü sınıflandırma alanında oldukça önemli gelişmeler elde etmiştir [64]. Derin ağlar, çok katmanlı bir yapıya sahip olup, özellikleri düşük-orta-yüksek [167] olmak üzere seviyeli bir şekilde bir uçtan bir uca iletir ve bu seviyeler katmanların derinliği (sayısı) artırılarak zenginleştirilebilir [64].

Yapılan bazı çalışmalar [168, 169], ağın derinliğinin önemini vurgulamaktadır. Buradan yola çıkarak akla şu soru gelebilir: Ağın daha iyi öğrenmesi için daha çok katman eklemek yeterli midir? [64]

Ağ derinleştikçe, doğruluk doymuşlaşmaya başlar ve bozulma meydana gelir. Daha derin ağlar, daha yüksek eğitim hatasına neden olmaktadır [64]. Hem eğitim setinde hem de test setinde hata arttığı için bu hatanın aşırı uyum nedeniyle ortaya çıkmadığı söylenebilir [165]. Burada meydana gelen bozulma kaybolan gradyan sorunundan meydana gelmektedir [64].

Düz ağlarda yani, sadece katmanların üst üste eklenmesi sonucu oluşturulan ağlarda derinlik arttıkça eğitim hatası da artar. Ancak, derin artık ağ ile derinlik arttıkça doğruluk artabilir ve artık ağlar kolayca optimize edilebilir. Artık öğrenme şeması şekil 4.4'de verilmiştir [64].




Şekil 4.4 Artık öğrenme

Şekil 4.4'te, $F(x) + x$, kısayol bağlantıları yardımıyla elde edilir [64]. Kısayol

bağlantıları [170–172], bir veya daha çok katmanı atlayan bağlantılardır [64].

ResNet mimarisinde bulunan bu kısayol bağlantıları çıktılarını, yığılmış katmanların (katman bloğunun) çıktısına eklemek ile görevlidir. Kısayol bağlantıları ekstra parametre veya hesaplama karmaşıklığına neden olmazlar. Bu, hem uygulamada hem de düz ağlar ile artık ağlar karşılaştırılırken önemlidir. Şekil 4.5’de ResNet mimarisinin yapısı verilmiştir [64] :



Şekil 4.5 ResNet mimarisi

Her birkaç yığılmış katmana yani katman bloğuna artık öğrenme eklenir. Artık öğrenme için bir $H(x)$ fonksiyonu düşünölsün. Bu fonksiyon, katman bloğu tarafından oluşturulacak olan eşleme olsun. x ise, bu katman bloğundaki ilk katmanın girişlerini temsil etsin. Doğrusal olmayan katmanların bir araya gelerek daha iyi tahminler yapabileceği varsayımından yola çıkarak bu yaklaşımın $H(x)$ fonksiyonunu yaklaşıklayarak değil, artık fonksiyonu olan $F(x) := H(x) - x$ 'i yaklaşıklayarak gerçekleştirildiği söylenebilir [64].

Burada asıl hedef, $H(x)$ 'i değil, artık fonksiyon olan $F(x)$ 'i yaklaştırmaktır. Bu da, öğrenme sürecinin artık fonksiyona yoğunlaşması demektir. Hem $H(x)$ fonksiyonuna yaklaşıklayan yaklaşım hem de artık fonksiyona odaklanan yaklaşım, istenen fonksiyonlara yaklaşımı sağlayabilir. Ancak, öğrenme süreci ve ağı karmaşıklığı bu iki yaklaşım arasında farklılıklara sebep olmaktadır ve bu son derece önemli bir noktadır. Ağı öğrenme süreci ve uygulanan yöntemlerin etkinliği ve verimliliği değerlendirilirken bu önemli noktaya dikkat edilmelidir [64].

Veri noktalarını istenen kriterlere uygun eşleştirmek için kimlik eşleme uygulanır. Kısayollarla kimlik eşlemenin temel yapı taşı ise şu şekildedir [64]: $y = F(x, W_i) + x$. Burada, x ilgili katmanın giriş vektörünü, y çıkış vektörünü temsil eder. $F(x, W_i)$ ise öğrenilecek olan artık ağı ifade eder. Bu ağı, giriş vektörü x ve ağırlıklar W_i ile belirli bir fonksiyonu temsil eder [64].

Şekil 4.4’deki örnekte $F = W_2\sigma(w_1x) : F(x, W_i)$ fonksiyonu, W_1 ve W_2 ağırlıklarıyla belirli bir aktivasyon fonksiyonu olan σ tarafından tanımlanır. Burada,

σ , ReLU (Rectified Linear Unit) olarak gösterilmiştir. Bu fonksiyon, giriş vektörü x üzerine uygulanan ağırlık matrisleri W_1 ve W_2 ile bir aktivasyon fonksiyonuna (ReLU) sokularak elde edilir. Burada $F + x$ işlemi ise, bir kısayol bağlantısı ve eleman bazında toplama ile gerçekleştirilir. Yani, ağ tarafından üretilen çıktı F ile giriş vektörü x arasında bir bağlantı kurulur ve sonuç olarak çıkış vektörü elde edilir. Bu, ağın daha derin ve karmaşık ilişkileri öğrenmesine yardımcı olabilir [64].

Eşit sayıda parametre, derinlik, genişlik ve hesaplama maliyetine sahip olan düz ağlar ile artık ağlar adil olarak karşılaştırılabilirler (önemsiz eleman bazında toplama dışında) [64].

ResNet mimarisi içerdikleri katman sayılarına göre farklı varyasyonlara sahiptir. Bunlar: ResNet18, ResNet34, ResNet50, ResNet101 ve ResNet152'dir. Örneğin: ResNet101 101 katmandan oluşurken, ResNet152 152 katmandan oluşur ve ResNet mimarisinin en derin ve en karmaşık varyasyonudur [64].


4.2.2 DenseNet Mimarisi

DenseNet mimarisi ilk olarak 2017 yılında Huang vd. tarafından "Densely Connected Convolutional Networks" başlıklı makalede tanıtılmıştır. Bu mimari, artıklı öğrenmeden çok daha gelişmiş olan, tüm önceki katmanların çıktılarının her bir katmanın çıktısına bağlandığı yoğun bir bağlantı yapısına sahiptir. Başka bir deyişle, önceki katmanlardan gelen tüm çıktılar, bir sonraki katmana giriş olarak iletilir ve her katman kendi çıktısını oluşturmak için önceki tüm katmanların çıktılarını alır [173].

DenseNet mimarisi, ResNet mimarisindeki kısayol bağlantılarının bağlantı desenine dönüştürülmesiyle oluşturulmuştur. Ağ içerisindeki katmanlar arasında bilgi akışının maksimum olması amacıyla geliştirilmiştir. Tüm katmanlar, eşleşen özellik haritası boyutlarıyla birbirlerine bağlanırlar [173].

Geleneksel mimarilerden farklı olarak L katmanlı bir ağa L bağlantı yerine $L(L + 1)/2$ bağlantı ekler. Mevcut katman, kendi özellik haritalarını, sonraki tüm $L - l$ katmana iletir [173].


ResNet mimarisinden farklı olarak bir katmana geçmeden önce, özellikler toplanır ve birleştirilir. Bu nedenle, l . katman, daha önceki tüm evrişim katmanlarının özellik haritalarından oluşmuş l girdiye sahiptir. Her katman daha önceki katmanlardan ek girişler alır ve mevcut katman kendi özellik haritasını sonraki katmanlara iletir, böylelikle ileri besleme korunur. DenseNet mimarisindeki bu yoğun bağlantı yapısı şekil 4.6'da verilmiştir [173] :



Şekil 4.6 Yoğun bağlantı yapısı

Bu yaklaşıma, yoğun bağlantı deseninden dolayı Yoğun Evrişimli Ağ (DenseNet) denilmiştir. Geleneksel ağlara göre yoğun bağlantı desenleri, gerekmeyen özellik haritalarını yeniden öğrenme ihtiyacı duymadığından daha az parametreye gereksinimi vardır [173].

Geleneksel ileri beslemeli ağlar, verinin katmanlar arasında geçerek işlendiği bir durum ve bunun sonucunda sonucun üretildiği bir algoritma olarak düşünülebilir. Her katman, önceki katmandaki bilgileri kullanarak işlem yapar ve elde ettiği sonuçları bir sonraki katmana ileterek işlem sürecini devam ettirir. Durum değişir ancak korunması gereken bilgi korunarak iletilir. DenseNet ise, korunan bilgi ile ağa eklenen bilgi arasında çok açık bir ayrım yapar. Ayrıca DenseNet'i geleneksel ağlardan ayıran en önemli farkı ise, çok dar katmanlar içerebiliyor olmasıdır. DenseNet mimarisinin yapısı şekil 4.7 de verilmiştir [173]:



Şekil 4.7 DenseNet mimarisi

DenseNet'in avantajlarından biri, daha iyi parametre verimliliği sağlamasıdır, bir diğer avantajı da ağ boyunca bilgi ve gradyanların daha iyi akışını sağlayarak kolay eğitilebilir olmasıdır [173]. Her katman, gradyanlara orijinal giriş sinyalinden

ve kayıp fonksiyonundan doğrudan bir erişim sağladığından örtük derin denetime [174] sahiptir. Bu, daha derin olan ağ mimarilerinin eğitimi için yardımcı olur. Ayrıca, yoğun bağlantılar düzenleyici bir etkiye de sahiptir. Bu da, eğitim seti küçük boyutlarda olan görevlerde aşırı uyumu azaltır [173].

Farklı katmanlarda öğrenilen özellik haritalarının birleştirilmesi, ardışık katmanlar için girdilerindeki çeşitliliği artırır, verimliliği de iyileştirir. Bu, ResNet mimarisi ile DenseNet mimarisi arasındaki önemli bir farktır [173].

Bir ağı, daha derin yapmanın yollarından biri de ağın genişliğinin artmasıdır. DenseNet, derin veya geniş mimarilerle temsil yeteneği kazanmak yerine, ağın potansiyelini özelliklerin tekrar kullanımı yoluyla artırarak, eğitimi kolaylaştırır ve son derece parametre verimliliği yoğun modeller elde eder [173].

DenseNet mimarisini daha iyi anlamak için evrişimli sinir ağından geçirilen bir x_0 görüntüsü ele alınsın. Bu ağ, her biri l katmanını belirleyen bir dizi doğrusal olmayan $H_l(\cdot)$ dönüşümünü içeren L katmandan oluşsun. $H_l(\cdot)$ fonksiyonu, bileşik bir fonksiyon olabilir [173]. Örneğin, toplu normalleştirme (BN) [175], ReLU [176], havuzlama [116] veya evrişim gibi işlemlerden oluşan bileşik bir fonksiyon olarak düşünülebilir. Burada l . katmanın çıktısı x_l ile temsil edilecek [173].

İleri beslemeli geleneksel evrişimli ağlarda, l . katmanın çıktısı $(l + 1)$. katmana girdi olarak iletiliyordu [139] yani bu $x_l = H_l(x_{l-1})$ katman geçişine yol açar [173]. ResNet [64] ise, doğrusal olmayan dönüşümleri atlayan bir kimlik işlevi ile bir geçiş bağlantısı ekliyordu yani, $x_l = H_l(x_{l-1}) + x_{l-1}$ [173].

ResNet mimarisinde, sonraki katmanlardan daha önceki katmanlara gradyanların doğrudan bir kimlik işlevi ile aktarılabilmesi bir avantajdır ancak, kimlik işlevi ile H_l fonksiyonunun çıktısı bir toplama işlemi ile birleştirilir, bu da ağıdaki bilgi akışını engelleyebilir. Burada yoğun bağlantılar devreye girmektedir [173].

DenseNet mimarisinde katmanlar arasındaki bilgi akışını arttırmak için farklı bağlantı deseni önerilmiştir. Burada herhangi bir katmandan sonraki tüm katmanlara bir bağlantı ekleniyor [173]. Yani; l . katman, önceki tüm katmanların özellik haritalarını x_0, x_1, \dots, x_{l-1} girişi olarak alır :

$$x_l = H_l([x_0, x_1, \dots, x_{l-1}]) \quad (4.2)$$

burada $[x_0, x_1, \dots, x_{l-1}]$, $0, 1, \dots, l - 1$ katmanlarında üretilen özellik haritalarının birleştirilmesini temsil ediyor [173].

(4.2) denkleminde, $H_l(\cdot)$ 'nin çoklu girişleri birleştirip bir tensöre dönüştürmesi

uygulamada kolaylık sağlar [173]. Burada uygulanan birleştirme işlemi özellik haritalarının boyutlarının değişmesi durumunda uygun değildir. Bu nedenle özellik haritalarının boyutunu değiştiren örnekleme katmanları için, bu mimari birden fazla yoğun bağlantılı bloğa bölünmüştür. Bu bloklar arasında bulunan katmanlara ise geçiş katmanları denilmektedir ve bu katmanlar evrişim ve havuzlama işlemi yapar [173].

Eğer her H_l işlevinden k özellik haritası üretilirse, l . katmanın giriş özellik haritası $k_0 + kx(l-1)$ olur, buradaki k_0 , giriş katmanındaki kanal sayısını temsil etmektedir. k ise, ağın büyüme hızını temsil ediyor [173].

Özellik haritaları, ağın genel durumunu temsil eden bir yapı olarak da düşünülebilir. Her katman kendi özellik haritasını bu duruma ekler. Ağın genel durumuna her katmanın ne kadar yeni bilgi ekleyeceği ise büyüme hızı tarafından düzenlenir. Ayrıca, ağın genel durumu bir defa verildikten sonra, geleneksel sinir ağı mimarilerinden farklı olarak katmandan katmana çoğaltılması gerekmez ve ağın her yerinden erişim sağlanabilir [173].

Her katman sadece k çıkış özellik haritası üretse de, genellikle daha fazla girişe sahiptir. 3×3 'lük her evrişimden önce 1×1 'lik bir evrişim uygulanabilir ve buna darboğaz katmanı denir. Böylelikle giriş özellik haritası sayısı azaltılır ve hesaplama verimliliği sağlanır. Darboğaz katmanına sahip ağa, yani H_l fonksiyonunun BN-ReLU-Conv(1x1)-BN-ReLU-Conv(3x3) varyasyonuna Yoğun Ağ-B denilmektedir [173].

Ayrıca, geçiş katmanlarında bulunan özellik haritası sayısı azaltılarak model sıkışıklığı arttırılabilir. Eğer yoğun bir blok m özellik haritası içeriyorsa, bu bloktan sonra gelen geçiş katmanı $\lfloor \theta m \rfloor$ çıkış özellik haritası üretebilir, burada $0 < \theta \leq 1$ sıkıştırma faktörüdür. Eğer $\theta = 1$ ise, geçiş katmanları boyunca özellik haritası sayısı değişmez. $\theta < 1$ olduğunda Yoğun Ağ'a, Yoğun Ağ-C denilir. Hem darboğaz kullanıldığında hem de $\theta < 1$ olduğunda ise Yoğun Ağ'a, Yoğun Ağ-BC denilir [173].

DenseNet mimarisi içerdikleri katman sayılarına göre farklı varyasyonlara sahiptir. Bunlar: DenseNet121, DenseNet169, DenseNet201 ve DenseNet161'dir. Örneğin: DenseNet169 169 katmandan oluşurken, DenseNet201 ise 201 katmandan oluşur [173].

4.3 Performans Metrikleri

Sınıflandırma modelinde amaç, sınıf etiketi bilinen örnekleri kullanarak sınıf etiketi bilinmeyen örnekleri tahmin etmektir. Sınıflandırma problemleri, ikili sınıflı veya çoklu sınıflı olabilir ve bu durumda çıktı, sınıf etiketleri veya olasılık şeklinde olabilir [177].

Performans metrikleri, önerilen modelin performansını ölçerler [178]. Bir sınıflandırma modelinin performansını ölçmek için farklı performans metrikleri kullanılabilir, bunlar: Karmaşıklık Matrisi (Confusion Matrix), Doğruluk (Accuracy), Kesinlik (Precision), Duyarlılık (Recall), F1-skor ve Özgüllük (Specificity)'dir [177–179].

Karmaşıklık Matrisi (Confusion Matrix): Sınıflandırma modellerinde tahminlerin özeti karmaşıklık matrisi ile verilir [179]. İkili veya çoklu sınıflı modelleri temsil edebilir [177]. Karmaşıklık matrisinde sonuçlar dört bölüme ayrılır [179]. Pozitif ve negatif olmak üzere iki sınıflı bir model için 4 olası sonuç vardır ve böyle bir durumda oluşan karmaşıklık matrisi tablo 4.1'de verilmiştir [177]:

Tablo 4.1 Karmaşıklık matrisi

	Tahmin Pozitif	Tahmin Negatif
Gerçek Pozitif	TP	FN
Gerçek Negatif	FP	TN

- TP (Doğru Pozitif): Modelin, pozitif sınıfa ait bir görüntüyü doğru tahmin ettiği durumdur,
- FP (Yanlış Pozitif): Modelin, pozitif sınıfa ait bir görüntüyü yanlış tahmin ettiği durumdur,
- TN (Doğru Negatif): Modelin, negatif sınıfa ait bir görüntüyü doğru tahmin ettiği durumdur,
- FN (Yanlış Negatif): Modelin, negatif sınıfa ait bir görüntüyü yanlış tahmin ettiği durumdur [179].

Karmaşıklık matrisi tablosu tahmin edilen ile gerçek çıktı arasında oluşturulmuştur ve tahmin edilen sonucun özetini temsil eder. Ayrıca, performans metriklerinin çoğu karmaşıklık matrisinden elde edilmektedir [177].

Doğruluk (Accuracy): Doğru bir şekilde sınıflandırılan örneklerin sayısının toplam örnek sayısına oranıdır [177]. Aşağıdaki şekilde hesaplanır [178]:

$$\frac{TP + TN}{TP + TN + FP + FN} \quad (4.3)$$

Kesinlik (Precision): Modelin, pozitif sınıfa ait olan ve doğru olarak etiketlediği örneklerin sayısının, pozitif olarak etiketlenen toplam örneklerin sayısına oranıdır [180, 181]. Bir başka deyişle pozitif olarak tahmin edilen örneklerin kaç tanesinin gerçekten pozitif olduğunun oranını verir. Yani, OSCC tanısı koyulan kaç hastanın gerçekten OSCC'li hasta olduğunu belirler. Bu metriğe pozitif tahmin değeri denilir. Burada önemli olan FP değeridir ve bu değer minimize edilmeye çalışılır [177]. Aşağıdaki şekilde hesaplanır [178]:

$$\frac{TP}{TP + FP} \quad (4.4)$$

Duyarlılık (Recall): Gerçek pozitif örneklerin kaç tanesinin doğru bir şekilde tahmin edildiğini belirler [177]. Yani, gerçek pozitif olarak tahmin edilen örneklerin sayısının, pozitif sınıfa ait örneklerin sayısına oranıdır [182, 183]. Bir başka deyişle modelin, gerçekte OSCC'li olan kaç hastayı doğru bir şekilde teşhis ettiğini belirler. Bu metrikte FN değeri önemlidir ve minimize edilmeye çalışılır [177]. Aşağıdaki şekilde hesaplanır [177]:

$$\frac{TP}{TP + FN} \quad (4.5)$$

F1-Skor: Kesinlik ve duyarlılık tanımlarından, bu iki metrik arasında bir denge olduğu söylenebilir [179]. Duyarlılık artığında, kesinlik azalır ve kesinlik artığında duyarlılık azalır [184–186]. Probleme göre biri maksimize, biri de minimize edilebilir [179]. Ancak, dengesiz dağılıma sahip problemlerde kesinlik ve duyarlılığın ikisi de önemlidir [177]. Her iki metriğin de optimal durumu istendiğinde F_β skoru kullanılır (Her metriğe farklı ağırlıklar verebilmek için). F_β skoru, kesinlik ile duyarlılığın harmonik ortalamasıdır ve her ikisi de eşit derecede önemlidir. $\beta = 1$ için F1 skoru elde edilir. F1 skoru, iyi bir tahmin yeteneğini belirtir [179]. Aşağıdaki şekilde hesaplanır [177]:

$$F_\beta = \frac{(1 + \beta^2) * Kesinlik * Duyarlılık}{\beta^2 * Kesinlik + Duyarlılık}$$
$$F1-Skor = \frac{2 * Kesinlik * Duyarlılık}{Kesinlik + Duyarlılık} \quad (4.6)$$

Özgüllük (Specificity): Duyarlılık (Recall) ile zıt bir metriktir. Hasta olmayan hastalardan kaçının model tarafından doğru bir şekilde (hastalığı olmayan olarak)

tahmin edildiğini belirtir. Bu metrik için FP değeri önemlidir ve minimize edilmeye çalışılır [177]. Aşağıdaki şekilde hesaplanır [177]:

$$\frac{TN}{FP + TN} \quad (4.7)$$

4.4 Sonuçlar

Bu çalışmada Evrişimli Sinir Ağlarından Resnet101, ResNet152, DenseNet169 ve DenseNet201 mimarileri kullanılarak ağız kanseri erken teşhisi için bir sınıflandırma yapılmıştır. Çalışma boyunca, kayıp fonksiyonu olarak CrossEntropyLoss kullanılmış ve 0.001 öğrenme oranı uygulanmıştır. Kullanılan modeller, ImageNet ağırlıkları ile önceden eğitilmiştir.

Burada amaç, bu dört farklı mimariyi farklı hiperparametreler kullanarak değerlendirmek ve en iyi çözümü seçmektir. Kullanılan modeller kendi aralarında değerlendirilirken farklı optimizasyon algoritmaları kullanarak optimizasyon algoritmalarının sonuca etkisi araştırılmıştır. İki farklı optimizasyon algoritması kullanılmıştır. Bunlar: SGD ve Adam'dır. Ayrıca dönem sayısının sonucu nasıl etkilediğini değerlendirmek ve doğru dönem sayısını belirleyebilmek için de farklı dönem sayılarında değerlendirmeler yapılmıştır. Dört model de önce 10 dönem için daha sonra 20 dönem için ve bu şekilde dönem sayısı 10'ar artırılarak en son 50 dönem için değerlendirilmiştir. ResNet ile DenseNet mimarisi karşılaştırılırken aynı zamanda bu mimariler kendi içlerinde de katman sayılarının etkisi bazında da değerlendirilmiştir. ResNet mimarisi için iki farklı katman sayısına sahip varyasyonu seçilmiş (ResNet101 ve ResNet152) aynı mimari üzerinde katman sayısının sonuca etkisi araştırılmıştır. Benzer şekilde DenseNet169 ve DenseNet201 için de değerlendirme yapılmıştır. Böylelikle ağız kanseri erken teşhisi için bu iki mimariden alınan bu dört model için en uygun olanı ve en uygun hiperparametreleri seçmek hedeflenmiştir.

Aşağıda Adam (Adaptif Moment Tahmini) optimizasyon algoritmasını kullanarak dört model için yapılan çalışmanın dönem sayılarına göre sonuçları sunulmaktadır. Değerlendirmeler doğruluk (accuracy), kesinlik (precision), duyarlılık (recall), F1-Skor ve özgüllük (specificity) performans metrikleri kullanılarak yapılmıştır.

Doğruluk (Accuracy) için sonuçlar şu şekildedir:

Tablo 4.2 Doğruluk değeri

Dönem Sayısı	ResNet101	ResNet152	DenseNet169	DenseNet201
10	0.9229	0.8854	0.9470	0.8940
20	0.8988	0.8969	0.9393	0.9037
30	0.9037	0.8921	0.9374	0.9470
40	0.9066	0.8882	0.9200	0.9432
50	0.8950	0.9075	0.9528	0.9268

Doğruluk, doğru tahminlerin toplam veri noktalarına oranını sağlar. Bu ölçüt, genel performansı ölçmede önemlidir. Yüksek bir doğruluk değeri, modelin doğru tahminlerde bulunma olasılığının yüksek olduğunu gösterir. Bu ölçütü etkileyen birçok faktör bulunmaktadır.

Kesinlik (Precision) için sonuçlar:

Tablo 4.3 Kesinlik değeri

Dönem Sayısı	ResNet101	ResNet152	DenseNet169	DenseNet201
10	0.9314	0.9041	0.9544	0.9024
20	0.8871	0.8895	0.9500	0.8961
30	0.9144	0.8808	0.9441	0.9592
40	0.9033	0.8957	0.9305	0.9530
50	0.9079	0.9118	0.9644	0.9288

Kesinlik, modelin pozitif olarak tanımladığı örneklerin ne kadarının gerçekten pozitif olduğunu ifade eder. Sınıflandırma problemlerinde modellerin performansını ölçmede tercih edilen metriklerden biridir.

Duyarlılık (Recall) için sonuçlar:

Tablo 4.4 Duyarlılık değeri

Dönem Sayısı	ResNet101	ResNet152	DenseNet169	DenseNet201
10	0.9247	0.8761	0.9458	0.8958
20	0.9189	0.9082	0.9344	0.9165
30	0.8935	0.9016	0.9354	0.9400
40	0.9153	0.8891	0.9150	0.9330
50	0.8858	0.9118	0.9402	0.9322

Duyarlılık, gerçek pozitiflerin doğru bir şekilde tahmin edilme oranını sağlar. Bu nedenle, bu önemli bir metrik olarak kabul edilir ve yüksek sonuçlar istenir.

F1-Skor için sonuçlar:

Tablo 4.5 F1-skor

Dönem Sayısı	ResNet101	ResNet152	DenseNet169	DesneNet201
10	0.9280	0.8898	0.9500	0.8990
20	0.9027	0.8987	0.9421	0.9061
30	0.9038	0.8910	0.9397	0.9495
40	0.9092	0.8923	0.9226	0.9428
50	0.8945	0.9118	0.9521	0.9304

F1-Skoru, kesinlik ve duyarlılık değerlerinin harmonik ortalamasıdır ve bu iki metriğin birlikte değerlendirilmesini temsil eder. Modelin doğruluğunu ve başarısını belirler.

Özgüllük (Specificity) için sonuçlar:

Tablo 4.6 Özgüllük değeri

Dönem Sayısı	ResNet101	ResNet152	DenseNet169	DesneNet201
10	0.9208	0.8957	0.9484	0.8920
20	0.8779	0.8854	0.9447	0.8904
30	0.9140	0.8830	0.9395	0.9549
40	0.8974	0.8873	0.9255	0.9534
50	0.9047	0.9028	0.9653	0.9207

Özgüllük, doğru negatiflerin doğru bir şekilde tanımlandığı yüzdeyi sağlar. Bu ölçümün yüksek bir değeri, hastalık bulunmayan bireyler için yanlış teşhislerin önlenmesinde önemlidir.

Aşağıda SGD (Stochastic Gradient Descent - Stokastik Gradyan İnişi) optimizasyon algoritmasını kullanarak dört model için yapılan çalışmanın dönem sayılarına göre sonuçları sunulmaktadır. Değerlendirmeler doğruluk (accuracy), kesinlik (precision), duyarlılık (recall), F1-Skor ve özgüllük (specificity) performans metrikleri kullanılarak yapılmıştır.

Doğruluk (Accuracy) için sonuçlar şu şekildedir:

Tablo 4.7 Doğruluk değeri

Dönem Sayısı	ResNet101	ResNet152	DenseNet169	DenseNet201
10	0.9557	0.9624	0.9566	0.9644
20	0.9461	0.9412	0.9634	0.9615
30	0.9644	0.9422	0.9547	0.9557
40	0.9441	0.9634	0.9499	0.9701
50	0.9461	0.9663	0.9461	0.9653

Yüksek bir doğruluk değeri, modelin doğru tahminlerde bulunma olasılığının yüksek olduğunu gösteriyordu. Tabloda SGD optimizasyon algoritması için dört modelin de dönem sayısı bazında doğruluk değerleri verilmiştir. Tablodan yola çıkarak doğruluğu yüksek olan model belirlenebilir.

Kesinlik (Precision) için sonuçlar:

Tablo 4.8 Kesinlik değeri

Dönem Sayısı	ResNet101	ResNet152	DenseNet169	DenseNet201
10	0.9601	0.9642	0.9610	0.9754
20	0.9461	0.9404	0.9712	0.9766
30	0.9660	0.9496	0.9705	0.9544
40	0.9555	0.9652	0.9562	0.9737
50	0.9527	0.9594	0.9507	0.9744

Tabloda seçilen dört modelin SGD optimizasyon algoritması kullanıldığında pozitif olarak tanımladığı örneklerin ne kadarının gerçekten pozitif olduğu belirtilmiştir. Daha önce de belirtildiği gibi bu metrik sınıflandırma problemleri için önem taşımaktadır.

Duyarlılık (Recall) için sonuçlar:

Tablo 4.9 Duyarlılık değeri

Dönem Sayısı	ResNet101	ResNet152	DenseNet169	DenseNet201
10	0.9487	0.9659	0.9556	0.9556
20	0.9561	0.9457	0.9564	0.9470
30	0.9642	0.9391	0.9390	0.9614
40	0.9338	0.9615	0.9454	0.9682
50	0.9379	0.9725	0.9435	0.9555

Duyarlılık, sınıflandırma problemleri için önemli olan metiklerden bir diğeridir. Bunun sebebi, gerçek pozitif vakaların doğru bir şekilde tahmin edilme oranını belirtmesidir, dolayısıyla yüksek sonuçlar vermesi istenir.

F1-Skor için sonuçlar:

Tablo 4.10 F1-skor

Dönem Sayısı	ResNet101	ResNet152	DenseNet169	DesneNet201
10	0.9543	0.9650	0.9582	0.9653
20	0.9510	0.9430	0.9637	0.9615
30	0.9650	0.9443	0.9544	0.9578
40	0.9445	0.9633	0.9507	0.9709
50	0.9452	0.9659	0.9470	0.9648

Keskinlik ve duyarlılık metriklerinden yararlanılarak hesaplanan F1-Skoru için tablodan yola çıkarak en yüksek sonucu veren model belirlenebilir.

Özgüllük (Specificity) için sonuçlar:

Tablo 4.11 Özgüllük değeri

Dönem Sayısı	ResNet101	ResNet152	DenseNet169	DesneNet201
10	0.9623	0.9583	0.9577	0.9738
20	0.9339	0.9365	0.9705	0.9764
30	0.9645	0.9455	0.9707	0.9493
40	0.9548	0.9653	0.9546	0.9721
50	0.9541	0.9602	0.9487	0.9750

Özgüllük değeri için yapılan değerlendirmenin sonuçları tabloda verilmiş olup, tablodan yola çıkarak negatif vakaları en iyi ayırt edebilen model belirlenebilir.

Sonuç olarak, tablolar incelendiğinde ağız kanseri erken teşhisinde bu dört modelin de başarılı olduğu söylenebilir. En iyi sonucu veren modeli seçmede ve doğru optimizasyon algoritması ile dönem sayısını belirlemede de tablolardan yola çıkarak bir sonuca varılabilir. Bu çalışma model, katman sayısı, optimizasyon algoritması, dönem sayısı gibi parametrelerin sınıflandırma sonucunu nasıl etkilediğini açıklar niteliktedir ve ileride yapılacak olan çalışmalara bu anlamda fikir verebilir, destek olabilir. Farklı modeller ve hiperparametreler de denenerek çalışma genişletilebilir ve sonuçlar iyileştirilebilir.

Elde edilen sonuçlardan yola çıkarak katman sayısının artmasının doğruluk üzerinde önemli bir etkiye sahip olduğunu ve doğruluğu artırabileceğini ancak bunun her zaman geçerli olmadığını söylemek mümkündür. Benzer şekilde optimizasyon algoritması seçimi ve dönem sayısı seçimi de doğruluk gibi diğer önemli metrikler üzerinde de ciddi bir etkiye sahiptir. Eğer dönem sayısı yetersiz ise, underfitting (eksik uyum) riskiyle karşılaşılır yani model yeterince eğitilemez ve verilere uygun şekilde uyarlanamayıp tahminleri yeterince doğru bir şekilde yapamaz, aşırı sayıda dönem sayısı ise, overfitting (aşırı uyum) sorununa yol açabilir yani model eğitim verilerine çok fazla uyum sağlayacağından genelleme yapma yeteneği düşer ve eğitim verileri için iyi bir performans sergilese de yeni verilere uyarlanamaz hale gelebilir. Bu çalışmada kullanılan modellerin yapıları overfitting (aşırı uyum) sorunuyla başa çıkmaya yönelik tasarlandığından bu durum burada söz konusu değildir.

5

SONUÇ

Bu çalışmada, OSCC biyopsi görüntülerinin sınıflandırılması için çeşitli CNN mimarileri ve değişik hiperparametreler kullanılarak bir analiz yapılmıştır. Kullanılan modelleri analiz etmek için ise doğruluk (AC), kesinlik (PR), özgüllük (SP), duyarlılık (RE) ve F1-skoru (F) parametreleri kullanılmaktadır. Elde edilen en yüksek sonuçlar Tablo 13 ve 14'te vurgulanmıştır. Performans ölçütlerine dayalı olarak, kullanılan modellerin ve bu modellere uygulanan hiperparametrelerin bu sınıflandırma problemi için oldukça etkili sonuçlar sağladığı ifade edilebilir. Bu araştırma, sağlık sektöründe erken tanı için uygun bir seçenek olarak değerlendirilebilir. Bu metot, ağız kanserinin sık görüldüğü, düşük gelirli ve gelişmemiş ülkelerde teşhis için tercih edilebilir ve tedavi için gerekli zaman kazandırılabilir, çünkü sonuçları hızlıdır ve maliyeti düşüktür. Bu şekilde, hastalığın mortalite ve morbidite oranları azaltılabilir ve dolayısıyla sağkalım oranı artırılabilir. Ayrıca, bu çalışma hiperparametrelerin modellere ve mimarilere olan etkisini de açıklamaktadır. Bu, gelecekteki araştırmalara rehberlik edebilir.

Tablo 5.1 Önceki çalışmalarla bulguları karşılaştırma. (Adam optimizasyonu için önerilen modeller)

Yazar	Model	AC (%)	F (%)	RE (%)	SP (%)	PR (%)
Welikala vd. [41]	ResNet101	N/A	78.30	93.88	N/A	67.15
Chu vd. [43]	SVM,KNN	70.59	N/A	N/A	84.12	N/A
Alhazmi vd. [45]	ANN	78.95	N/A	N/A	60.00	N/A
Rahman vd. [51]	AlexNet	90.06	90.15	N/A	87.38	N/A
Önerilen Model1	ResNet101	92.29	92.80	92.47	92.08	93.14
Önerilen Model2	ResNet152	90.75	91.18	91.18	90.28	91.18
Önerilen Model3	DenseNet169	95.28	95.21	94.58	96.53	96.44
Önerilen Model4	DenseNet201	94.70	94.95	94.00	95.49	95.92

Tablo 5.2 Önceki çalışmalarla bulguları karşılaştırma. (Stokastik Gradyan Azalma - SGD optimizasyonu için önerilen modeller)

Yazar	Model	AC (%)	F (%)	RE (%)	SP (%)	PR (%)
Welikala vd. [41]	ResNet101	N/A	78.30	93.88	N/A	67.15
Chu vd. [43]	SVM,KNN	70.59	N/A	N/A	84.12	N/A
Alhazmi vd. [45]	ANN	78.95	N/A	N/A	60.00	N/A
Rahman vd. [51]	AlexNet	90.06	90.15	N/A	87.38	N/A
Önerilen Model1	ResNet101	96.44	96.50	96.42	96.45	96.60
Önerilen Model2	ResNet152	96.63	96.59	97.25	96.53	96.52
Önerilen Model3	DenseNet169	96.34	96.37	95.56	97.07	97.12
Önerilen Model4	DenseNet201	97.01	97.09	96.82	97.64	97.66



KAYNAKÇA

- [1] T.c. sađlık bakanlıđı kanser nedir belirtileri. [Online]. Available: <https://hsgm.saglik.gov.tr/tr/kanser-nedir-belirtileri.html> (visited on 2024).
- [2] World health organization fact sheet detail cancer. [Online]. Available: <https://www.who.int/news-room/fact-sheets/detail/cancer> (visited on 2024).
- [3] P. Vineis, C. P. Wild, “Global cancer patterns: Causes and prevention,” *The Lancet*, vol. 383, no. 9916, pp. 549–557, 2014.
- [4] B. Keskinliç, M. Gültekin, A. Karaca, *et al.*, “Neden ulusal bir kanser programı,” *Türkiye Kanser Kontrol Programı, Keskinliç B, Gültekin M, Karaca AS et al (eds) First ed. Ankara: Republic of Turkey, Ministry of Health*, pp. 18–19, 2016.
- [5] F. Bray, J. Ferlay, I. Soerjomataram, R. L. Siegel, L. A. Torre, A. Jemal, “Global cancer statistics 2018: Globocan estimates of incidence and mortality worldwide for 36 cancers in 185 countries,” *CA: a cancer journal for clinicians*, vol. 68, no. 6, pp. 394–424, 2018.
- [6] N. Vigneswaran, M. D. Williams, “Epidemiologic trends in head and neck cancer and aids in diagnosis,” *Oral and Maxillofacial Surgery Clinics*, vol. 26, no. 2, pp. 123–141, 2014.
- [7] F. Kamangar, G. M. Dores, W. F. Anderson, “Patterns of cancer incidence, mortality, and prevalence across five continents: Defining priorities to reduce cancer disparities in different geographic regions of the world,” *Journal of clinical oncology*, vol. 24, no. 14, pp. 2137–2150, 2006.
- [8] *Oral cavity and oropharyngeal cancer*. [Online]. Available: <https://www.cancer.org/cancer/oral-cavity-and-oropharyngeal-cancer/about/what-is-oral-cavity-cancer.html>.
- [9] N. Kalavrezos, C. Scully, “Mouth cancer for clinicians part 2: Epidemiology,” *Dental update*, vol. 42, no. 4, pp. 354–359, 2015.
- [10] R. Sankaranarayanan, K. Ramadas, H. Amarasinghe, S. Subramanian, N. Johnson, “Oral cancer: Prevention, early detection, and treatment,” *Cancer: disease control priorities, third edition (volume 3)*, 2015.
- [11] H. Sung *et al.*, “Global cancer statistics 2020: Globocan estimates of incidence and mortality worldwide for 36 cancers in 185 countries,” *CA: a cancer journal for clinicians*, vol. 71, no. 3, pp. 209–249, 2021.

- [12] *World health organization oral health*. [Online]. Available: <https://gco.iarc.fr/today/data/factsheets/cancers/1-Lip-oral-cavity-fact-sheet.pdf> (visited on 2024).
- [13] S. Warnakulasuriya, "Global epidemiology of oral and oropharyngeal cancer," *Oral oncology*, vol. 45, no. 4-5, pp. 309–316, 2009.
- [14] M. Soler *et al.*, "Fiber intake and the risk of oral, pharyngeal and esophageal cancer," *International journal of cancer*, vol. 91, no. 3, pp. 283–287, 2001.
- [15] P. Speight, P. Farthing, "The pathology of oral cancer," *British dental journal*, vol. 225, no. 9, pp. 841–847, 2018.
- [16] C. M. Harris, G. Ghali, "Oral cancer: Etiology, diagnosis, classification and staging," *Peterson's Principles of Oral and Maxillofacial Surgery*, Milaro MM, Ghali GE, Larsen PE, Waite PD (eds). 3rd ed. Connecticut: People's Medical Publishing House, pp. 677–692, 2011.
- [17] L. Q. Chow, "Head and neck cancer. reply," *The New England journal of medicine*, vol. 382, no. 20, e57, 2020.
- [18] T. Wong, D. Wiesenfeld, "Oral cancer," *Australian dental journal*, vol. 63, S91–S99, 2018.
- [19] B. K. Joseph, "Oral cancer: Prevention and detection," *Medical Principles and Practice*, vol. 11, no. Suppl. 1, pp. 32–35, 2002.
- [20] Y. Su *et al.*, "Current insights into oral cancer diagnostics," *Diagnostics*, vol. 11, no. 7, p. 1287, 2021.
- [21] I. Chattopadhyay, M. Verma, M. Panda, "Role of oral microbiome signatures in diagnosis and prognosis of oral cancer," *Technology in cancer research & treatment*, vol. 18, p. 1533033819867354, 2019.
- [22] M. Trimarchi, G. Bertazzoni, M. Bussi, *et al.*, "Cocaine induced midline destructive lesions," *Rhinology*, vol. 52, no. 2, pp. 104–111, 2014.
- [23] M. Trimarchi, C. Bellini, B. Fabiano, S. Gerevini, M. Bussi, "Multiple mucosal involvement in cicatricial pemphigoid," *Acta Otorhinolaryngologica Italica*, vol. 29, no. 4, p. 222, 2009.
- [24] M. Biafora, G. Bertazzoni, M. Trimarchi, "Maxillary sinusitis caused by dental implants extending into the maxillary sinus and the nasal cavities," *Journal of Prosthodontics*, vol. 23, no. 3, pp. 227–231, 2014.
- [25] M. Trimarchi, S. Bondi, E. Della Torre, M. Terreni, M. Bussi, "Palate perforation differentiates cocaine-induced midline destructive lesions from granulomatosis with polyangiitis," *Acta Otorhinolaryngologica Italica*, vol. 37, no. 4, p. 281, 2017.
- [26] M. Lanzillotta *et al.*, "Deconstructing igg4-related disease involvement of midline structures: Comparison to common mimickers," *Modern Rheumatology*, vol. 27, no. 4, pp. 638–645, 2017.
- [27] A. Sosiawan, R. Chusnita, P. A. M. Laksanti, A. A. Anwar, N. F. Ramadhani, A. P. Nugraha, "Utilization of artificial intelligence-assisted histopathological detection in surveillance of oral squamous cell carcinoma staging: A narrative review," *World Journal of Advanced Research and Review*, vol. 16, no. 3, pp. 54–59, 2022.

- [28] S. B. Chinn, J. N. Myers, “Oral cavity carcinoma: Current management, controversies, and future directions,” *Journal of clinical oncology*, vol. 33, no. 29, p. 3269, 2015.
- [29] S. Silverman, A. R. Kerr, J. B. Epstein, “Oral and pharyngeal cancer control and early detection,” *Journal of Cancer Education*, vol. 25, pp. 279–281, 2010.
- [30] M. McCullough, G. Prasad, C. Farah, “Oral mucosal malignancy and potentially malignant lesions: An update on the epidemiology, risk factors, diagnosis and management,” *Australian dental journal*, vol. 55, pp. 61–65, 2010.
- [31] I. Gómez, J. Seoane, P. Varela-Centelles, P. Diz, B. Takkouche, “Is diagnostic delay related to advanced-stage oral cancer? a meta-analysis,” *European journal of oral sciences*, vol. 117, no. 5, pp. 541–546, 2009.
- [32] K. Hema Shree *et al.*, “Saliva as a diagnostic tool in oral squamous cell carcinoma—a systematic review with meta analysis,” *Pathology & Oncology Research*, vol. 25, pp. 447–453, 2019.
- [33] G. Ulaganathan *et al.*, “A clinicopathological study of various oral cancer diagnostic techniques,” *Journal of pharmacy & bioallied sciences*, vol. 9, no. Suppl 1, S4, 2017.
- [34] M. D. P. Beristain-Colorado *et al.*, “Application of neural networks for the detection of oral cancer: A systematic review,” *Dental and Medical Problems*, 2023.
- [35] G. Tanriver, M. Soluk Tekkesin, O. Ergen, “Automated detection and classification of oral lesions using deep learning to detect oral potentially malignant disorders,” *Cancers*, vol. 13, no. 11, p. 2766, 2021.
- [36] R. D. Uthoff *et al.*, “Point-of-care, smartphone-based, dual-modality, dual-view, oral cancer screening device with neural network classification for low-resource communities,” *PloS one*, vol. 13, no. 12, e0207493, 2018.
- [37] S. Xu *et al.*, “An early diagnosis of oral cancer based on three-dimensional convolutional neural networks,” *IEEE Access*, vol. 7, pp. 158 603–158 611, 2019.
- [38] R. K. Gupta, M. Kaur, J. Manhas, *et al.*, “Tissue level based deep learning framework for early detection of dysplasia in oral squamous epithelium,” *Journal of Multimedia Information System*, vol. 6, no. 2, pp. 81–86, 2019.
- [39] P. R. Jeyaraj, E. R. Samuel Nadar, “Computer-assisted medical image classification for early diagnosis of oral cancer employing deep learning algorithm,” *Journal of cancer research and clinical oncology*, vol. 145, pp. 829–837, 2019.
- [40] Q. Fu *et al.*, “A deep learning algorithm for detection of oral cavity squamous cell carcinoma from photographic images: A retrospective study,” *EClinicalMedicine*, vol. 27, 2020.
- [41] R. A. Welikala *et al.*, “Automated detection and classification of oral lesions using deep learning for early detection of oral cancer,” *IEEE Access*, vol. 8, pp. 132 677–132 693, 2020.

- [42] N. Das, E. Hussain, L. B. Mahanta, “Automated classification of cells into multiple classes in epithelial tissue of oral squamous cell carcinoma using transfer learning and convolutional neural network,” *Neural Networks*, vol. 128, pp. 47–60, 2020.
- [43] C. S. Chu, N. P. Lee, J. Adeoye, P. Thomson, S. Choi, “Machine learning and treatment outcome prediction for oral cancer,” *Journal of Oral Pathology & Medicine*, vol. 49, no. 10, pp. 977–985, 2020.
- [44] H. Lin, H. Chen, L. Weng, J. Shao, J. Lin, “Automatic detection of oral cancer in smartphone-based images using deep learning for early diagnosis,” *Journal of Biomedical Optics*, vol. 26, no. 8, pp. 086 007–086 007, 2021.
- [45] A. Alhazmi *et al.*, “Application of artificial intelligence and machine learning for prediction of oral cancer risk,” *Journal of Oral Pathology & Medicine*, vol. 50, no. 5, pp. 444–450, 2021.
- [46] V. Shavlokhova *et al.*, “Deep learning on oral squamous cell carcinoma ex vivo fluorescent confocal microscopy data: A feasibility study,” *Journal of Clinical Medicine*, vol. 10, no. 22, p. 5326, 2021.
- [47] K. Warin, W. Limprasert, S. Suebnukarn, S. Jinaporntham, P. Jantana, “Automatic classification and detection of oral cancer in photographic images using deep learning algorithms,” *Journal of Oral Pathology & Medicine*, vol. 50, no. 9, pp. 911–918, 2021.
- [48] F. Jubair, O. Al-karadsheh, D. Malamos, S. Al Mahdi, Y. Saad, Y. Hassona, “A novel lightweight deep convolutional neural network for early detection of oral cancer,” *Oral Diseases*, vol. 28, no. 4, pp. 1123–1130, 2022.
- [49] B. Nanditha, A. Geetha, H. Chandrashekar, M. Dinesh, S. Murali, “An ensemble deep neural network approach for oral cancer screening,” 2021.
- [50] H. Alkhadar, M. Macluskey, S. White, I. Ellis, A. Gardner, “Comparison of machine learning algorithms for the prediction of five-year survival in oral squamous cell carcinoma,” *Journal of Oral Pathology & Medicine*, vol. 50, no. 4, pp. 378–384, 2021.
- [51] A. Rahman *et al.*, “Histopathologic oral cancer prediction using oral squamous cell carcinoma biopsy empowered with transfer learning,” *Sensors*, vol. 22, no. 10, p. 3833, 2022.
- [52] M. A. Deif, H. Attar, A. Amer, I. A. Elhaty, M. R. Khosravi, A. A. Solyman, *et al.*, “Diagnosis of oral squamous cell carcinoma using deep neural networks and binary particle swarm optimization on histopathological images: An aiomt approach,” *Computational Intelligence and Neuroscience*, vol. 2022, 2022.
- [53] V. Liyanage, M. Tao, J. S. Park, K. N. Wang, S. Azimi, “Malignant and non-malignant oral lesions classification and diagnosis with deep neural networks,” *Journal of Dentistry*, vol. 137, p. 104 657, 2023.
- [54] M. Zhou *et al.*, “Deep learning algorithms for classification and detection of recurrent aphthous ulcerations using oral clinical photographic images,” *Journal of Dental Sciences*, vol. 19, no. 1, pp. 254–260, 2024.

- [55] J. Manikandan, B. V. Krishna, N. Varun, V. Vishal, S. Yugant, “Automated framework for effective identification of oral cancer using improved convolutional neural network,” in *2023 Eighth International Conference on Science Technology Engineering and Mathematics (ICONSTEM)*, IEEE, 2023, pp. 1–7.
- [56] Ş. T. Badik, M. Akar, “Machine learning classification models for the patients who have heart failure,” *Sigma Journal of Engineering and Natural Sciences*, vol. 42, no. 1, pp. 235–244, 2024.
- [57] M. Akar, N. M. Sirakov, “Support vector machine skin lesion classification in clifford algebra subspaces,” *Applications of Mathematics*, vol. 64, no. 5, pp. 581–598, 2019.
- [58] M. Akar, N. M. Sirakov, M. Mete, “Clifford algebra multivectors and kernels for melanoma classification,” *Mathematical Methods in the Applied Sciences*, vol. 45, no. 7, pp. 4056–4068, 2022.
- [59] *A brief history of artificial intelligence*. [Online]. Available: <https://www.livescience.com/49007-history-of-artificial-intelligence.html>.
- [60] V. V. Nabyev, *Yapay zeka: insan-bilgisayar etkileşimi*. Seçkin Yayıncılık, 2012.
- [61] G. Hinton *et al.*, “Deep neural networks for acoustic modeling in speech recognition: The shared views of four research groups,” *IEEE Signal processing magazine*, vol. 29, no. 6, pp. 82–97, 2012.
- [62] A. Graves, A. Mohamed, G. Hinton, “Speech recognition with deep recurrent neural networks,” in *2013 IEEE international conference on acoustics, speech and signal processing*, Ieee, 2013, pp. 6645–6649.
- [63] F. Chollet, “Xception: Deep learning with depthwise separable convolutions,” in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2017, pp. 1251–1258.
- [64] K. He, X. Zhang, S. Ren, J. Sun, “Deep residual learning for image recognition,” in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2016, pp. 770–778.
- [65] J. Devlin, M. Chang, K. Lee, K. Toutanova, “Bert: Pre-training of deep bidirectional transformers for language understanding,” *arXiv preprint arXiv:1810.04805*, 2018.
- [66] I. Sutskever, O. Vinyals, Q. V. Le, “Sequence to sequence learning with neural networks,” *Advances in neural information processing systems*, vol. 27, 2014.
- [67] L. Gualtieri, E. Rauch, R. Vidoni, “Emerging research fields in safety and ergonomics in industrial collaborative robotics: A systematic literature review,” *Robotics and Computer-Integrated Manufacturing*, vol. 67, p. 101998, 2021.
- [68] S. Palagi, P. Fischer, “Bioinspired microrobots,” *Nature Reviews Materials*, vol. 3, no. 6, pp. 113–124, 2018.

- [69] H. Menouar, I. Guvenc, K. Akkaya, A. S. Uluagac, A. Kadri, A. Tuncer, "Uav-enabled intelligent transportation systems for the smart city: Applications and challenges," *IEEE Communications Magazine*, vol. 55, no. 3, pp. 22–28, 2017.
- [70] S. Grigorescu, B. Trasnea, T. Cocias, G. Macesanu, "A survey of deep learning techniques for autonomous driving," *Journal of field robotics*, vol. 37, no. 3, pp. 362–386, 2020.
- [71] R. Lu, S. H. Hong, "Incentive-based demand response for smart grid with reinforcement learning and deep neural network," *Applied energy*, vol. 236, pp. 937–949, 2019.
- [72] M. Q. Raza, A. Khosravi, "A review on artificial intelligence based load demand forecasting techniques for smart grid and buildings," *Renewable and Sustainable Energy Reviews*, vol. 50, pp. 1352–1372, 2015.
- [73] K. Yu, A. L. Beam, I. S. Kohane, "Artificial intelligence in healthcare," *Nature biomedical engineering*, vol. 2, no. 10, pp. 719–731, 2018.
- [74] M. Elbadawi *et al.*, "Harnessing artificial intelligence for the next generation of 3d printed medicines," *Advanced Drug Delivery Reviews*, vol. 175, p. 113 805, 2021.
- [75] M. Jakšič, M. Marinč, "Relationship banking and information technology: The role of artificial intelligence and fintech," *Risk Management*, vol. 21, pp. 1–18, 2019.
- [76] B. L. Aylak, O. Okan, K. Yazıcı, "Yapay zeka ve makine öğrenmesi tekniklerinin lojistik sektöründe kullanımı," *El-Cezeri*, vol. 8, no. 1, pp. 74–93, 2021.
- [77] H. Shimizu, K. I. Nakayama, "Artificial intelligence in oncology," *Cancer science*, vol. 111, no. 5, pp. 1452–1460, 2020.
- [78] S. Badillo *et al.*, "An introduction to machine learning," *Clinical pharmacology & therapeutics*, vol. 107, no. 4, pp. 871–885, 2020.
- [79] B. Mahesh, "Machine learning algorithms-a review," *International Journal of Science and Research (IJSR).[Internet]*, vol. 9, no. 1, pp. 381–386, 2020.
- [80] V. Nasteski, "An overview of the supervised machine learning methods," *Horizons. b*, vol. 4, no. 51-62, p. 56, 2017.
- [81] A. Talwar, Y. Kumar, "Machine learning: An artificial intelligence methodology," *International Journal of Engineering and Computer Science*, vol. 2, no. 12, pp. 3400–3404, 2013.
- [82] G. James, D. Witten, T. Hastie, R. Tibshirani, *et al.*, *An introduction to statistical learning*. Springer, 2013, vol. 112.
- [83] T. Hastie, R. Tibshirani, J. H. Friedman, J. H. Friedman, *The elements of statistical learning: data mining, inference, and prediction*. Springer, 2009, vol. 2.
- [84] *Supervize me: What's the difference between supervised, unsupervised, semi-supervised and reinforcement learning?* [Online]. Available: <https://blogs.nvidia.com/blog/supervised-unsupervised-learning/>.

- [85] R. C. Deo, “Machine learning in medicine,” *Circulation*, vol. 132, no. 20, pp. 1920–1930, 2015.
- [86] R. Y. Choi, A. S. Coyner, J. Kalpathy-Cramer, M. F. Chiang, J. P. Campbell, “Introduction to machine learning, neural networks, and deep learning,” *Translational vision science & technology*, vol. 9, no. 2, pp. 14–14, 2020.
- [87] S. Kozyrev, “Classification by ensembles of neural networks,” *P-Adic Numbers, Ultrametric Analysis, and Applications*, vol. 4, pp. 27–33, 2012.
- [88] B. Jenkins, A. Tanguay, *Optical architectures for neural network implementation, handbook of neural computing and neural networks*, 1995.
- [89] J. L. Balcázar, R. Gavalda, H. T. Siegelmann, “Computational power of neural networks: A characterization in terms of kolmogorov complexity,” *IEEE Transactions on Information Theory*, vol. 43, no. 4, pp. 1175–1183, 1997.
- [90] N. Kasabov *et al.*, “Evolving spatio-temporal data machines based on the neucube neuromorphic framework: Design methodology and selected applications,” *Neural Networks*, vol. 78, pp. 1–14, 2016.
- [91] M. Zakaria, A. Mabrouka, S. Sarhan, “Artificial neural network: A brief overview,” *neural networks*, vol. 1, p. 2, 2014.
- [92] Y. Wu, J. Feng, “Development and application of artificial neural network,” *Wireless Personal Communications*, vol. 102, pp. 1645–1656, 2018.
- [93] F. Amato, A. López, E. M. Peña-Méndez, P. Vañhara, A. Hampl, J. Havel, *Artificial neural networks in medical diagnosis*, 2013.
- [94] Y. Wu, S. Wang, “A new algorithm to improve the learning performance of neural network through result-feedback,” *J. Comput. Res. Develop*, vol. 41, pp. 488–492, 2004.
- [95] A. Yazici, E. Öğüş, S. Ankaralı, S. Canan, H. Ankaralı, Z. Akkuş, “Artificial neural networks: Review,” *Türkiye Klinikleri Journal of Medical Sciences*, vol. 27, pp. 65–71, Feb. 2007.
- [96] J. Gaudart, B. Giusiano, L. Huiart, “Comparison of the performance of multi-layer perceptron and linear regression for epidemiological data,” *Computational statistics & data analysis*, vol. 44, no. 4, pp. 547–570, 2004.
- [97] S. Haykin, *Neural networks: a comprehensive foundation*. Prentice Hall PTR, 1998.
- [98] D. B. Ergül, A. B. V. Malkoçoğlu, S. A. Özgünler, “Mimari tasarım karar verme süreçlerinde yapay zekâ tabanlı bulanık mantık sisteminin değerlendirilmesi,” *Journal of Architectural Sciences and Applications*, vol. 7, no. 2, pp. 878–899, 2022.
- [99] Y. Bengio *et al.*, “Learning deep architectures for ai,” *Foundations and trends® in Machine Learning*, vol. 2, no. 1, pp. 1–127, 2009.
- [100] S. Min, B. Lee, S. Yoon, “Deep learning in bioinformatics,” *Briefings in bioinformatics*, vol. 18, no. 5, pp. 851–869, 2017.
- [101] M. Wainberg, D. Merico, A. DeLong, B. J. Frey, “Deep learning in biomedicine,” *Nature biotechnology*, vol. 36, no. 9, pp. 829–838, 2018.

- [102] Y. LeCun, Y. Bengio, G. Hinton, “Deep learning,” *nature*, vol. 521, no. 7553, pp. 436–444, 2015.
- [103] R. Hecht-Nielsen, “Theory of the backpropagation neural network,” *Neural Networks*, vol. 1, p. 445, 1988, INNS First Annual Meeting, issn: 0893-6080.
- [104] L. Bottou *et al.*, “Stochastic gradient learning in neural networks,” *Proceedings of Neuro-Nimes*, vol. 91, no. 8, p. 12, 1991.
- [105] *Deep learning (derin öğrenme) nedir?* [Online]. Available: <https://cloudtalktime.com/deep-learning-derin-ogrenme-nedir/>.
- [106] V. Nair, G. E. Hinton, “Rectified linear units improve restricted boltzmann machines,” in *Proceedings of the 27th international conference on machine learning (ICML-10)*, 2010, pp. 807–814.
- [107] K. Weiss, T. M. Khoshgoftaar, D. Wang, “A survey of transfer learning,” *Journal of Big data*, vol. 3, pp. 1–40, 2016.
- [108] G. Sünbül, A. Soyluk, “A review of using deep learning technology in the built environment of disaster management phases,” *Journal of Architectural Sciences and Applications*, vol. 9, no. Special Issue, pp. 201–218, 2024.
- [109] A. Shrestha, A. Mahmood, “Review of deep learning algorithms and architectures,” *IEEE access*, vol. 7, pp. 53 040–53 065, 2019.
- [110] F. Doğan, İ. Türkoğlu, “Derin öğrenme modelleri ve uygulama alanlarına ilişkin bir derleme,” *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, vol. 10, no. 2, pp. 409–445, 2019.
- [111] H. Wang, B. Raj, “On the origin of deep learning,” *arXiv preprint arXiv:1702.07800*, 2017.
- [112] C. Hung, “Deep learning in biomedical informatics,” in *Intelligent Nanotechnology*, Elsevier, 2023, pp. 307–329.
- [113] A. Fischer, C. Igel, “An introduction to restricted boltzmann machines,” in *Progress in Pattern Recognition, Image Analysis, Computer Vision, and Applications: 17th Iberoamerican Congress, CIARP 2012, Buenos Aires, Argentina, September 3-6, 2012. Proceedings 17*, Springer, 2012, pp. 14–36.
- [114] O. Kaynar, Y. Görmez, Y. E. Işık, “Oto kodlayıcı tabanlı derin öğrenme makinaları ile spam tespiti,” *3. Uluslararası Yönetim Bilişim Sistemleri Konferansı*, p. 44, 2016.
- [115] U. Murat, U. Emine, “Derin otomatik kodlayıcı tabanlı özellik çıkarımı ile android kötüçül yazılım uygulamalarının tespiti,” *Yönetim Bilişim Sistemleri Dergisi*, vol. 5, no. 2, pp. 21–28, 2019.
- [116] Y. LeCun, L. Bottou, Y. Bengio, P. Haffner, “Gradient-based learning applied to document recognition,” *Proceedings of the IEEE*, vol. 86, no. 11, pp. 2278–2324, 1998.
- [117] X. Zhang, C. Xv, M. Shen, X. He, W. Du, “Survey of convolutional neural network,” in *2018 International Conference on Network, Communication, Computer Engineering (NCCE 2018)*, Atlantis Press, 2018, pp. 93–97.

- [118] D. H. Hubel, T. N. Wiesel, “Receptive fields and functional architecture of monkey striate cortex,” *The Journal of physiology*, vol. 195, no. 1, pp. 215–243, 1968.
- [119] K. Fukushima, “Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position,” *Biological cybernetics*, vol. 36, no. 4, pp. 193–202, 1980.
- [120] R. Yamashita, M. Nishio, R. K. G. Do, K. Togashi, “Convolutional neural networks: An overview and application in radiology,” *Insights into imaging*, vol. 9, pp. 611–629, 2018.
- [121] *The mnist database*. [Online]. Available: <http://yann.lecun.com/exdb/mnist/>.
- [122] P. Lakhani, B. Sundaram, “Deep learning at chest radiography: Automated classification of pulmonary tuberculosis by using convolutional neural networks,” *Radiology*, vol. 284, no. 2, pp. 574–582, 2017.
- [123] P. F. Christ *et al.*, “Automatic liver and lesion segmentation in ct using cascaded fully convolutional neural networks and 3d conditional random fields,” in *Medical Image Computing and Computer-Assisted Intervention–MICCAI 2016: 19th International Conference, Athens, Greece, October 17–21, 2016, Proceedings, Part II 19*, Springer, 2016, pp. 415–423.
- [124] M. C. Chen *et al.*, “Deep learning to classify radiology free-text reports,” *Radiology*, vol. 286, no. 3, pp. 845–852, 2018.
- [125] K. Yasaka, H. Akai, O. Abe, S. Kiryu, “Deep learning with convolutional neural network for differentiation of liver masses at dynamic contrast-enhanced ct: A preliminary study,” *Radiology*, vol. 286, no. 3, pp. 887–896, 2018.
- [126] K. H. Kim, S. H. Choi, S. Park, “Improving arterial spin labeling by using deep learning,” *Radiology*, vol. 287, no. 2, pp. 658–666, 2018.
- [127] F. Liu, H. Jang, R. Kijowski, T. Bradshaw, A. B. McMillan, “Deep learning mr imaging–based attenuation correction for pet/mr imaging,” *Radiology*, vol. 286, no. 2, pp. 676–684, 2018.
- [128] J. Gu *et al.*, “Recent advances in convolutional neural networks,” *Pattern recognition*, vol. 77, pp. 354–377, 2018.
- [129] A. Dhillon, G. K. Verma, “Convolutional neural network: A review of models, methodologies and applications to object detection,” *Progress in Artificial Intelligence*, vol. 9, no. 2, pp. 85–112, 2020.
- [130] J. Naranjo-Torres, M. Mora, R. Hernández-García, R. J. Barrientos, C. Fredes, A. Valenzuela, “A review of convolutional neural network applied to fruit image processing,” *Applied Sciences*, vol. 10, no. 10, p. 3443, 2020.
- [131] J. Koh, M. Suk, S. M. Bhandarkar, “A multilayer self-organizing feature map for range image segmentation,” *Neural Networks*, vol. 8, no. 1, pp. 67–86, 1995.
- [132] L. Liu, C. Shen, A. van den Hengel, “Cross-convolutional-layer pooling for image recognition,” *IEEE transactions on pattern analysis and machine intelligence*, vol. 39, no. 11, pp. 2305–2313, 2016.

- [133] T. Wang, D. J. Wu, A. Coates, A. Y. Ng, “End-to-end text recognition with convolutional neural networks,” in *Proceedings of the 21st international conference on pattern recognition (ICPR2012)*, IEEE, 2012, pp. 3304–3308.
- [134] J. Yang, K. Yu, Y. Gong, T. Huang, “Linear spatial pyramid matching using sparse coding for image classification,” in *2009 IEEE Conference on computer vision and pattern recognition*, IEEE, 2009, pp. 1794–1801.
- [135] Y. Boureau, J. Ponce, Y. LeCun, “A theoretical analysis of feature pooling in visual recognition,” in *Proceedings of the 27th international conference on machine learning (ICML-10)*, 2010, pp. 111–118.
- [136] M. Ranzato, F. J. Huang, Y. Boureau, Y. LeCun, “Unsupervised learning of invariant feature hierarchies with applications to object recognition,” in *2007 IEEE conference on computer vision and pattern recognition*, IEEE, 2007, pp. 1–8.
- [137] N. Qian, “On the momentum term in gradient descent learning algorithms,” *Neural networks*, vol. 12, no. 1, pp. 145–151, 1999.
- [138] N. Aloysius, M. Geetha, “A review on deep convolutional neural networks,” in *2017 international conference on communication and signal processing (ICCSP)*, IEEE, 2017, pp. 0588–0592.
- [139] A. Krizhevsky, I. Sutskever, G. E. Hinton, “Imagenet classification with deep convolutional neural networks,” *Advances in neural information processing systems*, vol. 25, 2012.
- [140] J. Murphy, “An overview of convolutional neural network architectures for deep learning,” *Microway Inc*, pp. 1–22, 2016.
- [141] Z. Li, F. Liu, W. Yang, S. Peng, J. Zhou, “A survey of convolutional neural networks: Analysis, applications, and prospects,” *IEEE transactions on neural networks and learning systems*, vol. 33, no. 12, pp. 6999–7019, 2021.
- [142] M. T. Hagan, H. B. Demuth, M. H. Beale, *Design neural network*, 2002.
- [143] K. Chengeta, “A review of local feature algorithms and deep learning approaches in facial expression recognition with tensorflow and keras,” in *Pattern Recognition: 11th Mexican Conference, MCPR 2019, Querétaro, Mexico, June 26–29, 2019, Proceedings 11*, Springer, 2019, pp. 127–138.
- [144] D. H. Hubel, T. N. Wiesel, “Receptive fields, binocular interaction and functional architecture in the cat’s visual cortex,” *The Journal of physiology*, vol. 160, no. 1, p. 106, 1962.
- [145] S. Sakib, N. Ahmed, A. J. Kabir, H. Ahmed, “An overview of convolutional neural network: Its architecture and applications,” 2019.
- [146] C. Pramerdorfer, M. Kampel, “Facial expression recognition using convolutional neural networks: State of the art,” *arXiv preprint arXiv:1612.02903*, 2016.
- [147] Y. Tang, “Deep learning using linear support vector machines,” *arXiv preprint arXiv:1306.0239*, 2013.
- [148] A. Gulli, S. Pal, *Deep learning with Keras*. Packt Publishing Ltd, 2017.

- [149] X. Xia, C. Xu, B. Nan, “Facial expression recognition based on tensorflow platform,” in *ITM Web of Conferences*, EDP Sciences, vol. 12, 2017, p. 01 005.
- [150] Q. Wang, Y. Ma, K. Zhao, Y. Tian, “A comprehensive survey of loss functions in machine learning,” *Annals of Data Science*, pp. 1–26, 2020.
- [151] D. P. Kingma, J. Ba, “Adam: A method for stochastic optimization,” *arXiv preprint arXiv:1412.6980*, 2014.
- [152] S. Ruder, “An overview of gradient descent optimization algorithms,” *arXiv preprint arXiv:1609.04747*, 2016.
- [153] G. B. Orr, K. Müller, *Neural networks: tricks of the trade*. Springer, 1998.
- [154] R. G. Wijnhoven, P. de With, “Fast training of object detection using stochastic gradient descent,” in *2010 20th International conference on pattern recognition*, IEEE, 2010, pp. 424–427.
- [155] D. Saad, *On-line learning in neural networks*. Cambridge University Press, 2009.
- [156] J. Duchi, E. Hazan, Y. Singer, “Adaptive subgradient methods for online learning and stochastic optimization.,” *Journal of machine learning research*, vol. 12, no. 7, 2011.
- [157] N. Ma, X. Zhang, H. Zheng, J. Sun, “Shufflenet v2: Practical guidelines for efficient cnn architecture design,” in *Proceedings of the European conference on computer vision (ECCV)*, 2018, pp. 116–131.
- [158] S. Sharma, R. Kiros, R. Salakhutdinov, “Action recognition using visual attention,” *arXiv preprint arXiv:1511.04119*, 2015.
- [159] F. Korzeniowski, G. Widmer, “A fully convolutional deep auditory model for musical chord recognition,” in *2016 IEEE 26th International Workshop on Machine Learning for Signal Processing (MLSP)*, IEEE, 2016, pp. 1–6.
- [160] T. Sercu, C. Puhersch, B. Kingsbury, Y. LeCun, “Very deep multilingual convolutional neural networks for lvsr,” in *2016 IEEE international conference on acoustics, speech and signal processing (ICASSP)*, IEEE, 2016, pp. 4955–4959.
- [161] *Derin öğrenme teknikleriyle akciğer görüntüleri üzerinde kanser teşhisi*. [Online]. Available: <https://tez.yok.gov.tr/UlusalTezMerkezi/tezSorguSonucYeni.jsp>.
- [162] [Online]. Available: <https://www.kaggle.com/ashenafifasilkebede/dataset?select=val>.
- [163] A. M. Reza, “Realization of the contrast limited adaptive histogram equalization (clahe) for real-time image enhancement,” *Journal of VLSI signal processing systems for signal, image and video technology*, vol. 38, pp. 35–44, 2004.
- [164] E. Ç. Budak, “Üniversite öğrencilerinin bilgisayar okur-yazarlığını etkileyen faktörlerin veri madenciliği ile analizi,” *AJIT-e: Academic Journal of Information Technology*, vol. 4, no. 10, pp. 57–70, 2013.

- [165] J. Liang, “Image classification based on resnet,” in *Journal of Physics: Conference Series*, IOP Publishing, vol. 1634, 2020, p. 012 110.
- [166] Y. LeCun *et al.*, “Backpropagation applied to handwritten zip code recognition,” *Neural computation*, vol. 1, no. 4, pp. 541–551, 1989.
- [167] M. D. Zeiler, R. Fergus, “Visualizing and understanding convolutional networks,” in *Computer Vision–ECCV 2014: 13th European Conference, Zurich, Switzerland, September 6-12, 2014, Proceedings, Part I 13*, Springer, 2014, pp. 818–833.
- [168] K. Simonyan, A. Zisserman, “Very deep convolutional networks for large-scale image recognition,” *arXiv preprint arXiv:1409.1556*, 2014.
- [169] C. Szegedy *et al.*, “Going deeper with convolutions,” in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2015, pp. 1–9.
- [170] C. M. Bishop, *Neural networks for pattern recognition*. Oxford university press, 1995.
- [171] B. D. Ripley, *Pattern recognition and neural networks*. Cambridge university press, 2007.
- [172] W. N. Venables, B. D. Ripley, *Modern applied statistics with S-PLUS*. Springer Science & Business Media, 2013.
- [173] G. Huang, Z. Liu, L. Van Der Maaten, K. Q. Weinberger, “Densely connected convolutional networks,” in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2017, pp. 4700–4708.
- [174] C. Lee, S. Xie, P. Gallagher, Z. Zhang, Z. Tu, “Deeply-supervised nets,” in *Artificial intelligence and statistics*, Pmlr, 2015, pp. 562–570.
- [175] S. Ioffe, C. Szegedy, “Batch normalization: Accelerating deep network training by reducing internal covariate shift,” in *International conference on machine learning*, pmlr, 2015, pp. 448–456.
- [176] X. Glorot, A. Bordes, Y. Bengio, “Deep sparse rectifier neural networks,” in *Proceedings of the fourteenth international conference on artificial intelligence and statistics*, JMLR Workshop and Conference Proceedings, 2011, pp. 315–323.
- [177] A. Sharma, P. K. Mishra, “State-of-the-art in performance metrics and future directions for data science algorithms,” *Journal of Scientific Research*, vol. 64, no. 2, pp. 221–238, 2020.
- [178] A. Deshpande, V. V. Estrela, P. Patavardhan, “The dct-cnn-resnet50 architecture to classify brain tumors with super-resolution, convolutional neural network, and the resnet50,” *Neuroscience Informatics*, vol. 1, no. 4, p. 100 013, 2021.
- [179] K. Ali, Z. A. Shaikh, A. A. Khan, A. A. Laghari, “Multiclass skin cancer classification using efficientnets—a first step towards preventing skin cancer,” *Neuroscience Informatics*, vol. 2, no. 4, p. 100 034, 2022.
- [180] V. Shestak, D. Gura, N. Khudyakova, Z. Shaikh, Y. Bokov, *Chatbot design issues: Building intelligence with the cartesian paradigm. evolutionary intelligence*, 2020.

- [181] Z. A. Shaikh, "Keyword detection techniques: A comprehensive study.," *Engineering, Technology & Applied Science Research*, vol. 8, no. 1, 2018.
- [182] A. Sharma, R. Kumar, "Service-level agreement—energy cooperative quickest ambulance routing for critical healthcare services," *Arabian Journal for Science and Engineering*, vol. 44, no. 4, pp. 3831–3848, 2019.
- [183] Z. A. Shaikh, N. Moiseev, A. Mikhaylov, S. Yüksel, "Facile synthesis of copper oxide-cobalt oxide/nitrogen-doped carbon (Cu₂O-Co₃O₄/CN) composite for efficient water splitting," *Applied Sciences*, vol. 11, no. 21, p. 9974, 2021.
- [184] A. Sharma, Sarishma, R. Tomar, N. Chilamkurti, B.-G. Kim, "Blockchain based smart contracts for internet of medical things in e-healthcare," *Electronics*, vol. 9, no. 10, p. 1609, 2020.
- [185] Z. Liu, Z. A. Shaikh, F. Gazizova, "Using the concept of game-based learning in education.," *International Journal of Emerging Technologies in Learning*, 2020.
- [186] A. Sharma, R. Kumar, "Computation of the reliable and quickest data path for healthcare services by using service-level agreements and energy constraints," *Arabian Journal for Science and Engineering*, vol. 44, no. 11, pp. 9087–9104, 2019.

TEZDEN ÜRETİLMİŞ YAYINLAR

Makale

1. B. Süren, M. Akar, "Examination of ResNet and DenseNet Architectures in Early Diagnosis of Oral Cancer: An Evaluation", *Gazi University Journal of Science*, (In review).

Konferans Bildirisi

1. B. Süren, M. Akar, "The Use of Artificial Neural Networks in Oral Cancer Diagnosis", in *15th Ankara Mathematics Days (AMG 2024)*, Ankara, Türkiye, pp. 28-29, May 23-24, 2024.

Proje

1. Mutlu AKAR (Yürütücü), Betül SÜREN (Araştırmacı), "Ağız Kanseri Tanısında Yapay Sinir Ağlarının Kullanımı", YTÜ-BAPK Yüksek Lisans Projesi, (26.01.2024-Devam Ediyor), (Proje No: FYL-2024-6104).