



T.C.
KONYA TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

**SEFALOMETRİK NOKTALARIN DERİN
ÖĞRENME KULLANARAK OTOMATİK
TESPİTİ**

Mogham Njikam Mohamed Nourdine

YÜKSEK LİSANS

BİLGİSAYAR MÜHENDİSLİĞİ

Aralık-2021
KONYA
Her Hakkı Saklıdır

TEZ KABUL VE ONAYI

Mogham Njikam Mohamed Nourdine tarafından hazırlanan ‘‘Sefalometrik Noktaların Derin Öğrenme Kullanarak Otomatik Tespiti’’ adlı tez çalışması 14/12/2021 tarihinde ařağıdaki jüri tarafından oy birliğı / oy çokluğı ile Konya Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü Bilgisayar Mühendisliğı Anabilim Dalı’nda YÜKSEK LİSANS olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Başkan

Doç. Dr. Ahmet BABALIK

.....

Danışman

Dr. Öğr. Üyesi Betül UZBAŞ

.....

Üye

Dr. Öğr. Üyesi Ayşe Merve ACILAR

.....

Yukarıdaki sonucu onaylarım.

Prof. Dr. Saadettin Erhan KESEN
Enstitü Müdürü

TEZ BİLDİRİMİ

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

DECLARATION PAGE

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

Mogham Njikam Mohamed Nourdine
Tarih:14.12.2021

ÖZET

YÜKSEK LİSANS

SEFALOMETRİK NOKTALARIN DERİN ÖĞRENME KULLANARAK OTOMATİK TESPİTİ

Mogham Njikam Mohamed Nourdine

**Konya Teknik Üniversitesi
Lisansüstü Eğitim Enstitüsü
Bilgisayar Mühendisliği**

Danışman: Dr. Öğr. Üyesi Betül UZBAŞ

2021, 64 Sayfa

Jüri

**Doç. Dr. Ahmet BABALIK
Dr. Öğr. Üyesi Betül UZBAŞ
Dr. Öğr. Üyesi Ayşe Merve ACILAR**

Günümüzde her sektörde bilgisayarlar kullanılarak büyük miktarda veriler toplanmaktadır. Sağlık, savunma sanayi, uzay ve siber güvenlik gibi alanlarda makine öğrenmesi yöntemleri kullanılarak, toplanan bu veri yığınları yüksek başarı oranlarıyla raporlanıp bunlardan anlamlı bilgiler çıkarılabilmektedir. Medikal görüntü analizi alanında yapılan araştırmalara ilgi artmasıyla birlikte uzmanlar, kritik tıbbi analiz problemlerini ele almak için ilginç ve etkili yöntemlere yönelmiştir. Bu alanlardan biri de sefalometrik analizdir. Sefalometrik işaretler hastalık teşhisleri, oral ve maksillofasiyal cerrahi alanlarında değerlendirme ve kraniyofasiyal büyüme tahmini, tedavi planı, küratif etkisini değerlendirme ve farklı olguları karşılaştırmak için kullanılmaktadır.

Bu tez çalışmasında Evrişimsel Sinir Ağları (ESA) kullanılarak sefalometrik noktalarının otomatik tespitini yapan bir U-Net modeli geliştirilmiştir. 2015 IEEE Uluslararası Biyomedikal Görüntüleme Sempozyumu içinde Sefalometrik X-ray Görüntü Analizi Yarışması'nın himayesinde oluşturulmuş sefalometrik görüntüler kullanılmıştır. Toplam 19 Sefalometrik nokta otomatik tespit edilmiştir. 2 mm aralığında 74,0% Başarılı Algılama Oranı (BAO), 2,5 mm aralığında 81,4%, 3 mm aralığında 86,3% ve 4mm aralığında ise 92,2% BAO elde edilmiştir.

Anahtar Kelimeler: Evrişimsel Sinir Ağları, Sefalometrik Nokta Tespiti, Tıbbi Görüntü Analizi

ABSTRACT

MS THESIS

**AUTOMATIC DETECTION OF CEPHALOMETRIC POINTS
USING DEEP LEARNING**

Mogham Njikam Mohamed Nourdine

**Konya Technical University
Institute of Graduate Studies
Department of Computer Engineering**

Advisor: Asst. Prof. Dr. Betül UZBAŞ

2021, 64 Pages

Jury

**Assoc. Prof. Ahmet BABALIK
Assist. Prof. Dr. Betül UZBAŞ
Assist. Prof. Dr. Ayşe Merve ACILAR**

Today, large amounts of data are collected using computers in every sector. Using machine learning methods in areas such as networking, defense industry, space and cybersecurity, these data can be reported with high success rates and meaningful information can be extracted. With the increase in research in digital x-ray imaging, experts have successfully brought forward interesting and effective methods to address critical medical analysis problems. One of these fields is cephalometric analysis. Within the scope of the study of this thesis, a solution was presented with deep learning on cephalometric image analysis. Cephalometric analysis is used for disease diagnoses, evaluation in oral and maxillofacial surgery areas and craniofacial growth estimate, treatment plan, curative effect evaluation and comparison of different cases.

In this thesis study, a U-Net model was developed that makes automatic detection of Cephalometric points using Convolutional Neural Networks. The data used in the scope of this research are obtained from the publicly available dataset provided during the 2015 ISBI Grand Challenge Training Dataset. 19 Cephalometric points are detected automatically. 74,0% Success Detection Rate was achieved in the range of 2 mm, 81,4% in the 2.5 mm range, 86,3% in the 3mm range and 92,2% in the 4mm range.

Keywords: Convolutional Neural Networks, Cephalometric Points Detection, Medical Image Analysis

ÖNSÖZ

Yüksek lisans eğitimim boyunca değerli bilgilerini benimle paylaşan, tez çalışma konusu belirleyen, kaynaklara erişimde ve tezimin tamamlanmasında yardımlarını esirgemeyen, akademik ve sosyal anlamda bana faydalı olabilmek için elinden gelenden fazlasını sunan, danışman hoca statüsünü yerine getiren çok değerli tez danışmanım sayın Dr. Öğr. Üyesi Betül Uzbaş'a tüm içtenliğimle teşekkür ederim.

Bu yüksek lisans programı sürecinde tüm destekleriyle bana eşlik eden diğer üniversite hocalarıma teşekkürlerimi sunuyorum.

Hayatımın her döneminde beni destekleyen, her zaman yanımda olan sevgili eşime, en büyük şansım olan aileme ve tüm arkadaşlarıma ayrı ayrı teşekkür ederim. Bu tez çalışmasını rahmetli annem anısına ithaf ediyorum.

Mogham Njikam Mohamed Nourdine

KONYA-2021

İÇİNDEKİLER

ÖZET	i
ABSTRACT.....	ii
ÖNSÖZ	iii
İÇİNDEKİLER.....	iv
SİMGELER VE KISALTMALAR.....	vi
1. GİRİŞ.....	1
2. KAYNAK ARAŞTIRMASI.....	4
2.1. Tıbbi Görüntü İşleme Üzerine Yapılmış Derin Öğrenme Çalışmaları	5
2.2. Sefalometrik Noktaları Tespiti Üzerine Yapılmış Çalışmalar	8
3. MATERYAL VE YÖNTEM.....	13
3.1. Sefalometrik Analiz	13
3.2. Makine Öğrenmesi.....	15
3.2.1. Denetimli öğrenme	16
3.2.2. Denetimsiz öğrenme	18
3.2.3. Takviyeli öğrenme	18
3.2.4. Aşırı ve eksik öğrenme	19
3.2.5. Çapraz doğrulama (Cross validation)	20
3.2.6. Yanlılık (bias) ve varyans	20
3.3. Derin Öğrenme	21
3.3.1. Derin öğrenme yapısı.....	21
3.3.1.1. Evrişimsel Sinir Ağları (ESA).....	22
3.3.1.1.1. Evrişim katmanı	22
3.3.1.1.2. Havuzlama katmanı.....	25
3.3.1.1.3. Bırakma katmanı	26
3.3.1.1.4. Sınıflandırma katmanı	26
3.3.1.1.5. Tam bağlantılı katman.....	27
3.3.1.2. Tam Evrişimsel sinir ağları (TESA).....	27
3.3.2. U-Net	28
3.4. Geri Yayılım Algoritması	29
3.5. Hiperparametreler	32
3.5.1. Öğrenme hızı ve momentum katsayısı.....	33
3.5.2. Aktivasyon fonksiyonları (AF).....	34

3.5.2.1.	Lineer (doğrusal) fonksiyon	34
3.5.2.2.	Sigmoid fonksiyonu.....	35
3.5.2.3.	Tanh (hiperbolik tanjant) fonksiyonu	36
3.5.2.4.	Softmax fonksiyonu.....	37
3.5.2.5.	Rektifiye lineer birim (ReLU) fonksiyonu	37
3.5.2.6.	Üstel Doğrusal Birim (ELU)	38
3.5.2.7.	Sızıntı ReLU fonksiyonu.....	39
3.5.3.	Optimizasyon fonksiyonu	39
3.5.4.	Kayıp fonksiyonu.....	40
3.6.	Değerlendirme Metrikleri	41
3.6.1.	Ortalama mutlak hata.....	41
3.6.2.	Ortalama kare hatası	42
3.6.3.	Sefalometrik değerlendirme metrikleri.....	42
3.7.	Evrişimsel Sinir Ağında Performans Artırma Yöntemleri	44
3.8.	Veri Arttırma.....	45
4.	ÖNERİLEN MODEL VE BULGULAR.....	46
4.1.	Veri Seti	46
4.2.	Veri Ön İşleme ve Arttırma	49
4.2.1.	Yeniden boyutlandırma.....	49
4.2.2.	Veri Arttırma.....	49
4.3.	Önerilen Model	50
5.	SONUÇLAR VE ÖNERİLER.....	60
KAYNAKLAR	61	

SİMGELER VE KISALTMALAR

Kısaltmalar

AF	: Aktivasyon fonksiyon
ASM	: Aktif Şekil Modelleri
BAO	: Başarılı Algılama Oranı
DESA	: Derin Evrişimsel Sinir Ağları
DSA	: Derin Sinir Ağı
DÖ	: Derin Öğrenme
DVM	: Destek Vektör Makinesi
ELU	: Üstel Doğrusal Birim
ESA	: Evrişimsel Sinir Ağı
KSM	: Kısıtlı Boltzmann Makinesi
OKH	: Ortalama kare hatası
OMH	: Ortalama Mutlak Hata
ReLU	: Rektifiye Lineer Birimi
TESA	: Tam Evrişimsel Sinir Ağları
TSA	: Tekrarlayan Sinir Ağları
YSA	: Yapay Sinir Ağları

1. GİRİŞ

Son yıllarda, yapay zekâ bilgisayar biliminde büyük bir araştırma alanı olmuştur. Bu alanda gelişen teknolojiler sayesinde insanlar gibi düşünüp karar verebilecek akıllı uygulamalar geliştirilmiştir. Günümüzde bu teknolojiler kullanılarak tıp alanında çok sayıda araştırmalar yapılmış ve geleneksel yöntemler yerine daha iyi ve modern hastalık teşhis yöntemleri sunulmuştur. Bu uygulamalar insani hatalardan kaynaklanan ölüm sayısının azalmasını ve uzmanları gereksiz rutin işlerden kurtarıp zaman tasarrufu sağlamıştır.

Ortodontide tanı aracı olarak olan radyografi 1900 yılında W.A Price tarafından kullanılmaya başlanmıştır (Price, 1900). Radyografi, insan vücudundan oluşan dokuların, organların, kemiklerin ve damarların görüntülerini sağlamak için radyasyon kullanma bilimidir. Günümüzde sefalometrik radyografi, ortodontistler ve plastik cerrahlar için sayısız pratik uygulamaya sahip bir yöntemdir. Bu işlem, hastaların tedavisinde ortodontistler için neredeyse vazgeçilmez hale gelmiştir.

Sefalometrik analiz insan kafatasının diş ve iskelet ilişkilerinin analizidir. Sefalometrik görüntülerin analizleri sayesinde hastaların kemik, diş ve yumuşak doku yapılarının yorumlanması kolaylaşır. Bu analiz işlemi ortodonti tanı ve tedavi planlaması için kolaylık sağlar. Yaygın olarak ortodonti, ortopedi bölümlerinde oral ve maksillofasiyal cerrahi ve benzer alanlarda değerlendirme ve kraniyofasiyal büyüme tahmini, tedavi planı, küratif etkisini değerlendirme ve farklı olguları karşılaştırmak için kullanılır (Cardillo ve Sid-Ahmed, 1994a).

Sefalometrik noktaların koordinatlarını elde etmek için iki önemli yol vardır; dönüm noktası lokalizasyonu veya kraniyofasiyal anatomik yapı (Yue ve ark., 2006). Sefalometrik nokta işaretleri genellikle geleneksel bir ışık kutusu ile sefalometrik görüntüler izlenip ve bir kalemle manuel olarak işaretlenerek tespit edilir. Bu süreç çok monoton ve zaman alıcıdır. Başka bir yol ise, ekrandaki dijital sefalogramlarda yer işaretlerini doğrudan işaretlemektir. Klinik teşhiste farklı doktorların belirli noktalar için aynı pozisyonu bulmaları zordur, sonuçlar bir doktordan diğerine farklıdır, hatta bu işaretleri aynı doktorun iki farklı zamanda aynı bulma ihtimali düşüktür. Deneyimli bir uzman tarafından bile bu işlemin gerçekleştirilmesinde tutarsızlık olabilmektedir.

Otomatik sefalometrik analiz, verilerin yapısı nedeniyle zor bir görevdir. Klinik uygulamada ve araştırma ortamında bu sınırlamaları aşmak amacıyla sefalometrik

noktaları otomatik tespit etmek için girişimlerde bulunulmuştur. Bu nokta işaretlerini belirleme sırasında var olan zorlukların nedenleri, sefalometrik bir radyografinin düşük tanısal kalitesi, hastanın kafatası yapısının (sert ve yumuşak dokular) biyolojik özelliklerindeki büyük farklılıklar, örtüşen yapılar, anormallikler ve gri tonlamada küçük değişikliklerin olmasında kaynaklanmaktadır. Bu işlemi kolaylaştırmak adına araştırmacılar Derin Öğrenme (DÖ) ile bu işlemi gerçekleştirmeye çalışmaktadırlar (Litjens ve ark., 2017). Kliniklerde bu nokta işareti belirleme işleminin manuel olarak değil, bilgisayarlar kullanılarak otomatik olarak gerçekleştirilebilmesi, ortodontistlerin verimliliğini önemli ölçüde artıracaktır. Otomatik sefalometrik yer işareti tespiti, 25 yılı aşkın bir süredir araştırma konusu olmuştur ve yer işaretlerinin lokalizasyonunu otomatikleştirme girişimleri, değişen derecelerde başarı ile birçok araştırmacı tarafından denenmiştir (Lee ve ark., 2017; Goutham ve ark., 2019; Qian ve ark., 2019; Drevický ve Kodym, 2020). Sonuçların doğruluğunu artırmak için daha karmaşık tekniklere halen ihtiyaç duyulmaktadır.

Bu tez çalışmasında sağlık sektöründe yıllardır araştırma konusu olan sefalometrik nokta tespitine yeni bir yaklaşım sunulmuştur. Makine öğrenme tekniklerinden faydalanarak sefalometrik noktalarının otomatik tespitini yapan bir Evrişimsel Sinir Ağları (ESA) modeli geliştirilmiştir. Sefalometri, kafatasının X-ray görüntü boyutlarının bilimsel ölçümüdür. Önerilen yaklaşımda, sefalometrik noktaların koordinatları, çok katmanlı özelleştirilmiş bir U-Net model mimarisi kullanarak belirlenmiştir. Bu çalışmada önerilen çalışma ile ortodonti ve ortopedi bölümlerinde yapılan ön analiz işlerini kolaylaştırmak amaçlanmaktadır. Sefalometrik görüntülerin analizini daha kısa sürede yapmak ve bu alanlarda var olan uzman hatalarını azaltmak hedeflenmektedir. Sefalometrik noktaları DÖ kullanarak otomatik tespiti ile uzmanların teşhislerini kolaylaştırmak, deneyimsizlik veya diğer nedenlerinden kaynaklanan hataları azaltmak amaçlanmaktadır. Uzman sayısı az olan bölgeler için büyük fayda sağlayacağını öngörülmektedir.

Bu tez çalışmanın ikinci bölümünde tıbbi görüntüleme alanında DÖ kullanarak geliştirilmiş çalışmalara genel bir bakış verilmiştir. Aynı bölümünde, IEEE 2015 Uluslararası Biyomedikal Görüntüleme Sempozyumu (International Symposium on Biomedical Imaging, ISBI 2015) içinde Sefalometrik X-ray Görüntü Analizi Yarışmasında kabul edilmiş çalışmalardan bahsedilmiştir. Üçüncü bölümünde, kullanılan materyal ve yöntemlerden bahsedilmiştir. Bu bölümde makine öğrenmesinin ana kavramlarından ve DÖ yönteminden bahsedilmiştir. Aynı bölümde, Derin Evrişimsel

Sinir Ağlarından (DESA) ve bu arařtırmada kullanılan ESA modeli olan U-Net incelenmiřtir. Bu modelleri deęerlendirme metrikleri ve hiperparametrelerinden bahsedilmiřtir. Dördüncü bölümde, Sefalometrik iřaret lokalizasyondan ve kullanılan veri setinden bahsedilmiř, model mimarisi, modelinin deęerlendirme metrikleri ve eęitim prosedürü hakkında bilgi verilmiřtir ve dięer arařtırmacılarının bulduęu sonuçlar ile karřılařtırılmıřtır. Beřinci bölümünde, arařtırmanın sonuçları anlatılmıř ve öneriler sunulmuřtur.



2. KAYNAK ARAŞTIRMASI

Bu bölümde, DÖ kullanarak tıbbi veriler üzerinde yapılan araştırmaların özetleri ve elde edilen başarı sonuçları yer almaktadır. Tıbbi görüntü analizi, farklı görüntüleme yöntemleri ve dijital görüntü analizi tekniklerine dayalı tıbbi problemleri çözme ve analiz etme bilimidir. Tıbbi görüntü analizinin kullanımı hastalıkların tanısı konusunda giderek yaygınlaşmaktadır. Özellikle ESA'ya dayanan yöntemler bu alanda dikkat çekmektedir. Medikal alanda DÖ yöntemleri kullanarak yapılan araştırmalar genelde görüntü analizi ve sınıflandırma, nesne algılama, segmentasyon ve görselleştirmedeki çeşitli sorunları çözmek için yapılır. (Wu ve Razavi, 2015).

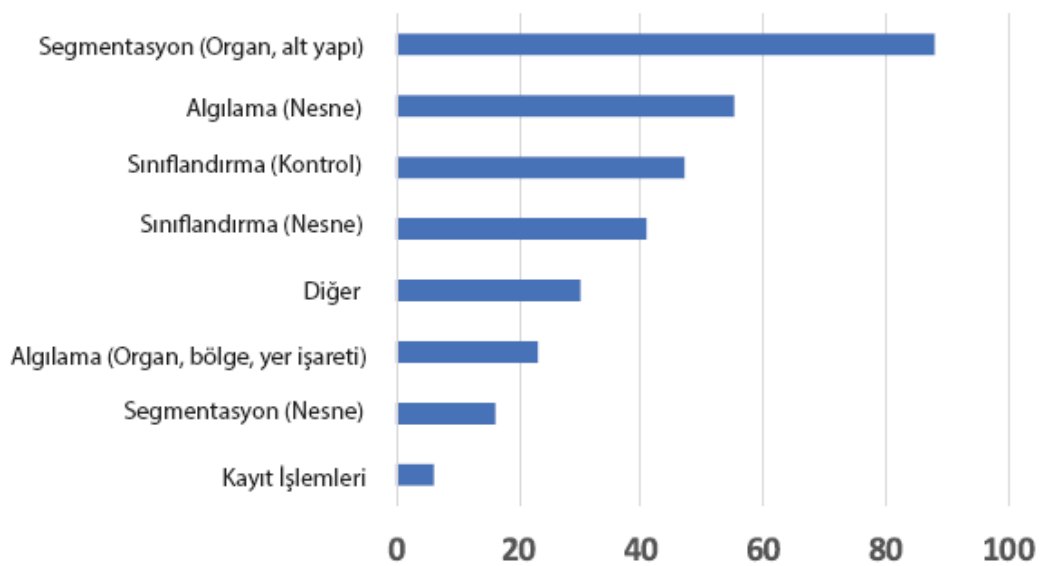
Tıbbi görüntü analizi uygulamalarındaki geleneksel yaklaşımlar ham verilerden özellik çıkarma ve bu özellikler ile makine öğrenimi modelleri kullanılarak analiz gerçekleştirilmek şeklindedir. Ancak, bu yaklaşımlar karmaşık desenleri olan zorlu görüntü tanıma görevlerinde başarılı sonuçlar vermemektedir. Bu sorunların üstesinden gelmek için bazı araştırmacılar tarafından çeşitli yöntemler denenmiştir (Wang ve ark., 2016). Özelleştirilmiş modeller kullanılarak her bir dönüm noktasının etrafındaki gri tonlamalı görünüm üzerinde çalışılmıştır. Bu modellerin performansı genellikle, bir şeklin daha ince ayrıntılarını takip edememeleri nedeniyle biyolojik şekil değişkenliğinin tüm aralığını yakalayamamalarından sınırlıdır. Alternatif bir strateji, kalıp eşleştirmeye dayanır (Vučinić ve ark., 2010). Bu yöntemlerin çoğu, yerel şablon eşleştirme uygulayarak yer işaretlerinin gerçek konumunu bulmak için yerel bir arama penceresi kullanır. Yerel şablon eşleştirme, yakınlarda benzer yapıların bulunması nedeniyle yanlış algılamayı önler ve hesaplama süresini azaltır. Bazı yer işaretlerinin değişkenliği yüksektir, bu da tek bir şablonda yakalanması zordur. Bu nedenle, her bir yer işaretini bulmak için birden fazla şablon kullanılır. Şablon eşleştirmeye dayalı tekniklerin çoğu, aşağıdaki adımları birleştirerek sonuçları optimize etmeye çalışır:

1. Kontrastı iyileştirmek, kenarları iyileştirmek ve gürültüyü bastırmak için görüntü ön işleme gerçekleştirilir.
2. Bir sonraki adımda, Aktif Şekil Modelleri (ASM), sinir ağları veya önceki anatomik bilgi kullanılarak görüntülerin bölünmesi gibi tekniklerden yararlanılarak her bir yer işareti için yerel bir arama alanı bulunur.
3. Son olarak, yerel şablon eşleştirme kullanılarak yer işaretleri bulunur.

2.1. Tıbbi Görüntü İşleme Üzerine Yapılmış Derin Öğrenme Çalışmaları

Tıbbi görüntü analizi alanında önerilen güncel çalışmaların çoğu nesne, organ segmentasyon problemini çözmek içindir. Nesne, organ, bölge ve dönüm noktası algılama problemleri ve nesne sınıflandırma alanında çok önemli çalışmalar sunulmuştur. Klinik ortamlarda var olan çözümler kullanılarak karşılaşılan problemlerden dolayı yeni çalışmalara gereksinim vardır. Bu çalışmada otomatik olarak tespit edilen sefalometrik yer işaretlerinin doğruluğunu ve güvenilirliğini geliştirmek amaçlanmıştır. Özelleştirilmiş bir U-net modeli kullanarak nokta tespitini otomatik yapılmıştır.

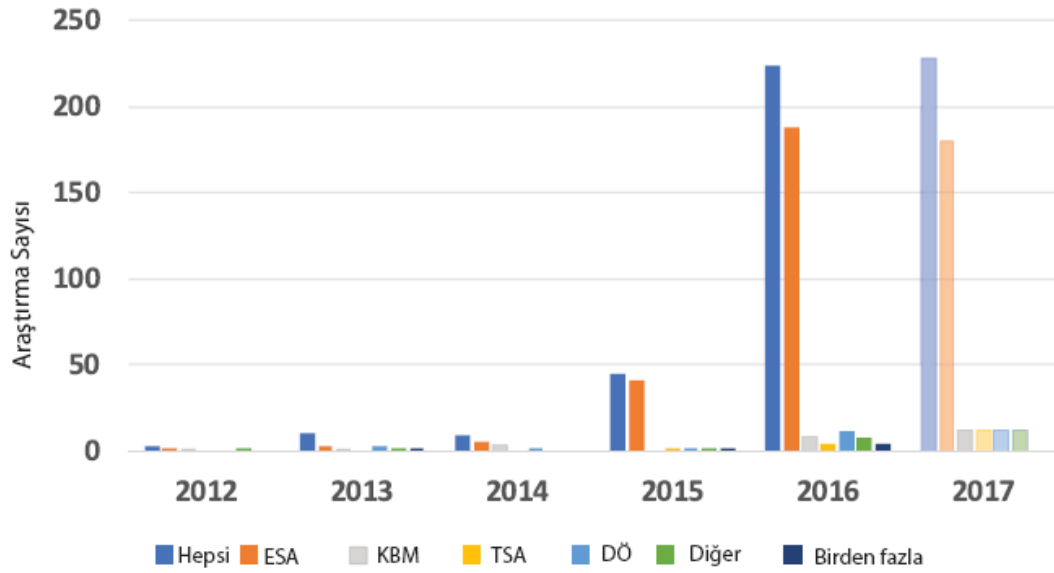
Şekil 2.1’de Litjens ve ark. (2017) tarafından incelenen çalışmaların dağılımları gösterilmektedir (Litjens ve ark., 2017).



Şekil 2.1. ESA dahil edilen makalelerin yaklaşım dağılımı (Litjens ve ark., 2017)

Litjens ve ark. (2017) tarafından incelenen 308 makalede, derin öğrenmenin tıbbi görüntü analizinin her yönünü kapsadığı gözükmemektedir. Bu süreç çok hızlı bir şekilde gerçekleşmiş ve Şekil 2.2’de gösterdiği gibi bu çalışmaların arasında 242 makale 2016 yılında veya 2017 yılının ilk ayında yayınlanmıştır. Bunlar çok çeşitli derin mimarileri kapsamaktadır. İlk çalışmalarda, özellik çıkarma olarak önceden eğitilmiş ESA’ları kullanılmıştır. Bu önceden eğitilmiş ağların kolayca indirilebilmesi ve herhangi bir tıbbi

görüntüye doğrudan uygulanabilmesi, kullanımlarını kolaylaştırmıştır. Son yıllarda, uçtan uca eğitilmiş ESA'ların tıbbi görüntüleme yorumlaması için tercih edilen yaklaşım haline geldiğini görülmektedir. Şekil 2.2'de gösterildiği gibi ESA 2015 yılından sonra yaygın olarak kullanmaya başlanmıştır.



Şekil 2.2. ESA dahil edilen makalelerin yayın yıllarına dağılımı (Litjens ve ark., 2017)

Nesne algılama, genellikle görüntü üzerinde bilinmeyen sayıda nesneyi yerleştirmeye ilgilidir. Tıbbi ortamda, bunlar genellikle patolojiler veya lezyonlardır ve bunları bulmak tanı sürecinin çok önemli bir parçasıdır. Derin öğrenmenin ortaya çıkmasından önce bu alanda geniş miktarda araştırma yapılmıştır. Bu çalışmalar hem doğruluğu artırmaya hem de uzmanların her vakada harcadığı zamanı azaltmaya odaklanmıştır (Greenspan ve ark., 2016).


ESA'lar 1993'te nodül tespiti için Lo ve ark. (1993) tarafından tıbbi görüntü analizine uygulanmıştır. O zamanlarda modellerin uzun ve zor eğitim süreleri nedeniyle bilgisayarda görme alanında çok kullanılmamıştır (Lo ve ark., 1993). Bu yıllarda tıbbi görüntü analizinde DÖ ile yürütülen çalışmaların çoğu veri eksikliğiyle karşı karşıya kalmıştır. Bunun yanında verilerdeki sınıf dengesizliği diğer bir problemdir. Tıbbi görüntü işlemlerinde, anormal veri sınıflarının görüntülerini bulmak genelde zordur.

Esteva ve ark. (2017) dermatoloji alanlarında ki çalışmaları gibi, tıbbi görüntüleme derin öğrenmenin birçok önemli başarılı kullanımı vardır (Esteva ve ark., 2017). Sundukları yöntemde girdi olarak yalnızca görüntü pikselleri ve hastalık etiketlerini kullanarak, doğrudan görüntülerden uçtan uca eğitilmiş tek bir ESA

kullanarak 129.450 klinik görüntü ile cilt lezyonlarının sınıflandırılmasını yapmışlardır. ESA'nın cilt kanserini sınıflandırma işleminde dermatologlarla karşılaştırılabilir düzeye geldiği kanıtlanmıştır.

Radyografik görüntülerdeki simgesel yapıların otomatik olarak algılanmasına yönelik önemli ilerlemeler kaydedilmiştir. Model eşleştirmesine dayalı en sağlam ve doğru sonuçlardan bazıları Rastgele Ormanlar (RO) kullanılarak elde edilmiştir (Breiman, 2001). Bu işlemlerde her bir dönüm noktası pozisyonları için oy verilir ve daha sonra tüm dönüm noktaları arasında istatistiksel yöntemlerle doğru değerleri belirlenir.


Segmentasyon tıbbi görüntüleme çalışmalarında DÖ ile ele alınan en yaygın görevdir. Genellikle ön plan sınıfları kümesi (bir veya birkaç farklı organ veya alt yapı) ve bir arka plan sınıfı arasında ayırım olarak tanımlanır. Şekil 2.3'te ISBI hücre izleme sonuçları gösterilmektedir. Ronneberger ve ark. (2015) tarafından yapılan çalışmada, çok az görüntü kullanarak uçtan uca bir modelin eğitebileceği ve elektron mikroskopik görüntülerin segmentasyon işleminde başarılı sonuçları elde edebileceği kanıtlanmıştır (Ronneberger ve ark., 2015). 2015 ISBI Görüntü Segmentasyon yarışmasından gelen "PhC-U373" veri seti kullanarak 92% Intersection Over Union (IOU) elde edilmiş ve "DIC-HeLa" veri seti üzerindeki çalışmalarda 77,5% IOU başarıya ulaşılmıştır. IOU semantik görüntü segmentasyon için bir değerlendirme metriktir. Şekil 2.3 bu araştırmanın giriş ve sonuç görselleri göstermektedir, (a) "PhC-U373" veri setinin bir giriş görüntüsünün parçası, (b) Manuel yer gerçeği ile Segmentasyon sonucu (sarı sınır), (c) "DIC-HeLa" veri setinin görüntüsü ve (d) Manuel yer gerçeği (sarı sınır) ile bölümlenme sonucu (rastgele renkli maskeler) göstermektedir.



Şekil 2.3. ISBI hücre izleme sonucu (Ronneberger ve ark., 2015).

Halka açık en büyük göğüs röntgeni veri seti olan CheXNet kullanarak Rajpurkar ve ark tarafından göğüs anormallikler tespit eden bir model geliştirilmiştir (Rajpurkar ve ark., 2017). Göğüs röntgenlerinden radyologlarının Pnömoni hastalığı tespit seviyesi

aşan bir algoritma geliştirilmiştir. Şekil 2.4'te, 121 katmandan oluşan bir model kullanılarak CheXNet veri setinden akciğer hastalığı yoğun olduğu bölge gösterilmektedir (kırmızı bölgeler hastalığın yoğun olduğu bölgeyi göstermektedir). Giriş görseli ve Pnömoni 85% pozitif olan bir çıktı görseli gösterilmektedir.



Şekil 2.4. CheXNet akciğer hastalığı tespit sonucu (Rajpurkar ve ark., 2017)

2.2. Sefalometrik Noktaları Tespiti Üzerine Yapılmış Çalışmalar

Literatürde, sefalometrik noktaların otomatik tespiti için çalışmalar bulunmaktadır. Başlangıçta araştırmacılar, yer işaretlerini lokalize etmek için görüntü iyileştirme, kenar algılama ve izleme teknikleri kullanmışlardır (Cardillo ve Sid-Ahmed, 1994a; Vučinić ve ark., 2010). Bu sistemler, yalnızca yakın veya kenarlardaki yer işaretlerini belirleyebilmektedir. X ışınları veya röntgen ışınların düşük kontrastı, karmaşık yapısı ve bulanık doğası nedeniyle, her zaman doğru kenarları çıkarmak zordur ve bu nedenle bazı nokta işaretlerinin tespiti düşük konum doğruluğuna sahip olabilir.


Cardillo ve Sid-Ahmed (Cardillo ve Sid-Ahmed, 1994b) araştırmalarında, yer işareti için arama alanını azaltmak amacıyla matematiksel modellemeyi kullanmışlar, ardından yer işaretlerinin tam konumunu tam olarak belirlemek için matematiksel morfolojiye dayalı şablon eşleştirme teknikleri uygulamışlardır. Algoritmada, iskelet topografyalarındaki ince farklılıkların üstesinden gelmek için eğitime istatistiksel bir yaklaşım ve algoritmayı boyut farklılıklarına karşı duyarsızlaştırmak için ayrıştırma kullanmışlardır. Çalışma 20 farklı yer işareti üzerinde yapılmıştır. Sunulan algoritma, 512×490 boyutunda rastgele seçilmiş 40 sefalometrik görüntü üzerinde test edilmiştir. Elde edilen dönüm noktası doğruluğu 2 mm tolerans için 85% olarak elde edilmiştir.

Chakrabarty ve ark. (2003) farklı yer işaretleri ve arka plan çerçeveleri arasındaki ayırım sınırlarını modellemek için Destek Vektör Makineleri (DVM) uygulamışlardır

(Chakrabartty ve ark., 2003). Çalışma, 700×500 piksel boyutunda 130 X-ışını filmi kullanılarak gerçekleştirilmiştir. Eğitim için 70 görüntü, çapraz doğrulama deneyleri için 20 görüntü ve eğitilmiş tanıyıcının performansını değerlendirmek için kalan 40 görüntü ayrılmıştır. Bu tür seçimler rastgele on kez tekrarlanmış ve nihai sonuçları elde etmek için değerlendirme sonuçlarının ortalaması alınmıştır. Sekiz yer işaretinin tespiti sonucu, 5 mm tolerans için doğruluğun 96% ve 1 mm tolerans için doğruluğun 87% olduğu belirtilmiştir.


Aktif görünüm modellerini kullanarak Vučinić ve ark. tarafından sefalometrik noktaları otomatik tespit eden bir algoritma sunulmuştur (Vučinić ve ark., 2010). Aktif görünüm modelinin sistemi, 7,2 ile 25,6 yaş arasındaki deneklerden rastgele seçilmiş, elle işaretlenmiş 60 dijital sefalogramı kullanılarak eğitilmiştir. Çalışma sonucunda 2 mm içinde tespit edilen yer işaretlerinin 61% ve 5 mm hassasiyet içinde tespit edilen yer işaretlerinin 95% başarısı vardır. Bu algoritma ile ortalama 1,68 mm doğruluk elde edilmiştir.

Bu alanda yüksek başarı elde eden çalışmalar arasında Lindner ve Cootes (2015) çalışması yer almaktadır (Lindner ve Cootes, 2015). Bu çalışmada, Rasgele Orman (RO) regresyon oylamasının uygulaması kullanılmıştır. Her 15 yer işaretinin için, bir görüntüye göre yer işaretinin konumunu tahmin eden bir RO eğitilmiştir. 150 görüntüden oluşan iki veri seti üzerinde yapılan doğrulama deneyleri ile 2mm hassas aralık için 1,6 mm ile 1,7 mm ortalama hata ile %75-%85 oranında BAO elde ettikleri gözükmektedir. Bu çalışmanın akışı Şekil 2.5'te gösterilmiştir.




Şekil 2.5. Regresyon oylamasının model şekilleri (Lindner ve Cootes, 2015)

Ibragimov ve ark. (2015) RO temelli şekil modelleriyle mevcut bir oyun-teorik dönüm noktası tespiti üzerine inşa edilen, sefalometrik X-ray dönüm noktası tespiti ve insan kafatasının kantitatif sefalometri için yeni bir yöntem sunmuşlardır (Ibragimov ve ark., 2015). Algılama performansını iyileştirmek için, tespit edilen her bir dönüm noktası konumunun kalan yer işaretlerinin konumlarından iyileştirildiği şekil tabanlı bir yer işareti iyileştirmesi ve her bir dönüm noktasıyla ilgili küresel ve yerel yoğunluk bilgilerinin birleştirildiği görünüme dayalı bir yer işareti iyileştirmesi uygulanmıştır. Model 150 sefalometrik X-ray görüntüsü üzerinde eğitilmiş ve 150 test görüntüsü üzerinde doğrulanmıştır. Şekil 2.6'da hedef nokta işaretinin (yeşil daire) genel görünümü (sol üst) ve yerel görünümü (sol alt) yakalayan çok ölçekli görünüm modeli gösterilmektedir. Hedef simge yapının (yeşil daire) konumunun kalan simgelerin (sarı daireler) konumu kullanılarak tanımlandığı şekil modeli (sağda) gösterilmektedir. Ortalama radyal hata açısından 1.84 ± 1.79 mm, (2 mm komşuluk içinde) %71,7 BAO elde etmişlerdir.




Şekil 2.6. RO temelli şekil modelleriyle mevcut bir oyun-teorik dönüm noktası tespiti üzerine inşa edilen, sefalometrik X-ray dönüm noktası tespiti (Ibragimov ve ark., 2015)

Lindner ve ark. (2016) tarafından yapılan çalışmada doğru lokalizasyon ve lateral sefalometrik görsellerinin Sefalometrik Nokta Analizi (FALA - Fully Automatic System for Accurate Localisation and Analysis) yapan bir sistem önerilmiştir (Lindner ve ark., 2016). FALA Lateral sefalogramlarda sefalometrik işaretler bulmayı ve iskelet malformasyonlarının sınıflandırılmasını kolaylaştırmıştır. Sistem ortalama hatayı 1,2 mm elde etmiş ve yer işaretlerinin %84,7'si kliniklerde kabul edilen 2,0 mm hassasiyet aralığında yer almıştır. FALA sistemi Lateral sefalogramlarda sefalometrik noktaları hızlı ve doğru bir şekilde tespit ve analiz eden bir yaklaşımdır. Şekil 2.7'de FALA sisteminin şematik genel bakışı verilmiştir.



CLM Framework'u üzerinde RO Regresyon Oylamasını Kullanarak FALA Sistemi



RO Eğitimi (Yer işaretine başına)

RO Regresyon Oylaması (Yer işaretine başına)

Şekil 2.7. FALA sistemine şematik genel bakış (Lindner ve ark., 2016)

3. MATERYAL VE YÖNTEM

Bu bölümde, sefalometrik nokta tespitinde kullanılan yöntemlerin sistematik bir incelemesi yapılmıştır. Makine öğrenmesine genel bir bakış yapılmış ve tez çalışmasında kullanılan DÖ yöntemlerinden ve çalışmanın değerlendirme metriklerinden bahsedilmiştir.


3.1. Sefalometrik Analiz

Sefalometrik analiz, insan kafatasının diş ve iskelet ilişkilerini analiz eder ve bu analizler kullanılarak hastaların kemik, diş ve yumuşak doku yapılarının yorumlanması sağlanır. Şekil 3.1’de, lateral sefalometrik radyografi görüntüsü gösterilmiştir. Bu görsel, lateral açıdan anatomik yapıları göstermektedir ve ortodontistler bu yapıları kullanarak hastaların tedavisinde önemli kararlar almaktadır (Athanasiou, 1995; Phulari, 2013). Sefalometrik analizin tanısal değeri, sefalometrik radyografilerde tanımlanmış yer işaretlerinin doğruluğuna bağlıdır.



Şekil 3.1. Dijital lateral sefalogramı (Lindner ve ark., 2016)


Sefalometrik noktalar arasında var olan ilişkiler kullanarak bu yapılarının değerlendirmeleri yapılmaktadır. Sefalometrik analizi için kullanılan yer işaretlerinin seçimi, kullanılan ölçüm standardına ve her ortodontistin kişisel tercihine ve deneyimine bağlıdır. Otomatik sefalometrik analiz algoritmalarının geliştirilmesi, doktorların değerli zamanlarından tasarruf etmesine yardımcı olacak ve bu işlem manuel olarak yapıldığında ortaya çıkan hataları azaltacaktır. Şekil 3.2’de bu analizler sırasında en çok kullanılan yer işaretleri gösterilmektedir.



Şekil 3.2. Bazı sefalometrik nokta işaretleri (Doff ve ark., 2009)

Ortodonti bölümünde, birçok yer işareti tanımlanmıştır, ancak Rakosi (1982) tarafından tanımlanan yaklaşık 30 işaret yaygın olarak kullanılmaktadır (Rakosi, 1982). Sefalometrik analiz için kullanılan yer işaretlerinin seçimi, kullanılan ölçüm standardına

ve her ortodontistin kişisel tercihine ve deneyimine bağlıdır. Bu yönde çıkan çok sayıda analiz araştırmaları, ortodontist uzmanlar için karışık hale gelmiştir. Bu araştırmacılar tarafından çok fazla yer işareti tanımlanmış ve birçok ölçüm önerilmiştir. Bu sorunu gidermek için Steiner en önemli parametreleri seçmiş ve en düşük sayıda ölçümle maksimum klinik bilgiyi sağlayacak noktaları belirlemiştir (Athanasiou, 1995). En yaygın olarak bulunan açık kaynaklı veri kümesindeki yer işareti sayısı 19'dur. Bu 19 noktanın yerleri Şekil 3.3'te gösterilmiştir. Bu tez çalışmasında bu 19 noktayı otomatik elde eden bir model geliştirilmiştir.

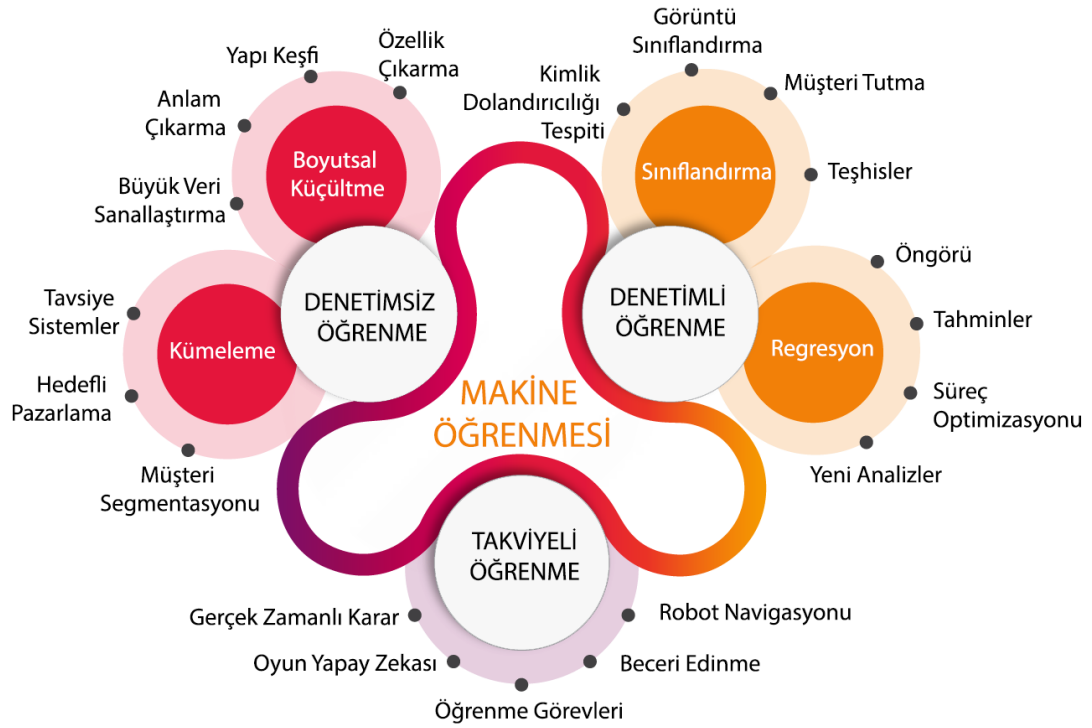


Şekil 3.3. Sefalometrik noktalar (Lindner ve ark., 2016)

3.2. Makine Öğrenmesi

Makine öğrenmesi, bilgisayar biliminin bir alt alanıdır. Verilerden anlamlı bilgileri çıkarabilen ve gereken tahminleri yapabilen bir yapay zekâ yöntemidir. Matematiksel formüllere dayalı modeller yardımıyla bu kararları üretebilmektedir. Bu kararları üretebilmek için, çeşitli yöntemler kullanılarak verilerden belli kalıplar aranır ya

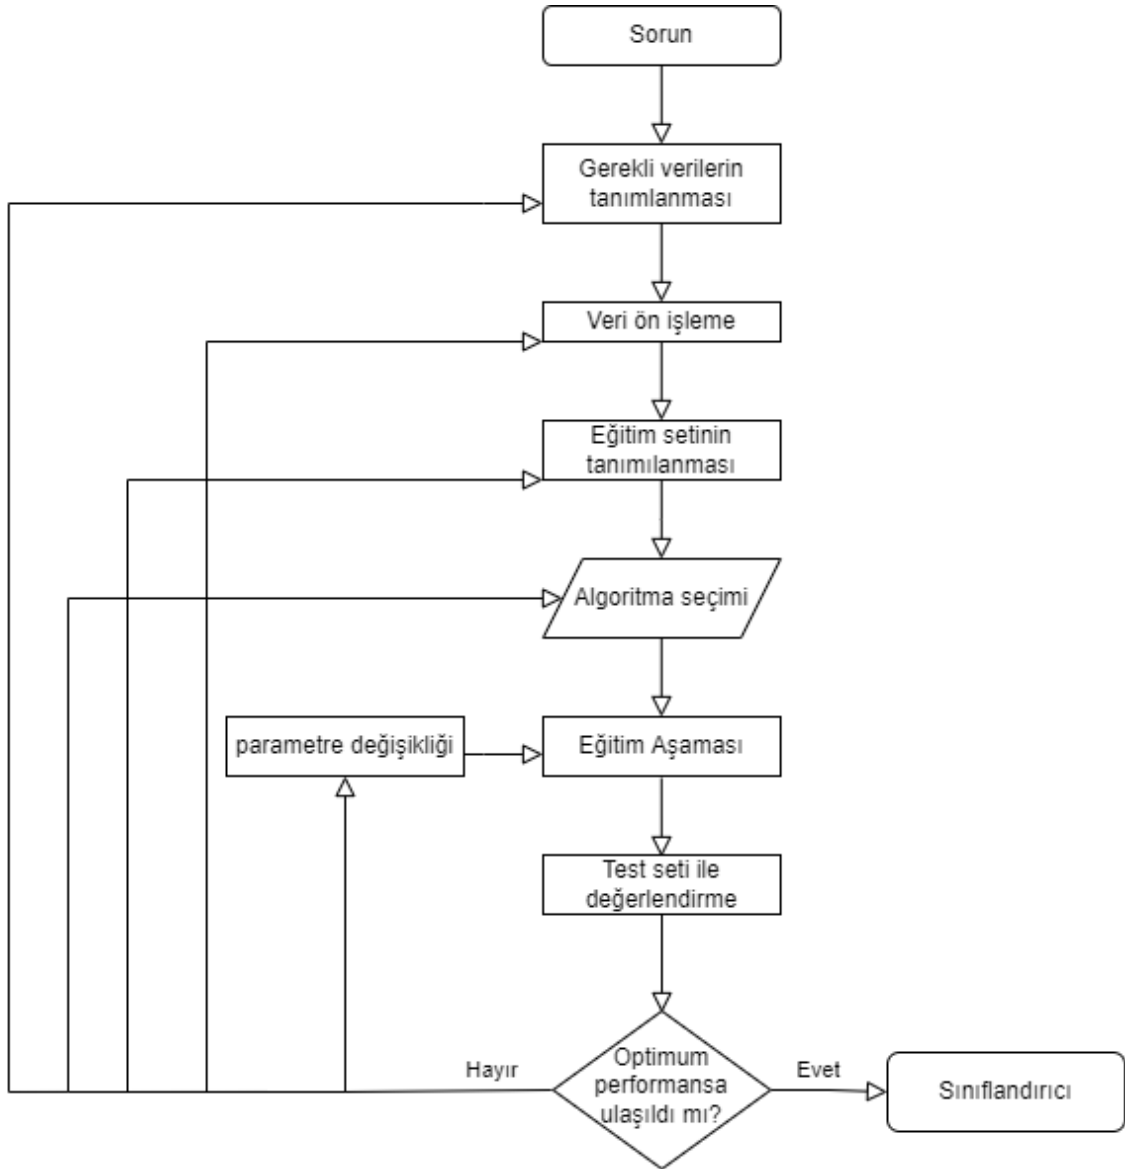
da bu verilerin arasındaki bağlantılar keşfedilerek öğrenimi yapılır. Makine öğrenmesi verilerden öğrenerek karmaşık işlevleri tahmin eden bir dizi istatistiksel aracın temelidir. Şekil 3.4'te gösterildiği gibi, makine öğrenmesi üç ana kategoriye sınıflandırılabilir. Bu kategoriler Denetimli, Denetimsiz ve Takviyeli Öğrenmedir.



Şekil 3.4. Makine öğrenme genel sınıflandırma (Krzyk, 2018)

3.2.1. Denetimli öğrenme

Denetimli öğrenmede, programının veri kümesi üzerinde sisteme giren x verileri ve bu verilerin karşılığı ya da çıktısı y değerleri kullanarak eğitilmektedir. Yani bu sistemleri $(x, y) \in X \times Y$, x 'in bir veri noktasını temsil ettiği ve y 'nin x için karşılık gelen gerçek tahmini temsil ettiği etiketli veri kümelerini kullanır. Bu girdi-çıkı çiftleri eğitim seti, herhangi bir girdiyi bir çıktıya eşleyen, hataları mümkün olduğunca en aza indirirken gelecekteki girdi-çıkı gözlemlerini tahmin eden deterministik bir fonksiyon bulmak için kullanılır. Şekil 3.5 denetimli öğrenmenin akış diyagramı göstermektedir.



Şekil 3.5. Başarılı bir sınıflandırıcı oluşturmak için kullanılan denetimli makine öğrenimi aşamaları (Osisanwo ve ark., 2017)

Bu yöntem bir öğrencinin bir öğretmenden temel aritmetiği öğrenme şekline benzer. Bu tür bir öğrenme, algoritmanın çıktısından beklenecek doğru cevaplarla etiketlenmiş verilere ihtiyaç duyar. Sınıflandırma ve regresyon problemleri için başarılı ve hızlı olduğu kanıtlanmıştır (Rende ve ark., 2016).

Sınıflandırma: Verilerin belirli sınıflara ayrılabilceği bir ortamda bir etiketin hangi sınıfa ait olduğuna karar veren yöntemdir. Sınıflandırmanın farklı kullanım durumları vardır, örneğin: hava durumunun, bir e-postanın istenmeyen posta olup olmadığının veya hayvan türlerinin belirlenmesi.

Regresyon: Verilerin arasında var olan bağlantısına ve ilişkilerine göre bir fonksiyon oluşturulmasına dayalıdır. Hisse senedi ve konut fiyatları gibi sürekli değişen değerlerin tahmin edilmesinde başarılıdır. Çalışma şekli, hedef tahmin çıktısı ile girdi özellikleri arasındaki ilişkileri ve bağımlılıkları modellemektir, böylece önceki veri kümelerinden öğrendiği ilişkilere dayalı olarak yeni veriler için çıktı değerlerini tahmin etmek mümkün olur.

3.2.2. Denetimsiz öğrenme

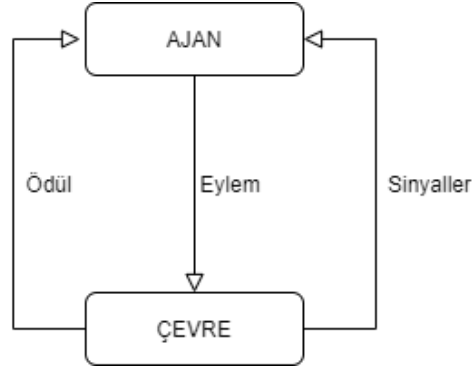
Denetimli öğrenmenin aksine, denetimsiz öğrenme yaklaşımında çıktıya sahip olmayan veri setlerinden öğrenme gerçekleşmektedir. Burada eğitimin amacı verilen girdi içindeki yapıyı bulmaktır. Denetimsiz öğrenme sistemleri, sistemi eğitmek için etiketlenmemiş veri kümelerini kullanır. Denetimsiz öğrenmenin amacı, nesne çiftleri arasındaki benzerliği araştırarak etiketlenmemiş verilerden yapı türetmektir ve genellikle yoğunluk tahmini veya veri kümeleme ile ilişkilendirilir. Denetimli öğrenme algoritmaları gibi verilerin arasında var olan benzerliklerden, ilişkilerden faydalanarak gerçekleştirilir. Kümeleme ve segmentasyon problemlerinde başarılıdır (Goodfellow ve ark., 2016).

Denetimsiz öğrenme, bazı uzmanlar tarafından gerçek yapay zekâ olarak görülür (Litjens ve ark., 2017). Bunun sebebi uzmanların verilerde ne arayacağını bilmediği ve verilerin kendisinin hedefleri içermediği durumlarda özellikle yararlı olduğu içindir. Denetimsiz makine öğrenme yöntemleri küme analizi, ilişkilendirme (Association) ve boyutsal küçülme (Dimensionality Reduction) olarak ayrılabilir.

3.2.3. Takviyeli öğrenme

Takviyeli öğrenme, Denetimli ve Denetimsiz Öğrenme ile üçüncü ana makine öğrenimi türüdür. Ajan, eylem, çevre, sinyal ve ödül olmak üzere beş önemli bileşenlerden oluşur. Takviyeli öğrenmenin amacı, çevre ile etkileşiminden yararlanarak ödülü en üst düzeye çıkarmak ve riski en aza indirmektir. Bu yöntem farklı olası durumlardan ya da sinyallerden geçen ortamı keşfederek periyodik olarak iyileşir. Performansı en üst düzeye çıkarmak için ideal davranış, araçlar tarafından otomatik olarak belirlenir. Bir geri bildirim (ödül), aracının davranışını iyileştirmesine izin verir.

Şekil 3.6'da takviyeli öğrenmenin genel akışını göstermektedir, ajanlar tarafından sinyaller algılanır, algılanan sinyale karşılık bir eylem üretilip bu eylemin ödül değeri atanır ve ajana geri bildirilir (Schmidhuber, 2015).



Şekil 3.6. Takviyeli öğrenme

Takviyeli öğrenme sistemleri, sabit bir eğitim veri kümesi üzerinde çalışmaz, sistem ve deneyimleri arasında bir geri bildirim döngüsü üretilir. Veri olarak sinyal-eylem-ödül üçlülerinin gözlendiği dinamik bir ortam düşünülmüştür. Takviyeli öğrenmede, ödülleri en üst düzeye çıkarmak amaçlanır. Takviyeli Öğrenme için en çok kullanılan algoritmalarından biri, bölümün sonunda ödülleri toplamaya ve ardından beklenen maksimum gelecekteki ödülü hesaplamaya dayanan Monte Carlo'dur. İkinci bir popüler algoritma, her adımda ödülleri tahmin eden ilkinden farklı bir yaklaşım kullanan Zamansal Fark Öğrenimidir.

3.2.4. Aşırı ve eksik öğrenme

Bir modelin hem eğitim verileri üzerinden hem de hiç görmediği test verileri üzerinde başarılı sonuçlar ve performans vermesi beklenir. Modeli eğitirken görmediği veriler seçilerek genelleme hata oranı hesaplanmaktadır. Elde edilen hata sonuçları düşük olduğunda, modelinin iyi çalıştığını söylenebilir. Model eğitim verileri üzerinde düşük hataya sahip olup, hiç görmediği veriler üzerinde çalıştırıldığında hata oranı yüksek çıkarsa model aşırı öğrenmiş olabilir.

Eksik öğrenme durumlarında, model veriler arasındaki örüntüleri eksik öğrenir, test verileri üzerinde başarısız olur ve ortaya çıkan hata oranı yüksek olur. Bu durum modelin veri seti üzerinde yeterince öğrenmediğinden kaynaklanır.

Aşırı ve eksik öğrenme gibi sorunları önlemek için modeller eğitilirken değişkenler azaltılabilir, daha fazla verilerle model eğitilebilir ve erken durdurma uygulanabilir (Goodfellow ve ark., 2016).

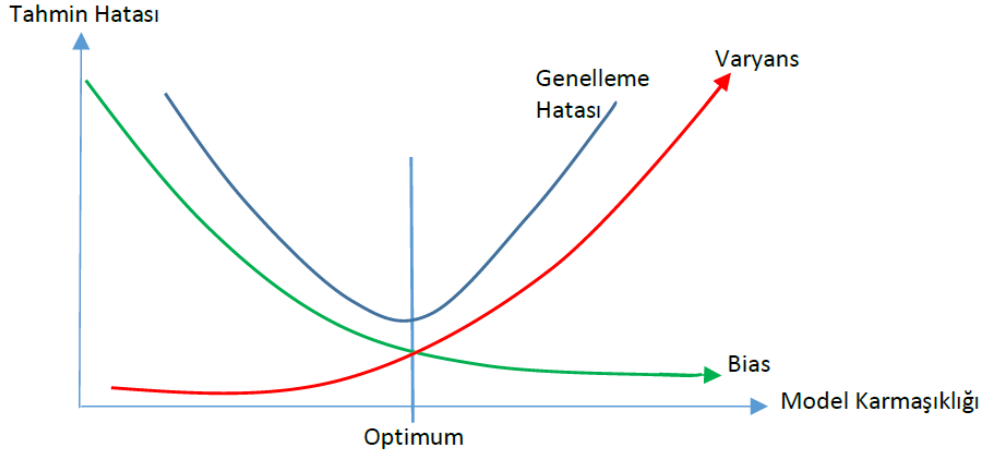
3.2.5. Çapraz doğrulama (Cross validation)

Bir modeli doğrulamak ve başarısını değerlendirmek için kullanılan bir tekniktir. Eğitilen modelin genelleme kabiliyetini ya da yanlılığı ölçmek için çapraz doğrulama kullanılır. Veri seti birkaç bölüme ayrılıp birden fazla değerlendirme metrikleri kullanılarak model eğitilip değerlendirilir. Veri setleri genelde eğitim ve doğrulama ya da test kümesi olmak üzere ayrılır. Bu işlem sırasında veri setleri oluşturmak için kullanılan yöntem başarıyı önemli yönde etkileyebilir. Eğitim ve test dağılımları önemlidir. Bu sebeplerden meydana gelen sorunları tespit edebilmek için çapraz doğrulamaya ihtiyaç duyulur (Kohavi, 1995).

Çapraz doğrulama genel olarak modeli eğitirken meydana gelen sorunları önlemek için kullanılır. Modelin eğitim sırasında iyi sonuçları vermesi ve önceden görmediği veriler üzerinde başarının geride kalması durumlarını önlemek için uygulanır.

3.2.6. Yanlılık (bias) ve varyans

Modelin genel hatasını optimum noktaya getirebilmek için yanlılık (bias) ve varyans hatalarının dengesini tutmak gerekir. Yanlılık bir modelin tahmin edilen değer ile gerçek değer arasındaki farkıdır. Varyans ise modelin gösterdiği değişkenlik değeridir. Model eğitirken performansı üzerinde dalga duyarlılığının gösterdiği hata oranıdır. Yüksek varyans durumlarında, model aşırı öğrenme durumuna düşebilir. Şekil 3.7'de yanlılık ile varyansın arasındaki ters ilişki gösterilmiştir. Yanlılık değeri artması durumunda varyans değeri azalır ve bu değerler arasındaki dengeye ulaşıldığında model en üst performansına ulaşmış durumda olur (Prasad, 2019).



Şekil 3.7 Yanlılık Varyans ilişkisi (Malkoçoğlu, 2020)

3.3. Derin Öğrenme

DÖ bir makine öğrenmesi yöntemidir. Çok katmanlı yapay sinir ağlarından oluşan ve insanların beyin yapısına ve görme yeteneğine sahip olan bir yöntem olarak düşünülebilir. Bu yetenekleri kullanarak ham verilerden nesne tespiti, tahmini ve sınıflandırma problemlerini çözebilmektedir.

DÖ yöntemleri sağlık, savunma sanayi, uzay ve siber güvenlik, robotik, görsel ve nesne tanıma, nesne tespiti ve keşfi gibi birçok alanda sonuçların başarısını önemli ölçüde iyileştirmiştir. DÖ sadece verilerin doğru şekilde temsil edilmesini sağlamakla kalmaz, modellerine derinlik kavramını ekleyerek bilgisayarın çok adımlı bilgisayar programlarını öğrenmesini sağlar (Goodfellow ve ark., 2016).


3.3.1. Derin öğrenme yapısı

DÖ kendi içinde yapay zekanın bir alt alanı olan makine öğreniminin bir alt kümesidir. DÖ modellerinden en popüler olanı evrimsel sinir ağlarıdır. Bunlar evrişim, havuzlama katmanlarından ve son aşamasında tam bağlı bir katmandan ya da bir sınıflandırma katmanından oluşur. Bir DÖ modeli ilk olarak verileri alır ve bu katmanlardan geçirerek modeli eğitir. Hata farkını hesaplayarak modelin gereken ayarları yapılır, optimum hata oranını ulaştığında durur.

3.3.1.1. Evrişimsel Sinir Ağları (ESA)

Evrişimsel sinir ağları, şu anda görüntü analizi ve DÖ için en önde gelen algoritmalarından biridir. Geleneksel makine öğrenimi için ilgili özelliklerin manuel olarak çıkarılması gerekirken, DÖ belirli özellikleri öğrenmek için girdi olarak ham görüntüleri kullanır. ESA'lar bir giriş ve çıkış katmanından ve onların arasında birkaç gizli katmandan oluşur. Ara katmanlara örnek olarak evrişimsel katmanlar, havuzlama katmanları ve tam bağlantılı katmanlar verilebilir.

ESA katmanları için optimal bir konfigürasyon ya da kesin bir formül bulunmamaktadır. Bu değerleri bulmak için en iyi yaklaşım deneme yaklaşımıdır, bazı katman konfigürasyonları test edilir ve ne kadar iyi çalıştıkları ölçülür. AlexNet gibi önceden eğitilmiş ağlar da ilk katman yapılandırması olarak kullanılabilir. Ancak bu durumda, AlexNet katman konfigürasyonundan ilham alınırken, kendi katman konfigürasyonu uygulamaları takip edilir. Şekil 3.8'de ESA genel mimarisinin birleşeni verilmiştir.



Şekil 3.8. Evrişimsel sinir ağının mimarisi (Özkan ve Ülker, 2017)


ESA'nın güçlü yönlerinden biri, çevirme, ölçekleme ve döndürme gibi dönüşümlere karşı değişmez olmasıdır. Bilgisayarlı görme problemlerinde özellikle nesne algılamada çevirme, döndürme ve ölçeklendirmedeki değişkenlik önemli işlemlerinden biridir. Tam ESA'ların en büyük avantajı, tüm görüntüyü giriş olarak almaları ve böylece tüm bağlamı görmeleridir.

3.3.1.1.1. Evrişim katmanı

Evrişim katmanı ESA'nın ana yapı taşıdır ve girdi görüntüsünde özellik çıkarma bu katmanın temel amacıdır. Evrişim katmanı genel olarak giriş katmanından sonra gelen

ilk katmandır ve görüntü üzerinde dolaşarak belirli filtrelerle çıkış verisini oluşturur. Makine öğrenimi uygulamalarında giriş katmanı genellikle çok boyutlu bir veri dizisi alır ve çekirdek genellikle öğrenme algoritması tarafından uyarlanan çok boyutlu bir parametre dizisidir. Bu çok boyutlu dizilere tensörler denir.

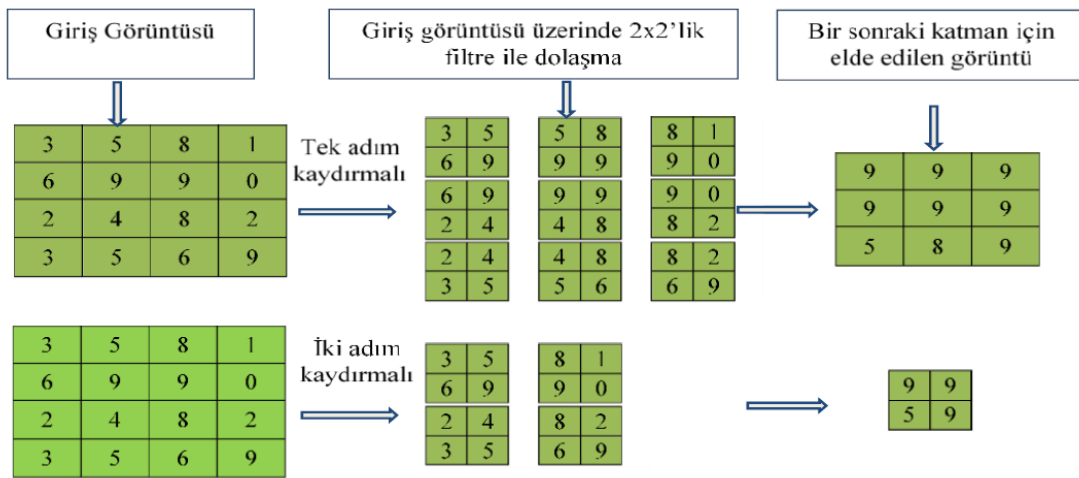
Evrişim katmanında giriş görüntülerindeki düşük ve yüksek seviyeli özellikler filtreler yardımıyla keşfedilir. Filtreler işlemine göre değişiklik gösteren 2×2 , 3×3 , 4×4 gibi farklı boyutlardan oluşabilir. Filtre, evrişim katmanının özellikleri öğrenmesine izin veren kayan bir penceredir. Filtrelerinin derinliği görüntü boyutlarına ve derinliğine bağlıdır ve girdi kanalları ile aynıdır. RGB görüntüleri için 3 derinliğinde bir filtre uygulanırken tek kanallı görüntüler için 1 derinliğinde filtreler kullanılmaktadır. Filtre uygulamadan önce belirli bir noktada konumlandırılır (mesela sol üst köşede). Uygulanan iki matris arasındaki indisler çarpılır ve çıkan sonuçlar toplanılarak çıktı matrisine depolanır. Bu işlemi tamamladıktan sonra filtre sağa belirlenen kaydırma adımı kadar kaydırılır (örneğin 1px). Birinci satırı bitirene kadar çarpma ve kaydırma işlemleri devam edilir ve ikinci satırına geçerek işlemler tekrarlanır. Tüm matris üzerinde bu işlemi gerçekleştirdikten sonra çıktı matrisi oluşturulur (Fei-Fei Li ve ark., 2020). Şekil 3.9'da gösterildiği gibi 3B görüntü girdisi $7 \times 7 \times 3$ olan bir matris, filtreleme işlemlerinden sonra $3 \times 3 \times 2$ boyutunda matrisine inmiştir. Şekilde 1 adım kaydırma yapılarak evrişim işlemi nasıl yapıldığı gösterilmiştir.



Şekil 3.9. 3B görüntü girdisi 7x7x3 olan bir matristen, filtreleme işlemlerinden sonra 3x3x2 matris elde eden hesaplama şeması (Fei-Fei Li ve ark., 2020)

3.3.1.1.2. Havuzlama katmanı

Havuzlama katmanı, ESA katmanları arasına sıklıkla eklenen bir katmandır. Genelde ReLu katmanından sonra gelen bir katmandır ve bu katmanın görevi, ağ içindeki parametreleri ve hesaplama sayısını azaltmaktan sorumludur. Sonraki evrişim için giriş boyutları genişliği ya da yüksekliği azalır. Bu sayede ağdaki uyumsuzluk kontrol edilmiş olunur. Doğrusal olmayan alt örnekleme gerçekleştirir ve daha basit bir çıktı için parametre sayısını azaltır. Genel olarak veriler, girdi olarak evrişimsel bir ağ katmanına girdiğinde üç farklı aşamadan geçer. İlk aşama, evrişim fonksiyonunun paralel olarak gerçekleştirildiği ve verileri doğrusal aktivasyonlar olarak aktardığı yerdir. İkinci aşama, modele doğrusal olmayan bir özellik eklemekten sorumludur. Örneğin, doğrultulmuş doğrusal fonksiyon bu aşamada kullanılabilir. Son olarak, çıktıyı bir sonraki katmana teslim etmeden önce değiştirmek için son aşamada havuzlama işlevi gerçekleştirilir. Görüntü tanıma durumunda, özellik haritasını bulduktan sonra, havuzlama katmanı, ilgili olmayan veya algılamamanın sonucunu etkilemeyecek gereksiz bilgileri ortadan kaldıracaktır. Havuzlama, modelin küçük çevirilere karşı daha dayanıklı olmasına da yardımcı olur. Birçok havuzlama işlemleri vardır, fakat en popülerleri maksimum havuzlama ve ortalama havuzlamadır. Şekil 3.10'da gösterildiği gibi, ReLu katmanından elde edilen bir giriş görüntüsü ile başlayan bu havuzlama işlemi tek adım kaydırmalı ya da iki adım kaydırmalı işlemleri sonunda sonraki katmalar için yeni görüntüler oluşturur.




Şekil 3.10. 5X5 giriş görüntüsü üzerinde 2X2 filtre uygulaması (Özkan ve Ülker, 2017)

Bir havuzlama katmanı, aşağı örneklemenin yanı sıra girdinin küçük çevirileri altında y'nin değişmezliğini sağlayan bir araçtır. Evrimsel katmanlarla birlikte çok sık kullanılır. Havuzlama işlemi, aritmetik bir işlev kullanarak yakındaki girdilerin bir özet istatistiğini hesaplar. Havuzlama işlemi evrişime benzer, ancak doğrusal kombinasyonu komşuların girdisinin maksimumu veya ortalaması gibi başka bir fonksiyonla değiştirir.

3.3.1.1.3. Bırakma katmanı

Bırakma katmanı, makine öğrenimi algoritmalarının düzenlenmesi için bir yöntemdir. Bırakma katmanının ana fikri, eğitimin her yinelemesinden sonra girdi birimlerini rastgele devre dışı bırakmaktır. Böylelikle ağın ezberlemesi gibi sıkıntılar önlenmiş olur. Şekil 3.11'de bırakma işleminden önce ve sonraki ağ yapısını gösterilmektedir. Ağın birkaç düğümü rasgele kaldırılır ve kalan verilerle modelin eğitime devam edilir.



Şekil 3.11. Solda tam bağlı sinir ağı ve sağda bırakma uygulanarak üretilen daha küçük bir ağ örneği (Srivastava ve ark., 2014)

Bırakma işlemi aşırı öğrenmeyi önemli ölçüde azaltır ve diğer düzenleme yöntemlerine göre önemli iyileştirmeler sağlar.

3.3.1.1.4. Sınıflandırma katmanı

Bu katman sınıflandırma problemlerinde kullanılan bir katmandır. Modelde sınıflandırma yapılacak nesnelerin sayısına eşittir. En çok kullanılan sınıflandırma

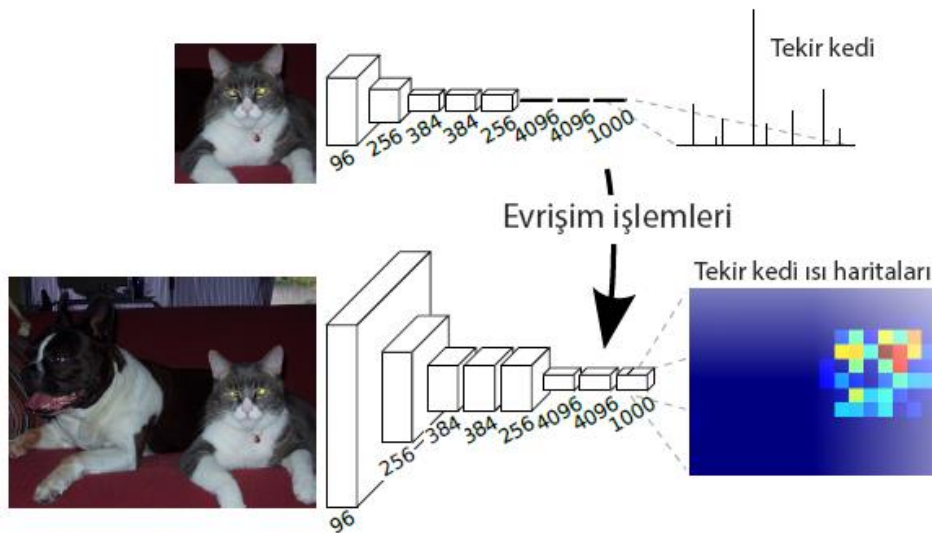
katmanı softmax sınıflandırıcıdır. Sınıflandırma işlemi sırasında 0-1 aralığında değerleri üretir ve 1'e en yakın değer üreten o sınıfa ait olunur.

3.3.1.1.5. Tam bağlantılı katman

Bir sinir ağındaki tam bağlantılı katmanlar, bir katmandaki tüm girdilerin bir sonraki katmanın her aktivasyon birimine bağlandığı katmanlardır. Modellerin çıkış değeri oluşturmak için önceki katmanlar tarafından çıkarılan verileri derleyen tam bağlantılı katmanlardır. Evrişim Katmanından sonra en çok zaman alan ikinci katmandır.

3.3.1.2. Tam Evrişimsel sinir ağları (TESA)


Tam evrişimsel sinir ağları (TESA) görüntülerin özelliklerinin hiyerarşilerini sağlayan güçlü bir modellerdir. Bu yöntem Long ve ark. tarafından 2015 yılında önerilmiştir (Long ve ark., 2015). ESA modeline çok yakın olan TESA modeli piksel şekillendirme çok daha başarılıdır ve piksellerin hangi gruba ait oldukları konusunda daha başarılı olabilmektedir. Sınıflandırma işlemleri etiketlenmiş görüntüleri alır ve bu görüntüleri pikselden piksele işler ve olasılık haritası oluşturur. Bu model önceden eğitilmiş modellerden de yararlanarak eğitilebilir. Şekil 3.12'de TESA kullanarak giriş görüntüsünden bir çıktı ısı haritası gösterilmektedir. Tam bağlantılı evrişim katmanlarına dönüştürerek, bir sınıflandırma ağının ısı haritası oluşturulmuş.



Şekil 3.12. TESA kullanarak oluşturulan ısı haritası (Long ve ark., 2015)

3.3.2. U-Net

Geleneksel evrişimsel sinir ağından geliştirilen U-Net, ilk olarak 2015 yılında Ronneberger ve ark. (2015) tarafından biyomedikal görüntüleri işlemek için tasarlanmış ve uygulanmıştır (Ronneberger ve ark., 2015). Genel bir evrişimsel sinir ağı, girdinin bir görüntü ve çıktının etiketi olan bir görüntü sınıflandırma problemine odaklanır, ancak biyomedikal durumlar, sadece bir hastalık olup olmadığını ayırt etmemizi değil, aynı zamanda anormallik alanını lokalize etmemizi gerektirir. U-Net modeli bu tarz problemler için iyidir. Bu büyük başarısının nedeni, bir görüntünün sınırlarını belirleyebilmesi, ayırt edebilmesi ve ayrıca her pikseli sınıflandırabilmesidir. Bu işlem sonunda görselin boyutunun değişmemesi de büyük bir avantajdır.



Şekil 3.13. Orijinal U-Net mimarisi (Ronneberger ve ark., 2015)

Şekil 3.13'te orijinal U-Net mimari gösterilmektedir. Bu mimari, adı itibariyle 'U' şeklindedir. Her mavi kutu, çok kanallı bir özellik haritasına karşılık gelir. Kanal sayısı kutunun üstünde belirtilmiştir. x-y boyutu kutunun sol alt kenarında verilmiştir. Beyaz kutular, kopyalanan özellik haritalarını temsil eder. Oklar gerçekleştiren farklı işlemleri gösterir.

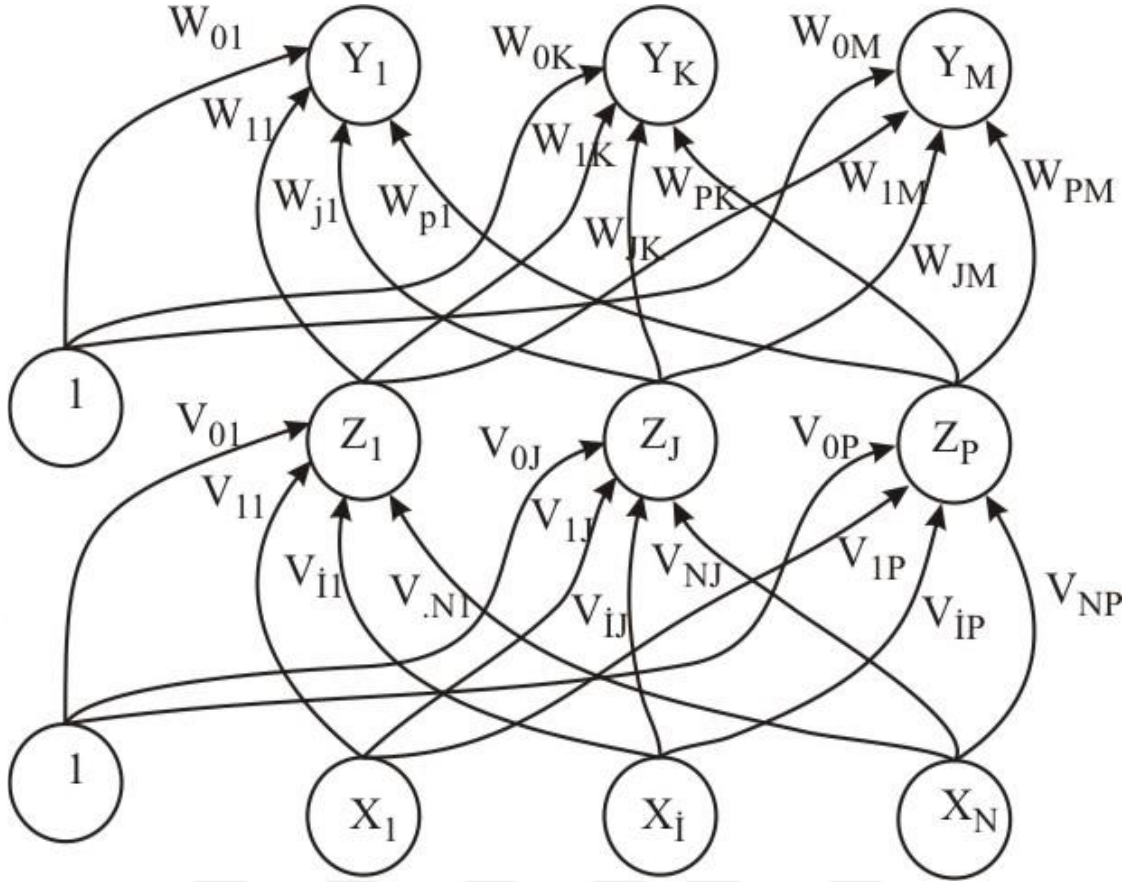
U-Net mimari genel olarak üç ana bloğa ayrılabilir, birinci blok kodlama ya da aşağı örnekleme yolu olarak geçmektedir. Bu blok birkaç kodlama adımlarından oluşur ve modelin özellik çıkarımından sorumludur. Onun ardında ikinci sıraya gelen darboğaz bloğu yer alır, iki evrişimsel katmandan oluşur. En son olarak kod çözme ya da yukarı örnekleme bloğu gelir. Bu adımlarda ters evrişim işlemleri uygulanarak model katmanların çıktıkları çözer ve çıkan sonuçları aynı giriş boyutlara sahip özelliklerle birleştirilir.

U-Net modelinin ana avantajlardan biri, az veriler üzerinde yüksek başarı elde edebilmektir. ESA modelleri genel olarak büyük veri setlerine ihtiyaç duymaktadır.

3.4. Geri Yayılım Algoritması

Geri yayılım algoritması, Çok Katmanlı Algılayıcıları eğitmek için kullanılan bir algoritmadır. İlk olarak 1970'lerde tanıtılmıştır, 1986 yıllarında Rumelhart ve ark. tarafından sunulan makale ile popülerliği artmıştır (Nielsen, 2015). Bu makale, geri yayılımın daha önceki öğrenme yaklaşımlarından çok daha hızlı çalıştığını ve daha önce çözülemeyen sorunları çözmek için sinir ağlarının kullanılmasını mümkün kılan birkaç sinir ağını tanımlamaktadır. Eğitim sırasında, her bir nöronun ağırlıkları hesaplanır ve güncellenir. Bir YSA'nın giriş katmanı ile çıkış katmanı arasındaki katman veya katmanlar gizli katman olarak isimlendirilmektedir. Bir sinir ağlarında kaç tane gizli katman kullanılacağı ve her bir gizli katmanda kaç nöron olacağının kesin bir kuralı yoktur (Yüksek ve ark., 2007).

Basit bir ifadeyle, bir ağ üzerinden her ileri geçişten sonra, modelin parametrelerini (ağırlıklar ve bias) ayarlarken geriye doğru bir geçiş gerçekleştirir. YSA'nın hatasını minimum noktaya getirmeye hedeflenen geri yayılım algoritması maliyet fonksiyonu olarak gradyan iniş tekniğini kullanmaktadır (Nielsen, 2015). Bu işlem aktivasyon fonksiyonlarının yardımlarıyla gerçekleştirilir. Aktivasyon fonksiyonu, sürekli, kolayca türevi alınabilir ve tekdüze bir şekilde azalmayan bir fonksiyon olmalıdır.



Şekil 3.14 İleri beslemeli çok katmanlı sinir ağı şeması, x , z , y vektörleri ile V , W matrisleri (Yüksek ve ark., 2007)

Şekil 3.14'teki bir modelinin eğitimini geri yayılım algoritması aşağıdaki adımları izlenerek hesaplanabilir (Yüksek ve ark., 2007):

1. Birinci adımda, nöronlarının ağırlıklarının katsayıları küçük katsayılarla atanır.
2. Her bir eğitim verisinin (x, t) değerlerini hesaplamak için 3-8 adımları tekrarlanır.

İleri besleme (Feedforward)

3. Her bir x_i (x_1, \dots, x_n) nöronu x_i input sinyalini alır ve bir sonraki katmandaki gizli katmanda yer alan nöronlara aktarır.

4. Her bir z_j nöronu, tüm giriş sinyallerinin bağlı oldukları ağırlıklarla çarpımını toplar ve aktivasyon fonksiyonu ile çıkış sinyalini hesaplar. Bu hesaplamalardan çıkan sonuç çıkış nöronlarına gönderilir.

$$z_in_j = \sum x_i v_{ij} + v_{0j} \quad (3.1)$$

$$z_in_j = f(z_in_j) \quad (3.2)$$

5. Her bir çıkış y_k nöronu, kendine giriş olarak verilen giriş sinyallerinin bağlı oldukları ağırlıklarla çarpımını toplar ve aktivasyon fonksiyonu ile çıkış sinyalini hesaplar.

$$z_in_k = \sum z_j w_{jk} + w_{0k} \quad (3.3)$$

$$y_k = f(y_in_k) \quad (3.4)$$

Hatanın geriye yayılması

6. Her bir çıkış nöronu y_i (y_1, \dots, y_m) için giriş eğitim verisine karşılık gelen hedef değerine bakılır ve hata terimini hesaplar:

$$\delta_k = (t_k - y_k) f'(y_in_k) \quad (3.5)$$

Sonra, w_{jk} katsayısını güncellemede kullanılacak değişim miktarı hesaplanır:

$$\nabla w_{jk} = \alpha \delta_k z_j \quad (3.6)$$

Bu adımdan sonra w_{0k} eğilimi değerini güncellemek için kullanılacak değişim miktarı hesaplanır:

$$\nabla w_{0k} = \alpha \delta_k \quad (3.7)$$

7. Her bir gizli nöron z_j (z_1, \dots, z_p), yukarı katmandan gelen delta girişlerini toplar:

$$\delta_in_j = \sum_{k=1}^m \delta_k w_{jk} \quad (3.8)$$

Bu hesaplama gerçekleştirdikten sonra, hata terimini hesaplanır:

$$\delta_j = \delta_{in_j} f'(z_{in_j}) \quad (3.9)$$

Daha sonra, v_{ij} katsayısını güncellemede kullanılacak değişim miktarı hesaplanır:

$$\nabla v_{ij} = \alpha \delta_j x_i \quad (3.10)$$

Son adımında, v_{0j} eğilim değerini güncelleyebilecek için kullanılacak değişim miktarı hesaplanır:

$$\nabla v_{0j} = \alpha \delta_j \quad (3.11)$$

Ağırlık güncelleme

8. Ağırlık değerleri hesaplanan değişim miktarları kullanılarak güncellenir.

$$w_{jk}(yeni) = w_{jk}(eski) + \nabla w_{jk} \quad (3.12)$$

$$v_{ij}(yeni) = v_{ij}(eski) + \nabla v_{ij} \quad (3.13)$$

9. En son geri yayılım bitiş şartı kontrol edilir.

3.5. Hiperparametreler

DÖ veya makine öğrenimi senaryolarında, model performansı büyük ölçüde seçilen hiperparametre değerlerine bağlıdır. Hiperparametre keşfinin amacı, en iyi performansla sonuçlanan bir konfigürasyon bulmaktır ve bu amaç için çeşitli hiperparametre konfigürasyonları arasında arama yapmaktır. Modellerin yapısını belirleyen ve ağırlık nasıl eğitileceğini belirleyen değişkenlerdir. Makine öğreniminde hiperparametre optimizasyonu, belirli bir makine öğrenimi algoritmasının bir doğrulama setinde ölçülen en iyi performansı sağlayan hiperparametreleri bulmayı amaçlar. Bu metrikleri katman sayısı, kullanılan aktivasyon fonksiyonu, modelin öğrenme hızı ve optimizasyon algoritmasına göre değişiklik göstermektedir. Modelin yapısı tamamen

probleme bağılı olup, kullanılan veri setine göre deęişim de gösterebilmektedir. Bu hiperparametreler model ve iyileştirici olmak üzere ikiye ayrılmaktadır. Aktivasyon fonksiyonu, dropout (bırakma) ve katman sayısı gibi deęişkenlikler model hiperparametrelerdir çünkü modelinin yapısında yer almaktadırlar. Öğrenme hızı, veri batch sayısı yani veri seti grubu ve devir sayısı gibi metrikleri ise modelinin iyileştiricileri olarak yer almaktadır ve modelinin eğitim ve optimizasyon yapılarında yer almaktadırlar. Bu hiperparametreler eğitimden önce ayarlanır ve modeli eğitirken kullanılır, ancak bunlar ortaya çıkan modelin bir parçası değildir. Modelin eğitimi sırasında bu hiperparametreler sürekli güncellenir ve eğitim sonundaki son deęeri ile model oluşturulur. Bu nedenle, doęru hiperparametre deęerlerinin ayarlanması çok önemlidir çünkü modelin performansını doğrudan etkiler.

3.5.1. Öğrenme hızı ve momentum katsayısı

Öğrenme hızı, minimum kayıp fonksiyonuna doęru hareket ederken her yinelemede adım boyutunu belirleyen bir optimizasyon parametresidir. Öğrenme hızı, model ağırlıkları her güncellendiğinde tahmini hata yanıtına göre modelin ne kadar deęiştirileceğini belirleyen bir hiperparametredir. Modelin öğrenme sürecindeki kullanılan ağırlık deęişimini belirler. Bu deęer sabit bir deęer olarak atanabilir ya da belli bir momentum katsayısının oranına göre deęişen bir deęer belirlenebilir. Model eğitim boyunca modelin eğitimi için belirlenen parametreleri kullanır, her devirden sonraki devire aktaracak ağırlık deęerleri bulmak için geriye doęru türev alınır ve sonucun farkını öğrenme oranı ile çarpar. Çürüme (Decay) oranı ve momentum deęerleri kullanarak bu işlem gerçekleştirilir. Öğrenme hızı deęeri çok küçük ve çok da büyük olmamalıdır. Küçük bir deęer seçildiğinde, modelin eğitim süreci uzun sürmektedir ve ezberleme gibi sıkıntılara yol açabilir. Modelin başarısını doğrudan etkilendięi için bu deęerlerin doęru bir şekilde tanımlanması gerekmektedir.

Standartlaştırılmış öğrenme hızı ve momentum deęerleri 1'den küçük ve 10^{-6} 'dan büyüktür, ancak bu aralıktan farklı olabilmektedir (Bengio, 2012). 0,01 varsayılan deęeri, genellikle standart çok katmanlı sinir aęları için uygundur ancak yalnızca bu varsayılan deęere güvenilmemesi gerekmektedir.

3.5.2. Aktivasyon fonksiyonları (AF)

Aktivasyon Fonksiyonları, yapay sinir ağlarında bir giriş sinyalinin bir çıkış sinyaline dönüştürmek için kullanılır ve sonraki katmana girdi olarak gönderilir. Bir yapay sinir ağında, girdilerin ve bunlara karşılık gelen ağırlıkların çarpımlarının toplamı hesaplanır ve bir sonraki katmana girdi olarak sağlanacak değeri bulmak için bir aktivasyon fonksiyonu uygulanır. Bir modelinin tahmin doğruluğu, kullanılan katman sayısına ve daha da önemlisi kullanılan aktivasyon fonksiyonunun tipine bağlıdır (Hao, 2017). Daha iyi bir model doğruluğu için kullanılacak minimum veya maksimum katman sayısını ya da aktivasyon fonksiyonunun tipini belirten bir kılavuz yoktur. En yaygın olarak kullanılan aktivasyon fonksiyonları lineer olmayan aktivasyon fonksiyonlarıdır. Modelleri eğitirken bir aktivasyon fonksiyonu tanımlanmadığı takdirde, bir sinir ağı, tahmin edilen çıktının girdi ile aynı olduğu bir doğrusal regresyon modeli gibi çalışır.

Lineer aktivasyon fonksiyonunun sınırı lineerdir ve eğer kullanılırlarsa, ağ sadece girdinin lineer değişikliklerine uyum sağlayabilir, ancak gerçek dünyada hatalar lineer olmayan özelliklere sahiptir. Bu sebeple, bir sinir ağında lineer olmayan aktivasyon fonksiyonları, lineer aktivasyon fonksiyonlarına göre tercih edilir (Hao, 2017).


Daha iyi performans ve daha az hatalı sonuçlar için, bir ağdaki gizli katman sayısı, eğitim yöntemleri, hiperparametre ayarı vb. gibi pek çok parametre göz önünde bulundurulmalıdır ve aktivasyon fonksiyonu dikkate alınması gereken en önemli parametrelerden biridir. Bazı modeller için doğru aktivasyon fonksiyonunu seçmek zor olabilir ve çok fazla araştırma ve denemeler gerektirebilir. Herhangi bir aktivasyon fonksiyonunu seçmek için basit bir kural yoktur, ancak aktivasyon fonksiyonunu seçimi içeriğe bağlıdır, yani gerçekleştirilecek göreve bağlıdır. Farklı aktivasyon fonksiyonlarının hem avantajları hem de dezavantajları vardır ve bu tasarladığımız sistemin türüne bağlıdır. Sınıflandırma problemleri için sigmoid fonksiyonların bir kombinasyonu iyi sonuçlar verir. ReLU fonksiyonu en yaygın kullanılan işlevdir ve çoğu durumda diğer fonksiyonlarına göre daha iyi performans göstermektedir.

3.5.2.1. Lineer (doğrusal) fonksiyon

Doğrusal aktivasyon fonksiyonu, giriş ile doğru orantılıdır. Şu şekilde tanımlanabilir:

$$f(x) = ax \quad (3.14)$$

a deęişkeninin deęeri, kullanıcı tarafından seçilen herhangi bir sabit deęer olabilir. Burada $f(x)$ fonksiyonunun türevi sıfır deęil, kullanılan sabitin deęerine eşittir. a deęeri sıfır olmayan ve x girdi deęerinden bağımsız olan bir deęerdir ve her geri yayılım adımında güncelleme faktörü aynı olsa da ağırlıklar ve yanlılıklar güncellenmektedir. Şekil 3.15 lineer fonksiyonun genel çizimini göstermektedir.



Şekil 3.15. Lineer aktivasyon fonksiyonu (Hao, 2017)


Lineer işlevi kullanmanın pek bir faydası yoktur çünkü her yineleme için aynı gradyan deęeri nedeniyle hatayı iyileştirmeyecektir. Ayrıca model verilerden karmaşık kalıpları tanımlayamaz. Bu nedenle doğrusal fonksiyonlar, basit görevler için idealdir.

3.5.2.2. Sigmoid fonksiyonu

Sigmoid fonksiyonu, doğrusal olmayan en yaygın kullanılan aktivasyon fonksiyonudur. Bu fonksiyon girdiyi 0 ile 1 aralığında deęerlere dönüştürür. Denklem 3.15 bu fonksiyonunun genel tanımınıdır.

$$f(x) = \frac{1}{1+e^{-x}} \quad (3.15)$$

Sigmoid fonksiyonu sürekli türevlenebilir bir fonksiyon ve düzgün S-şekilli olan bir fonksiyondur. Şekil 3.16 sigmoid fonksiyonunun genel çizimini göstermektedir.




Şekil 3.16. Sigmoid fonksiyonu (Hao, 2017)

3.5.2.3. Tanh (hiperbolik tanjant) fonksiyonu

Tanh fonksiyonu hiperbolik tanjant fonksiyonudur. Tanh fonksiyonu sigmoid fonksiyonuna benzer ancak orijine göre simetriktir. Bu, önceki katmanlardan farklı çıktı işaretleri ile sonuçlanır. Şekil 3.17 Tanh fonksiyonu genel çizimini göstermektedir.

Tanh fonksiyonu bu şekilde tanımlanabilir:

$$f(x) = 2 \operatorname{sigmoid}(2x) - 1 \quad (3.16)$$



Şekil 3.17. Tanh fonksiyonu (Hao, 2017)

Tanh fonksiyonu süreklidir ve türevlenebilir, tüm çıkış değerleri -1 ile 1 aralığındadır. Sigmoid fonksiyonu ile karşılaştırıldığında, tanh fonksiyonunun gradyanı daha diktir. Tanh fonksiyonu, belirli bir yönde değişmekle sınırlı olmayan ve sıfır merkezli gradyanlara sahip olduğu için sigmoid fonksiyona göre tercih edilmektedir.

3.5.2.4. Softmax fonksiyonu

Softmax fonksiyonu, çoklu sigmoid fonksiyonlarının birleşimidir. Bir sigmoid fonksiyonunun 0 ile 1 aralığında değerler döndüren bir aktivasyon fonksiyonu, bu değerleri belirli bir sınıfın veri noktalarının olasılıkları olarak ele alınabilir. Softmax fonksiyonu, ikili sınıflandırma problemlerinde kullanılan sigmoid fonksiyonlarından farklı olarak çok sınıflı sınıflandırma problemlerinde de kullanılabilir (Hao, 2017). Tüm bireysel sınıfların her veri noktası için olasılığını döndürebilen bir fonksiyondur. Denklem 3.17 softmax denklemini vermiştir.


$$\sigma(\vec{z})_i = \frac{e^{z_i}}{\sum_{j=1}^K e^{z_j}} \quad (3.17)$$

- σ = Softmax değeri
- \vec{z} = Giriş vektörü
- e^{z_i} = Giriş vektörü için standart üstel fonksiyon
- K = Çok sınıflı sınıflandırıcıdaki sınıf sayısı
- e^{z_j} = Çıktı vektörü için standart üstel fonksiyon

Çoklu sınıf sınıflandırması için bir model oluştururken, ağın çıkış katmanı, hedefteki sınıf sayısı kadar nörona sahip olması gerekmektedir.

3.5.2.5. Rektifiye lineer birim (ReLU) fonksiyonu

ReLU sinir ağlarında yaygın olarak kullanılan doğrusal olmayan bir aktivasyon fonksiyonudur. ReLU işlevini kullanmanın avantajı, tüm nöronların aynı anda etkinleştirilmemesidir. Şekil 3.18'de gösterildiği gibi, bir nöronun yalnızca lineer dönüşümün çıktısı sıfır olduğunda devre dışı bırakılır.




Şekil 3.18. Rektifiye lineer birim (ReLU) fonksiyonunun grafiği (Hao, 2017)

ReLU, diğer işlevlerden daha verimlidir, tüm nöronlar aynı anda etkinleştirilmediğinden, bir seferde belirli sayıda nöron etkinleştirilir. Bazı durumlarda, gradyan değeri sıfırdır, bu nedenle, sinir ağı eğitiminde geri yayılım adımı sırasında ağırlıklar ve yanlılıklar güncellenemiyor.

3.5.2.6. Üstel Doğrusal Birim (ELU)

Üstel Doğrusal Birim (Exponential Linear Unit, ELU) da Rektifiye Doğrusal Birimin (ReLU) bir çeşididir. ELU, x 'in negatif değerleri için bir parametre eğimi sunar. Negatif değerleri tanımlamak için bir log eğrisi kullanır. Şekil 3.19 üstel doğrusal birim fonksiyonu genel çizimini göstermektedir.

$$\begin{aligned} f(x) &= x, & x &\geq 0 \\ f(x) &= a(e^x - 1), & x &< 0 \end{aligned} \quad (3.18)$$




Şekil 3.19. ELU fonksiyonunun grafiği (Hao, 2017)

3.5.2.7. Sızıntı ReLU fonksiyonu

Sızıntı ReLU, ReLU fonksiyonunun bir versiyonudur, burada x 'in negatif değerleri için, ReLU fonksiyonlarının değerini sıfır olarak tanımlamak yerine, x 'in son derece küçük lineer bileşeni olarak tanımlanır. Şekil 3.20 ReLU fonksiyonunun genel çizimini göstermektedir.

$$\begin{aligned} f(x) &= 0.01x, & x < 0 \\ f(x) &= x, & x \geq 0 \end{aligned} \quad (3.19)$$



Şekil 3.20. Sızıntı ReLU fonksiyonunun grafiği (Hao, 2017)

3.5.3. Optimizasyon fonksiyonu

Optimizasyon fonksiyonları modelin başarısını artırmak için kullanılır. Modelin sonucu ve beklenen sonuç arasındaki farkı düşürmek için kullanılır. Optimizasyon işlemi, modelinin başarısı artırmak için sinir ağlarının ağırlıklar ve öğrenme hızı gibi özelliklerini

değiřtirmek için kullanılan algoritmalar veya yöntemlerdir. Modelinin optimum çalışma noktasına getirebilmek için kullanılan optimizasyon fonksiyonları arasında Adam, Stokastik Gradyan İniř Metodu (Stochastic Gradient Descent - SGD), AdaGrad, AdaDelta ve RMSProp gibi fonksiyonları mevcuttur. Bu algoritmalar, kayıpları azaltmaktan ve mümkün olduđu kadar en dođru sonuçları sađlamaktan sorumludur.

Bir DÖ çalışmasında, eğitim süreci ve performans oldukça önemlidir. Çok fazla parametre ve yöntem olan bir ortamda en iyi yöntemi yakalayabilmek kolay değildir. Yapay sinir ağlarında ağırlıkların deđerlerini en iyi öğrenme süreci gerçekleşene kadar her aşamada güncellemek gerekir ve bu güncelleme işlemi belirli yöntemler kullanılarak gerçekleştirilir. Gradyan İniři bu yöntemlerden en çok kullanılan yöntemdir (Ruder, 2018). Parametreleri güncellemeden önce tüm eğitim setini işler sonra gereken güncellemeleri yapar ve sonraki adıma geçer. Gradyan iniřinin üç çeşidi vardır; Batch Gradient Descent, Mini-Batch Gradient Descent ve Stochastic Gradient Descent. Amaç fonksiyonunun gradyanını hesaplamak için kullandığımız veri miktarında farklılık gösterirler. Veri miktarına bađlı olarak, parametre güncellemesinin dođruluđu ile bir güncellemeyi gerçekleřtirmek için gereken süre arasında bir denge kurmaya çalışır.

Çalışmamızda, Adam optimizasyon algoritması kullanılmıştır. Adam (**AD**Aptive **M**oment estimation) günümüzde yaygın olarak kullanılmaktadır. Adam, RMSprop ve Stokastik Gradyan İniři'nin momentum ile bir kombinasyonu olarak görülebilir. Bu algoritma, RMSprop algoritması gibi öğrenme hızını ölçeklendirmek için kare gradyanları kullanır ve momentum ile Stokastik Gradyan İniři gibi gradyan yerine gradyanın hareketli ortalamasını kullanarak momentumdan yararlanır (Nielsen, 2015).

3.5.4. Kayıp fonksiyonu

Sinir ağları, stokastik gradyan iniři kullanılarak eğitilir ve modeli tasarlarırken ve yapılandırırken bir kayıp fonksiyonu seçilmesi gerekir. Seçim yapılabileceđi birçok kayıp fonksiyonları vardır. Makineler bir kayıp fonksiyonu aracılığıyla öğrenir. Belirli bir algoritmanın verilen verileri ne kadar iyi modellediđini deđerlendirme yöntemidir. Tahminler gerçek sonuçlardan çok fazla saparsa, kayıp fonksiyonu büyük sonuçları verir. Optimizasyon fonksiyonlarının yardımıyla, kayıp fonksiyonu tahmindeki hatayı azaltmayı öğrenir. Makine öğreniminde algoritmalar için tek boyutlu bir kayıp

fonksiyonu yoktur. Seçilen makine öğrenimi algoritmasının türü ve türevleri hesaplama kolaylığı gibi belirli bir problem için bir kayıp fonksiyonu seçiminde çeşitli faktörler vardır.

Genel olarak, kayıp fonksiyonları iki ana kategoriye sınıflandırılabilir; Regresyon kayıpları ve Sınıflandırma kayıpları. Sınıflandırmada, sonlu kategorik değerler kümesinden çıktıyı tahmin etmeye çalışılır. Regresyon ise bir şeyin sürekli değerini tahmin etmekle ilgilenir. Regresyon kayıpları olarak Ortalama Kare Hatası (Mean Square Error), Ortalama Mutlak Hata (Mean Absolute Error) fonksiyonları ve Sınıflandırma problemleri için Mentşe Kaybı (Hinge Loss or Multi class SVM Loss), Çapraz Entropi Kaybı (Cross Entropy Loss) gibi kayıp fonksiyonları sayılabilir.

3.6. Değerlendirme Metrikleri

Makine öğrenimi modellerini değerlendirirken doğru metriği seçmek çok önemlidir. Bazı uygulamalarda tek bir metriğe bakmak bir modeli ne kadar iyi çalıştığını söylemeyebilir, bu nedenle bir modelinin performans ölçümünde birden fazla metrikleri kullanmak daha iyidir. Bu metrikler kayıp fonksiyonundan farklıdır. Kayıp fonksiyonu, model performansının bir ölçüsünü gösteren ve bir makine öğrenimi modelini eğitmek için kullanılan (bir optimizasyon yöntemi kullanarak) işlevlerdir ve genellikle model parametrelerinde türevlenebilir. Metrikler bir modelin performansını (eğitim ve test sırasında) ölçmek için kullanılır ve türevlenebilir olmaları gerekmez. Bazı görevler için performans metriği türevlenebilirse hem kayıp fonksiyonu olarak hem de performans değerlendirme metriği olarak kullanılabilir.

3.6.1. Ortalama mutlak hata

Ortalama mutlak hata, veri kümesindeki gerçek ve tahmin edilen değerler arasındaki mutlak farkın ortalamasını temsil eder. Veri setindeki artıkların ortalamasını ölçer. Mutlak Hata, ölçümlerindeki hata miktarıdır. Ölçülen değer ile gerçek değer arasındaki farktır. Mutlak değer sembolü gereklidir çünkü bazen ölçüm daha küçük olur ve negatif bir sayı verir. Ortalama Mutlak Hata (OMH), tüm bu mutlak hataların ortalamasıdır.

$$OMH = \frac{1}{n} \sum_{i=1}^n |x_i - x| \quad (3.20)$$

- n = hata sayısı,
- x = orijinal değer
- x_i = tahmin edilen değer
- $|x_i - x|$ = mutlak hatalar.

3.6.2. Ortalama kare hatası

Ortalama Kare Hatası, veri kümesindeki orijinal ve tahmin edilen değerler arasındaki kare farkının ortalamasını temsil eder. Artıkların varyansını ölçer. Ortalama kare hatası (OKH), bir regresyon çizgisinin bir dizi noktaya ne kadar yakın olduğunu söyler. Bunu, noktalardan regresyon çizgisine olan mesafeleri (hatalar) alarak ve bunların karesini alarak yapar. Herhangi bir olumsuz işareti kaldırmak için kare alma gereklidir. Ayrıca daha büyük farklılıklara daha fazla ağırlık verir. Bir dizi hatanın ortalamasını bulduğunuz için buna ortalama kare hatası denir. OKH ne kadar düşükse, tahmin o kadar iyidir. Bir regresyon probleminde OKH değeri her zaman pozitif ve sıfıra yakın ise modelinin performansı yüksek olduğunu söylenebilir. OKH formülü denklem 3.21 verilmiştir.

$$OKH = \frac{1}{n} \sum_{i=1}^n (x_i - x)^2 \quad (3.21)$$

- n = hata sayısı,
- $(x_i - x)^2$ = kare farkını.
- x = orijinal değer
- x_i = tahmin edilen değer

3.6.3. Sefalometrik değerlendirme metrikleri

Modellerin performansı değerlendirmek için iki ana kriter göz önünde bulundurulur. İlk değerlendirme kriteri, ilgili standart sapma ile ortalama radyal hatadır. Radyal hata formülü denklem 3.22'de verilmiştir.

$$R = \sqrt{\Delta x^2 + \Delta y^2} \quad (3.22)$$


Δx , x yönünde tahmin edilen ve doktor tarafından belirlenen gerçek yer işareti konumu arasındaki mutlak mesafedir. Δy , y yönünde tahmin edilen ve doktor tarafından belirlenen gerçek yer işareti konumu arasındaki mutlak mesafedir.

Radyal hatasının kullanarak Ortalama Radyal Hatası (ORH) ve Standart Sapma (SS) değerleri elde edilmektedir. Denklem 3.23'te, ORH ile SS arasındaki ilişkileri gösterilmiştir.

$$ORH = \frac{\sum_{i=1}^N R_i}{N} \quad (3.23)$$

$$SS = \sqrt{\frac{\sum_{i=1}^N (R_i - ORH)^2}{N-1}} \quad (3.24)$$

İkinci değerlendirme kriteri, 2.0 mm, 2.5 mm, 3.0 mm ve 4.0 mm hassasiyet aralığına göre başarı algılama oranıdır. BAO sefalometrik noktaların lokalizasyonlarının değerlendirilmesi için kullanılan genel metriktir. Bu metrik tahmin edilen noktalarının pozisyonu ve gerçek pozisyonu arasındaki hata oranını vermektedir. ISBI 2015 yarışması sırasında yarışmacıların modelleri performans değerlendirmek için kullanılmıştır (Wang ve ark., 2015). Şekil 3.21'de kırmızı, mavi, yeşil ve sarı yuvarlaklar ile bir nokta üzerinde çizilmiştir.



Şekil 3.21. Bir dönüm noktasının dört hassas aralığı: 2,0 mm (kırmızı daire), 2,5 mm (mavi daire), 3,0 mm (yeşil daire) ve 4,0 mm (sarı daire) (Wang ve ark., 2015)

Bir dönüm noktasının başarıyla algılanmış sayılması için, öngörülen ve açıklanmalı konumlar z mm'nin altında olmalıdır. Tespit edilen ve referans işaret arasındaki mutlak farkı, doktorların işaretinden daha büyük değilse, başarılı tespit, aksi takdirde yanlış tespit olarak kabul edilir. Denklem 3.25'de BAO denklemi tanımlanmıştır.

$$p_z = \frac{\sum\{j:\|L_a(j)-L_b(j)\| < z\}}{\sum\Omega} \times 100 \quad (3.25)$$

- L_a = Tespit edilen yer işaretinin konumlarını temsil eder
- L_b = Referans verilen yer işaretinin konumlarını temsil eder
- z = Değerlendirme sırasında kullanılan dört aralık, 2.0 mm, 2.5 mm, 3.0 mm ve 4.0 mm.
- Ω = Yapılan tespit sayısı

3.7. Evrimsel Sinir Ağında Performans Artırma Yöntemleri

DÖ problemlerinde ESA, birçok alanda ve tıbbi görüntü analizi alanında hem segmentasyon hem de regresyon problemlerinde yüksek doğruluk sağlamaktadır. Eğitim sürecinde, doğruluk seviyesini yükseltmek ve eğitim süresini azaltmak için eğitim sürecinin iyileştirilebilecek bazı hiperparametreler vardır. Bir ESA probleminde performans artışını gerçekleştirebilmek için çeşitli yöntemler vardır.

Derin öğrenme, büyük miktarda veriye sahip durumlarda çok iyi çalışır. ESA'nın verilerden özellikleri otomatik öğrenme yeteneği kazabilmesi için çok veriden geçerek öğrenmesi gerekmektedir. Veri eksikliği durumunda, var olan çeşitli veri büyütme yöntemlerinden faydalanarak veri büyütme uygulanabilir. Veri örnek sayısını artırmak için genellikle kullanılan görüntü büyütme parametreleri yakınlaştırma, kesme, döndürme, ön işleme vardır. Bu parametrelerin kullanımı, DÖ modelinin eğitimi sırasında modelin öğrenmesi gereken özelliklere sahip görüntülerin üretilmesinde yardımcı olur. Daha fazla veri ile modeli eğitip, erken durdurma uygulanıp ve çapraz doğrulama ile aşırı ve eksik öğrenme engellenebilir ve performansında artış sağlanabilir.

3.8. Veri Arttırma

Görüntü verilerini artırma, mevcut bir görüntü veri setini genişletmek için mevcut görüntülerden varyasyonlar oluşturmak için kullanılan bir tekniktir. Bu tekniği kullanarak mevcut görüntü veri setinden yeni ve farklı görüntüler oluşturulur. ESA modelinin etkili bir şekilde eğitilmesi için çok sayıda görüntüye ihtiyaç vardır. Daha büyük bir veri seti ile modelin öğrenme performansı artar ve aşırı öğrenme gibi sıkıntılardan kaçınılır. Bir ESA modeli, nesnelere farklı boyutlarda, yönlerde veya farklı aydınlatmalarda sınıflandırılabilir (Prasad, 2019). Bu nedenle, küçük görüntü veri kümelerinde her bir veri nesnelere yaklaştırarak veya uzaklaştırarak, dikey veya yatay olarak çevirerek veya nesne için anlamlı olan parlaklığı değiştirerek nesnelere farklı boyutlara dönüştürebilir. Bu şekilde, varyasyonlarla zengin, çeşitli bir veri seti elde edilebilir.

Görüntü arttırma, modeli eğitmeden önce bir ön işleme adımı olarak uygulanabilir veya gerçek zamanlı olarak uygulanabilir. Bu işlemi mevcut görüntü üzerinde yaklaştırmak, birkaç derece döndürmek veya kırpma gibi farklı dönüştürme teknikleri uygulanarak yapılır.

4. ÖNERİLEN MODEL VE BULGULAR


Bu tez çalışmasında ESA kullanarak sefalometrik noktaların otomatik tespitini yapan bir yaklaşım önerilmiştir. Bölüm 2’de anlatıldığı gibi son zamanlarda bilgisayar destekli sefalometrik analiz problemini çözmek için çeşitli yöntemler geliştirilmiştir (Lee ve ark., 2017; Goutham ve ark., 2019; Qian ve ark., 2019; Drevický ve Kodym, 2020). Bu işlemi gerçekleştirebilmek için manuel tanımlanmış noktalarının koordinat bilgileri ve iyi tasarlanmış bir algoritma gerekmektedir. Günümüzde, daha yüksek doğrulukla sefalometrik analizi gerçekleştirebilecek yöntemleri bulmak için araştırmalar devam etmektedir. Bu tez çalışmasında yapılan araştırmada bir otomatik sefalometrik analizi yaklaşımı önerilmiştir. Sefalometrik yer işaretlerini otomatik lokalizasyonunu gerçekleştirmek için U-Net modelinden esinlenerek çok katmanlı bir DÖ modeli tasarlanmıştır. Uzmanlar tarafından manuel olarak belirlenen 19 sefalometrik yer işareti bu model kullanılarak otomatik olarak elde edilmiştir. Bu araştırma için IEEE 2015 Uluslararası Biyomedikal Görüntüleme Sempozyumu (ISBI 2015) kapsamında oluşturulan sefalometrik X-ray görüntü veri seti kullanılmış ve bu veri setine veri büyütme uygulanmıştır.

4.1. Veri Seti

Bu tez çalışmasında, IEEE Uluslararası Biyomedikal Görüntüleme Sempozyumu 2015 (International Symposium on Biomedical Imaging, ISBI 2015)’te sunulan sefalometrik nokta tespitleri için kullanılan veri kümesi kullanılmıştır (Wang ve ark., 2016). Bu veri seti Lateral sefalogram görsellerden oluşur. Tüm sefalogramlarda aynı formatta ve aynı tarama makinesinden elde edilmiştir. Görüntülerin çözünürlüğü 1935x2400 piksel ve 0,1 mm piksel aralığından oluşmaktadır. İki uzman ortodontist (on beş yıllık deneyime sahip bir üst düzey ve altı yıllık deneyime sahip bir genç) tarafından manuel olarak tespit edilmiştir (Lindner ve ark 2016). Sadelik ve tutarlılık için, bu çalışmada doğruluk değerlendirmesi için sadece kıdemli hekimden gelen zemin gerçeği kullanılmıştır.

Yarışmanın yazarları, veri kümesini birbiriyle çakışmayan görüntü gruplarına ayırmıştır: araştırma için kullanılan **eğitim** seti 150 görüntü ve **test1** 150 görüntü içermektedir. Veri kümesinden her bir gözlem bir sefalogram ve Şekil 4.1’de gösterilen

19 sefalometrik nokta konumlarından oluşur. Yer işaretlerinin açıklaması Tablo 4.1'de sunulmuştur.



Şekil 4.1. Sefalometrik noktaların konumları (Juneja ve ark., 2021)

Tablo 4.1. Sefalometrik yer işaretlerinin tanımları (Juneja ve ark., 2021)

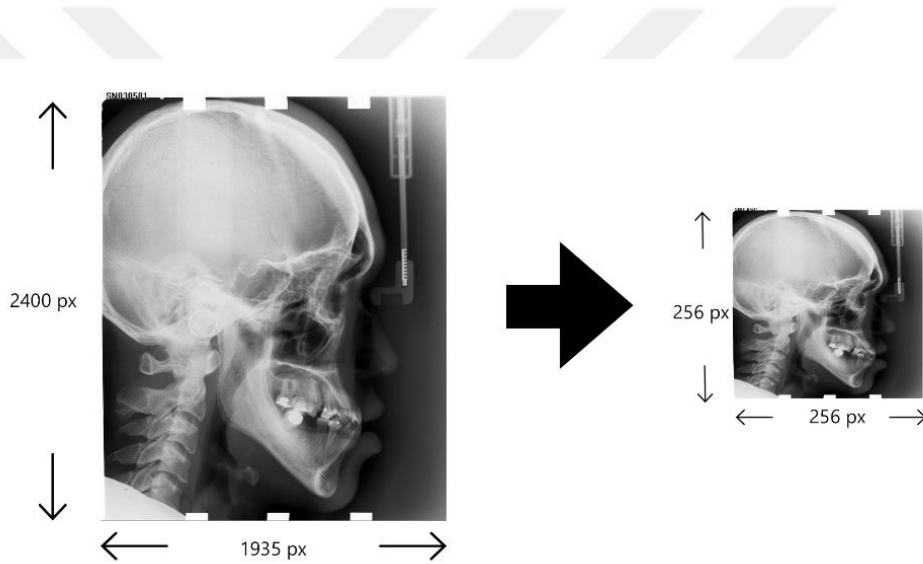
Yer İşareti		Açıklama
L1	Sella	İnsan kafatasının sfenoid kemiğinin çerçevesinde yer almaktadır
L2	Nasion	İki burun kemiği, frontal ile nazal kemikleri birleştiği noktada yer almaktadır
L3	Orbitale	Kemik yörüngesinin ya da orbital konturunun en alt noktasında yer almaktadır
L4	Porion	Kulak yolunun üst kenarında yer almaktadır
L5	Subspinale	Tabandan maksillanın kadar kavisli gövde ana hatlarını noktasında yer almaktadır
L6	Supramentale	En arka merkez noktası, çenenin üzerinde, mandibula üzerinde, pogonion ve infradentat arasında yer alır
L7	Pogonion	Çenenin ön orta noktası
L8	Menton	Sefalogramın lateral görünümünde çenedeki en alt noktası
L9	Gnathion	Çenenin profil eğriliğinin en dışa dönük noktası
L10	Gonion	Mandibula açısında en alt arka noktası
L11	Incision Inferius	Mandibular merkezin kenar merkez noktası
L12	Incision Superius	Maksiller merkezin kenar merkez noktası
L13	Upper Lip	Üst membranöz dudağın kenarında bir noktası
L14	Lower Lip	Alt membranöz dudağın kenarında bir noktası
L15	Subnasale	Orta sagital düzlemde, nazal septumun üst dudağı ile birleştiği noktası
L16	Soft tissue pogonion	Orta sagital düzlemde yumuşak doku çenesindeki noktası
L17	Posterior nasal spine	Sert damağın palatin kemiğinin arka omurgasının tepe noktası
L18	Anterior nasal spine	İki maksiller kemiğin intermaksiller suturede birleştirilmesi ile oluşan bir noktası
L19	Articulare	Temporal kemik ile mandibula konturlarının kesişim (geçiş) noktası

4.2. Veri Ön İşleme ve Arttırma

Kullanılan veri seti üzerinde veri boyutlandırma ve veri arttırma işlemleri gerçekleştirilmiştir.

4.2.1. Yeniden boyutlandırma

Veri büyütme işlemi gerçekleştirilmeden önce görsellerin boyutları küçültmüştür. Tüm orijinal veri setlerinin görüntünün çözünürlüğü TIFF formatında 1935 x 2400 pikseldir. Görseller 256 x 256 pikseli görsellere indirilmiştir. Şekil 4.2’de bir görselinin orijinal hali ve boyutları küçülttükten sonraki halleri gösterilmektedir.



Şekil 4.2. Orijinal görseli üzerinde boyutlandırma uygulandıktan sonraki halleri

4.2.2. Veri Arttırma

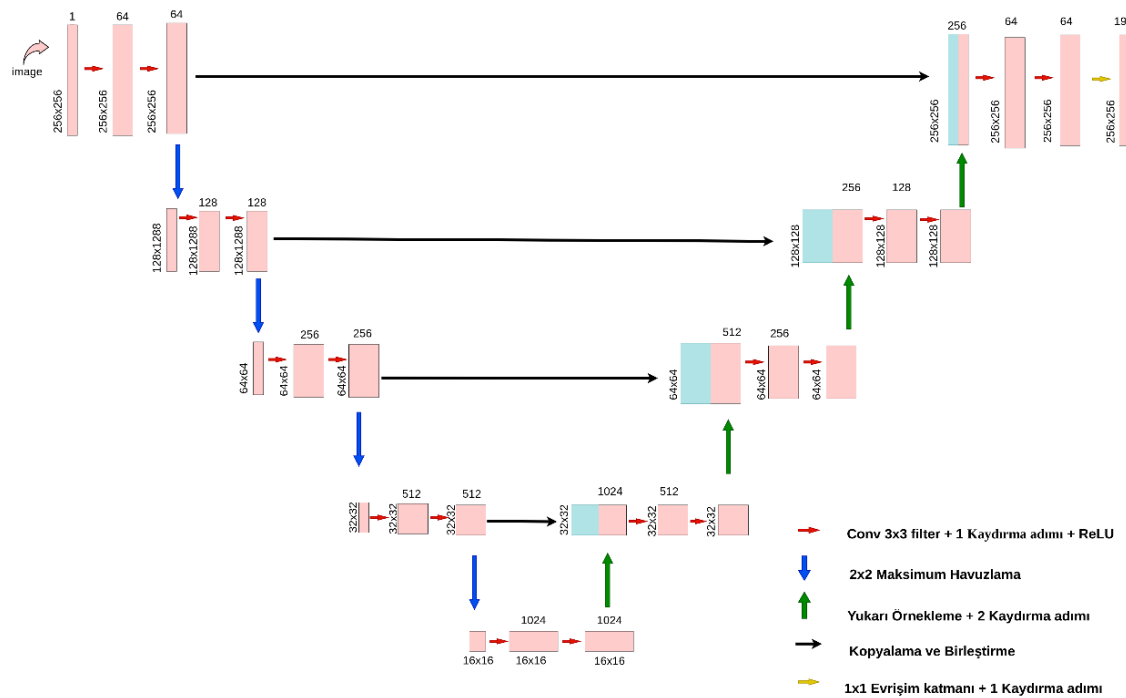
256x256 sefalometrik görüntü üzerinde 1 ve 3 piksel 4 farklı yönde (sağ, sol, aşağı, yukarı) kaydırılarak veri arttırma işlemi gerçekleştirilmiştir. Eğitim veri kümesindeki her görüntü için bu metrikleri kullanılarak kaydırma işlemi gerçekleştirilmiştir. Kaydırma işlemi ile her görüntüden dört yeni görüntü elde edilmiştir. Bu işlem, Imgaug (Jung, 2018) adlı ünlü görüntü büyütme kütüphanesi kullanılarak gerçekleştirilmiştir. Imgaug, kilit noktalar veya yer işaretleri, sınırlayıcı kutular, ısı haritaları ve segmentasyon haritalarının görüntü büyütme için kullanılan bir

kütüphanesidir. Görüntüler üzerinde veri büyütme işlemini gerçekleştirdikten sonra, 1350 yeni görüntü oluşturulmuştur.

4.3. Önerilen Model


Otomatik sefalometrik nokta tespiti için tıbbi veri işlemede popüler olan U-Net ağına dayalı bir ESA mimarisi tasarlanmıştır. ESA'ya giriş, tek kanallı gri tonlu bir görüntüdür. Tüm modeller daha hızlı eğitim süreleri için 256×256 boyutundaki görüntülerle eğitilmiştir. Karşılık gelen, $19 \times 256 \times 256$ hacimli nokta uzayları elde edilmiştir. Her nokta uzayı, hekim tarafından belirlenmiş dönüm noktası konumunda ortalanan sabit bir varyans ve genliğe sahip bir Gaussian içeren tek bir dönüm noktasına karşılık gelir. Modelin son adımında, her nokta konumu için varyans aynı olan bir Gauss filtresi ile birleştirilir ve maksimum aktivasyon değeri sahip nihai tahmini dönüm noktası konumu olarak seçilir. Model PyTorch (Paszke ve ark., 2017) framework'u kullanılarak geliştirilmiştir.

Model tasarımı, bazı değişikliklerle U-Net (Ronneberger ve ark., 2015) mimarisini yakından takip eder. Aşağı örnekleme (Down Sampling) yolundan ve ardından simetrik yukarı örnekleme (Up Sampling) yolundan oluşur. Bu çalışma üzerinde özelleştirilmiş U-Net mimarisinin Şekil 4.3'te gösterilmektedir.



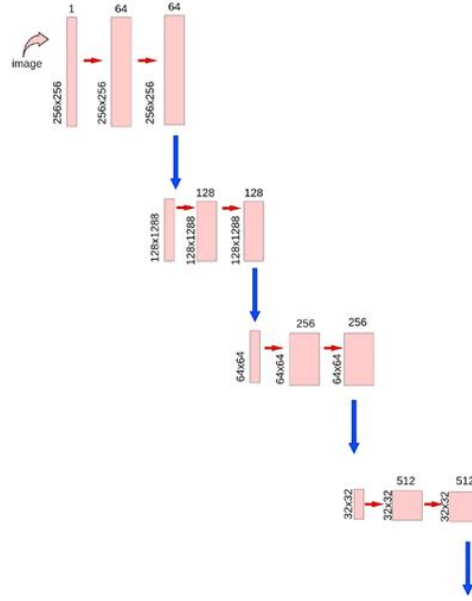
Şekil 4.3. Önerilen modelin mimarisi

Giriş görsellerinin boyutlarına aşağı örnekleme uygulanması çözünürlüğün indirgenmesini sağlar ve ağıın yer işaretlerinin göreceli konumları hakkındaki bilgileri içeren görüntü üzerinde daha fazla özellik öğrenmesini sağlar. Şekil 4.4'te gösterildiği gibi, çift evrişim katmalarından sonra bir maksimum havuzlama katmanı gelir. Giriş görüntüsünün kanal boyutu ilk olarak ağıın daha zengin özellikleri modellemesine izin veren bu çift evrişim kullanılarak genişletilir. Aşağı örneklemede her süreç iki evrişim katmanından oluşur ve bu evrişim işlemi girişte görüntünün derinliğini artırır ve kanal sayısı 1'den \rightarrow 64'e değişir.




Şekil 4.4. Önerilen modelin giriş parçası

Aşağıyı gösteren mavi ok, görüntünün boyutunu yarıya indiren maksimum havuzlama işlemidir (boyut 256x256'dan \rightarrow 128x128'e düşürülmektedir). Maksimum havuzlama katmanı, özellik haritasının çözünürlüğünü genişlik ve yükseklik boyutlarını yarıya indirir. Her aşağı örnekleme seviyesi benzer bir model izler. Tüm süreçlerde, giriş özelliği haritası bir çift evrişimden geçirilir, ilk önce kanallarının sayısını iki kat artırır ve ardından bir maksimum havuzlama katmanından geçirilir. Bu işlem Şekil 4.5'te gösterildiği gibi 3 kez tekrarlanır ve en alt noktaya ulaşır. Aşağı örnekleme yolu, 64, 128, 256, 512 ve 1024 filtre boyutlarına sahiptir.




Şekil 4.5. Önerilen modelde aşağı örnekleme

Darboğaz noktasında, Şekil 4.6’da gösterildiği gibi maksimum havuzlama katmanı olmadan 2 evrişim katmanı kullanılmıştır. Bu adımda görüntü $16 \times 16 \times 1024$ olarak yeniden boyutlandırıldı. Bu adımdan sonra model yukarı örnekleme ile devam etmektedir.




Şekil 4.6. Önerilen modelde darboğaz

Yukarı örnekleme yolu, kanal boyutunu iki katına çıkaran bir evrişimin uygulanmasından oluşur. Karşılık gelen aşağı örnekleme seviyesinden önceki özellik haritası bu sonuçla birleştirilir ve bir çift evrişimden geçirilir. En son görüntü orijinal boyutuna yükseltilecektir. Şekil 4.7’de yukarı örnekleme bir işlemi gösteriliyor.



Şekil 4.7. Önerilen modelde yukarı örnekleme

Bu işlem, yukarı örnekleme yolundaki her seviye için tekrar eder. Filtre boyutunu yarıya indiren transpoze evrişim yoluyla yukarı örnekleme yolunda orijinal 256x256 boyutunu elde edene kadar kademeli olarak artırılır. Karşılık gelen aşağı örnekleme seviyesinden özellik haritası sonuca birleştirilir ve bunu filtre boyutu alt seviyeden yukarıya doğru azalan bir çift evrişim izler (1024, 512, 256, 128 ve 64). İlk aşamada transpoze evrişimi uyguladıktan sonra görüntü 16x16x1024'tan \rightarrow 32x32x512'ye büyütülür ve ardından bu görüntü, karşılık gelen aşağı örnekleme kısmını ile birleştirilir ve birlikte 32x32x1024 boyutunda bir görüntü oluşturur. Önceki katmanlardan gelen bilgileri birleştirme amacı, daha kesin bir tahmin yapabilmektir. Aşağı örnekleme sırasında olduğu gibi, en üst düzeye ulaşmak için bu işlem 3 kez tekrarlanmıştır. En üst seviyedeki son evrişim katmanında, model tahminleri olarak dönüm noktası nokta uzayını oluşturmak için 1x1 filtreler kullanılmıştır. Şekil 4.8'de gösterildiği üzere, son adımda tahmin gereksinimleri karşılamak için görüntü yeniden şekillendirilmiştir. Son çift evrişim, tahmin nokta uzayını oluşturmak için 19 filtre uygulanmıştır.



Şekil 4.8. Önerilen modelin son katmanları

Modelin tahmin ettiği noktaların koordinatları ve gerçek koordinatları arasındaki farkı yani hatayı en küçük değerine getirmek için Adam Optimizasyon kullanıldı. Modelin ilk öğrenme hızı 10^{-3} olarak belirlendi ve ağırlık azaltma (weight decay) değeri 10^{-4} ağırlığı kullanıldı. Uygulama, 64-bit Intel® Core™ i7-9700F CPU @ 3.00GHz 3.00GHz 16.0GB RAM Bilgisayarda PyTorch (Paszke ve ark., 2017) framework'u kullanılarak geliştirildi. Eğitim için verinin 85:15 oranı kullanılarak bir eğitim ve

doğrulama oranına bölünmüştür. Eğitim için toplam 1148 görüntü doğrulama için 202 görsel kullanılmıştır. Eğitimi hızlandırmak için her evrişimin ReLU aktivasyonu uygulandıktan sonra toplu normalleştirme katmanı gelmektedir. Eğitim ve doğrulama kaybı hesaplamaları için OKH kullanılmıştır. En iyi doğrulama kaybından sonra 10 epok sonunda daha iyi bir doğrulama kaybı elde edilmediği takdirde eğitim durduruldu. Tablo 4.2’de elde edilen eğitim sonuçları, Tablo 4.3’te doğrulama sonuçları gösterilmektedir.

Tablo 4.2. Eğitim sırasında elde edilen BAO

Epok Sayısı	Eğitim Kaybı	Başarı Algılama Oranı (BAO)			
		2mm	2,5mm	3mm	4mm
1	0.1144	0.1211	0.1711	0.2077	0.2924
2	0.064	0.3875	0.5375	0.6346	0.8014
3	0.04898	0.4944	0.6503	0.7555	0.9049
4	0.04217	0.5754	0.7252	0.8227	0.9412
5	0.0373	0.6474	0.7838	0.8669	0.9629
6	0.03275	0.7052	0.8377	0.9113	0.9794
7	0.02856	0.7687	0.8853	0.9434	0.9895
8	0.02488	0.8216	0.9193	0.9637	0.9945
9	0.0214	0.8731	0.9462	0.9812	0.9971
10	0.01836	0.915	0.9676	0.9907	0.9984
11	0.01602	0.9462	0.982	0.9948	0.9986
12	0.01394	0.9662	0.9907	0.9976	0.9991
13	0.01228	0.979	0.995	0.9985	0.9991
14	0.01126	0.9843	0.9963	0.9988	0.9992
15	0.009859	0.9925	0.9985	0.999	0.9991
16	0.00915	0.9944	0.9989	0.9991	0.9992
17	0.008436	0.9961	0.9992	0.9994	0.9995
18	0.007975	0.9968	0.9994	0.9995	0.9995
19	0.007412	0.9975	0.9994	0.9995	0.9996
20	0.006833	0.9985	0.9994	0.9995	0.9996
21	0.006332	0.9984	0.9995	0.9996	0.9996
22	0.005933	0.9991	0.9995	0.9995	0.9995

Eđitim devam ederken modelin eđitim kaybı azaltılmaktadır. Eđitim verilerinin başarı algılama oranı her 4 metriklerinde artmaktadır. Doğrulama kümesinde en iyi performansa sahip model ađırlıkları kaydedilmiştir. 11'inci epoktan sonra 10 epok sonunda daha iyi bir doğrulama kaybı kaydedilmemiş ve bu noktada eđitim sonlandırılmıştır.

Tablo 4.3. Doğrulama veri seti üzerinde BAO


Epok	Dođrulama Kaybı	Başarı Algılama Oranı (BAO)			
		2mm	2,5mm	3mm	4mm
1	0.08854	0.2603	0.3762	0.4625	0.6196
2	0.05579	0.451	0.5985	0.7006	0.8656
3	0.05652	0.475	0.6269	0.723	0.8713
4	0.05534	0.4935	0.636	0.7397	0.8749
5	0.0485	0.5714	0.7183	0.7869	0.896
6	0.0533	0.5125	0.6639	0.7613	0.8825
7	0.05007	0.5745	0.7032	0.7757	0.883
8	0.04604	0.6141	0.7389	0.8101	0.9078
9	0.04756	0.6175	0.7423	0.8025	0.8927
10	0.04965	0.5925	0.7254	0.7908	0.8867
11	0.04591	0.6258	0.7465	0.8166	0.8999
12	0.04705	0.6144	0.74	0.8111	0.8947
13	0.0478	0.6266	0.7421	0.8025	0.8874
14	0.04719	0.6277	0.7449	0.8153	0.895
15	0.04721	0.6258	0.7478	0.8111	0.8986
16	0.04751	0.6295	0.753	0.815	0.9018
17	0.04818	0.6152	0.7491	0.8137	0.8953
18	0.04854	0.6261	0.7546	0.8142	0.8932
19	0.04732	0.6316	0.7574	0.8124	0.8947
20	0.04692	0.6449	0.7613	0.8134	0.8979
21	0.04821	0.6347	0.7592	0.8184	0.8973
22	0.04773	0.6371	0.7561	0.8103	0.8942

Bu alanda yüksek doğrulukla sefalometrik noktaları tespit etmiş çalışmalar ile modelimizi karşılaştırabilmek için önerilen model kullanılarak ortaya çıkan sonuçları 2015 IEEE Biyomedikal Sefalometrik yarışmasında belirlenen sefalometrik değerlendirme metrikleri kullanarak değerlendirilmiştir. Önerilen model ile test1 veri seti üzerinde değerlendirmeler yapılmıştır. Yarışmada verilen eğitim1 verisetinde bulunan 150 örnek ve veri artırma işleminden sonra elde edilen 1350 örnek ile eğitim yapılmış sonuçlar karşılaştırılmıştır. Tablo 4.4'te eğitim süreci tamamladıktan sonra modelin test1 veri seti üzerinde başarısı hesaplanmıştır. Veri artırma yaptıktan sonra modelden daha başarılı sonuçlara ulaşılmıştır. 2 mm aralığında 74,0%, 2,5 mm aralığında ise 81,4%, 3 mm aralığında 86,3% ve 4 mm aralığında 92,2% BAO elde edilmiştir.

Tablo 4.4. Veri artırmadan önce ve sonra elde edilen başarılı sonuçları

Veri seti	Başarı Algılama Oranı - BAO (%)			
	2 mm	2.5 mm	3 mm	4 mm
Veri artırımı yapılmadan önce	69.37	78.0	84.6	91.12
Veri artırımı yapıldıktan sonra	74.0	81.4	86.3	92.2

Veri artırma işleminden sonra çıkan sonuçları yarışmada belirlenen sefalometrik değerlendirme metrikleri kullanarak ISBI 2015 Challenge yarışmasına katılıp çalışmalarını kabul edilmiş diğer araştırmacılarının (Ibragimov ve ark., 2015; Lindner ve Cootes, 2015) sonuçlarıyla karşılaştırılmıştır. Şekil 4.9'da önerilen model ile verileri kullanarak elde edilen sonuçlar, aynı veri kümesine dayalı olarak diğer çalışmalar tarafından bulunan sonuçlar gösterilmektedir.



Şekil 4.9. ISBI 2015 yarışmasına katılan yarışmacıların BAO sonuç karşılaştırması.

Ibragimov ve ark. tarafından önerilen yaklaşımla 2mm aralığında %71.7, 2.5mm'de %77.4, 3mm'de %81.9 ve 4mm aralığında %88'lik bir BAO elde etmiştir (Ibragimov ve ark., 2015). Lindner ve ark. tarafından önerilen yöntem 2 mm aralığında %73.7, 2.5 mm aralığında %80.2, 3 mm aralığında %85.2 ve 4 mm aralığında %91.5 elde etmiştir (Lindner ve Cootes, 2015). Önerilen yöntem, tüm değerlendirme metriklerinde daha iyi sonuçlar vermektedir.


Tablo 4.5'te Test1 veri setinde bulunan örneklerin L1'den L19'a olan tüm noktalarının tespit sonuçlarının 2.0mm, 2.5mm, 3.0mm ve 4.0mm hassasiyet aralıkları için ortalama başarı algılama oranları verilmiştir.

Tablo 4.5. Sefalometrik Noktalara göre BAO

Sefalometrik Noktaları		BAO			
		2.0 mm	2.5 mm	3.0 mm	4.0 mm
L1	Sella	0.82	0.8833	0.9267	0.98
L2	Nasion	0.7267	0.7633	0.7933	0.8667
L3	Orbitale	0.6267	0.84	0.8867	0.92
L4	Porion	0.5567	0.6267	0.6867	0.7967
L5	Subspinale	0.58	0.6833	0.7933	0.8933
L6	Supramentale	0.7267	0.7833	0.81	0.9067
L7	Pogonion	0.8067	0.86	0.94	0.9933
L8	Menton	0.8267	0.92	0.94	0.9867
L9	Gnathion	0.9267	0.9467	0.9733	0.9933
L10	Gonion	0.4467	0.5467	0.6833	0.69
L11	Incision Inferius	0.8333	0.9267	0.9667	0.9933
L12	Incision Superius	0.9133	0.9533	0.98	0.9933
L13	Upper Lip	0.8067	0.8667	0.9133	0.9733
L14	Lower Lip	0.9267	0.9533	0.98	1.0
L15	Subnasale	0.7267	0.86	0.9067	0.96
L16	Soft tissue pogonion	0.7667	0.8067	0.8567	0.8967
L17	Posterior nasal spine	0.8333	0.88	0.9067	0.9733
L18	Anterior nasal spine	0.7033	0.7533	0.7867	0.88
L19	Articulare	0.5133	0.62	0.6667	0.7967

Bazı sefalometrik noktalar yüksek doğrulukla tespit edilirken, bazıları daha düşük doğruluk ile tespit edilmiştir. Tablo 4.5'e bakıldığında elde edilen sonuçlardan 2mm aralığında en başarılı tespit edilen noktalar L9 (Gnathion) ile L14 (Lower Lip)'dir, ikisi de 92.67% BAO ile elde edilmiştir. En başarısız nokta ise L19 (Articulare), 51.33% BAO ile tespit edilmiştir.

Şekil 4.10'da Test1 setinden seçilen örnek bir görselin sefolametric noktalarının tespiti gösterilmiştir. Tespit edilen noktalar 1935x2400 orijinal boyutu üzerinde yerleştirilmiştir



Şekil 4.10. Test1 veri setinden seçilmiş bir örnek üzerinde orijinal sefalometrik noktaların (kırmızı) ve model ile tahmin edilen noktaların (yeşil) gösterimi

Şkil 4.10'da sunulan görsellerde kırmızı noktalar gerçek noktaları, yeşil noktalar model kullanarak tahmin edilen noktaları göstermektedir. Bu görüntüden 2mm aralığında 78.95%, 2.5mm 84.21%, 3mm aralığında ise 89.47% ve 4mm aralığında 100% BAO elde edilmiştir.

5. SONUÇLAR VE ÖNERİLER

Sefalometri, ortodontide önemli bir klinik ve araştırma aracıdır. Kraniofasial iskeletin mutlak ve göreceli ölçümlerini elde etmek için uzun yıllardır kullanılmaktadır. Anatomik yer işaretlerinin tanımlanması zor ve zaman alıcı bir işlem olmasından dolayı otomatik yöntemler araştırılmaktadır. Sefalometrik yer işaretlerini otomatik olarak bulma üzerine araştırmacılar farklı yöntemler kullanarak çalışmalar yapmıştır. (Arik ve ark., 2017; Lee ve ark., 2017; Goutham ve ark., 2019; Qian ve ark., 2019; Drevický ve Kodym, 2020; Juneja ve ark., 2021). Klinik ortamlarda var olan çözümler kullanılarak karşılaşılan problemlerden dolayı yeni çalışmalara gereksinim vardır. Bu çalışmada otomatik olarak tespit edilen sefalometrik yer işaretlerinin doğruluğunu ve güvenilirliğini geliştirmek amaçlanmıştır. Özelleştirilmiş bir U-net modeli kullanarak nokta tespitini otomatik yapılmıştır.

Bu çalışmayı gerçekleştirebilmek için IEEE 2015 Uluslararası Biyomedikal Görüntüleme Sempozyumu (ISBI 2015) kapsamında sunulan sefalometrik veri kümesi kullanılmıştır. Eğitim veri setine veri artırma uygulanmış ve başarılı bir şekilde toplam 1350 yeni görüntü oluşturulmuştur. Tüm modeller, daha hızlı eğitim ve daha kolay deneyler sağlamak için, görüntülerinin boyutları 1935x2400'tan 256x256'ya indirilmiş ve eğitim yapılmıştır. Eğitilen modelle toplam 19 Sefalometrik nokta otomatik tespit edilmiştir. ISBI 2015 kapsamında sunulan test1 verisi kullanılarak başarı ölçülmüştür. 2 mm aralığında 74,0% BAO, 2,5 mm aralığında 81,4%, 3 mm aralığında 86,3% ve 4mm aralığında ise 92,2% BAO elde edilmiştir.

Ortodonti ve ortopedi bölümlerinde sefalometrik nokta tespiti kullanılmaktadır. Oral ve maksillofasial cerrahi alanlarda değerlendirme ve kraniofasial büyüme tahmini, tedavi planı, küratif etkisini değerlendirme ve farklı olguları karşılaştırmak için sefalometrik noktalar kullanılabilir. Önerilen yaklaşımla, klinik ortamlarda sefalometrik analiz yükünü azaltmak ve yorgunluk gibi nedenlerden kaynaklı insanların hatalarını gidermek amaçlanmaktadır. Daha fazla görüntüden oluşan veri setleri kullanmak DÖ başarısını arttırmaktadır. İlerleyen çalışmalarda daha büyük veri setleri kullanarak otomatik sefalometrik noktaları tespit etmek ve bu noktaları kullanıp otomatik sefalometrik analizler yapmak planlanmaktadır.

KAYNAKLAR

- Arik, S. Ö., Ibragimov, B. ve Xing, L., 2017, Fully automated quantitative cephalometry using convolutional neural networks, *Journal of Medical Imaging*, 4 (1), 014501.
- Athanasiou, A., 1995, *Orthodontic Cephalometry*. London: Mosby-Wolfe.
- Bengio, Y., 2012, Practical recommendations for gradient-based training of deep architectures, In: *Neural networks: Tricks of the trade*, Eds: Springer, p. 437-478.
- Breiman, L., 2001, Random forests, *Machine learning*, 45 (1), 5-32.
- Cardillo, J. ve Sid-Ahmed, M. A., 1994a, An image processing system for locating craniofacial landmarks, *IEEE transactions on medical imaging*, 13 (2), 275-289.
- Cardillo, J. ve Sid-Ahmed, M. A. J. I. t. o. m. i., 1994b, An image processing system for locating craniofacial landmarks, 13 (2), 275-289.
- Chakrabartty, S., Yagi, M., Shibata, T. ve Cauwenberghs, G., 2003, Robust cephalometric identification using support vector machines, *Conference proceedings: ICME*, 6-9.
- Doff, M., Hoekema, A., Pruijm, G., Van Der HOEVEN, J., De Bont, L. ve Stegenga, B. J. J. o. O. R., 2009, Effects of a mandibular advancement device on the upper airway morphology: a cephalometric analysis, 36 (5), 330-337.
- Drevický, D. ve Kodým, O., 2020, Evaluating Deep Learning Uncertainty Measures in Cephalometric Landmark Localization, *BIOIMAGING*, 213-220.
- Esteva, A., Kuprel, B., Novoa, R. A., Ko, J., Swetter, S. M., Blau, H. M. ve Thrun, S., 2017, Dermatologist-level classification of skin cancer with deep neural networks, *nature*, 542 (7639), 115-118.
- Fei-Fei Li, Danfei Xu, Ranjay Krishna ve Byun, A., 2020, CS231n Convolutional Neural Networks for Visual Recognition.
- Goodfellow, I., Bengio, Y., Courville, A. ve Bengio, Y., 2016, *Deep learning*, MIT press Cambridge, p.
- Goutham, E., Vasamsetti, S., Kishore, P. ve Sardana, H. K., 2019, Automatic Localization of Landmarks in Cephalometric Images via Modified U-Net, *2019 10th international conference on computing, Communication and Networking Technologies (ICCCNT)*, 1-6.
- Greenspan, H., Van Ginneken, B. ve Summers, R. M., 2016, Guest editorial deep learning in medical imaging: Overview and future promise of an exciting new technique, *IEEE transactions on medical imaging*, 35 (5), 1153-1159.
- Hao, Z., 2017, *Activation Functions in Neural Networks*, Singapore.
- Ibragimov, B., Likar, B., Pernus, F. ve Vrtovec, T., 2015, Computerized cephalometry by game theory with shape-and appearance-based landmark refinement, *Proceedings of International Symposium on Biomedical imaging (ISBI)*.
- Juneja, M., Garg, P., Kaur, R., Manocha, P., Batra, S., Singh, P., Singh, S., Jindal, P. J. B. S. P. ve Control, 2021, A review on cephalometric landmark detection techniques, 66, 102486.
- Jung, A. B., 2018, *Imgaug - Image augmentation in machine learning experiments*, Online; accessed 30-Oct-2018; <https://imgaug.readthedocs.io/>.
- Kohavi, R., 1995, A study of cross-validation and bootstrap for accuracy estimation and model selection, *Ijcai*, 1137-1145.
- Krzyk, K., 2018, *Coding Deep Learning For Beginners, Towards Data Science*.
- Lee, H., Park, M. ve Kim, J., 2017, Cephalometric landmark detection in dental x-ray images using convolutional neural networks, *Medical Imaging 2017: Computer-Aided Diagnosis*, 101341W.

- Lindner, C. ve Cootes, T. F., 2015, Fully automatic cephalometric evaluation using random forest regression-voting, *IEEE International Symposium on Biomedical Imaging*.
- Lindner, C., Wang, C.-W., Huang, C.-T., Li, C.-H., Chang, S.-W. ve Cootes, T. F., 2016, Fully automatic system for accurate localisation and analysis of cephalometric landmarks in lateral cephalograms, *Scientific reports*, 6, 33581.
- Litjens, G., Kooi, T., Bejnordi, B. E., Setio, A. A. A., Ciompi, F., Ghafoorian, M., Van Der Laak, J. A., Van Ginneken, B. ve Sánchez, C. I., 2017, A survey on deep learning in medical image analysis, *Medical image analysis*, 42, 60-88.
- Lo, S.-C. B., Lin, J.-S., Freedman, M. T. ve Mun, S. K., 1993, Computer-assisted diagnosis of lung nodule detection using artificial convolution neural network, *Medical Imaging 1993: Image Processing*, 859-869.
- Long, J., Shelhamer, E. ve Darrell, T., 2015, Fully convolutional networks for semantic segmentation, *Proceedings of the IEEE conference on computer vision and pattern recognition*, 3431-3440.
- Malkoçoğlu, A. B. V., 2020, Akut Lenfoblastik Lösemi Hücrelerinin Derin Öğrenme Yöntemleri ile Sınıflandırılması, *T.C. Ondokuz Mayıs Üniversitesi Lisansüstü Eğitim Enstitüsü*.
- Nielsen, M. A., 2015, Neural networks and deep learning, Determination press San Francisco, CA, p.
- Osisanwo, F., Akinsola, J., Awodele, O., Hinmikaiye, J., Olakanmi, O., Akinjobi, J. J. I. J. o. C. T. ve Technology, 2017, Supervised machine learning algorithms: classification and comparison, 48 (3), 128-138.
- Özkan, İ. ve Ülker, E., 2017, Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri, *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, 6 (3), 85-104.
- Paszke, A., Gross, S., Chintala, S., Chanan, G., Yang, E., DeVito, Z., Lin, Z., Desmaison, A., Antiga, L. ve Lerer, A., 2017, Automatic differentiation in pytorch.
- Phulari, B., 2013, An atlas on cephalometric landmarks, JP Medical Ltd, p.
- Prasad, A., 2019, The Bias-Variance trade-off : Explanation and Demo, *Towards Data Science*.
- Price, W. A. J. T. D. R., 1900, The Roentgen rays with associated phenomena and their applications in dentistry, 54 (2), 84.
- Qian, J., Cheng, M., Tao, Y., Lin, J. ve Lin, H., 2019, CephaNet: An Improved Faster R-CNN for Cephalometric Landmark Detection, *2019 IEEE 16th International Symposium on Biomedical Imaging (ISBI 2019)*, 868-871.
- Rajpurkar, P., Irvin, J., Zhu, K., Yang, B., Mehta, H., Duan, T., Ding, D., Bagul, A., Langlotz, C. ve Shpanskaya, K., 2017, Chexnet: Radiologist-level pneumonia detection on chest x-rays with deep learning, *arXiv preprint arXiv:1711.05225*.
- Rakosi, T., 1982, An atlas and manual of cephalometric radiography.
- Rende, F. Ş., Bütün, G., Karahan, Ş., Enstitüsü, B. T. ve TÜBİTAK BİLGEM, G., 2016, Derin Öğrenme Algoritmalarında Model Testleri: Derin Testler, Bilişim Teknolojileri Enstitüsü, TÜBİTAK BİLGEM.
- Ronneberger, O., Fischer, P. ve Brox, T., 2015, U-net: Convolutional networks for biomedical image segmentation, *International Conference on Medical image computing and computer-assisted intervention*, 234-241.
- Ruder, S. J. p. a., 2018, An overview of gradient descent optimization algorithms., 2016.
- Schmidhuber, J. J. N. n., 2015, Deep learning in neural networks: An overview, 61, 85-117.

- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I. ve Salakhutdinov, R. J. T. j. o. m. l. r., 2014, Dropout: a simple way to prevent neural networks from overfitting, 15 (1), 1929-1958.
- Vučinić, P., Trpovski, Ž. ve Šćepan, I. J. T. E. J. o. O., 2010, Automatic landmarking of cephalograms using active appearance models, 32 (3), 233-241.
- Wang, C.-W., Huang, C.-T., Hsieh, M.-C., Li, C.-H., Chang, S.-W., Li, W.-C., Vandaele, R., Marée, R., Jodogne, S. ve Geurts, P. J. I. t. o. m. i., 2015, Evaluation and comparison of anatomical landmark detection methods for cephalometric x-ray images: a grand challenge, 34 (9), 1890-1900.
- Wang, C.-W., Huang, C.-T., Lee, J.-H., Li, C.-H., Chang, S.-W., Siao, M.-J., Lai, T.-M., Ibragimov, B., Vrtovec, T. ve Ronneberger, O., 2016, A benchmark for comparison of dental radiography analysis algorithms, *Medical image analysis*, 31, 63-76.
- Wu, Y. ve Razavi, R. J. P. A., Santa Barbara, 2015, An Introduction to deep learning: examining the advantages of hierarchical learning.
- Yue, W., Yin, D., Li, C., Wang, G. ve Xu, T., 2006, Automated 2-D cephalometric analysis on X-ray images by a model-based approach, *IEEE transactions on biomedical engineering*, 53 (8), 1615-1623.
- Yüksek, A. G., Bircan, H., Zontul, M. ve Kaynar, O., 2007, Sivas İlinde Yapay Sinir Ağları İle Hava Kalitesi Modelinin Oluşturulması Üzerine Bir Uygulama.