



**TARAMALI ELEKTRON MİKROSKOBU
GÖRÜNTÜLERİ ÜZERİNDEN DENTİN
TÜBÜLLERİNİN DERİN ÖĞRENMEYE DAYALI
ANALİZİ**

**2023
DOKTORA TEZİ
BİLGİSAYAR MÜHENDİSLİĞİ**

Anday DURU

**Tez Danışmanı
Prof. Dr. İsmail Rakıp KARAŞ**

**TARAMALI ELEKTRON MİKROSKOBU GÖRÜNTÜLERİ ÜZERİNDEN
DENTİN TÜBÜLLERİNİN DERİN ÖĞRENMEYE DAYALI ANALİZİ**

Anday DURU

**Tez Danışmanı
Prof. Dr. İsmail Rakıp KARAŞ**

**T.C.
Karabük Üniversitesi
Lisansüstü Eğitim Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalında
Doktora Tezi
Olarak Hazırlanmıştır**

**KARABÜK
Kasım 2023**

Anday DURU tarafından hazırlanan “TARAMALI ELEKTRON MİKROSKOBU GÖRÜNTÜLERİ ÜZERİNDEN DENTİN TUBÜLLERİNİN DERİN ÖĞRENMEYE DAYALI ANALİZİ” başlıklı bu tezin Doktora Tezi olarak uygun olduğunu onaylarım.

Prof. Dr. İsmail Rakıp KARAŞ

.....

Tez Danışmanı, Bilgisayar Mühendisliği Anabilim Dalı

Bu çalışma, jürimiz tarafından Oy Birliği ile Bilgisayar Mühendisliği Anabilim Dalında Doktora tezi olarak kabul edilmiştir. 10/11/2023

Ünvanı, Adı SOYADI (Kurumu)

İmzası

Başkan : Prof. Dr. Ergin YILMAZ (BEUN)

.....

Üye : Prof. Dr. İsmail Rakıp KARAŞ (KBÜ)

.....

Üye : Doç. Dr. M. Kamil TURAN (KBÜ)

.....

Üye : Doç. Dr. Ümit ATILA (GÜ)

.....

Üye : Doç. Dr. Fatih KARAYÜREK (KBÜ)

.....

KBÜ Lisansüstü Eğitim Enstitüsü Yönetim Kurulu, bu tez ile, Doktora derecesini onamıştır.

Doç. Dr. Zeynep ÖZCAN

.....

Lisansüstü Eğitim Enstitüsü Müdürü

“Bu tezdeki tüm bilgilerin akademik kurallara ve etik ilkelere uygun olarak elde edildiğini ve sunulduğunu; ayrıca bu kuralların ve ilkelerin gerektirdiği şekilde, bu çalışmadan kaynaklanmayan bütün atıfları yaptığımı beyan ederim.”

Anday DURU

ÖZET

Doktora Tezi

TARAMALI ELEKTRON MİKROSKOBU GÖRÜNTÜLERİ ÜZERİNDEN DENTİN TÜBÜLLERİNİN DERİN ÖĞRENMEYE DAYALI ANALİZİ

Anday DURU

Karabük Üniversitesi

Lisansüstü Eğitim Enstitüsü

Bilgisayar Mühendisliği Anabilim Dalı

Tez Danışmanı:

Prof. Dr. İsmail Rakıp KARAŞ

Kasım 2023, 97 sayfa

Dişler sindirim sisteminin başlangıcında yer alan ve yiyeceklerin fiziksel sindirimini başlatan vücudumuzun önemli bir parçasıdır. Ayrıca, insanın sosyal ve profesyonel hayatında da etkinliği büyüktür. Dişlerde yaşanan olumsuzluk doğrudan hayat kalitesini etkilemekte ve sağlık açısından problem oluşturabilmektedir. Diş hassasiyeti yaygın bir ağız sağlığı problemi ve dentin tabakasının açığa çıkmasından kaynaklanan ağrı olarak kabul edilmektedir. Önleme ve tedavi açısından diş hassasiyeti üzerine yapılan araştırmalar, dentin tübüllerinin durumuyla doğrudan ilişkilidir ve tübül tıkanıklıkları üzerine yapılan incelemeler bu konuda büyük önem taşımaktadır. Dentin tübül tıkanıklıkları taramalı elektron mikroskopu görüntüleri üzerinden de değerlendirilebilir ve her bir dentin tübülünün manuel olarak değerlendirilmesini gerektirir. Bu nedenle sonuçlar büyük ölçüde incelemeyi yapan kişiye göre değişebilmektedir. Bu araştırma alanı, daha güvenilir ve tekrarlanabilir sonuçlar üretmek için farklı ve etkili yöntemlere ihtiyaç duymaktadır.

Bu çalışmada, dentin tbl tıkanıklıklarının gvenilir bir şekilde llmesi iin yapay zeka destekli sinir ađı modeli nerildi. Etik kurul izni ve diřlerin temin edilmesinin ardından elde edilen doksan altı diř rneđi kesildi ve dentin diskler ıkarıldı. Dentin tbllerini farklı seviyelerde doldurmak iin eřitli duyarsızlařtırıcı ajanlar kullanıldı. Diřler grntlemeye hazır hale getirilip, taramalı elektron mikroskop ile grntler elde edilmiřtir. Bu grntler 48 x 48 znrlkte ve 2795 adet dentin tbl grntsn iermektedir. Grntlerdeki tbller alanında uzman kiřiler tarafından beř kategori altında etiketlenmiřtir ve deđerlendiriciler arası gvenilirliđi lmek iin Cohen's Kappa testi uygulanmıřtır. Daha bařarılı eđitim gerekleřtirmek iin iin veri artırma teknikleri yalnızca eđitim veri setine uygulanmıřtır. Beř sınıfa ait toplam 10700 grnt ieren artırılmıř veri, ađın eđitim veri kmesi olarak kullanılmıřtır. nerilen konvolsyonel sinir ađı, dentin tbl oklzyonlarının derecesini %89.76 genel dođruluk oranıyla beř sınıfa ayırabilmiřtir. Ayrıca, oluřturulan modelin sonuları gncel modellerle karřılařtırılmıř ve tartıřılmıřtır. Bu tezde dentin tbllerinin tespitinin yanısıra taramalı elektron mikroskop ile grntlenen dentin tbl oklzyonlarının seviyesini tespit etmek iin konvolsyonel sinir ađlarının kullanılmasına odaklanılmıřtır. Sonular, nerilen konvolsyonel sinir ađı mimarisinin son derece bařarılı bir alternatif olduđunu ve segmente edilmiř dentin tbl grntlerinin objektif ve otomatik sınıflandırılmasına izin verdiđini gstermektedir.

Anahtar Szckler : Derin đrenme, yapay zeka, taramalı elektron mikroskobu, diř hassasiyeti, dentin tblleri.

Bilim Kodu : 92432

ABSTRACT

Ph. D. Thesis

DEEP LEARNING BASED ANALYSIS OF DENTIN TUBULES FROM SCANNING ELECTRON MICROSCOPE IMAGES

Anday DURU

**Karabük University
Institute of Graduate Programs
Department of Computer Engineering**

Thesis Advisor:

Prof. Dr. İsmail Rakıp KARAŞ

November 2023, 97 pages

Teeth are an important part of our body that are located at the beginning of the digestive system and initiate the physical digestion of food. Additionally, they play a significant role in a person's social and professional life. Negative changes in teeth can directly affect quality of life and lead to health problems. Tooth sensitivity is a common oral health problem and is considered pain caused by the exposure of the dentin layer. Research on prevention and treatment of tooth sensitivity is directly related to the condition of dentin tubules, and investigations of tubular blockages are of great importance. Dentin tubule blockages can be evaluated through scanning electron microscope images, which require manual evaluation of each dentin tubule. Therefore, results can vary greatly depending on the person performing the examination. This research field requires different and effective methods to produce more reliable and repeatable results. In this study, an artificial intelligence-supported neural network model was proposed for the reliable measurement of dentin tubule

blockages. After obtaining ethical approval and procuring teeth, ninety-six tooth samples were sectioned and dentin discs were removed. Various desensitizing agents were used to fill the dentin tubules at different levels. The teeth were prepared for imaging, and images were obtained using scanning electron microscopy. These images have a resolution of 48 x 48 and contain 2795 images of dentin tubules. The tubules in the images were labeled under five categories by experts in the field, and the Cohen's Kappa test was applied to measure inter-rater reliability. Data augmentation techniques were applied only to the training data set to achieve better training. The augmented data set contained a total of 10700 images for the five classes and was used as the training data set. The proposed convolutional neural network was able to classify the degree of dentin tubule occlusion into five classes with an overall accuracy rate of 89.76%. Additionally, the results of the created model were compared and discussed with current models. This thesis focused on the use of convolutional neural networks to detect dentin tubules and determine the level of dentin tubule occlusion observed in scanning electron microscopy images. The results show that the proposed convolutional neural network architecture is an extremely successful alternative and allows for objective and automatic classification of segmented dentin tubule images.

Key Word : Deep learning, artificial intelligence, scanning electron microscope, dentine hypersensitivity, dentinal tubules.

Science Code : 92432

TEŐEKKÜR

Bu tez alıřmasının planlanmasında, arařtırılmasında, yrtlmesinde ve oluřumunda ilgi ve desteęini esirgemeyen, engin bilgi ve tecrbelerinden yararlandığım, ynlendirme ve bilgilendirmeleriyle alıřmamı bilimsel temeller ıřığında Őekillendiren sayın hocam Prof. Dr. İsmail Rakıp KARAAŐ'a sonsuz teŐekkrlerimi sunarım.

alıřmanın bařlangıcından itibaren bilgi birikimiyle, tezimin izleme ařamasında ve deney srecinde katkı saęlayan Do. Dr. Fatih KARAYREK'e, sunduęu deęerli bilgi ve akademik katkılarıyla Do. Dr. M. Kamil TURAN ve Dr. ęr. yesi Eftl ŐEHİRLİ'ye, derin ęrenme konusuna ilgi duymamı saęlayan ve deęerli bilgilerini paylařan Do. Dr. mit ATİLA'ya teŐekkr ederim.

Sevgili aileme tm destekleri ve manevi hibir yardımı esirgemedен yanımda oldukları iin tm kalbimle teŐekkr ederim.

Bu tez alıřması TBİTAK 2211-C Yurt İi ncelikli Alanlar Doktora Burs Programı kapsamında desteklenmiřtir. Desteklerinden dolayı TBİTAK'a teŐekkr ederim.

İÇİNDEKİLER

	<u>Sayfa</u>
KABUL.....	ii
ÖZET.....	iv
ABSTRACT.....	vi
TEŞEKKÜR.....	viii
İÇİNDEKİLER	ix
ŞEKİLLER DİZİNİ.....	xii
ÇİZELGELER DİZİNİ	xiv
SİMGELER VE KISALTMALAR DİZİNİ	xv
BÖLÜM 1	1
GİRİŞ	1
1.1 TEZİN TANIMI	1
1.2. TEZİN AMACI	2
1.3. ÖZGÜN DEĞER.....	3
1.4. TEZ ORGANİZASYONU	4
BÖLÜM 2	6
LİTERATÜR ARAŞTIRMASI	6
2.1. DENTİN HASSASİYETİNİN ÖNLENMESİ.....	6
2.2. DENTİN TÜBÜLLERİ VE GÖRÜNTÜ İŞLEME.....	8
BÖLÜM 3	12
DİŞLER.....	12
3.1. DİŞLERİN İNSAN VÜCUDUNDAKİ ÖNEMİ	12
3.2. DİŞLERİN YAPISI.....	13
3.3. DENTİN HASSASİYETİ	13
BÖLÜM 4	15

	<u>Sayfa</u>
MAKİNE ÖĞRENMESİ	15
4.1. MAKİNE ÖĞRENİMİ YAKLAŞIMLARI.....	18
4.1.1 Konvolüsyonel Sinir Ağları	28
4.1.1.1. Konvolüsyonel Sinir Ağlarının Elemanları	31
4.1.1.2 Konvolüsyon Ağlarının Eğitim Süreci.....	45
4.1.1.3 Konvolüsyon Ağ Katmanlarının Görselleştirilmesi.....	47
4.1.1.4 Hiperparametreler	50
4.1.1.5 Konvolüsyonel Sinir Ağ Yöntemlerine Dayalı Modeller	54
4.1.2 Sınıflandırma Modellerinde Başarı Kriterleri.....	56
4.2. TRANSFER ÖĞRENME.....	59
BÖLÜM 5	62
MATERYAL	62
5.1. DENTİN TÜBÜL GÖRÜNTÜLERİNİN ALINMASI.....	62
5.1.1. Dişlerden Dentin Disklerin Çıkarılması	62
5.1.2. Duyarsızlaştırıcı Ajanların Dentin Disklere Uygulanması.....	64
5.1.3. Taramalı Elektron Mikroskobu Görüntülerinin Alınması	65
BÖLÜM 6	69
METOT.....	69
6.1 VERİ SETİ.....	69
6.2 VERİ ARTIRMA	70
6.3 ÖNERİLEN CNN MİMARİSİ.....	71
BÖLÜM 7	76
DENEYSEL SONUÇLAR VE TARTIŞMA.....	76
7.1. ÖNERİLEN CNN MODELİ.....	76
7.2. TRANSFER ÖĞRENME.....	80
7.3. TARTIŞMA.....	81
BÖLÜM 8	84
SONUÇLAR VE DEĞERLENDİRMELER	84

	<u>Sayfa</u>
KAYNAKLAR	86
ÖZGEÇMİŞ	97

ŞEKİLLER DİZİNİ

Sayfa

Şekil 3.1. Yetişkin insanın azı dişi kesiti.....	13
Şekil 3.2. Dentin tübüllerinin örnek SEM görüntüleri	14
Şekil 4.1. Yapay zekanın barındırdığı birimler	18
Şekil 4.2. Makine öğrenimi yaklaşımlarının gruplandırılması.....	19
Şekil 4.3. Danışmanlı öğrenme modeline genel bakış	20
Şekil 4.4. Örnek SVM.....	22
Şekil 4.5. Örnek RF.....	23
Şekil 4.6. Örnek MLP.....	23
Şekil 4.7. Danışmansız öğrenme modeline genel bakış.....	25
Şekil 4.8. Takviyeli öğrenme modeline genel bakış.....	26
Şekil 4.9. Mevcut verilerin geleneksel makine öğrenimi algoritmalarının performansı üzerindeki etkisini gösteren grafik.....	27
Şekil 4.10. Biyolojik sinir ağı örneği.....	29
Şekil 4.11. Görselin matris formundaki hali.....	32
Şekil 4.12. Konvolüsyon için gerekli görüntü ve filtre matrisleri.....	32
Şekil 4.13. Konvolüsyon işlemi örneği	33
Şekil 4.14. Bir deve görüntüsü üzerinden filtrelerle çeşitli özelliklerin çıkarımı	34
Şekil 4.15. CNN ile özellik haritalarının çıkarılması	35
Şekil 4.16. Özellik haritasının derinliği.....	36
Şekil 4.17. Matris üzerinde yapılan sıfır doldurma işlemi	36
Şekil 4.18. Maksimum havuzlama işleminin matris üzerinde oluşturduğu çıktı	37
Şekil 4.19. Maksimum havuzlamanın görüntü matrisi üzerinde ortaya çıkardığı değişiklik	37
Şekil 4.20. Nöron model yapısı	38
Şekil 4.21. Lineer aktivasyon fonksiyonu	39
Şekil 4.22. İkili adım aktivasyon fonksiyonu.....	39
Şekil 4.23. Sigmoid aktivasyon fonksiyonu	40
Şekil 4.24. Hiperbolik tanjant fonksiyonu.....	41
Şekil 4.25. ReLU aktivasyon fonksiyonu.....	41
Şekil 4.26. Leaky ReLU aktivasyon fonksiyonu.....	44

Sayfa

Şekil 4.27. Sınıflandırma katmanı	45
Şekil 4.28. Görüntünün konvolüsyon ağında izlediği süreç	46
Şekil 4.29. Konvolüsyonel nöral ağdan öğrenilen özellikler	48
Şekil 4.30. Konvolüsyonel sinir ağı tarafından öğrenilen özellik haritalarına dair görseller	48
Şekil 4.31. El yazısı rakamlarla eğitilmiş bir ConvNet'i görselleştirme	49
Şekil 4.32. Havuzlama işlemini görselleştirme	49
Şekil 5.1. Dentin disklerin Struers Secotom50 kesme cihazı ile dıştan çıkarılması	63
Şekil 5.2. Struers Tegramin-30 zımparalama ve parlatma cihazı	63
Şekil 5.3. Ultrasonik temizleyici	64
Şekil 5.4. Metalografik işlemlerin ardından çıkarılan dentin disk	64
Şekil 5.5. Q150R Rotary-Pumped spuetter coater (kaplama cihazı)	65
Şekil 5.6. Kaplama yapıldıktan sonra dentin disklerin görüntüsü	66
Şekil 5.7. Carl Zeiss Ultra Plus Gemini FE-SEM cihazı	66
Şekil 5.8. Dentin tübüllerinin örnek SEM görüntüsü	67
Şekil 5.9. Dentin tübüllerinin örnek SEM görüntüsü	67
Şekil 5.10. Dentin tübüllerinin örnek SEM görüntüsü	68
Şekil 5.11. Dentin tübüllerinin örnek SEM görüntüsü	68
Şekil 6.1. Veri artırma işleminden sonra oluşturulan örnek görüntüler.	70
Şekil 6.2. Önerilen CNN mimarisi katmanları	73
Şekil 7.1. K-fold çapraz doğrulama sonucu her devirde elde edilen doğruluk grafiği	78
Şekil 7.2. Doğruluk ve kayıp eğrileri	78
Şekil 7.3. Normalize edilmiş ve edilmemiş konfüzyon matrisleri	79
Şekil 7.4. TL ve FT tekniklerinin verisetimiz üzerinde uygulama aşamaları.	80
Şekil 7.5. TL ve FT yöntemleri ile elde edilen sonuçlar	81

ÇİZELGELER DİZİNİ

	<u>Sayfa</u>
Çizelge 4.1. Hiperparametre Optimizasyon Teknikleri	52
Çizelge 4.2. Hata Matrisi Elemanları – L2	57
Çizelge 6.1. Üretilen veri setinin özellikleri.	70
Çizelge 6.2. 48x48 gri skala görüntülerin kullanıldığı önerilen CNN mimarisi	72
Çizelge 7.1. Optimum hiperparametreleri bulmak için kullanılan GS algoritması ...	76
Çizelge 7.2. GS kullanılarak elde edilen optimum hiperparametre değerleri	77
Çizelge 7.3. Test verisinin sınıflandırma sonuçları.....	79

SİMGELER VE KISALTMALAR DİZİNİ

SİMGELER

N	: Sınıf sayısı
M	: Molar
θ	: kutupsal açı
σ	: Sigmoid fonksiyonu
NaCl	: Sodyum Klorür
SiC	: Silisyum Karbür
C ₆ H ₈ O ₇	: Sitrik Asit

KISALTMALAR

- CNN : Konvolüsyonel Sinir Ağları
SEM : Taramalı elektron mikroskobu
ML : Makine öğrenmesi
NN : Nöral ağlar
DL : Derin öğrenme
RNN : Tekrarlayan sinir ağları
DNN : Derin sinir ağları
GAN : Üretken karşıt ağlar
DRL : Derin pekiştirmeli öğrenme
TL : Transfer öğrenme
FT : Hassas ayar
TP : Doğru pozitif
TN : Doğru negatif
FP : Yanlış pozitif
FN : Yanlış negatif
DP : Dentin geçirgenliği
DT : Dentin geçirgenliği
LDA : Doğrusal ayırma analizi
SVM : Dentin geçirgenliği
GS : Alan Tarama
NB : Naïve Bayes
K-NN : K-en yakın komşuluk
RF : Rastgele Orman
MLP : Çok katmanlı algılayıcı

BÖLÜM 1

GİRİŞ

1.1 TEZİN TANIMI

İnsan vücudu, oldukça işlevsel ve kendine özgü birçok özelliğiyle inanılmaz bir yapıdadır. Bu yapıdaki her bir organ ve sistem, insan hayatı için önemli bir rol oynamasının yanısıra vücudun düzgün çalışmasını da sağlar. Bu önemli parçalardan biri, genellikle gözden kaçan ama oldukça önemli bir rol oynayan dişlerdir. Dişler, sadece yiyeceklerin fiziksel sindirimine yardımcı olmakla kalmaz, aynı zamanda konuşma ve gülümseme gibi sosyal etkileşimlerde de etkilidir. Dişlerin sağlıklı olması, ağız ve diş sağlığına bağlı birçok hastalığın da önlenmesine yardımcı olur. Dişlerdeki olumsuzluklar hayat kalitesini etkileyebilir ve sağlık sorunlarına neden olabilir. Bu nedenle diş sağlığına özen göstermek, genel sağlık açısından da son derece önemlidir.

Diş, hayatımız boyunca kullandığımız sert ve dayanıklı mineralize dokumuzdur. Koparma, kesme, tutma ve parçalama işlevlerine sahiptir. Diş sayesinde yiyecekler mekanik işlemde geçer ve midenin daha rahat sindirmesine yardımcı olur. Süt dişlerinden sonra çıkan kalıcı dişler daimidir ve her tip dişin kendine özgü işlevi vardır. Dişlerde, üzerine gelen kimyasal veya fiziki etkilerden dolayı, zaman içerisinde yıpranmalar, bozunmalar meydana gelebilir. Bu durumlar hayat kalitesini düşürmektedir ve tedavi edici yöntemlerin geliştirilmesi bu bakımdan oldukça önemlidir.

Dişin en dış tabakasında beyaz renkli enamel, altında ise dentin isimli yapı bulunur. Dentin, enamel kadar sert bir doku olmasa da serttir ve dişin hacimsel olarak en büyük kısmını oluşturmaktadır. Ayrıca, dentin içerisinde mikroskobik tübüller barındırmaktadır. Eğer enamel dokusu zarar görürse, dentin yapısı açığa çıkar ve diş

üzerine gelen sıcak, soğuk veya kimyasal uyaranlar hissedilebilir. Bu durum ise dentin hassasiyeti olarak adlandırılmaktadır. Dentin hassasiyeti oldukça yaygındır ve hayat kalitesini oldukça etkilemektedir. Yiyeceklerin öğütülmesi esnasında oluşan hassasiyetin önüne geçmek için tedaviler yapılmakta, ürünler araştırılmakta ve geliştirilmektedir. Ortaya çıkarılan çalışmalar dentin üzerinde bulunan tübüllere yapılan işlemleri içermektedir. Tübüller üzerinde yapılan çalışmalar ve ajanların etkileri uzman kişiler tarafından emek yoğun biçimde değerlendirilmesini gerektirmektedir. Daha hızlı ve objektif değerlendirme için makine öğrenmesiyöntemlerinin kullanılması bu süreci hızlandıracak ve objektif sonuçlar ortaya çıkarılmasında önemli bir rol üstlenecektir.

1.2. TEZİN AMACI

Dentin hassasiyeti oldukça sık rastlanılan ve dentin yüzeyinin açığa çıkmasıyla ilişkilendirilen klinik durumdur. Bu durum yeme, içme, diş fırçalama hatta nefes alma esnasında bile hastayı rahatsız edebilmektedir. Bütün yaş gruplarında olabilir ve günlük aktivitelerde oluşturacağı rahatsızlık dolayısıyla hayat kalitesini olumsuz etkileyebilir. Bu sebepleri ortadan kaldırmak amacıyla diş hassasiyetinin etkisini azaltacak çeşitli tedavi yöntemleri vardır. Bu yöntemlerin temel amacı dentin tübüllerini tıkamak veya o bölgeyi hissiyat kaybına uğratarak tedavi etmektir. Piyasada bulunan birçok ürünün içeriğinde yer alan duyarsızlaştırma ajanının tübüller üzerindeki etkisini inceleme yöntemlerinden birisi de taramalı elektron mikroskobu (SEM) altında tübülleri incelemektir. İncelenen tübüllerin o bölgedeki miktarı, çapı, doluluk oranı, yoğunluk gibi hesapların yapılması çalışmayı yapan kişi için oldukça fazla emek ve zaman kaybına yol açmaktadır. Böylelikle çalışmalarda asıl amaç olan duyarsızlaştırma ajanının etkisini izlemekten uzaklaşmaktadır. Ayrıca, hesaplamalardaki uzman görüşleri de birbirinden farklı olabilmektedir. Çalışmalardaki bu farkı en aza indirmek, elle yapılan bu hesaplamaları bilgisayar ortamında otomatikleştirmek, doğruluk ve tekrarlanabilirlik hassasiyetini yükseltmek bu tezin amacını oluşturmaktadır. Bu amaç doğrultusunda oluşturulan hedefler şu şekilde sıralanmıştır.

Öncelikli hedef veri setinin hazırlanmasıdır. Veri setinin hazırlanması için gereken dişler etik kurul izni ile temin edildikten sonra dişlerin dentin kısmı çıkarılıp SEM ile incelenebilecek hale getirilmelidir. Veri seti oluşturulurken hazırlanan dentin üzerinden olabildiğince farklı noktalara odaklanarak tübüllerin çok sayıda dijital görüntüleri alınacaktır.

Tespit edilen tübüllerin yapısı da önemlidir. Çalışmalarda kullanılan duyarsızlaştırma ajanının etkisine bağlı olarak tübüllerin içi farklı oranlarda dolmaktadır ve bu durum diş hassasiyeti tedavisi ile doğrudan ilişkili bir durumdur. Bu duyarsızlaştırma ajanlarının oluşturduğu etkiyi incelerken tübüllerin hangi oranlarda dolu olduğu da uzman tarafından değerlendirilmektedir.

Bu çalışmanın amacı dişin dentin yapısı üzerinde bulunan mikro boyuttaki tübüllerini tespit edebilen ve açıklıklarına göre yüksek doğrulukta sınıflandırabilen bir derin öğrenme ağı oluşturmak ve eğitmektir. Böylelikle tübül açıklıkları incelenirken bilgisayar ile daha objektif bir değerlendirme yapılabilir, ortaya sayısal bir değerlendirme sunulabilir. Ayrıca, çok daha hızlı ölçüm sonuçları üretilebilir. Tespit edilen dentin tübüllerini üzerinden uzman görüşleri dahilinde duyarlılık, özgüllük ve doğruluk gibi parametreler hesaplanacaktır. Ayrıca, bu çalışma dentin tübüllerini üzerinde yapılacak araştırmaların daha hızlı değerlendirilmesine ve böylelikle daha fazla araştırma yapılmasına olanak sağlayabilir.

1.3. ÖZGÜN DEĞER

Dentin hassasiyetinde önemli etkisi olan dentin tübüllerini üzerinde yapılan çalışmaların değerlendirilmesi noktasında yapılan istatistiki değerlendirmeler manuel olarak yapılmaktadır ve kişiye göre değişebilen sonuçlar ortaya çıkabilir. Bu durumun yanı sıra oldukça emek ve zaman alan bu değerlendirme süreci günümüz bilgisayarlarının geldiği nokta düşünüldüğünde çok daha hızlı ilerlemesi gereken bir analizdir. Çekilen SEM görüntüleri üzerindeki tübüller uzmanlar tarafından tespit edilmekte, sayılmakta, sınıflandırılmakta, yoğunluğu ve çapları gibi bilgiler manuel yöntemlerle hesaplanmaktadır. Bilgisayarların geldiği hesaplama ve görüntü işleme kabiliyetleri düşünüldüğünde bu yöntem oldukça eski ve zaman alan bir yöntem

olduğu çok açıktır. Bu eksikliğı gidermek adına, görüntülerin otomatik görü yöntemleriyle bilgisayarda analizinin yapılması oldukça gereklidir. Literatür araştırmasında da belirtileceğı üzere görüntüler üzerindeki değerlendirmelerin otomatik yapılması üzerine odaklanılan çalışmaların oldukça az olması, bu alandaki gereksinimi artırmıştır. Otomatik değerlendirme üzerine yapılan çalışmaların az olmasının aksine SEM görüntüleri aracılığıyla dentin tübülleri üzerinde yapılan araştırmalar güncelliğini ve devamlılığını korumaktadır. Çalışmamızdaki özgün nokta ise literatürdeki otomatik değerlendirme metotlarında kullanılan yöntemler yerine, makine öğrenmesi tabanlı bir yöntemle yaklaşılacaktır. Yapılan araştırmaların daha hızlı ilerlemesi ve daha doğru değerlendirilmesi noktasında manuel yapılan değerlendirmelere kıyasla makine öğrenmesi yöntemleri yapılan literatür çalışması da göz önünde bulundurulduğunda çok daha iyi performans göstereceğı öngörülmektedir. Önerilen tez halihazırda kullanılmakta olan değerlendirme yöntemi yerine, bu alanda daha önce kullanılmamış makine öğrenmesi yöntemi kullanarak literatüre katkı sunacaktır. Yapılacak çalışmayla birlikte bu alandaki değerlendirme yöntemine bir yenisini eklenerek araştırmaların daha hızlı, başarılı ve tutarlı sonuçlara ulaştırılması hedeflenmektedir.

1.4. TEZ ORGANİZASYONU

Birinci bölümde “Giriş” kısmına yer verilmiş olup çalışmanın kısa tanımı, tezin amacı, özgün değeri ve tezin organizasyonundan bahsedilmiştir. Burada problem hakkında okuyucu bilgilendirilmiştir ve çözüm önerisi sunulmuştur. İkinci bölümde yer alan “Literatür Araştırması” başlığında güncel literatür taraması yapılarak dentin hassasiyetinin önlenmesi ve bu alanda yapılan görüntü işleme çalışmalarına yer verilmiştir. Üçüncü bölümde ise “Dişler” başlığı altında dişlerin insan vücudundaki önemi, dişlerin yapısı ve dentin hassasiyeti konuları hakkında bilgilendirme yapılmıştır. Ardından tez çalışmamızda kullanacağımız makine öğrenmesi modelleri ve özellikle derin öğrenme konularını kapsamlı şekilde içeren bilgilendirme Bölüm 4’de “Makine Öğrenmesi” başlığı altında okuyucuya sunulmuştur. Ayrıca, derin öğrenmenin neden dentin hassasiyeti konusunda uygun bir çözüm olarak kullanılabileceğinden bahsedilmiştir. Bölüm 5’de yer alan “Materyal” kısmında yaptığımız çalışma için kullandığımız dentin tübül görüntülerini elde ederken hangi

aşamalardan geçtiğine yer verilmiştir. Ardından gelen Bölüm 6 ise “Metot” kısmını içermektedir ve kullanılan veri setinden oluşturulan derin öğrenme modeline kadar kapsamlı bilgilendirme bu bölümde yapılmıştır. Bölüm 7, “Deneysel Sonuçlar ve Tartışma” kısmıdır ve yapılan çalışmalardan sonra elde edilen veriler burada paylaşılıp, yorumlanmıştır. Bölüm 8 ise çalışmamızın “Sonuçlar ve Değerlendirmeler” kısmıdır. Burada tez çalışmamızın genel itibariyle elde ettiği en iyi sonuçlar ve değerlendirmeleri yapılmıştır. Ayrıca, bu çalışmanın literatüre hangi yönlerde katkı sağladığından ve bu alanda yapılabilecek yeni çalışmalar hakkında da değerlendirmelere yer verilmiştir.

BÖLÜM 2

LİTERATÜR ARAŞTIRMASI

2.1. DENTİN HASSASİYETİNİN ÖNLENMESİ

Diş hassasiyeti dişlerin sıcak soğuk tatlı veya asitli yiyecek ve içecek gibi uyaranlara maruz kalmasının ardından oluşan ağrı hissi veren bir durumdur. Diş tarafına bakacak olursak diş üzerindeki enamel tabakasının aşınması ve dentin tübüllerinin açık olması önemli bir etkidir [1]. Dentin tübülleri dişlerin içinde bulunan ve sinirlere ulaşan mikro yapıda dentin tabakasının içinde yer alan kanallardır. Uyaranlar bu kanalların etkisiyle sinirlere ulaşabilir ve diş hassasiyetine neden olur.

Yedi ülkede yapılan araştırma raporuna göre soğuk hava uyarana karşı en az bir dişte hassasiyet yaşayanların yaygınlığı %20.6 ile %41.9 arasında tespit edilmiştir [5-10]; ayrıca diş hassasiyetine dair soruyu ankette tamamlayan hastaların %26.8'i diş hassasiyeti bildirmiştir. Bu nedenle önleyici tedaviler ve dentin hassasiyetinin klinik yönetimi önemli bir alandır [2]. Evde veya profesyonel kullanım için çeşitli aktif maddeler içeren geniş bir ağız bakım ürünleri yelpazesi mevcuttur fakat diş hassasiyetinin tedavisi için fikir birliğine varılamamıştır [3,4].

Dentin tübülleri çeşitli uyaranların pulpaya ulaşmasında ve iletiminde kullanılan bir geçit konumundadır. Odontoblastlar ve buna bağlı sinir lifleri dentin sıvı akışındaki değişikliklere karşı duyarlıdır [5]. Dentin hassasiyetinin tedavi sürecinde kullanılan iki temel strateji: pulpa dokusunda nöral aktiviteyi duyarsızlaştırma ve dentin tübüllerini kapatmak, tıkamaktır [6]. İlk sinir duyarsızlaştırma stratejisi, nöral iletimi engellemek için potasyum bazlı terapiyi kullanır. İkinci olarak diş hassasiyetine dair tedavi yaklaşımı, dentin tübüllerinin fiziksel tıkanmasını ve/veya sızdırmazlığını, böylece dentin tübülleri içindeki sıvı akışının azaltılmasını içerir [1]. Teorik olarak,

dentin geçirgenliğinde (DP) bir azalmanın diş hassasiyeti tedavisi için faydalı olduğu düşünülmektedir [3].

Ancak bu tedavi sınıflamasına göre uygulanan ajanlar dentin hassasiyeti üzerine tamamen etkili bir tedavi sunmamaktadır. Bu yüzden; hassasiyet giderici ajanların geliştirilmesi devam etmektedir ve bu ajanlar profesyonel veya evde kullanılmak üzere tüketiciye sunulmaktadır.

Bu ajanlardan biri olan Novamin (sodyum fosfosilikat) dentin tübüllerinin kapatılmasında oldukça etkilidir. Novamin ağız ortamına girdiğinde, tükürükle aktifleşen ve dentin tübülleri içinde açıkta bulunan dentin üzerinde kristalin hidroksikarbonat apatit tabakası oluşturan sodyum, kalsiyum ve fosfat iyonlarını serbest bırakır [7]. Dentin hassasiyetin giderilmesine yönelik kullanılan diğer bir ajan ise; arjinin kalsiyum karbonattır. Bu ajanın iki önemli bileşeni olan arjinin ve kalsiyumun tükürükte doğal olarak bulunması, ayrıca dentinal tübüller içinde ve dentin yüzeyindeki koruyucu katmanda kalsiyum ile fosfat içeren, dentin benzeri mineralleri depolayan ve tübüllerdeki tıkamayı hızlandırmak için arjinin ve karbonatın birlikte çalışması bu hassasiyet giderici ajanı etkili kılmaktadır [8].

Klinik çalışmalarda arjinin kalsiyum karbonat uygulamasının dentin hassasiyetinin azaltılmasında etkili olabileceği gösterilmiştir [9,10]. Listerine® (hassasiyet için geliştirilmiş koruma) potasyum oksalat ve sodyum florür içermektedir. Son yapılan çalışmalar, çözünebilir formdaki potasyum oksalatın, dentin tübülleri içerisinde dentinal sıvı akışını keserek dentin hassasiyetini önleyen kalsiyum oksalat çökeltilerini oluşturduğu göstermiştir [11]. Teethmate (kalsiyum fosfat içerikli hassasiyet giderici) tükürükle birlikte spontan olarak hidroksiapatite dönüşebilen tetrakalsiyum fosfat ve dikalsiyum fosfat anhidrazı içermektedir. Partiküller arasında kimyasal reaksiyon su ile karıştırılması ile tetiklenir daha sonra karışım içindeki kalsiyum ve fosfat iyonları saniyeler içinde salınmaya başlar ve kristalize hidroksiapatit tabakası diş yüzeyinde oluşur. Bu reaksiyon sonucu dentin tübüllerinin tıkanması meydana gelir. Labaratuvar çalışmaları yapay tükürük içerisinde dört haftalık sekanslarda Teethmate uygulamasının dentin geçirgenliğinde azalma meydana getirdiğini göstermiştir [12,13]. SmartProtect®, glutraldehit, triklosan, olaflur, 2-

propanol içerir. İçeriğindeki trioklosan anti inflamatuvar etki gösterirken, flor içeriği ile de dentin tübüllerinde tıkanma sağlar [14]. Gluma hassasiyet giderici ajan içeriğinde bulunan %35 hidroksietilen metakrilat (HEMA) ve %5 gluteraldehit ile dentin hassasiyetine karşı etkilidir [15]. Yapılan bu tez çalışmasında da yukarıda verilen dentin hassasiyeti giderici kimyasal ajanların dentin disklere uygulanması ve dentin tübüllerinde fiziki oklüzyon oluşturması planlanmaktadır.

Yapılan literatür araştırmasında da görüleceği üzere dentin tübüllerinin dış ortamlarla ilişkisini azaltmak veya durdurmak dentin hassasiyetinin tedavisinde etkilidir. Jel uygulanması, kaplama yapılması, diş macunları gibi dentin tübüllerini etkileyen veya tıkayan etkiye sahip ürünler sürekli geliştirilmektedir. Bu ürünler vasıtasıyla diş hassasiyetinin etkileri azaltılması ve yaşam kalitesinin artırılması amaçlanmaktadır. Ürünlerin geliştirilmesi sürecinde dentin üzerine uygulanan ürünlerin etkisinin incelenmesi dentin tübüllerinin gözlemlenmesiyle olmaktadır. Dentin tübülleri üzerindeki açıklıklar incelenmekte ve nicel olarak değerlendirilmesi gerekmektedir. DP üzerindeki performanslarının değerlendirilmesi hidrolik iletkenlik testi, ışık mikroskobu, konfokal lazer tarama mikroskobu (CLSM), transmisyon elektron mikroskobu (TEM) ve SEM görüntüleri ile yapılabilir [16–19]. Bu görüntüleme teknikleri arasında SEM'in numune hazırlama süreci çok azdır veya hiç yoktur ve geniş bir görüş alanı sağlar. Yüksek çözünürlük özelliğinden dolayı uygulanan ürünün etkinliği detaylı olarak görülebilmektedir. Etki mekanizmasını araştırmak ve DP hakkında bilgi toplamak için yüksek çözünürlüklü görüntü oldukça yardımcı olacaktır. SEM görüntülerinin değerlendirilmesi bu noktada oldukça değerlidir çünkü bilgisayar yüksek hassasiyetle ölçüm yapabilir ve dentin tübüllerini belirli şartlara göre sınıflandırabilir.

2.2. DENTİN TÜBÜLLERİ VE GÖRÜNTÜ İŞLEME

SEM görüntülerinde dentin tübül tıkanıklıklarının sayılması ve değerlendirilmesi, DP'nin istatistiksel ölçümü için birçok çalışmada kullanılmıştır [20,21]. Dentin tübüllerini manuel olarak saymak ve derecelendirmek pratik değildir ve zaman alıcıdır, bu nedenle yanlış yorumlama ve ölçümlerden kaçınmak için bilgisayar destekli analiz çok önemlidir. Bilgisayar destekli analiz dentin tübüllerinin

değerlendirilme sürecine önemli katkılar sağlayacaktır. Dijital görüntü işleme teknikleri ve makine öğrenimi yöntemleri tıbbın çeşitli dallarında çok başarılı sonuçlar vermesine rağmen, dentin tübül tıkanıklıklarının otomatik analizi daha az çalışılan konulardan biridir.

Tübüller üzerinde özellikle diş hassasiyetine yönelik birçok araştırma olmasına rağmen bilgisayar ile tübül görüntülerini otomatik analiz etme alanında literatürde oldukça az kaynak bulunmaktadır. Leonardo Ciocca ve ark.'nın yaptıkları çalışmada geleneksel yöntemlerle tübüllerin sayılmasının güvenilir ve tekrarlanabilir olmadığına değinilmiştir [22]. Ayrıca kişiye bağlı sonuçların değişebileceğinden bahsetmişlerdir. Bu probleme bağlı olarak tübüllerin tam otomatik değerlendirilmesi için bilgisayarlı analiz tekniği önermişlerdir. Periyodontal sebeplerle çıkarılan dokuz diş 2mm'lik diskler haline getirildikten sonra çeşitli çözeltiler yardımıyla tübüllerin açığa çıkması sağlanmıştır. Kontrol grubu da aynı numuneler üzerinden alınan görüntülerle elde edilmiştir. MATLAB ve image processing toolbox yardımıyla oluşturulan analiz algoritması, SEM'den gelen görüntüleri işlemeye yönelik oluşturulmuştur. Algoritma öncelikle görüntüleri normalize işlemine tabi tutarak en koyu pikseli siyaha, en açık olanı ise beyaz seviyesine orantılayacak şekilde çevirmektedir. Böylelikle dinamik aralığın artırılması ve birbiriyle homojen görüntülerin oluşturulması hedeflenmiştir. Buna ek olarak özellik çıkarımındaki tekrarlanabilirliğin de artırılması amaçlanmıştır. Gürültü azaltma, histogram eşitleme işlemlerinin ardından binary resim elde edilmektedir. Elde edilen görüntüdeki gereksiz bilgileri de ortadan kaldırmak için uygulanan morfolojik işlemlerden sonra kapalı bölümler otomatik olarak tanımlanmakta ve işaretlenmektedir. Ardından görüntüdeki her tübül algoritma ile sayılarak piksel cinsinden alanı hesaplanmaktadır. Manuel yapılan incelemeye kıyasla oluşturulan yazılım işlemleri hızlandırmış ve başarılı sonuç elde etmişlerdir [22]. Bu çalışma önerilecek tez konusuna en yakın makaleyi içermektedir. 2005 yılında yapılan bu çalışma zamanın tekniklerini kullanarak hem daha hızlı hem de daha tekrarlanabilir sonuçlar üretmeyi başardıklarını iddia etmişlerdir. Fakat yapılan bu çalışmadaki problem görüntüdeki her piksel işleme alındığı için bazı threshold üzerindeki pikseller de maksimum lokal gradient olarak işlenebilir. Bu maksimum noktalar birleşerek tübül varmış gibi yeni sınır belli edebilirler. Bir diğer problem ise dentin

görüntüsü üzerindeki birikintileri veya çöküntüleri tübül olarak nitelendirebilmektedirler. SEM görüntülerini farklı şekillerde almak dahi başarıyı etkileyebilmektedir. Yüksek büyütmelerde de hata oranı daha çok çıkabilmektedir şeklinde çalışmadaki problemleri de belirtmişlerdir.

R.C. Olley ve ark.'ı da dentin tübüllerinin ölçülmesinde yenilikçi bir bilgisayarlı çalışma yöntemi geliştirmeyi amaçlamışlardır. Yaptıkları çalışmada hassas ve güvenilir ölçümün gereksiniminden ve manuel sayım yönteminin yüzlerce SEM görüntüsü üzerinden sayılmasının ne kadar kullanışsız bir yöntem olduğundan bahsetmişlerdir. Bu problemden yola çıkarak yapılan çalışmada dijital görüntü işleme teknikleri kullanılarak daha hassas ve doğru bir analiz yapmayı hedeflemişlerdir [23]. Sınıflandırma ölçeği olarak ise Claydon ve ark.'nın yaptıkları görsel ölçeklendirme baz alınmıştır [24]. Yazılım sırasıyla şu işlemleri yaparak çalışmaktadır. Görüntü dosyaları sabit diskten bulunur. Bağımsız değişken x ve bağımlı değişken y arasındaki ilişkinin n'inci dereceden modellendiği polinom regresyonu bütün görüntülere uygulanarak odak düzlemini iyileştirmek için kullanılmıştır. Görüntüdeki gürültü ve ayrıntıları azaltmak için Gaussian blur kullanılır. Ardından pikseller arasındaki ilişki ve yoğunluk kullanılarak açık dentin tübüllerinin kenarları bulunur. Görüntüdeki objeleri ve sınırları bulmak için görüntüyü birden çok bölüme ayrılır ve arka plan yok edilir. Sonrasında görüntüyü threshold yöntemiyle binary formata çevirilir ve threshold değerinde büyük olanlar obje pikseli şeklinde işaretlenir. Dentin tübül açıklıkları analiz için renk değişikliği yapılarak vurgulanır ve bütün görüntü seçilerek $0.83\mu\text{m}$ 'den büyük olan içi boş çember objeleri sayılır ve sonraki görüntüye geçilir. Görüntüler hem program hem de uzman tarafından değerlendirildikten sonra korelasyon değeri 0.8'den büyük olarak hesaplanmıştır.

Literatürdeki bu çalışmalar görüntü üzerinde çeşitli filtreleme teknikleri ardından tübüllerin analizi veya tübül alanlarının hesaplanması üzerinde yoğunlaşmıştır. Ayrıca, çalışmalar otomatik tübül değerlendirme yönteminin literatürdeki gereksinimine ve manuel yöntemlerin zorluklarına değinmişlerdir. Bilgisayarın bu konuda iyi sonuçlar çıkarabileceklerini belirtmişlerdir ve yaptıkları çalışmalarla da bunu kanıtlamışlardır. Otomatik sınıflandırmanın, dentin hipersensitivitesi (DH) ile

ilgili arařtırmalar için binlerce dentin túbül görüntüsünü etiketleme sürecini kolaylařtıracasına řüphe yoktur. Özellikle derin öğrenme (DL) algoritmaları, özellikle konvolüsyonel sinir ađları (CNN), geleneksel analiz yöntemlerinin dezavantajlarını ortadan kaldırabilir ve görüntü sınıflandırması için yüksek başarı oranları sunabilir [25].

BÖLÜM 3

DİŞLER


3.1. DİŞLERİN İNSAN VÜCUDUNDAKİ ÖNEMİ

İnsan vücudunda dokuz ana organ sistemi bulunmaktadır. Bunlar cilt, kas sistemi, iskelet sistemi, dolaşım sistemi, solunum sistemi, sindirim sistemi, boşaltım sistemi, sinir sistemi, endokrin sistemi ve üreme sistemidir. Bu sistemler arasından sindirim sistemi hücrelerimizin sürekli ihtiyacı olan ve hücrelerimizin yakıtı olan besinlerin vücuda alınması ve işlenmesinden sorumludur. Sindirim, besinleri kan dolaşımına aktarmak üzere mekanik ve kimyasal olarak ayırma işlemidir. Kimyasal sindirimin vücutta daha iyi gerçekleşmesi için mekanik sindirim yardımıyla mekanik olarak besinleri daha küçük parçalara ayırmak gereklidir. Ağızdaki mekanik sindirim, besinlerin çiğneme ile daha küçük parçalara ayrılmasından oluşur. Ağız boşluğunda hem mekanik hem de kimyasal sindirim besin ile hemen başlar. Ağızda yeterince sindirilen besin yemek borusuna yutulur. Yemek borusunda herhangi bir sindirime uğramadan mideye geçen besinler burada tekrar mekanik ve kimyasal sindirime uğrar. Peristaltik kasılmalarla çalkalama işlemine maruz kalan besinlerin boyutu burada küçülür, ayrıca kimyasal sindirime de maruz kalır. Enzimatik salgılarla parçalan besinler daha sonra ince bağırsakta emilmeyi veya depolanmayı bekler. İşlenmeyen miktar ise kalın bağırsağa aktarılarak vücuttan atılmayı bekler [26].

Sindirimin ilk aşamasında besinlerin öncelikli karşılaştığı nokta olan ağız boşluğunda bulunan dişler çiğnemenin en büyük yardımcılarından ve kimyasal sindirim için besinlerin yüzey alanını artırarak enzimlerin besin yüzeyine daha iyi nüfuz etmesini sağlar. Bu nedenle, sindirim sistemi, vücudumuz için hayati önem taşıyan besinlerin sindirilmesinde kritik bir rol oynar.

3.2. DİŞLERİN YAPISI

Dişler insan vücudundaki en sert maddelerdir ve çiğnemede önemli bir rolü olmasının yanısıra konuşmada da önemli rol oynar. Diş taç ve kök kısmı olmak üzere iki kısımda incelenmektedir. Diş tacı, diş eti üzerinde kalan ve görülebilen kısmı temsil ederken, kök kısmı ise diş etinin altında kalan kısımdır. Şekil 3.1’de yetişkin insanın azı dişi kesiti görselleştirilmiştir.




Şekil 3.1. Yetişkin insanın azı dişi kesiti [27]

Dişin kök kısmı, dişlerin kemik yuvasına bağlanmasında rol oynayan sement ile kaplıdır. Dişin merkezinde ise mineralize olmayan diş pulpası bulunur. Bu yumuşak bağ dokusu sinirler ve çevre dokularla bağlantılı damar ağı, periodontal ligament ve kemik yuvası bulundurur [28]. Dişin taç kısmında bulunan diş minesini besinlerin ilk karşılaştığı yerdir ve yüksek oranda mineralize ve koruyucu diş minesinin altında dentin tabakası bulunur.

3.3. DENTİN HASSASİYETİ

Günümüzde tükettiğimiz yiyecekler ve içeceklerden dolayı veya farklı nedenlerle diş minesini korozyona uğrayabilir ve bu kısmı aşındırarak dentin tabakasının açığa

çıkmasına sebep olabilir. Dentin, dişin büyük bölümünü oluşturur ve yüksek oranda kalsiyum içermektedir [29]. Sert bir doku olan dentin yapısal olarak mikroskopik tübüller içermektedir (Şekil 3.2) ve diş minesi zarar gördüğünde bu yollardan termal, buharlaştırıcı, dokunsal, ozmotik veya kimyasal uyarılardan dolayı kısa ve keskin ağrı oluşabilir. Bu durum dentin haricinde başka bir diş kusurundan veya patolojisinden kaynaklanmıyorsa DH veya dentin aşırı duyarlılığı olarak tanımlanmaktadır [30].



Şekil 3.2 Dentin tübüllerinin örnek SEM görüntüleri

Dentin hassasiyeti sık görülen bir durumdur ve hastaların bir diş hekimine görünmelerinde ana etmenlerden biridir. Dentin hassasiyetinin etiyolojik faktörleri arasında dişeti çekilmesi, fırça abrazyonu ve erozyon gibi faktörler sayılabilir [31]. Olası dentin hassasiyetini önlemek için hastalar beslenmelerinde bazı yiyecek ve içeceklerden ayrıca hassasiyet oluşturacağı gerekçesiyle dişlerinin temizlemekten kaçınırlar. Bu şekilde yetersiz ağız hijyen bakımı çürük gelişimini hızlandırır ve beraberinde periodontal problemleri de oluşturur. Dentin hassasiyetinin arkasında dört mekanizma bulunmaktadır. Bunlar; odontoblastik transdüksiyon teorisi [32], nöral teori [33], ağrı kontrol teorisi [34] ve Brannstrom'un hidrodinamik teorisidir [35]. Dentin hassasiyetinin giderilmesindeki güçlüğüne bağlı olarak; bazı yöntemler bu mekanizmalara bağlı olarak geliştirilmiştir. Bu mekanizmalardan en çok kabul gören, dentin hassasiyetine neden olan tübül içindeki sıvı akışkanlığına bağlı açık dentin kanalları olduğunu dile getiren Brannstrom hidrodinamik teorisidir [36]. Bu hidrodinamik teoriye göre, ağız ortamında belirli uyarılara maruz kalan dentin tübülleri, tübül sıvısının hareketine izin verir, bu da dolaylı olarak pulpa sinirlerinin ekstremitelerini uyararak diş hassasiyetine neden olur.

BÖLÜM 4

MAKİNE ÖĞRENMESİ

Yapay zekanın bir alt kümesi olan Makine Öğrenmesi (ML), son yıllarda oldukça gelişim göstermiştir. Nöral ağlar (NN), ML'nin alt kümesidir ve DL'nin ortaya çıkmasına öncü olmuştur. Başlangıcından bu yana DL ciddi bir ivme yakalayıp oldukça başarılı uygulamalar ve sonuçlar ortaya çıkarmıştır. Alt başlıklar halinde derin öğrenme uygulamalarını örneklendirecek olursak ;

- Görüntü Tanıma: CNN son yıllarda görüntü tanıma konusunda büyük başarı elde etmiştir. Bu başarı özellikle ImageNet [37] veri kümesi ile oldukça yüksek performans elde etmiştir. CNN'ler, makinelere objeleri, insanları ve değişkenleri tanıma ve yorumlama becerisi kazandırarak, yapay zeka alanında önemli bir yer edinmiştir. CNN'lerin bu başarıları, yapısındaki özelliklerden kaynaklanmaktadır. Bu sinir ağı türü, öğrenme sürecinde veriye özgü filtreler kullanarak, girdi verilerinden özelliklerin çıkarılmasını sağlar. Bu sayede, görüntü, video veya ses gibi farklı veri türlerinde, önemli özelliklerin çıkarılması için oldukça etkilidir.

Özellikle ImageNet veri kümesi ile yapılan çalışmalar, CNN'lerin yüksek doğruluk oranlarına sahip modeller ürettiğini göstermiştir. Bu veri kümesi, 1000 farklı sınıfa ait 1.2 milyon görüntüden oluşmaktadır ve CNN'ler, bu veri kümesindeki farklı sınıfları doğru bir şekilde tanımlayarak, insan benzeri bir görüntü tanıma yeteneği kazanmıştır.

Bu nedenle, CNN'lerin yapısı, görüntü tanıma konusunda oldukça yüksek performans gösteren modeller oluşturmak için son derece etkilidir. Bu konu, tezin ana konusunu oluşturduğu için, bölüm 4.1.1'de daha ayrıntılı olarak

incelenmektedir. İlgili bölümde, CNN'lerin yapısı, öğrenme süreci, veri ön işleme teknikleri ve görüntü tanıma uygulamaları hakkında kapsamlı bilgi verilmektedir.

- Doğal Dil İşleme: Dil çevirisi ve metin oluşturma gibi görevlerde en gelişmiş performansı elde etmek için tekrarlayan sinir ağları (RNN'ler) ve dönüştürücü mimariler kullanılmıştır [38]. RNN'ler, sıralı verilerin işlenmesinde oldukça etkilidir ve doğal dil işleme uygulamalarında sıklıkla kullanılır. Bu tür sinir ağları, önceki adımlardaki girdileri hafızalarında saklayarak sonraki adımlardaki çıktıları hesaplamak için kullanır. Bu sayede, dil çevirisi ve metin oluşturma gibi görevlerde, RNN'ler, doğal dil öğrenimi yapabilen modeller oluşturmak için kullanılır. Bu teknolojiler, dil işlemenin farklı alanlarında kullanılmaktadır ve doğal dil anlama ve üretme yeteneğiyle birlikte insan-makine etkileşimini geliştirmeye yönelik önemli adımlar atılmasına vesile olmaktadır.

Dönüştürücü mimariler ise, dil işleme için son derece etkili olan bir sinir ağı mimarisidir. Bu mimariler, büyük veri kümeleri ile eğitilerek dilin yapısını anlamak için kullanılırlar. Bu sayede, dil çevirisi ve metin oluşturma gibi görevlerde, dönüştürücü modeller, dilin yapısını anlayarak doğal dil işleme problemlerini çözmek için kullanılır.

Konuşma tanıma, doğal dil işleme alanında önemli bir konudur ve günümüzde birçok uygulama alanında kullanılmaktadır. Bu uygulamaların başında, sesli asistanlar, telefon görüşmelerindeki otomatik yanıt sistemleri, diktatör programları, araç içi bilgi ve eğlence sistemleri gibi alanlar gelmektedir.

Konuşma tanıma sistemlerinin geliştirilmesinde, derin sinir ağları (DNN'ler) son derece etkilidir. Bu sinir ağı mimarileri, büyük veri kümeleri ile eğitilerek, kelime hata oranında önemli bir azalma sağlayabilirler [39]. DNN'ler, özellikle ses verilerinin özellik çıkarma işlemleri için kullanılırlar. Bu işlemler, ses verilerinin frekans spektrumu gibi özelliklerini matematiksel

olarak temsil eden vektörlere dönüştürerek, daha sonra çeşitli işlemlerden geçirilirler.

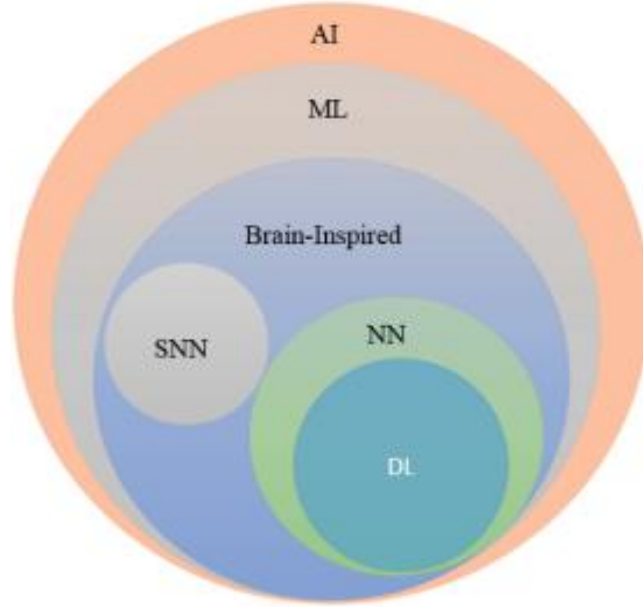
- Oyun oynama: Derin pekiştirmeli öğrenme (DRL) alanı, bilgisayarların çeşitli görevleri öğrenmeleri için kullanılan bir yaklaşımdır. Bu yaklaşım, bir ajanın belirli bir ortamda belli bir görevi başarması için gerekli olan en iyi eylemleri öğrenmesi üzerine odaklanır. Bu amaçla, DRL yöntemleri genellikle derin sinir ağları kullanarak bir ajanın ortamla etkileşimini modeller ve optimal eylemleri öğrenmek için bir ödül fonksiyonunu maksimize etmeye çalışır.

Bu yöntem, sadece bilgisayar oyunlarındaki başarılarıyla değil, aynı zamanda robot kontrolü, finansal piyasa tahmini ve otomatik araba sürüşü gibi gerçek dünya uygulamalarında da etkili bir şekilde kullanılmıştır. Özellikle oyun alanında, DRL'nin başarıları oldukça dikkat çekicidir. Atari oyunlarından başlayarak, AlphaGo ve AlphaZero gibi insanüstü düzeyde performans gösteren modeller geliştirilmiştir [40]. Özellikle, DRL yaklaşımları, insanların çözmesi zor olan karar verme problemlerinde ve hatta insanlardan daha iyi sonuçlar elde etme konusunda da potansiyel göstermektedir.

- Üretken modeller: Bu modeller, gerçekçi görüntüler, videolar, metinler ve diğer veri türlerini oluşturmak için kullanılır. Üretken Karşıt Ağlar (GAN) bilinen en üretken modellerdendir. GAN'lar, iki derin sinir ağından oluşan bir modeldir: bir üretici ağ ve bir ayırt edici ağ. Üretici ağ, gerçekçi görüntüler üretmeye çalışırken, ayırt edici ağ, gerçek ve üretilmiş görüntüleri ayırt etmeye çalışır [41]. Bu süreçte, üretici ağ, gerçekçi görüntüler üretmek için kendi hatalarını azaltmaya çalışır ve bu da sonunda daha gerçekçi görüntüler üretir.

Değişken Otomatik Kodlayıcılar (VAE) [42] benzer şekilde gerçekçi görüntüler üretmek için kullanılır. VAE'ler, bir çeşit kodlayıcı ve üretici ağ kombinasyonudur. Kodlayıcı, verileri biraz daha özetleyen bir formatta kodlar ve bu kodlar, üretici ağ tarafından gerçekçi görüntüler oluşturmak için kullanılır.

Yukarıda da belirtildiği üzere oldukça farklı alanlarda kullanılabilen yapay zeka türevlerinin son yıllarda oldukça sık kullanılmasının sebepleri arasında donanım maliyetlerinin azalması, bilgisayar çiplerinin verileri işleme kapasitesinin artması ve makine öğrenmesi alanında ortaya çıkan son gelişmeler gösterilebilir [43]. Şekil 4.1 yapay zekanın alt birimlerine göre nasıl sınıflandırıldığına dair görsel içermektedir.

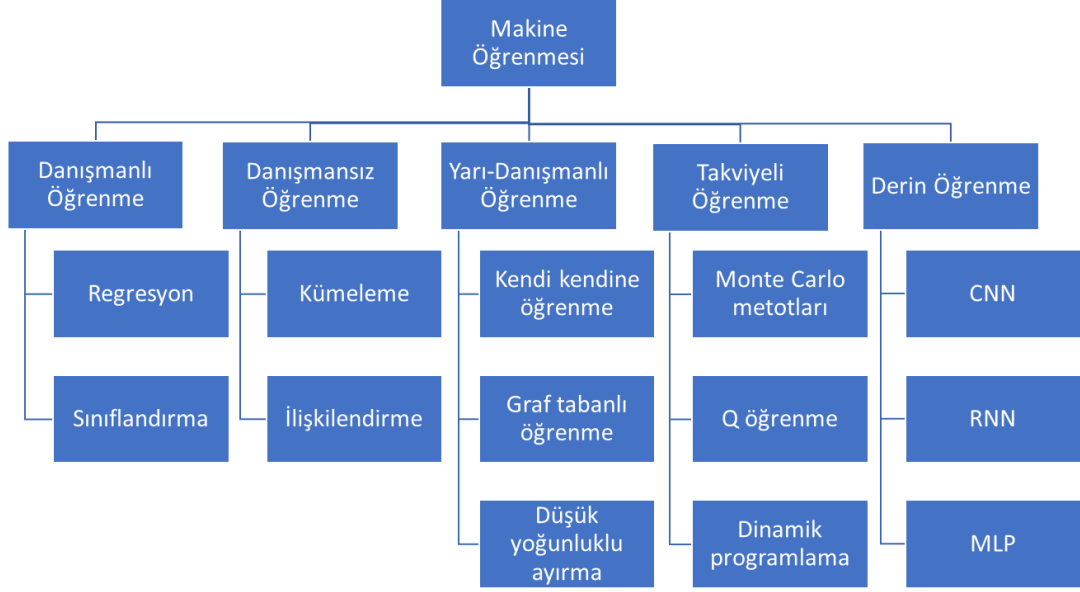


Şekil 4.1 Yapay zekanın barındırdığı birimler [44].

Derin öğrenmede giriş ve çıkış katmanlarının arasında birçok katman bulunur, bu katmanlarda lineer olmayan bilgilerin işlenmesi sağlanabilir ve ağırlıkların değiştirilebilmesi sayesinde verileri öğrenebilir ve ardından bu verileri kullanarak gelecekteki verileri tahmin etmeye çalışır. Öğrenme kısmında model parametrelerinin tahmin edilmesi ve en uygun parametrelerin ilgili iş için belirlenerek kullanılmasıdır. Bu tahminler ile ağırlıklar tekrar ayarlanır ve öğrenme süreci tekrar başlar. Bu döngü sayesinde derin öğrenme yapısı özellik öğrenimi ve örüntü sınıflandırmasını giderek hassas ve doğru tahminlerle yapabilir.

4.1. MAKİNE ÖĞRENİMİ YAKLAŞIMLARI

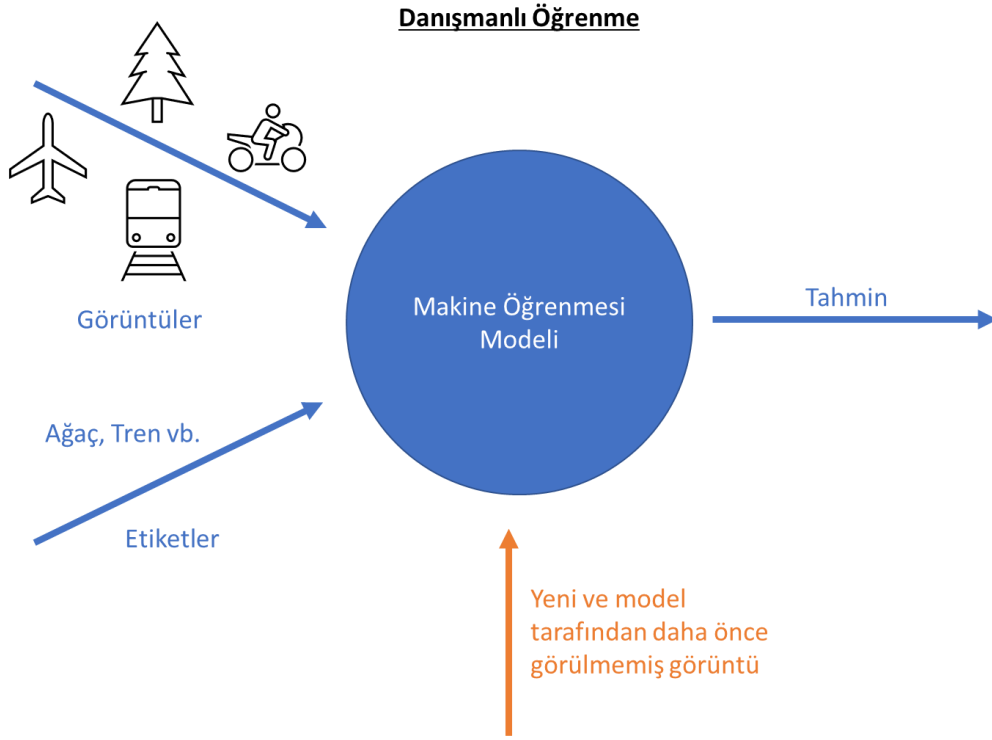
Makine öğrenimine benzer şekilde, derin öğrenme yaklaşımları danışmanlı, yarı danışmanlı, danışmansız, takviyeli öğrenme ve derin öğrenme olarak dört kategoride sınıflandırılabilir (Şekil 4.2).



Şekil 4.2 Makine öğrenimi yaklaşımlarının gruplandırılması.

Danışmanlı öğrenme, makine öğrenmesinin alt dallarından birisidir ve etiketli veri setleri üzerinden öğrenmeye dayalıdır. Etiketli veri setleri, nesnelere sınıflandırılmış bir şekilde bulunduğu veri setleridir. Bu nesnelere sınıflandırılması, bir öğrenme modeli oluşturmak için kullanılır. Bu model, veri setindeki gözlemlerin özelliklerine ve sınıflandırmasına göre öğrenir. Örneğin, bir görüntü sınıflandırma modeli, görüntülerin özelliklerinden yaptığı çıkarımlara göre görüntüyü sınıflandırabilir. Model, gerçek sınıflandırmayı (etiketi) kendi sonucuyla karşılaştırarak hatalar bulabilir ve kendisini bu hatalardan öğrenerek geliştirebilir. Bu geliştirme, geriye yayılım yöntemi gibi tekniklerle gerçekleştirilebilir. Bu şekilde daha iyi öğrenme amaçlanır. Eğitimi tamamlanan model, gelecekteki olayları tahmin etmek veya verileri analiz etmek için kullanılabilir. Şekil 4.3’de danışmanlı öğrenme sistemi görselleştirilmiştir.

Danışmanlı öğrenme modelleri, regresyon ve sınıflandırma durumlarını içerir. Regresyon modelleri, veri setindeki özellikleri kullanarak bir sonuç tahmini yapar. Örneğin, bir ev fiyatı tahmin modeli, evin özelliklerine göre bir fiyat tahmini yapabilir. Sınıflandırma modelleri ise, veri setindeki gözlemleri belirli sınıflara ayırır. Örneğin, bir spam filtresi modeli, gelen e-postaları spam ve spam olmayan kategorilerine ayırabilir.



Şekil 4.3 Danışmanlı öğrenme modeline genel bakış

Sınıflandırma, makine öğrenmesinin temel bir dalıdır ve veri analizi için kullanılan önemli bir yöntemdir. Bu yöntem, veri setindeki özellikleri kullanarak bir çıktı sınıfı tahmini yapar. Sınıflandırma algoritmaları, genellikle iki veya daha fazla sınıf arasındaki ayrımı yapmayı hedeflemektedir.

Karar ağaçları, sınıflandırma ve regresyon problemleri için kullanılan denetimli öğrenme yöntemlerindedir. Karar ağaçları, kararlar hakkında bir model oluşturmak için akış diyagramı şeklinde bir ağaç temsili kullanır. Ağaç kök düğümle başlar ardından test ve sonuçlara göre diğer düğümlere dallanarak devam eder. Kökten yaprağa giden yollar, sınıflandırma kurallarını temsil eder. Her yaprak düğümü ise hesaplamalardan sonra alınan sınıf etiketini temsil etmektedir. Bu algoritma, veri setindeki özelliklerin sınıflandırılmasını kolaylaştıran ağaç yapıları kullanır. Karar ağaçları, sınıflandırma yapmak için belirli özelliklerin birbirine göre önemini belirler ve bu özellikleri kullanarak verileri sınıflandırır.

Doğrusal Ayırma Analizi (LDA) sınıflandırma problemleri için kullanılan denetimli öğrenme yöntemlerindedir. LDA, veri kümesindeki sınıfları birbirinden ayırt etmek

için en uygun özellik kombinasyonunu bulmayı amaçlar. Veri noktalarını farklı sınıflara göre daha iyi ayırt edebilen yeni özellikler oluşturmak için ve boyutsal azaltma tekniği olarak da işlev görür. Böylelikle veri setindeki özellik sayısını azaltırken, sınıflandırma performansını artırır. Özellikler arasında sınıfları ayırt etmek için kullanılan lineer bir formülasyonu ortaya çıkarmak amacıyla kullanılır. Skor fonksiyonuna göre, sınıflandırma problemi için skoru maksimize eden lineer katsayıları tahmin etmek amacıyla kullanılır [45]

Naïve Bayes (NB) teoremine göre çalışan denetimli bir öğrenme modelidir. Veri noktasının hangi sınıfa ait olduğunu tahmin etmek için kullanılır, her özellik bağımsız nitelendirilir ve birbirini etkilemediği varsayılır. Naive Bayes'in temeli Bayes Teoremi'ne dayanır. Bayes Teoremi, bir olayın olasılığını, bu olayın meydana gelmesine yol açabilecek diğer olayların olasılıklarıyla ilişkilendirir. Bayes Teoremi'nin genel formülü:

$$P(A|B) = \frac{P(B|A) * P(A)}{P(B)}$$

Burada, $P(A|B)$: B şartı altında A'nın olasılığı

$P(B|A)$: A şartı altında B'nin olasılığı

$P(A)$: A'nın genel olasılığı

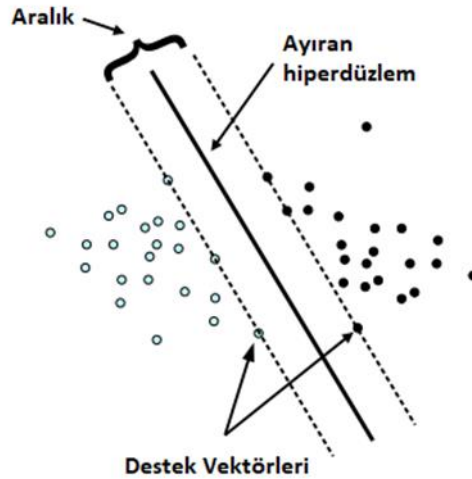
$P(B)$: B'nin genel olasılığı

K en yakın komşuluk (K-NN), sınıflandırma ve regresyon problemlerini çözmek için kullanılan denetimli öğrenme modellerindendir. Bu algoritma, bir veri noktasının sınıfını belirlemek için komşu noktaların sınıfını kullanır. Bu modelde komşuluk ilişkilerini belirlemek için veri noktaları arasındaki uzaklık bir ölçüm metodu seçilerek hesaplanır. k en yakın komşu arasından çoğunluğun bulunduğu sınıfa göre yeni veri ilgili sınıfa atanır.

Doğrusal ve lojistik regresyon, sınıflandırma algoritmaları olarak kullanılan diğer yöntemlerdir. Doğrusal regresyon, bir bağımlı değişkeni bir veya daha fazla bağımsız değişkene bağlayan bir regresyon yöntemidir ve sınıflandırma yapmak için

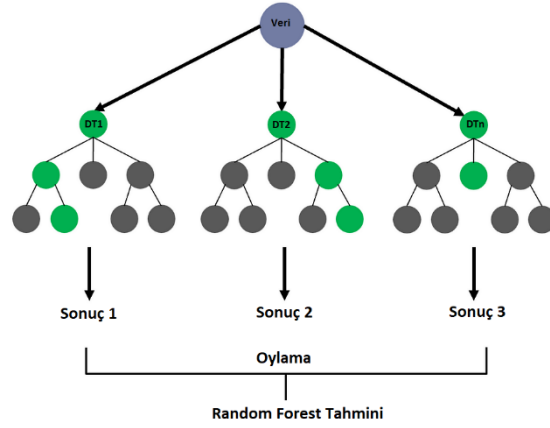
kullanılabilir. Lojistik regresyon ise, bir bağımlı değişkenin sınıflandırmasını yapmak için kullanılan bir yöntemdir ve genellikle iki sınıf arasındaki ayrımı yapmak için kullanılır.

Destek vektör makineleri (SVM), hem sınıflandırma hem de regresyon problemleri için kullanılan denetimli öğrenme modellerinden biridir. Sınıf sınırları üzerinde bulunan ve hiperdüzleme en yakın olan veri noktaları bulunur. Bu veri noktalarına "destek vektörler" denir. Hiperdüzlem, bu destek vektörlerin konumlarına göre belirlenir. SVM, veriyi farklı sınıflara bölen en iyi hiperdüzlemi belirlemeye çalışırken, hiperdüzlem ile sınıfların en yakın veri noktaları arasındaki mesafeyi maksimize etmeye çalışır [46]. Yüksek boyutlu veri kümelerini işlemek için doğrusal ve doğrusal olmayan çekirdekler kullanır. SVM, verileri bir veya daha fazla boyutlu uzayda temsil eder ve sınıflar arasındaki sınırları bulur (Şekil 4.4).




Şekil 4.4. Örnek SVM [47]

Rastgele Orman (RF) sınıflandırma ve regresyon görevleri için kullanılan denetimli makine öğrenme modelidir. RF, eğitim kümesinin rastgele seçilmiş bir alt kümesi ile eğitilen birçok Karar Ağacı içerir. Çoğunluk oylamasına dayalı olarak eğitilmiş bir Karar Ağacı tarafından bir karar alınır. RF için belirtilen bir parametre olan Karar Ağacı sayısıdır. Örnek bir RF temsili Şekil 4.5'de gösterilmiştir.



Şekil 4.5. Örnek RF.

Yapay Sinir Ağı (MLP), sınıflandırma problemleri ve regresyon görevleri için kullanılan denetimli bir Makine Öğrenimi modelidir. MLP giriş (input), gizli (hidden) ve çıkış (output) olmak üzere üç ana katmandan oluşur. Bir veri kümesindeki özellikler giriş katmanında kabul edilir. Modelin öğrenme yeteneğini gizli katmanlar artırır. Bu katmanlardaki her düğüm, giriş verileriyle ağırlıklar aracılığıyla bağlanır ve bu bağlantılar öğrenme süreci boyunca güncellenir. İleri yayılım, modelin verileri girişten çıkışa nasıl aktardığını hesaplar, geri yayılım ise tahmin hatalarını hesaplayarak ağırlıkları güncellemek için kullanılır. Çıkış katmanı ise modelin tahminlerini ürettiği yerdir. Örnek bir MLP temsili Şekil 4.6'da gösterilmiştir.



Şekil 4.6. Örnek MLP.

Regresyon: Sınıflandırma, bir veri kümesindeki özellikleri kullanarak bir çıktı sınıfı tahmin etmek için kullanılırken, regresyon ise sürekli bir çıktı değeri tahmin etmek için kullanılır. Bir bağımlı değişken ve bir veya daha fazla bağımsız değişken


arasındaki ilişkiyi modeller ve bu ilişkiyi kullanarak bağımlı değişkenin sürekli bir sayısal çıktısını tahmin etmeyi amaçlar. Regresyon modelleri, ekonomi, pazarlama, mühendislik ve diğer birçok alanda kullanılır.

Örneğin, bir şirketin gelirini tahmin etmek için regresyon modeli kullanılabilir. Bu modelde, bağımlı değişken şirketin geliri, bağımsız değişkenler ise şirketin çalışan sayısı, reklam harcamaları ve pazarlama stratejileri gibi faktörler olabilir. Model, bu faktörlerin şirketin geliri üzerindeki etkisini ölçer ve gelecekteki geliri tahmin etmek için kullanılabilir.

Yarı danışmanlı öğrenme: Veri kümesinde bulunan nesnelere sadece bir kısmının etiketlenmiş, ayrıca etiketlenmemiş verilerin de kullanıldığı bir öğrenme yöntemidir. Etiketli örnekler, sınıflandırma veya regresyon için kullanılan bir model oluşturmak için kullanılırken, etiketlenmemiş örnekler, modelin güncellenmesi ve daha iyi öğrenme sağlanması için kullanılır. Yarı danışmanlı öğrenmede, etiketlenmemiş verilerin kullanılması nedeniyle, büyük veri kümeleri üzerinde çalışırken özellikle yararlıdır. Örneğin, bir şirketin milyonlarca müşterisi varsa ve bu müşterilerden sadece bir kısmı hakkında etiketli veriler varsa, yarı danışmanlı öğrenme algoritmaları, etiketlenmemiş müşteriler hakkında da tahminler yapmak için kullanılabilir.

Yarı danışmanlı öğrenme algoritmaları, k-NN, Naive Bayes ve çeşitli türevlerinden oluşan algoritmalarda kullanılabilir. Bu algoritmalar, etiketlenmiş verileri kullanarak model öğrenirken, etiketlenmemiş verileri de dahil ederek modeli geliştirmek için kullanılır.

Danışmansız öğrenme: Veri kümesinde bulunan nesnelere sınıflandırılmış bir şekilde verilmediği bir öğrenme türüdür. Veri kümesinde bulunan nesnelere etiketlenmemiş olması nedeniyle, algoritmanın kendi başına veriler arasındaki benzerlikleri ve farklılıkları bulması gerekmektedir (Şekil 4.7). Bu özellikleri bulduktan sonra, nesnelere bu özelliklerine göre gruplara ayrılabilir ve veri kümesindeki yapıyı anlamaya yardımcı olabilir.



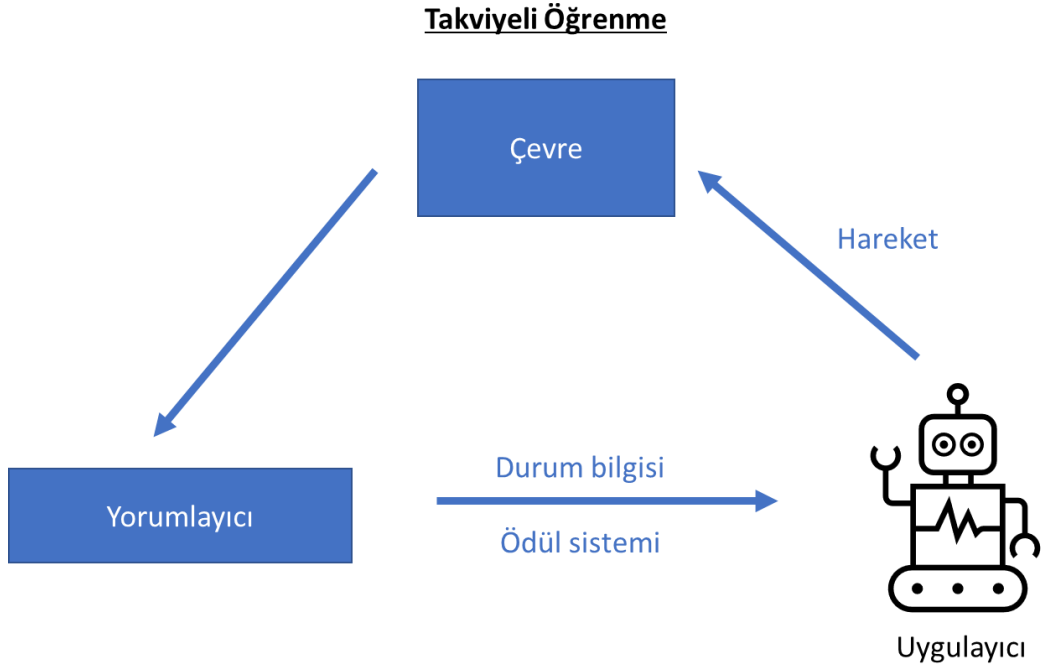
Şekil 4.7 Danışmansız öğrenme modeline genel bakış

Danışmansız öğrenmede modeller kümeleme ve boyut indirgeme başlıklarında incelenebilir. Kümeleme, bir veri kümesindeki nesnelere benzer özelliklere göre gruplandırılan bir danışmansız öğrenme yöntemidir. Veri kümesindeki her nesne, kümeleme algoritması tarafından benzer nesnelere aynı gruba atanır. Bu sayede, bir veri kümesindeki nesnelere benzer özelliklerine göre farklı kümelere ayrılması sağlanır.

Boyut indirgeme, veri kümesinde bulunan özellik sayısını azaltarak verilerin daha az boyutlu bir uzayda temsil edilmesini sağlar. Bu, veri kümesindeki veri boyutunu azaltarak daha hızlı ve daha verimli bir öğrenme süreci elde etmeye yardımcı olur. Boyut indirgeme özellik seçimi ve özellik çıkarma başlıkları altında incelenebilir. Özellik seçimi, özellikler arasında en önemli olanı seçerek ve diğerlerini atma işlemini, tek tek özelliklerin performansına bakarak veya özellikler arasındaki ilişkilerin incelenmesine dayanarak yapar. Örneğin, müzik servisi, kullanıcıların müzik tercihlerine dayalı olarak öneri yapmak için danışmansız öğrenme kullanabilir. Kullanıcının dinlediği şarkılardan, oluşturduğu çalma listelerinden, aradığı müzik türlerinden ve benzeri faktörlerden yararlanarak, algoritma müzik tercihleri hakkında öngörülerde bulunabilir ve yeni şarkı önerileri sunabilir.

Takviyeli öğrenme (RL) makine öğrenimi yöntemleri arasında en etkili ve güçlü yöntemlerden biridir. Bu yöntem, bir sistem için en iyi davranışı belirlemek için kullanılır ve sistemi bir ortamda çalıştırarak ve bu ortamda yaptığı hareketlerden kazançlarını takip ederek öğrenir. RL, birçok farklı uygulama alanı için kullanılabilir. Örneğin, robotik sistemlerin kontrolünde, otomasyon sistemlerinde ve oyun endüstrisinde kullanılabilir. RL, bir robotun çevresindeki nesnelere nasıl tepki vereceğini öğrenmesi için kullanılabilir. Bu sayede robot, belirli bir görevi yerine getirirken karşılaşılabileceği farklı durumlar için doğru tepkiyi öğrenebilir.

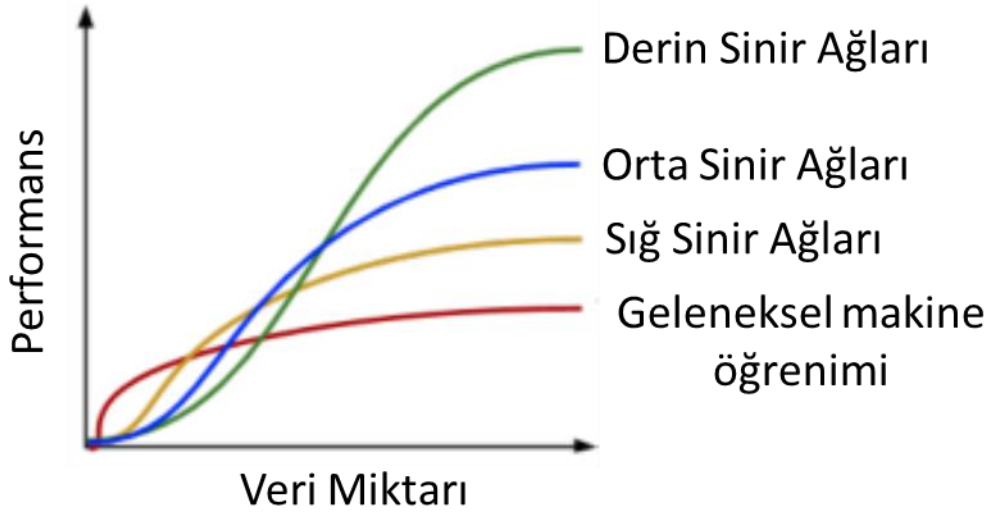
RL'de, tahmin edilen hatalar ödül veya ceza olarak kullanılır (Şekil 4.8). Hata büyük olduğunda ceza yüksek ve ödül oranı düşüktür. Tam tersi durumda, yani hata küçüldükçe, ceza düşük ve ödül yükselir. Bu sayede, modelin performansı en üst düzeye çıkarılır ve ideal davranış otomatik olarak belirlenir. Q-learning, RL modelinin en popüler örneklerinden biridir. Bu yöntem, bir tablo kullanarak öğrenme sürecini gerçekleştirir. Tabloda, her durum için bir dizi eylem değeri bulunur. Q-learning, bu tablodaki eylem değerlerini güncelleyerek öğrenme sürecini gerçekleştirir ve sonunda ideal davranışı belirler.



Şekil 4.8 Takviyeli öğrenme modeline genel bakış

Derin öğrenme, yapay zeka teknolojilerinde önemli bir yer tutmaktadır. Yapay sinir ağları, doğal olarak oluşan sinir ağlarının matematiksel bir modellenmesi olarak kullanılmaktadır. Bu yapay sinir ağları, insan beyninin öğrenme ve karar verme süreçlerindeki şekilleri taklit eder. Derin öğrenme algoritmaları, verileri işlemek için çok sayıda katman içeren sinir ağlarından oluşur. Her katman, bir önceki katmanın çıktısını girdi olarak alır ve daha karmaşık özellikler oluşturarak verileri işler. Bu nedenle, derin öğrenme, birçok karmaşık problemin çözümü için kullanılabilir.

Derin öğrenmenin geldiği nokta ve bilgisayarların artan işlem gücüyle eskiden hayal olan birçok uygulama günümüzde gerçekleşmeye başlamıştır. Örneğin, sürücüsüz araçlar, derin öğrenme algoritmaları ile donatılmıştır. Bu algoritmalar, araçların çevresindeki nesnelere ve engelleri algılamasına yardımcı olur ve aracın güvenli bir şekilde ilerlemesini sağlar. Ayrıca, tıbbi görüntüleme ve teşhis, doğal dil işleme, robotik ve oyun gibi birçok alanda derin öğrenme kullanılmaktadır.



Şekil 4.9 Mevcut verilerin geleneksel makine öğrenimi algoritmalarının performansı üzerindeki etkisini gösteren grafik [48]

Derin öğrenme, geleneksel yöntemlerden farklı olarak verileri doğrusal olmayan bir yaklaşımla işleyebilir. Bu, verilerin daha karmaşık kalıplarını tanımlayabilmesi anlamına gelir. Ayrıca, derin öğrenme algoritmaları, daha fazla veri aldıkça


performanslarını artırabilir (Şekil 4.9). Bu nedenle, derin öğrenme, büyük veri analizi ve büyük veri işleme alanlarında da önemli bir yer tutmaktadır.

Son zamanlarda, algoritmaların optimizasyonu, gelişmiş hesaplama donanımı ve büyük miktarda görüntüleme verilerine erişim nedeniyle, derin öğrenme, klasik makine öğrenimi çerçevesine göre tartışılmaz bir üstünlük sergilemiştir. Algoritmanın, verilerdeki yapıların hiyerarşisini yansıtan özellik birleşimini öğrendiği bir tür temsil öğrenmesidir [49]. CNN ve tekrarlayan sinir ağları (RNN), yapay sinir ağları (YSA) kullanan farklı derin öğrenme yöntemleridir.

Uygulamamıza en uygun derin öğrenme algoritmaları, görüntü bölümlenme ve sınıflandırmaya etkin bir şekilde uygulanabilen CNN'lerdir. CNN'ler, tam bağlantıları uygulamak için milyarlarca ağırlık kullanmak yerine, konvolüsyon ve havuzlama katmanlarını kullanarak konvolüsyon matematiksel işlemini taklit edebilir ve ağırlıkların sayısını önemli ölçüde azaltabilir. CNN'ler ayrıca uzamsal değişmezliğe de izin verebilir. Farklı konvolüsyonel katmanlar için, birden fazla çekirdek eğitilebilir ve ardından birçok konumla değişmeyen özelliği öğrenebilir. Önemli özellikler otomatik olarak öğrenilebildiği için, özellik çıkarımı işlemi çok daha pratiktir. Bu nedenle, CNN'lerin uygulama alanı oldukça geniştir.

4.1.1 Konvolüsyonel Sinir Ağları

CNN mimarisi, görsel korteksin organizasyonundan biyolojik olarak esinlenmiştir Şekil (4.10) [50,51]. Özellikle görsel sistemin yapısı, görsel ilişkileri katman katman kodlayacak şekilde davranır. Her katman kademeli olarak daha spesifik özellikleri temsil eder [52]. CNN, aynı örüntülü davranışı taklit etmek için tasarlanmıştır. CNN bir tür derin öğrenme modelidir ve görüntü tanıma, sınıflandırma, segmentasyon ve daha birçok görevi yapmak için en güçlü araçlardan biridir [53–55]. Her giriş görüntüsü, ilgili nesnelere sınıflandırmak için bir dizi katmandan geçer. Katmanlar, nöronlara ağırlık atamak için kullanılan yapı taşlarıdır.



Şekil 4.10 Biyolojik sinir ağı örneği

Konvolüsyonel sinir ağlarının özellikle görüntü işleme ve tanıma alanında kullanımı oldukça yaygınlaşmaktadır [56]. Bu sinir ağı tipi görüntüleri girdi olarak alır fakat diğer yöntemlere kıyasla vektörleştirme işlemine maruz bırakmadan görüntüler üzerinde işlemler yapar. Bu durum da CNN ağını görüntü üzerinde bulunması istenen özelliklerin pozisyonlarına duyarlı bir sistem haline getirir. Görüntü üzerindeki ilgili nesne nerede olursa olsun bulunabilir hale gelmiş olacaktır. Görüntüler CNN tarafından alındıktan sonra çeşitli filtreler ile özellik haritası oluşturmaya çalışır. Filtreler görüntülerdeki ayrıntıları yakalamaya yöneliktir ve görüntü üzerindeki özelliklerin ortaya çıkarılmasına katkı sağlarlar. Diğer derin öğrenme yöntemlerinde rastlanabilen görüntüler uygulanabilen konvolüsyonel işlem yerine görüntünün vektörize edilmesi ile eğitim yapılabilir, ardından başarılı tahminler yürüterek iyi sonuçlar ortaya çıkabilir. Fakat istenen özellik görüntü üzerinde bütün haldeyse tahmin değerleri düşebilir. Bu durum, vektörleştirme işleminden dolayı ilgili piksel etrafındaki önemli olabilecek bilgilerin yok olmasına neden olabilir [57]. Örneğin $5 \times 5 = 25$ giriş özelliği ve $3 \times 3 = 9$ çıkış özelliği olan görüntü tamamen bağı bir katman olsaydı $25 \times 9 = 225$ parametrelilik bir ağırlıklı matrisimiz olurdu. Günümüzdeki görüntü boyutlarını düşünecek olursak konvolüsyon yerine böyle bir yöntem seçmek maliyeti artıracak ve eğitim süreci zorlaşacaktır.

CNN çok katmanlı yapılardan oluşur ve istenen nesnelerin bulunmasına yönelik optimize filtreler içermektedir. Filtreler ardından oluşan özellik haritaları aslında ilgili özelliklerin nerede bulunduğu dair bilgi verir. Katmanlar şeklinde devam eden süreç son katmanda, görüntü üzerindeki nesnelere hakkında tahmin yapar.

CNN'lerin kullanımı pek çok açıdan avantajlıdır. Başlıca avantajlar şu şekilde sıralanabilir:

- Önemli özelliklerin çıkarımında insan gözetimi gerektirmez,
- Görüntü tanıma ve sınıflandırma işlemlerinde çoklu katman yapıları nedeniyle ayrıntılı özellikler öğrenebilirler, bu durum da ağın performansını artırır,
- Vektör halinde görüntü yerine görüntünün olduğu gibi kullanılmasının ağ parametre sayısını ciddi oranda düşürerek hesaplamaların kolaylaşması modelin hızlı bir şekilde eğitilmesine ve test edilmesine izin verir. Bu, modelin geliştirilmesi ve optimize edilmesi sürecini hızlandırır,
- Ağırlık paylaşımı ile eğitim zamanının ve maliyetin düşmesi,

CNN'lerin avantajları arasında yer almaktadır. Bu avantajların yanısıra bazı dezavantajlar da CNN'ler için şu şekilde açıklanabilir:


- Ağı başarılı bir şekilde eğitebilmek ve nesnelere bulabilmek için oldukça fazla eğitim verisine ihtiyaç duyulmaktadır. Ayrıca verilerin etiketli olmaları gereklidir. Küçük veri kümelerinde eğitim zor ve performans düşük olmaktadır,
- Genellikle belirli bir görev için tasarlandıklarından, farklı bir görev için başarılı olamayabilirler,
- Gerekli özelliklerin yanısıra gereksiz özellikleri de öğrenme riskleri vardır. CNN'ler, girdi verisinde bulunan bütün özellikleri öğrenmeye çalıştıklarından dolayı gereksiz özellikleri de öğrenme durumu oluşabilir, bu da modelin performansını düşürebilir,

- Katman sayısı arttıkça öğrenme hızı yavaşlayabilir: CNN'ler, çok sayıda katmana sahip olabilirler ve bu katmanların her biri için ayrı ayrı öğrenme işlemleri yapılır. Bu durum da öğrenme hızını yavaşlatabilir,
- Özellikle büyük veri kümeleri için yüksek maliyetli olabilir. CNN'ler yüksek hesaplama gücü gerektirirler ve bu nedenle yüksek maliyetli olabilir,
- Başarı düşüklüğü, veri dağılımının düzensizliğinden kaynaklanabilir. CNN'ler, veri dağılımı düzensiz olan veri kümelerinde daha düşük performans gösterebilirler. Bu nedenle, veri kümesinin ön işleme işlemlerine dikkat etmek önemlidir.

4.1.1.1. Konvolüsyonel Sinir Ağlarının Elemanları


Konvolüsyonel sinir ağları görüntüleri sınıflandırmak için kullanılan özel tasarımı sinir ağı türüdür. Girdi katmanı, konvolüsyonel katman, havuzlama katmanı, tamamen bağlı katman ve çıktı katmanı CNN mimarisinin tipik öğeleridir [36]. Ağın nasıl çalıştığını daha iyi kavramak adına sinir ağını oluşturan elemanların daha detaylı açıklamaları bu bölümde paylaşılmıştır. CNN'lerin temel elemanları şunlardır:

- **Girdi katmanı:** CNN'e girdi olarak verilen görüntüyü temsil eder. Girdi katmanı, görüntünün piksel değerlerinden oluşan matrislerdir. Şekil 4.11'de örnek bir görüntünün matris formunda nasıl gözüktüğüne dair görsel yer almaktadır.



Şekil 4.11 Görşelin matris formundaki hali.

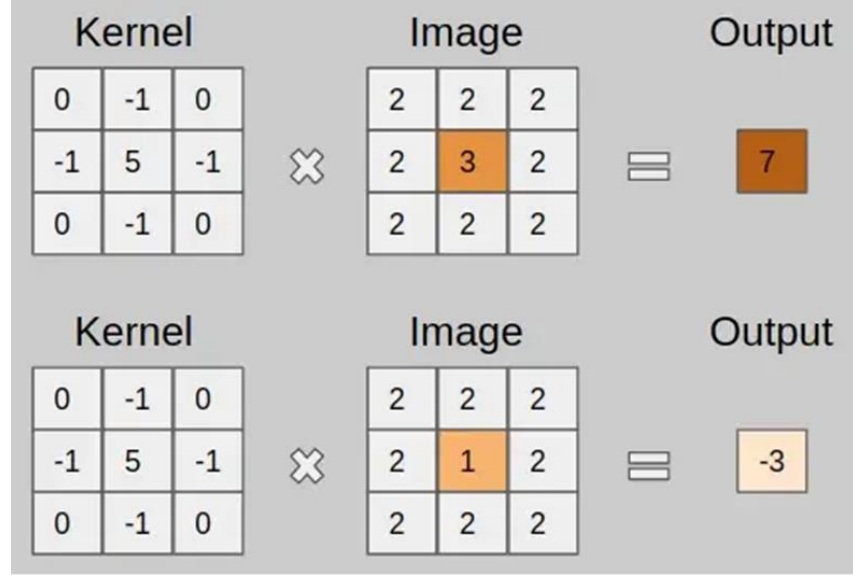
- **Konvolüsyon katmanları:** Konvolüsyon, filtre matrisleri aracılığıyla özellik öğrenmeyi gerçekleştiren ilk ve temel katmandır. Görüntü matrisi ve filtre ile gerçekleştirilen matematiksel bir işlemdir (Şekil 4.12). Filtre tüm görüntü boyunca adım adım hareket ettirilerek özellik haritası üretilir. Bir görüntüye birden fazla filtre uygulanarak farklı özellikler de çıkarılabilir.



Şekil 4.12 Konvolüsyon için gerekli görüntü ve filtre matrisleri.








Bu filtreler, girdi katmanındaki görüntüleri çeşitli şekillerde konvolüsyon uygular ve özellikleri bulmaya yardımcı olur örneğin Şekil 4.12'deki gibi bir girdi görüntüsünden belirli özellikler çıkarılması için bir çekirdek (kernel) kullanılır. Bu çekirdek görüntü boyunca isteğe bağlı şekilde (stride) kaydırılan ve çarpılan bir matristir. Şekil 4.13'de görüntü keskinleştirme için kullanışlı olan bir çekirdek verilmiştir. İlgili hesaplama yapıldıktan sonra ilk görüntü için değer 7'ye çıkarken, ikinci görüntünün değeri -3'e düşmüştür. Böylelikle görüntüde bulunan 3 ve 1 arasındaki contrast farkı 7 ve -3 ile

değişmiştir. Böylelikle görüntüdeki kontrast farkı artarak daha keskin bir görüntü oluşur.




Şekil 4.13 Konvolüsyon işlemi örneği[58]

Bu duruma benzer farklı özellikleri ortaya çıkaran çekirdekler bulunmaktadır ve ilgili özellikteki çekirdek görüntüye uygulandığında çıktılar da değişmektedir. Şekil 4.14’de örnek görüntü üzerine uygulanan filtrelerin ardından ortaya çıkan görüntüler yer almaktadır.

Operation	Filter	Convolved Image
Identity	$\begin{bmatrix} 0 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 0 \end{bmatrix}$	
Edge detection	$\begin{bmatrix} 1 & 0 & -1 \\ 0 & 0 & 0 \\ -1 & 0 & 1 \end{bmatrix}$	
	$\begin{bmatrix} 0 & 1 & 0 \\ 1 & -4 & 1 \\ 0 & 1 & 0 \end{bmatrix}$	
	$\begin{bmatrix} -1 & -1 & -1 \\ -1 & 8 & -1 \\ -1 & -1 & -1 \end{bmatrix}$	
Sharpen	$\begin{bmatrix} 0 & -1 & 0 \\ -1 & 5 & -1 \\ 0 & -1 & 0 \end{bmatrix}$	
Box blur (normalized)	$\frac{1}{9} \begin{bmatrix} 1 & 1 & 1 \\ 1 & 1 & 1 \\ 1 & 1 & 1 \end{bmatrix}$	
Gaussian blur (approximation)	$\frac{1}{16} \begin{bmatrix} 1 & 2 & 1 \\ 2 & 4 & 2 \\ 1 & 2 & 1 \end{bmatrix}$	

Şekil 4.14 Bir deve görüntüsü üzerinden filtrelerle çeşitli özelliklerin çıkarımı [59]


Bu şekilde yapılan taramayla görüntünün herhangi bir yerinde özellik bulunabileceğinden CNN'ler görüntü işleme için oldukça verimli olabilir. Özellik çıkarımı için elle yapılmış çekirdekler kullanmak yerine, Derin CNN'ler aracılığıyla gizli özellikleri çıkarabilen bu çekirdek değerlerini eğitilebilir ve öğrenilebilir bir süreçtir. Böylelikle, istenilen çekirdek değerlerini sistem kendisi belirleyerek optimum değerlerde oluşturacaktır. Öğrenilen çekirdek değerleri ardından çıkarılan özellik haritasına dair örnek görüntü Şekil 4.15'da verilmiştir.



Şekil 4.15 CNN ile özellik haritalarının çıkarılması

Konvolüsyon işlemi için belirttiğimiz üç hiperparametre çıktı boyutunu etkiler. Bu hiperparametreler derinlik, adım ve sıfır doldurmadır [60].

Derinlik: Derinlik, konvolüsyon işlemi için kullanılan filtre sayısına karşılık gelir. Şekil 4.16'da gösterilen ağda, üç farklı filtre kullanılarak tekne görüntüsünün konvolüsyonunu gerçekleştirildiğinden üç farklı özellik haritası üretilir. Bu üç özellik haritası yığılmış 2 boyutlu matrislerdir, bu nedenle özellik haritasının derinliği üç olacaktır.



Şekil 4.16 Özellik haritasının derinliği.


Adım: Adım, filtre matrisimizi giriş matrisi üzerinde kaydığımız piksel adım sayısıdır. Adım bir olarak seçildiğinde, filtreler her seferinde bir piksel hareket eder. Adım iki olduğunda ise filtreler her seferinde iki piksel atlayarak işlemleri gerçekleştirir. Daha büyük bir adıma sahip olmak, daha küçük özellik haritaları ortaya çıkarır.

Sıfır doldurma: Kenar piksellere filtrenin düzgün biçimde uygulanabilmesi için giriş matris sınırlarının etrafını sıfırlarla doldurmak işlem kabiliyeti açısından yarar sağlar. Sıfır dolgunun diğer bir özelliği, özellik haritalarının boyutunu kontrolüne de yardımcı olur. Şekil 4.17’de sıfır doldurulmuş örnek matris yer almaktadır.

0	0	0	0	0	0
0	35	19	25	6	0
0	13	22	16	53	0
0	4	3	7	10	0
0	9	8	1	3	0
0	0	0	0	0	0


Şekil 4.17 Matris üzerinde yapılan sıfır doldurma işlemi

- **Havuzlama katmanları:** Havuzlama katmanı, hesaplama karmaşıklığını azaltmak ve aşırı öğrenmeyi önlemek için gerçekleştirilen aşağı örnekleme işlemidir [61]. Girdiyi küçük bir miktarda değiştirdiğimizde havuzlanmış çıktılar değişmediği kavramına dayanır. Bu katman tipi girdi katmanındaki görüntüleri küçültür ve özelliklerini güçlendirir. Maksimum havuzlama işleminin görseli Şekil 4.18’de verilmiştir.



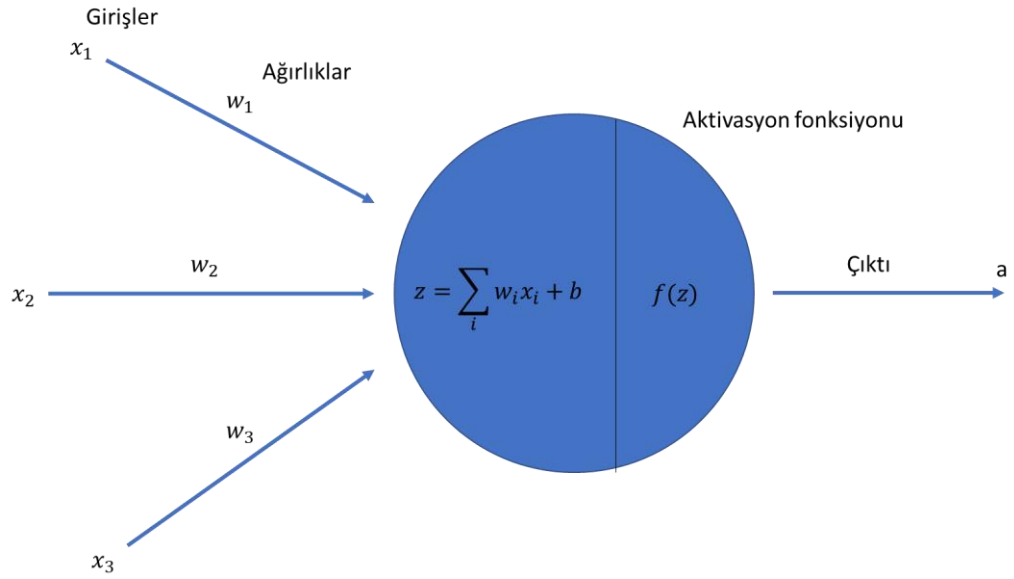
Şekil 4.18 Maksimum havuzlama işleminin matris üzerinde oluşturduğu çıktı.

Ağın daha az parametreyle çalışmasını ve daha iyi özellikler bulmasını sağlar. Minimum havuzlama, ortalama havuzlama veya maksimum havuzlama çeşitleri mevcuttur. Maksimum havuzlama, minimum veya ortalama havuzlamaya kıyasla daha iyi performans sağlamaktadır [62]. Havuzlama işlemi yapılan görüntüden sonra ortaya çıkan örnek görüntü Şekil 4.19’da verilmiştir.



Şekil 4.19 Maksimum havuzlamanın görüntü matrisi üzerinde ortaya çıkardığı değişiklik


Aktivasyon fonksiyonları: Aktivasyon fonksiyonlarının işlevi nöronun etkinleştirilip etkinleştirilmeyeceğine toplam ağırlıklı girdi değerine bağlı olarak karar vermesidir. Bu karar verme görevini ise fonksiyona gelen değerlere göre yapılan matematiksel işlemler ile gerçekleştirir. Böylelikle bir sonraki katmana ilgili değer aktarılmaktadır veya çıktı değeri oluşturulmaktadır (Şekil 4.20). Aktivasyon fonksiyonları farklı matematiksel modellere göre çıktı oluşturur, lineer ve lineer olmayan şeklinde iki ana başlık altında toplanabilir Lineer ve ikili adım aktivasyon fonksiyonları lineer başlığı altında incelenirken, sigmoid, hiperbolik tanjant, ReLU ve Leaky ReLU lineer olmayan aktivasyon fonksiyonları başlığı altında nitelendirilmektedir. Aşağıda kullanılan fonksiyonların içeriklerine yer verilmiştir.



Şekil 4.20 Nöron model yapısı


Lineer aktivasyon fonksiyonu Şekil 4.21’de görüleceği üzere doğrusal ilerlemektedir. Çıktı değerini girdi değeri üzerinde işlem yapmadan döndürmektedir. Fonksiyon denklem 4.1’de verilmiştir ve herhangi bir aralıkta sınırlı değildir.

$$f(x) = y \quad (4.1)$$



Şekil 4.21 Lineer aktivasyon fonksiyonu


İkili adım fonksiyonu ilgili nöronun aktif olup olmayacağına dair kararı eşik değerine göre veren işleve sahiptir (Şekil 4.22). Dezavantajı ise birden fazla degree sahip çıktı sağlayamamasıdır bu bakımdan çoklu sınıflandırma problemleri için uygun bir seçenek değildir. Matematiksel olarak denklem 4.2 ile ifade edilmektedir.



Şekil 4.22 İkili adım aktivasyon fonksiyonu

$$f(x) = \begin{cases} 0 & \text{for } x < 0 \\ 1 & \text{for } x \geq 0 \end{cases} \quad (4.2)$$


Sigmoid fonksiyonu herhangi bir değeri girdi olarak alıp aşağıda verilen matematiksel ifadeye göre 0 ile 1 aralığında çıktı üretir (Şekil 4.23). Giriş değeri büyük sayılara yaklaştıkça sigmoid fonksiyonu da 1'e daha yakın değerler üretirken, giriş değeri ne kadar küçülürse çıkışta 0'a daha yakın değerler çıkar (Denklem 4.3). Yaygın olarak kullanılan fonksiyonlardan biridir özellikle olasılık tahmin edilmesi gereken modeller için uygundur. Olasılık değeri 0 ile 1 arasında olduğu için sigmoid istenilen çıktıları sağlayabilir.



Şekil 4.23 Sigmoid aktivasyon fonksiyonu

$$f(x) = \frac{1}{1 + e^{-x}} \quad (4.3)$$


Hiperbolik tanjant fonksiyonunun işlevi, sigmoid fonksiyonu ile benzer yapıdadır fakat çıktı aralığı -1 ile 1 aralığında değişmektedir (Şekil 4.24). Giriş değeri büyük sayılara yaklaştıkça sigmoid fonksiyonu da 1'e daha yakın değerler üretirken, giriş değeri ne kadar küçülürse çıkışta -1'e daha yakın değerler çıkar (Denklem 4.4).



Şekil 4.24 Hiperbolik tanjant fonksiyonu

$$f(x) = \frac{(e^x - e^{-x})}{(e^x + e^{-x})} \quad (4.4)$$

ReLU fonksiyonu lineer değildir ve en çok kullanılan aktivasyon fonksiyonlarından biridir. Pozitif girdileri aynen döndürürken sıfırdan küçük veya sıfır değeri için 0 döndürmektedir (Şekil 4.25). Grafıksel olarak şu şekilde temsil edilir.



Şekil 4.25 ReLU aktivasyon fonksiyonu

Yukarıda gördüğümüz gibi, ReLU fonksiyonu sadedir ve karmaşık matematik içermediği için ağır hesaplamalar gerektirmez. Bu nedenle modelin eğitilmesi veya çalıştırılması daha az zaman alabilir. Örneğin, görüntülerde insan yüzlerini algılayan bir modelde, kulakları tanımlayabilen bir nöron olabilir ve görüntü bir yüze ait değilse ve bir gemi veya dağa ait ise bu nöronun etkinleştirilmemesi gerektiği açıktır. ReLU, tüm negatif girişler için sıfır çıkış verdiği için, herhangi bir birimin hiç etkinleşmemesi muhtemeldir, bu durum da ReLU ile mümkün olabilir (Denklem 4.5).

$$f(x) = \begin{cases} \max(0, x) & x > 0, \\ 0 & \text{otherwise} \end{cases} \quad (4.5)$$

Sigmoid veya tanh aktivasyon fonksiyonu gibi çoğunlukla ReLU'dan önce kullanılan aktivasyon fonksiyonları doymuştur. Bu, tanh ve sigmoid için sırasıyla büyük değerlerin bire ve küçük değerlerin -1 veya 0'a yapıştığı anlamına gelir. Bu tip fonksiyonlar ikili sınıflandırmalar için daha uygundur. Ayrıca, işlevler, sigmoid için 0,5 ve tanh için 0,0 gibi, girdilerinin orta noktaları etrafındaki değişikliklere gerçekten duyarlıdır. Bu durum kaybolan gradyan problemine neden olur.

Sinir ağırları, gradyan iniş algoritması kullanılarak eğitilir. Gradyan iniş, her iterasyondan sonra kaybı azaltmak ve ağırlıklardaki değişikliği elde etmek için temel olarak zincir kuralı ile geriye doğru yayılma adımını içerir. Ağırlıkların güncellenmesinde türevler önemli bir rol oynamaktadır. Sigmoid veya tanh gibi türevleri -2 ila 2 aralığında yalnızca düzgün değerlere sahip olan ve başka yerlerde düz olan aktivasyon fonksiyonlarını kullandığımızda, artan katman sayısı ile birlikte gradyan azalmaya devam eder. Bu, ilk katmanlar için gradyan değerini azaltır ve bu katmanlar düzgün bir şekilde öğrenemez. Başka bir deyişle, ağırlıkların derinliği ve değeri sıfıra kaydıran aktivasyon nedeniyle gradyanları kaybolma eğilimindedir.

Öte yandan ReLU, girdi büyüdüğünde eğimi düzleşmediği veya "doymadığı" için bu sorunla karşılaşmaz. Bu nedenle ReLU aktivasyon fonksiyonu kullanan modeller daha hızlı öğrenir.


Ancak ReLU aktivasyon fonksiyonunda patlayan gradyan gibi bazı problemler var. Patlayan gradyan, kaybolan gradyanın zıttıdır ve büyük hata gradyanlarının biriktiği ve eğitim sırasında sinir ağı modeli ağırlıklarında çok büyük güncellemelerle sonuçlandığı yerde meydana gelir. Bu durumlarda model kararsızdır ve eğitim verilerinden öğrenemez [63].

Ayrıca, tüm negatif değerler için sıfır olmasının bir dezavantajı vardır ve bir nöron bir kez negatif olduğunda, tekrar değer alması pek olası değildir. Bu tür nöronlar, girdiyi ayırt etmede herhangi bir rol oynamazlar ve esasen yararsızdırlar. Zamanla, ağın büyük bir kısmı hiçbir şey yapmadan kalabilir. Düşük öğrenme oranları genellikle bu sorunu hafifletir. Alternatif olarak, Leaky ReLU kullanılabilir. Sızdıran ReLU fonksiyonu, ReLU'nun geliştirilmiş versiyonudur. ReLU aktivasyon fonksiyonuna gelince, sıfırdan küçük olan tüm giriş değerleri için gradyan 0'dır, bu da o bölgedeki nöronları devre dışı bırakır ve kaybolan ReLU sorununa neden olabilir.

Leaky ReLU bu sorunu çözmek için tanımlanmıştır. Girişlerin (x) negatif değerleri için ReLU aktivasyon fonksiyonunu 0 olarak tanımlamak yerine, onu x 'in son derece küçük bir doğrusal bileşeni olarak tanımlarız. Bu aktivasyon fonksiyonunun formülü Denklem 4.6'da verilmiştir.

$$f(x) = \begin{cases} x, & x > 0 \\ ax, & x \leq 0 \end{cases} \quad (4.6)$$

Bu formül herhangi bir pozitif girdi alırsa aynı değeri döndürür, ancak x 'in herhangi bir negatif değeri için, x 'in 0,01 katı olan çok küçük bir değer döndürür. Böylece negatif değerler için de çıktı verir. Bu küçük değişikliği yaparak, grafiğin sol tarafındaki gradyanın sıfır olmaz. Dolayısıyla artık negatif bölgedeki nöronlar da aktif olabilir (Şekil 4.26).




Şekil 4.26 Leaky ReLU aktivasyon fonksiyonu

SoftMax fonksiyonu çok sınıflı sınıflandırma problemlerinde kullanılmaktadır (Denklem 4.7). Denklem çıktı olarak her sınıf için olasılık değeri verir. N sınıf sayısını temsil eder, i ve j ise sınıfları temsil etmektedir. Çıkış vektörü ise bütün sınıfların olasılık değerini verir.

$$\sigma(\hat{\mathbf{x}})_i = \frac{e^{x_i}}{\sum_{j=1}^N e^{x_j}} \quad (4.7)$$

- **Tam bağlantılı (fully connected) katmanlar:** Tamamen bağlı katmandaki nöronlar normal sinir ağlarına benzer yapıdadır. Kendisinden önce bulunan konvolüsyon katmanı vektörleştirilerek (flatten) tamamen istenilen sayıda nörona bağlanır. Bu katmanlar nöronlar için doğru ağırlıkları öğrenmeye çalışır, görüntüleri ağırlıklar ve bağımlılıklar kullanarak sınıflandırır.
- **Çıktı katmanı:** Bu katman eğitim veri kümesine bağlı olarak, CNN'nin sınıflandırdığı görüntüleri çıktı olarak verir. Her sınıfın olasılık dağılımı bu katmanda Softmax veya Sigmoid fonksiyonlarından sonra belli olur ve girdi katmanındaki görüntüler en yüksek olasılık seçilecek şekilde sınıflandırılır.

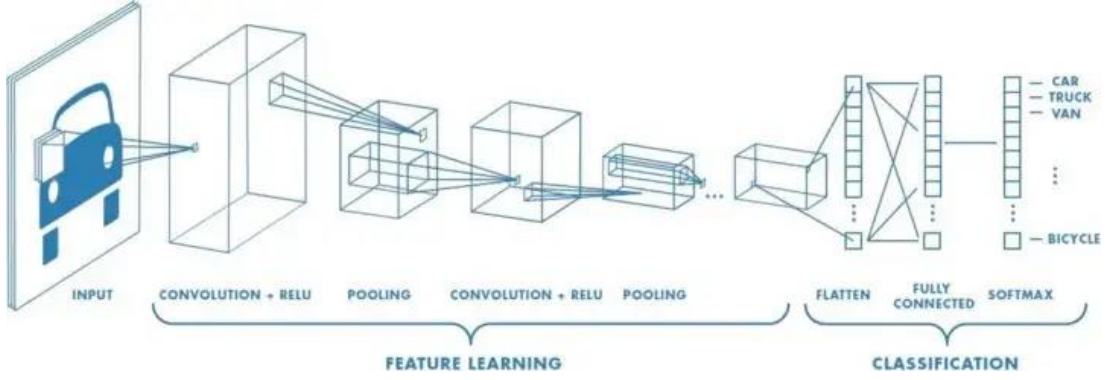


Şekil 4.27 Sınıflandırma Katmanı

Flatten layer, tamamen bağlı katman ve softmax katmanı, bir CNN'in sınıflandırma bölümünün temel yapı taşlarıdır ve birlikte çalışarak sınıflandırmaya yardımcı olurlar (Şekil 4.27).

4.1.1.2 Konvolüsyon Ağlarının Eğitim Süreci

Derin öğrenme modellerinde giriş, konvolüsyon ve havuzlama katmanları görüntüdeki özellikleri bulmak amacıyla işlemler yaparken devamında gelen tam bağlı ve çıktı katmanı sınıflandırma amacıyla çalışmaktadır. Bu katmanlar ardından olasılık değerleri 0 ve 1 arasında olan nesneyi sınıflandırmak için Softmax fonksiyonunu uygulayacaktır. Örnek bir görüntü üzerinde bulunan bir cisim ağın tahmin etmesini istediğimizde ağın oluşturulması ve eğitilmesi gerekir. Eğitimin ardından veriler Şekil 4.28'deki gibi katmanlardan geçerek sistemin tahmini ortaya çıkacaktır.



Şekil 4.28 Görüntünün konvolüsyon ağında izlediği süreç [59]

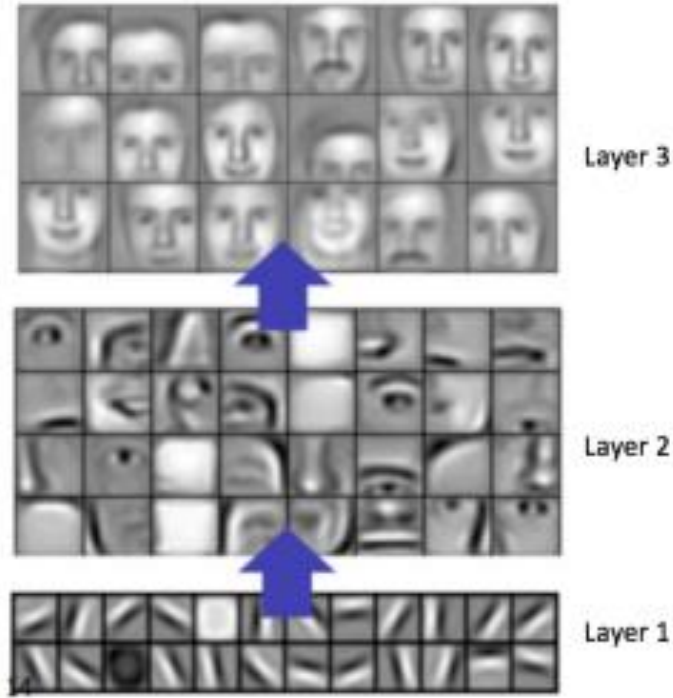
Giriş görüntüsündeki nesneyi ağı öğrenme süreci şu şekilde gerçekleşecektir:

1. Oluşturulan CNN mimarisindeki boyutlara uygun olarak filtre değerleri ve parametreler rastgele atanır.
2. İlk görüntü katmanlardan geçerek mimarideki çıktı sayısına bağlı olarak her sınıf için olasılık değeri oluşturur. İlk sonuçlar rastgele üretilmiş olacaktır.
3. Üretilen çıktıya bağlı olarak gerçek değerden ne kadar sapıldığını gösteren hata hesaplaması yapılır.
4. Ağırlıklar ve diğer parametreler geri yayılım algoritması kullanılarak güncel değerlerini alırlar. Kullanılan optimizasyon algoritmasına (Örn. SGD, GD, ADAM) uygun olarak çıktı hatası azaltılacak şekilde ilerlenir. Parametrelerin optimize edilmesi işleminde, geri yayılım ve gradyan iniş adı verilen bir optimizasyon algoritması aracılığıyla çıktılar ve gerçek etiketleri arasındaki farkı en aza indirecek şekilde eğitim gerçekleşir [3]. Filtre sayısı, filtre boyutları, ağ mimarisi gibi parametreler ilk adımda belirlenir ve eğitim süresince değişmez.
5. Bütün görüntüler için 2.madde ile 5.madde arasındaki işlemler tekrar edilerek optimum filtre değerleri yakalanmaya çalışılır ve ardından test verilerinde sonuçlar kontrol edilir.


4.1.1.3 Konvolüsyon Ağ Katmanlarının Görselleştirilmesi

Derin sinir ağları, gizli katmanlarda daha üst düzey özellikleri öğrenebilir. Bu durum ağın oldukça güçlü yönlerinden birisidir ve özellik mühendisliği ihtiyacını azaltır. Bir SVM ile görüntü sınıflandırıcı oluşturmak istersek ham piksel matrisleri, SVM'yi eğitmek için en iyi girdi değildir, bu nedenle renk, frekans alanı, kenar algılayıcılar vb. temelinde yeni özellik gereksinimi olur. CNN'de ağ, görüntünün ham haliyle beslenir. İlk olarak, görüntü birçok konvolüsyonel katmandan geçer. Bu konvolüsyonel katmanlarda ağ, katmanlarında yeni ve giderek karmaşıklaşan özellikler öğrenir. Daha sonra dönüştürülen görüntü bilgisi, tamamen bağlantılı katmanlardan geçerek bir sınıflandırmaya veya tahmine dönüşür. Görüntü sınıflandırırken, CNN birinci katmanda ham piksellerden basit özellikleri örneğin kenarları algılamayı öğrenebilir, ardından gelen katmanda kenarlar yardımıyla basit şekiller algılanabilir ve sonraki katmanda bu şekilleri yüz şekilleri gibi daha yüksek seviyeli ve karmaşık özellikleri sınıflandırmak amacıyla kullanabilir [14].

Şekil 4.29 ve Şekil 4.30'da girdi görüntüsüne uygulanan konvolüsyon katmanı sayısı arttıkça artan kompleks yapının görselleri yer almaktadır. Bu şekiller anlamlı gözükse de eğitilen ağa bağlı olarak insanlar için anlamı olmayan nesnelere algılayabilir.




Şekil 4.29: Konvolüsyonel nöral ağdan öğrenilen özellikler [64]



Şekil 4.30 Konvolüsyonel sinir ağı tarafından öğrenilen özellik haritalarına dair görseller [65].

Öğrenilen özelliklerin görselleştirilmesi ImageNet veri seti üzerinde eğitilmiş GoogLeNet birçok katmanın ardından nasıl çıkarımlar yaptığını göstermektedir (Şekil 4.30). CNN'in nasıl çalıştığını anlamak adına başka bir örnek olarak, Adam Harley, el yazısı rakamlardan oluşan MNIST veritabanında eğitilmiş bir CNN'in görselleştirmelerini ayrıntıları anlamak adına sunmuştur [66]. Ağın '8' girişi için nasıl çalıştığı Şekil 4.31'de görselleştirilmiştir.



Şekil 4.31 El yazısı rakamlarla eğitilmiş bir ConvNet'i görselleştirme. [66]

Şekil 4.31'de görseli verilen ağda kullanılan giriş görüntüsü 1024 piksel (32×32) görüntü'den oluşmaktadır. İlk konvolüsyon katmanı altı adet benzersiz 5×5 filtrenin giriş görüntüsüne uygulanmasıyla oluşturulur. Görüldüğü üzere altı farklı filtre kullanmak, altı derinlikli özellik haritası üretilir.

Konvolüsyon katmanının ardından gelen altı özellik haritası üzerinde ayrı ayrı 2×2 maksimum havuzlama (adım 2 ile) yapan katmanı takip eder. Maksimum havuzlamada 2×2 filtrenin en yüksek değeri seçilerek sonraki katmana aktarılır (Şekil 4.32). Burada yapılan küçük değişikliklerin görüntünün genelinde büyük değişikliğe yol açmamaktadır.



Şekil 4.32 Havuzlama işlemini görselleştirme. [66].

Ardından tekrar konvolüsyon ve havuzlama katmanları kullanılarak daha kompleks özellikler tespit edilebilir. Ardından tamamen bağlı katmanlar yer alır ve el yazısı rakamlar veriseti için on adet nörona denk gelen son softmax katmanı gerekir. Bizim görselimizde yer alan sekiz sayısının en yüksek olasılığı alması beklenir.

4.1.1.4 Hiperparametreler

Tüm sinir ağı modelleri giriş katmanı ve çıkış katmanı içermektedir, bunlar haricinde derin öğrenme modelinin karmaşıklığı, gizli katman sayısına ve her katmandaki nöron sayısı gibi iki ana hiperparametreye bağlıdır, bu da derin öğrenme modellerini oluşturmak için ayarlanır. Bu iki hiperparametre, veri kümesinin veya problemin karmaşıklığına göre belirlenir. Derin öğrenme modellerinin, aşırı uyumdan kaçınarak amaç fonksiyonlarını modellemek için yeterli kapasiteye sahip olmaları gerekmektedir. Bir sonraki aşamada, belirli işlev türlerinin ayarlanması gereklidir. İlk ayarlanması gereken işlev türü, problem türüne (örneğin, ikili sınıflandırma problemleri için ikili çapraz entropi, çok sınıflı sınıflandırma problemleri için çoklu çapraz entropi ve regresyon problemleri için RMSE gibi) bağlı olarak seçilen kayıp fonksiyonu türüdür. Başka bir önemli hiperparametre, doğrusal olmayan işlevleri modellemek için kullanılan aktivasyon işlevi türüdür ve 'softmax', 'rectified linear unit (ReLU)', 'sigmoid', 'tanh' veya 'softsign' gibi ayarlanabilir. Son olarak, optimizasyon türü stokastik gradyan inişi (SGD), adaptif momentum (Adam), kök ortalama kare yayılımı (RMS) olarak seçilebilir.

Öğrenme hızı, DL modellerinde en önemli hiperparametrelerden biridir. Bu, her iterasyonda adım büyüklüğünü belirler ve amaç fonksiyonunun yakınsamasını sağlar. Büyük bir öğrenme hızı öğrenme sürecini hızlandırır, ancak gradyan yerel bir minimum etrafında salınabilir veya yakınsayamayabilir. Öte yandan, küçük bir öğrenme hızı yumuşak bir yakınsama sağlar, ancak daha fazla eğitim gerektirerek model eğitim süresini artırır. Uygun bir öğrenme hızı, amaç fonksiyonunun makul bir süre içinde global minimuma yakınsamasını sağlamalıdır. Diğer yaygın bir hiperparametre drop-out oranıdır. Drop-out, aşırı öğrenmeyi azaltmak için önerilen bir standart düzenleme yöntemidir. Bu durumda, belirli bir oranda nöron rastgele çıkarılır ve eğitim yapılır. Çıkarılacak nöronların yüzdesi ayarlanması gereklidir.

Mini-batch boyutu ve eğitim verilerinin tamamını geçen tam eğitim dönemi sayısı olan "epochs" diğer hiperparametrelerdir. Mini-batch boyutu, eğitim sürecinin kaynak gereksinimlerini ve iterasyon sayısını etkiler. "Epochs" sayısı eğitim veri setinin büyüklüğüne bağlıdır ve aşırı öğrenmeyi önlemek için değeri uygun seçilmelidir. Belirtildiği üzere birçok hiperparametre bulunmaktadır ve bu parametreler ağın başarısını doğrudan etkilemektedir. En uygun hiperparametre değerlerine ulaşmak için bu değerlerin optimizasyonu gerekmektedir.

Hiperparametre Optimizasyonu

Çok katmanlı yapay sinir ağlarının nasıl tasarlandığı, en yüksek temsil yeteneğine bağlı özellikleri çıkarmak ve seçmek ağın başarısını etkileyen önemli faktörlerdendir [67,68]. Kaç katmandan oluştuğu, katmanlarda yapılan işlemler, kaç nöron içerdiği, aktivasyon fonksiyonu, optimizasyon algoritması seçimi problemin çözümünde oldukça önemlidir. Makine öğrenme modelleri tasarlarken, modelde kullanılan algoritmalar veya teknikler parametre girişi gerektirir ve tasarımcının karar vermesi gereken hiperparametreler de yer alır. En uygun hiperparametrelerin bulunması problem ve veri kümesine göre değişmektedir ve modeli tasarlayan kişinin uygun olan yapıyı bulması gereklidir. En uygun hiperparametre grubunu seçmek, özellikle araştırılması gereken önemli bir sorundur [69]. Hiperparametrelerin seçimi tasarımcının deneyimlerine, farklı alanlardaki uygulamaların kendi problemine etkisine, güncel eğilimlere ve modelin tasarımına bağlı olarak değişmektedir [70]. Bu tür hiperparametreleri seçmek zaman alan ve zahmetli bir süreç olsa da, son zamanlarda bir problemin çözümü için en uygun hiperparametre grubunu seçmek için farklı teknikler geliştirilmiştir [71]. Hiperparametre optimizasyon teknikleri Çizelge 4.1'de altbaşlıklarıyla birlikte verilmiştir.

Çizelge 4.1 Hiperparametre Optimizasyon Teknikleri

Bağımsız Teknikler	Bayesian Optimizasyon	Multi-fidelity Optimizasyon	Gradyan Tabanlı Optimizasyon	Metaheuristic Algoritmalar
Deneme-yanılma(Babysitting)	Gaussian	Successive halving		Genetik Algoritmalar
Alan Tarama(GS)	Random Forest	Hyperband		Particle Swarm Optimizasyon
Rastsal Arama(RS)	Tree-structured Parzen estimator (TPE)	Bayesian Optimizasyon HyperBand		

Hiperparametre optimizasyon teknikleri içerisinde bağımsız teknikler başlığı altında deneme-yanılma (babysitting), alan tarama (Grid Search), rastsal arama (Random Search) yer almaktadır. Deneme-yanılma yöntemi en temel metotlardan olmasının yanı sıra hiperparametreler manuel olarak ayarlanarak ilerlenir. Araştırmacı modelin hiperparametre değerlerini bilgi birikimi, tahmin ve önceki analizlere dayanarak, sonuçtan memnun olana kadar test eder. Problemdaki çözümün manuel ayarlanması birçok hiperparametre, karmaşık model, zaman, lineer olmayan hiperparametre etkileşimi gibi faktörlerden dolayı oldukça zordur. Hiperparametre ayarlanmasındaki bu dezavantajlar hiperparametrelerin otomatik olarak optimize edilmesi için araştırmalara ihtiyacı doğurmuştur [72,73]

GS tekniği en çok kullanılan uygun hiperparametre bulma algoritmalarındandır [74]. GS, kullanıcı tarafından belirlenen sonlu değer kümesini değerlendirir ve verilen hiper-parametre kombinasyonlarının tümünü inceleyen kapsamlı bir arama yöntemi olarak düşünülebilir. GS uygulanabilir ancak temel dezavantajı, yüksek boyutlu hiper-parametre yapılandırma alanı için verimsiz olmasıdır, çünkü hiper-parametre sayısı arttıkça değerlendirmelerin sayısı üssel olarak artar. Bu üssel büyüme maliyetlidir. GS için k parametre bulunursa ve her birinin n farklı değeri varsa, hesaplama karmaşıklığı $O(nk)$ oranında üssel olarak artar [75].

RS, GS'ye benzer ancak arama alanındaki tüm değerleri test etmek yerine, önceden tanımlanmış üst ve alt sınır arasından belirli sayıda örnekleme, aday hiper-parametre değerleri olarak rastgele seçer ve daha sonra bu adaylardan belirlenen süreçte eğitir. RS'nin teorik temeli, yapılandırma alanı yeterince büyükse, o zaman

global optimumlar veya en azından onların yaklaşımlarının tespit edilebileceğidir. Kaynak yeterliliğine göre RS, GS'den daha büyük hiperparametre alanı tarayabilir ve yaklaşık global optimumu tespit edebilir [76]. RS'nin başlıca avantajı, her değerlendirmenin bağımsız olduğu için kolayca paralelleştirilebilir ve kaynak tahsis edilebilir olmasıdır. GS'nin aksine, RS belirtilen dağılımdan sabit sayıda parametre kombinasyonu örnekler, bu da küçük, kötü performans gösteren bölgede çok zaman kaybetme olasılığını azaltarak sistem verimini artırır. RS'de toplam değerlendirme sayısı, optimizasyon süreci başlamadan önce sabit değer n olarak ayarlandığı için, RS'nin hesaplama karmaşıklığı $O(n)$ 'dir [77].

Hiperparametre optimizasyon tekniklerinde gradyan tabanlı algoritmalar, yalnızca sürekli hiper-parametreleri destekledikleri ve konveks olmayan hiperparametre optimizasyon problemleri için yerel optimumu tespit edebildikleri için yaygın bir tercih değildir [78]. Bu nedenle, gradyan tabanlı algoritmalar öğrenme hızı gibi belirli hiperparametreleri optimize etmek için kullanılabilirler.

Bayesian optimizasyon (BO), önceki elde edilen sonuçlara dayalı olarak gelecekteki değerlendirme noktalarını belirler. Bir sonraki hiper-parametre yapılandırmasını belirlemek için BO, iki temel bileşeni kullanır: yerine koyma modeli ve edinim işlevi. Yerine koyma modeli, mevcut tüm gözlemlenen noktaları amaç fonksiyonuna uygun hale getirmeyi amaçlar [79]. Olasılıksal yerine koyma modelinin tahmini dağılımını elde ettikten sonra, edinim işlevi, keşif ve sömürü arasındaki dengeyi sağlayarak farklı noktaların kullanımını belirler. Keşif, örnekleme yapmaktır ve daha önce örnekleme yapılmamış alanlardaki örnekleri içerirken, sömürü, önceki dağılıma dayalı olarak global optimumun muhtemelen gerçekleşeceği şu anki iyi hedef veren bölgelerde örnekleme yapmaktır. BO modelleri, keşif ve sömürü süreçlerini dengeleyerek mevcut en muhtemel optimal bölgeleri tespit etmeye ve keşfedilmemiş bölgelerde daha iyi yapılandırmaları kaçırmamaya çalışır [80].

Hiperparametre optimizasyonlarının önemli sorunu, büyük hiperparametre alanı ve büyük veri kümesi ile artan maliyettir [81]. Çoklu-fidelite optimizasyon teknikleri, sınırlı zaman ve kaynak kısıtlamasını çözmek için yaygın olarak kullanılan yaklaşımlardır. Zaman kazanmak için insanlar, orijinal veri kümesinin bir alt

kümesini veya özelliklerin bir alt kümesini kullanabilirler [82]. Çoklu-fidelite, düşük-fidelite ve yüksek-fidelite değerlendirmelerini içerir ve bunları pratik uygulamalar için birleştirir [83]. Düşük-fidelite değerlendirmelerinde, maliyeti düşük ancak genelleme performansı düşük bir nispeten küçük bir alt küme değerlendirilir. Yüksek-fidelite değerlendirmelerinde, daha iyi genelleme performansı ile daha büyük bir alt küme, düşük-fidelite değerlendirmelerinden daha yüksek bir maliyetle değerlendirilir. Çoklu-fidelite optimizasyon algoritmalarında, kötü performans gösteren yapılandırmalar, her hiper-parametre değerlendirme turundan sonra oluşturulan alt kümelerde değerlendirilmenin ardından elenir ve yalnızca iyi performans gösteren hiper-parametre yapılandırmaları tüm eğitim kümesinde değerlendirilir.

Metaheuristic algorithms, çoğunlukla biyolojik teorilerden ilham alan ve optimizasyon problemleri için yaygın olarak kullanılan bir dizi algoritmadır. Birçok geleneksel optimizasyon yönteminin aksine, metaheuristikler konveks olmayan, sürekli olmayan ve düzgün olmayan optimizasyon problemlerini çözebilme kapasitesine sahiptirler. Popülasyon tabanlı optimizasyon algoritmaları (POA'lar), genetik algoritmalar (GA'lar), evrimsel algoritmalar, evrimsel stratejiler ve parçacık sürü optimizasyonu (PSO) gibi POA türlerini içeren önemli bir metaheuristik algoritma türüdür [84]. POA'lar, her nesilde bir popülasyon oluşturarak başlar ve günceller; her nesildeki her birey, küresel optimum tespit edilene kadar değerlendirilir [85]. Farklı POA'lar arasındaki temel farklar, popülasyonların oluşturulması ve seçilmesi için kullanılan yöntemlerdir [86]. POA'lar, N bireyden oluşan bir popülasyonun en fazla N iş parçacığı veya makine üzerinde paralel olarak değerlendirilebileceği için kolayca paralelleştirilebilirler [87].

4.1.1.5 Konvolüsyonel Sinir Ağ Yöntemlerine Dayalı Modeller

CNN yöntemlerine dayalı ağ modelleri, görüntü işleme üzerine odaklanmış öğrenme yöntemleridir. Bu modellerin ortak noktası mimaride yer alan konvolüsyon işlemi ve görüntülerdeki özellikleri belirlemeye yönelik özel bir tasarıma sahip olmasıdır. Bu tasarım sayesinde veriler üzerindeki anlamlı kısımlar daha az parametreyle daha kompleks özellikler öğrenebilir. Modeller görüntüdeki nesnelere ne olduğu, nasıl

görüldüğü ve ilgili nesnenin segmentasyonu mümkündür. 1990'ların sonlarından 2010'ların başına kadar olan yıllarda konvolüsyonel sinir ağları kuluçka aşamasındaydı. Daha fazla veri ve bilgisayar gücü kullanılabilir hale geldikçe, konvolüsyonel sinir ağlarının üstesinden gelebileceği görevlerin de karmaşıklığı arttı. CNN ile geliştirilmiş mimari, bilgi işlem gücü yardımıyla çok daha karmaşık nesnelerin ve nesne hiyerarşilerinin öğrenilmesine olanak tanır. Aşağıda kronolojik olarak CNN yöntemlerine dayalı kullanışlı ağ modelleri ve özelliklerinden bahsedilmektedir.

- LeNet: Yann LeCun tarafından 1998 yılında geliştirilen ilk CNN ağıdır [88]. El yazısı sayıların tanınması görevini çözmek için bu ağ kullanılmıştır.
- AlexNet: Alex Krizhevsky, Ilya Sutskever ve Geoffrey Hinton tarafından 2012 yılında geliştirilmiştir [89]. Önceki yaklaşımlara ve CNN'lerin mevcut yaygın uygulamasına kıyasla büyük ölçekli görsel (ImageNet) tanıma yarışmasında (ILSVRC) ilk defa kullanılarak üstün performans göstermiştir.
- ZFNet: Matthew D. Zeiler ve Rob Fergus tarafından 2013 yılında geliştirilmiştir [90]. AlexNet'in temel alınarak tasarlanmış ve daha az katman ile gelişme sağlanmıştır. Mimari hiperparametrelerini değiştirerek AlexNet'te bir gelişme sunmuşlardı.
- GoogleLeNet: LeNet ağ tasarımının etkileriyle Google tarafından 2014 yılında geliştirilmiştir [91]. Google Street View görüntülerinin sınıflandırılmasında bu ağ kullanılmıştır. Ana katkısı, ağdaki parametre sayısını önemli ölçüde azaltan başlangıç modülünün geliştirilmesiydi. (60M ile AlexNet'e kıyasla 4M).
- VGGnet: Oxford Üniversitesi tarafından 2014 yılında geliştirilmiştir [92] ve "Very Deep Convolutional Networks for Large-Scale Image Recognition" (Büyük Ölçekli Görüntü Tanıma için Çok Derin Konvolüsyonel Ağlar) adlı makalede tanımlanmıştır. Çok katmanlı bir yapıda ve çok sayıda filtre içerir, ayrıca görüntü tanıma görevlerinde yüksek performans göstermektedir. Ağın

derinliğinin (katman sayısı) iyi performans için kritik bir bileşen olduğunu göstermesiyle katkı sağlamıştır.

- Resnet: Kaiming He, Xiangyu Zhang, Shaoqing Ren ve Jian Sun tarafından geliştirilmiştir [93] ve "Deep Residual Learning for Image Recognition" (Görüntü Tanıma için Derin Residüel Öğrenme) adlı makalede tanımlanmıştır. Bu ağ, aşırı öğrenme (overfitting) problemine karşı dayanıklıdır ve görüntü tanıma görevlerinde yüksek performans göstermektedir.

CNN, tipik olarak konvolüsyon, havuzlama ve tamamen bağlı katmanlar olmak üzere üç tür katmandan oluşan matematiksel bir yapıdır. Konvolüsyon ve havuzlama katmanları özellik çıkarımı gerçekleştirirken, çıkarılan özellikler aşamalı olarak daha karmaşık hale gelebilir. Tamamen bağlantılı olan üçüncü katman, çıkarılan özellikleri sınıflandırma gibi nihai sonucu tahmin eder. Bu şekilde geliştirilen mimari, bilgi işlem gücü yardımıyla çok daha karmaşık nesnelerin ve nesne hiyerarşilerinin öğrenilmesine olanak tanır.

4.1.2 Sınıflandırma Modellerinde Başarı Kriterleri

Karmaşıklık matrisi, bir sınıflandırma algoritmasının performansını değerlendirmek için kullanılan bir tablodur. Bir sınıflandırma problemindeki tahmin sonuçlarının bir özetidir ve her sınıf için doğru ve yanlış tahminlerin sayısını gösterir. Bir algoritmanın performansını görselleştirmeye ve geliştirmeye yardımcı olabilecek kalıpları belirlemeye olanak tanır. Karmaşıklık matrisi, bir sınıflandırma algoritmasının performansını anlamak için yararlı bir araçtır ve kötü performans gösterdiği alanları belirleyerek algoritmanın iyileştirilmesine yardımcı olmak için kullanılabilir.

Matrisin satırları gerçek sınıf etiketlerini temsil ederken, sütunlar tahmin edilen sınıf etiketlerini temsil eder. Köşegen öğeler, her sınıf için doğru tahminlerin sayısını temsil ederken, köşegen dışı öğeler, yanlış tahminlerin sayısını temsil eder. Bir sınıflandırma probleminde tahmin edilen sınıf etiketlerinin ve gerçek sınıf

etiketlerinin bir özetidir. Gerçek Pozitif (TP), Yanlış Pozitif (FP), Yanlış Negatif (FN) ve Gerçek Negatif (TN) elemanlarından oluşan matris örneğimizde dört eleman ile temsil edilmektedir. Çizelge 4.2’de hata matrisi elemanlarının yerleri verilmiştir ve matris elemanlarını daha ayrıntılı ifade edecek olursak;

Çizelge 4.2 Hata Matrisi Elemanları – L2

		TAHMİN				
		L1	L2	L3	L4	L5
GERÇEK	L1	TN	FP	TN	TN	TN
	L2	FN	TP	FN	FN	FN
	L3	TN	FP	TN	TN	TN
	L4	TN	FP	TN	TN	TN
	L5	TN	FP	TN	TN	TN

TP, bir testin pozitif sonucu vermesi durumunda testin gerçekten pozitif olan bir kişiyi doğru olarak pozitif olarak tanımladığı anlamına gelir. Örneğin, bir COVID-19 testi pozitif çıktığında ve kişinin gerçekten COVID-19'a sahip olduğu tespit edildiğinde, bu durum bir TP olarak kabul edilir.

FP, bir testin pozitif sonucu vermesi durumunda testin gerçekten negatif olan bir kişiyi yanlış olarak pozitif olarak tanımladığı anlamına gelir. Örneğin, bir COVID-19 testi pozitif çıktığında ancak kişinin gerçekten COVID-19'a sahip olmadığı tespit edildiğinde, bu durum bir FP olarak kabul edilir.

FN, bir testin negatif sonucu vermesi durumunda testin gerçekten pozitif olan bir kişiyi yanlış olarak negatif olarak tanımladığı anlamına gelir. Örneğin, bir COVID-19 testi negatif çıktığında ancak kişinin gerçekten COVID-19'a sahip olduğu tespit edildiğinde, bu durum bir FN olarak kabul edilir.

TN, bir testin negatif sonucu vermesi durumunda testin gerçekten negatif olan bir kişiyi doğru olarak negatif olarak tanımladığı anlamına gelir. Örneğin, bir COVID-19 testi negatif çıktığında ve kişinin gerçekten COVID-19'a sahip olmadığı tespit edildiğinde, bu durum bir TN olarak kabul edilir.

Karışıklık matrisinde hassasiyet, gerçek pozitif oran (TPR) veya geri çağırma (recall) olarak da bilinir. Model tarafından yapılan gerçek pozitif tahminlerin sayısının veri setindeki toplam gerçek pozitif vaka sayısına bölünmesi olarak tanımlanır.

Duyarlılık (Sensitivity), geliştirilen uygulamanın hedeflenen nesnenin doğru bir şekilde tespit etme yeteneğini ifade eder. Bir hastalığın teşhisi veya bir güvenlik tehdidinin tespiti gibi yanlış negatiflerin yanlış pozitiflerden daha maliyetli veya zararlı olduğu durumlarda önemlidir. Örneğin, nadir görülen bir hastalık için yapılan tıbbi bir testin hassasiyeti yüksekse, hastalığa sahip hastaların çoğunu doğru bir şekilde tespit edebilecektir. Bu oran önemlidir çünkü testin, hasta için ciddi sonuçlar doğurabilecek hastalık vakalarını gözden kaçırma olasılığının düşük olduğu anlamına gelir. Öte yandan, düşük duyarlılığa sahip bir test birçok hastalık vakasını gözden kaçırabilir ve yanlış negatif sonuçlara neden olabilir. Bir karışıklık matrisinde duyarlılık denklem 4.9 kullanılarak hesaplanır:

$$Duyarlılık = \frac{TP}{TP+FN} \quad (4.9)$$

Özgüllük (Specificity), bir testin negatif sonuçlarının doğruluğunu ölçer. Yani, bir testin özgüllük değeri, o testin gerçekten negatif olan bir kişiyi doğru olarak negatif olarak tanımlama ihtimalini gösterir. Örneğin, bir COVID-19 testinin specificity değeri yüksekse, bu testin gerçekten COVID-19'a sahip olmayan kişileri doğru olarak negatif olarak tanımlama ihtimali de yüksek demektir.

Özgüllük değerini hesaplamak için TN değerini, TN ve FP değerlerinin toplamına böleriz. Specificity değeri denklem 4.10 şeklinde hesaplanır. Bu değer yüksek olduğu için testin negatif sonuçlarının doğruluğu yüksektir.

$$\text{Özgüllük} = \frac{TN}{TN+FP} \quad (4.10)$$

Doğruluk başarısı (Accuracy), bir testin veya modelden elde edilen sonuçların doğruluğunu ölçer. Yani, accuracy değeri, bir testin veya modelin doğru sonuçlar verme ihtimalini gösterir. Örneğin, bir COVID-19 testinin accuracy değeri yüksekse, bu testin gerçekten COVID-19'a sahip olan ve olmayan kişileri doğru olarak tanımlama ihtimali de yüksek demektir.

Doğruluk başarısı değerini hesaplamak için TP ve TN değerlerini toplayıp, bütün değerlerin toplamına böleriz. Accuracy değeri denklem 4.11'de belirtilen şekilde hesaplanır:

$$\text{Doğruluk} = \frac{TP+TN}{TP+TN+FP+FN} \quad (4.11)$$

Doğruluk değeri 0 ile 1 arasında bir değerdir ve yüksek değerler tahminlerin daha doğru sonuçlar verdiği anlamına gelir.

4.2. TRANSFER ÖĞRENME

Transfer öğrenme, makine öğrenmesi alanında son yıllarda oldukça popüler hale gelmiştir. Bu yöntem, daha önce bir görev için eğitilmiş bir modelin, farklı bir probleme uyarlanmasını sağlar. Örneğin, bir ağ, araç tespiti yapan bir sınıflandırıcı olarak eğitilmiş olabilir. Ancak aynı ağın, tırları sınıflandırmak için de kullanılabilmesi mümkündür. Transfer öğrenmenin avantajlarından biri, daha az veriye sahip olan yeni bir görevde bile başarılı sonuçlar elde edebilmesidir. Bunun nedeni, önceden yüksek sayıda veri ile eğitilmiş bir ağın, belirli bir konuda genelleştirme yeteneğine sahip olmasıdır. Yani, bir görevde uzmanlaşan ağın, bu uzmanlığını başka bir görev için de kullanabilmesidir. Öğrenme işlemi en baştan almak yerine, önceden belirlenmiş ağırlıkların kullanılması, eğitim sürecinin daha hızlı ve daha az kaynak tüketmesine olanak tanır. Bu nedenle, özellikle büyük ölçekli veri setleri ile çalışan uygulamalarda, transfer öğrenmenin kullanımı oldukça yaygındır.

Transfer öğrenme genellikle, görüntü işleme ve doğal dil işleme gibi alanlarda kullanılır. Örneğin, bir görüntü sınıflandırıcısı, farklı bir görüntü sınıflandırma görevi için uyarlanabilir. Aynı şekilde, bir dil modeli, farklı bir doğal dil işleme görevi için de kullanılabilir. Transfer öğrenme, makine öğrenmesi alanında oldukça yararlı bir tekniktir. Eğitim verilerinin etiketli olması, modelin doğruluğunu artırır ve daha iyi sonuçlar elde etmesini sağlar. Ancak, etiketli veri toplamak her zaman kolay değildir. Transfer öğrenimi, önceden eğitilmiş modellerin etiketlenmiş verileri kullandığı için bu sorunu da çözmüş olur. Önceden eğitilmiş modellerin kullanımını sayesinde, yeni görevler için yalnızca son katmanların tekrar eğitilmesiyle yapılabilir. CNN, ilk katmanlarda köşeleri tespit ederken, orta katmanlarda şekilleri, son katmanlarda ise göreve özel spesifik özellikler bulunur. Transfer öğrenme bu noktada yalnızca son katmanların tekrar eğitilmesi ile öne çıkmaktadır. Ayrıca daha önce eğitilmiş etiketli verisetinin de avantajını kullanmış olur. Yani önceki verisetinde bulunan yararlı bilgiler bu şekilde yeni göreve transfer edilmiş olur. En önemli avantajı ise eğitim zamanının azalması, iyi performans ve daha az veriyle de iyi performans sunabilmesidir.

Transfer öğrenmede iş akışı şu şekilde ilerlemektedir.

- Önceden eğitilmiş ağı seçimi yapılır,
- Daha önce büyük ve genel veri setiyle eğitilmiş ağı katmanlarını al,
- Bu katmanları dondur,
- Eğitilebilir yeni katmanlar ekle,
- Yeni veri setiyle eğitimi gerçekleştir.

Öncelikle, transfer öğrenme işlemi için kullanılacak önceden eğitilmiş ağı seçimi yapılır. Bu ağ, genellikle büyük ve genel bir veri seti üzerinde eğitilir ve yüksek performans gösterir. Daha sonra, bu önceden eğitilmiş ağı belirli katmanları alınarak, transfer öğrenme modelinin temeli oluşturulur. Bu katmanlar, özellik çıkarma işlemi için kullanılacaktır. Bu katmanlar dondurulur, çünkü daha önce eğitildikleri veri setindeki özellikleri öğrenmişlerdir ve bu özellikler, yeni veri setinde de geçerli olabilir. Daha sonra, transfer öğrenme modeline yeni eğitilebilir katmanlar eklenir. Bu katmanlar, yeni veri setine uyum sağlamak ve veri setinin

özelliklerine göre öğrenme işlemini gerçekleştirmek için kullanılacaklardır. Bu şekilde, önceden eğitilmiş ağı özellikleri ve yeni eğitilebilir katmanların öğrenme yetenekleri birleştirilerek yeni bir model oluşturulur ve yeni veri setinde eğitilir. Eğitim sırasında, önceden eğitilmiş ağı katmanları dondurulduğu için bu katmanlar üzerinde yapılan değişiklikler, önceden öğrenilmiş özellikleri etkilemez.

Son olarak, eğer yeni veri setine daha iyi adapte olmak isteniyorsa, ince ayar işlemi yapılabilir. Bu işlemde, önceden eğitilmiş ağı tüm katmanları veya belirli bir kısmı eğitime açılır ve düşük öğrenme katsayısı ile yeni veri seti ile birlikte tekrar eğitilir. Bu sayede, önceden öğrenilmiş özelliklerin yanı sıra yeni veri setindeki özellikler de modele eklenir ve daha iyi performans elde edilir [94].

BÖLÜM 5

MATERYAL

5.1. DENTİN TÜBÜL GÖRÜNTÜLERİNİN ALINMASI

Dentin üzerinde yapacağımız çalışma Karabük Üniversitesi Etik Kurulu tarafından (2021/531, 4/8/2021) onaylandı ve hastalar çalışmaya dahil edilmeden önce imzalı bilgilendirilmiş onam verdiler. Çalışmaya periodontal veya ortodontik nedenlerle çekilmiş toplam 96 adet üçüncü büyük azı dişi dahil edilmiştir. Dişlerin hiçbirinde çürük veya restorasyon bulunmamaktadır.

5.1.1. Dişlerden Dentin Disklerin Çıkarılması

Çekilmiş dişler çeker ocak içerisinde tüm organik maddelerden arındırılarak iki hafta boyunca 4 °C'de 0.15 M NaCl çözeltisinde korunmuştur. Secotom-50, Struers kesme cihazı düşük devirde ve su soğutmalı şekilde ayarlanarak elmas disk (Ø 125 mm × 0.35 mm × 12.7 mm, 33°C) ile dişlerin uzun eksenine dik olacak şekilde her diştin dentin diski çıkarılmıştır. Diskler çıkarılırken koronal enamel ve diş pulpasından ayrı olacak şekilde olmasına dikkat edilmiştir ve diskler 1.05 mm ±0.18 kalınlıklarındadır. Şekil 5.1'de diştin dentin disk çıkarma işlemi görselleştirilmiştir. Disklerin yüzey üzerindeki girintili çıkıntılı alanların giderilmesi, homojen yüzeylere sahip olması gerekliliği ve alacağımız görüntülerin kalitesinin artması gerektiği için bütün dentin diskler metalografik işleme tabi tutulmuştur. Metalografik işlem sırasında 200, 300, 400 ve 600 tane boyutlarına sahip SiC kağıdı ve 3µm elmas pasta kullanılmıştır (Şekil 5.2). Yüzey temizliği ve düzleştirilmesi yapıldıktan sonra, distile suda bekletilmiştir ve ardından yüzey temizliği sırasında kalan partiküllerin giderilmesi için 10 dk boyunca çalkalanmıştır.



Şekil 5.1 Dentin disklerin Struers Secotom – 50 kesme cihazı ile dişten çıkarılması



Şekil 5.2 Struers Tegramin-30 zımparalama ve parlatma cihazı

Metalografik işlemlerin ardından dentin diskler tekrar saf su ile yıkandı ve yabancı maddeleri uzaklaştırmak amacıyla 20 dakika ultrasonic temizleyicide bekletilmiştir. Ardından dentin diskleri %37,5 ortofosforik asit solüsyonunda bekletilerek dentin tübüllerinin açılması amaçlanmıştır. Tübüller açıldıktan sonra dentin diskleri tekrar saf su ile yıkayıp, ultrasonik temizleyiciye bırakılmıştır (Şekil 5.3) ve böylelikle ortofosforik kalıntısı da dentin disklerden uzaklaştırılmıştır.



Şekil 5.3 Ultrasonik temizleyici

5.1.2. Duyarsızlaştırıcı Ajanların Dentin Disklere Uygulanması

Dentin diskleri etkileyen ve duyarsızlaştırıcı etkiye sahip ajanlar, dentin tübüllerini tıkayıp diş hassasiyetinin yönetimi için kullanılmaktadır. Dişlerden çıkarılan ve bir önceki bölümde ayrıntıları verilen işlemlerden sonra hazırlanan dentin diskler 16 disk içerecek şekilde altı gruba ayrıldı (Şekil 5.4). Üreticilerin talimatları göz önünde bulundurularak Teethmate® ve Smartprotect® ilk iki disk grubuna uygulandı. Üçüncü, dördüncü ve beşinci gruplara Novamin®, arginin-kalsiyum karbonat ve %1.4 potasyum-oksalat uygulandı. Altıncı grup ise kontrol olarak kabul edildi ve bu gruptaki diskler herhangi bir ajana maruz bırakılmadan yalnızca NaCl çözeltisine maruz bırakıldı.



Şekil 5.4 Metalografik işlemlerin ardından çıkarılan dentin disk

Duyarsızlaştırıcı ajanlara maruz bırakılan dentin diskleri petri kabına alınarak %6'lık bir $C_6H_8O_7$ çözeltisine bir dakika boyunca konuldu ve ardından iki dakika süresince salin içerisinde durulandı. Dentin diskler çeşitli duyarsızlaştırıcı ajanlara maruz bırakılarak tübüllerin tıkanması üzerindeki etkilerinin farklı olması amaçlanmıştır. Çeşitli seviyelerde dentin oklüzyonu oluşturmak, oluşturulacak veri seti için daha fazla ayırt edici bilgi sağlamaktadır.

5.1.3. SEM Görüntülerinin Alınması

Duyarsızlaştırma ajanları dentin disklere uygulandıktan sonra SEM analizine uygun hale gelmesi için kaplama işlemi yapılması gereklidir. Bu işlem için vakum ortamında Au-Pd alaşımı ile kaplanmıştır (Şekil 5.5 - Q150R Rotary-Pumped Sputter Coater, Quorum). Şekil 5.6'da kaplanmış dentin disklerin görüntüsü bulunmaktadır.



Şekil 5.5 Q150R Rotary-Pumped sputter coater (kaplama cihazı)




Şekil 5.6 Kaplama yapıldıktan sonra dentin disklerin görüntüsü

Dentin disklerinden görüntülenebilen dentin tübülleri taramalı elektron mikroskobu ile elde edilmiştir (Şekil 5.7 - Carl Zeiss Ultra Plus Gemini FE-SEM, Zeiss). 3000x büyütme ile rastgele alınan görüntüler yüzey morfolojisinin değerlendirilmesinde kullanılmıştır.




Şekil 5.7 Carl Zeiss Ultra Plus Gemini FE-SEM cihazı


Şekil 5.8 ve Şekil 5.11 arasında SEM cihazından alınan örnek görüntülere yer verilmiştir. Çeşitli tiplerde kullandığımız duyarsızlaştırma ajanlarının dentin tübülleri üzerinde farklı etkiler oluşturması ve kullanılacak veri setinin daha geniş yelpazede bilgi verebilmesi için çok sayıda görüntü almaya özen gösterilmiştir.




Şekil 5.8 Dentin tübüllerinin örnek SEM görüntüsü



Şekil 5.9 Dentin tübüllerinin örnek SEM görüntüsü



Şekil 5.10 Dentin tübüllerinin örnek SEM görüntüsü



Şekil 5.11 Dentin tübüllerinin örnek SEM görüntüsü

BÖLÜM 6

METOT

6.1 VERİ SETİ

Dentin disklerinden elde edilen 2795 adet dentin tübülü görüntüsü 48x48 çözünürlükte gri tonlamalı biçimde kaydedildi. Yapılan literatür taramasındaki araştırmalarda da öne çıkan sınıflandırma değerlendirmesi açısından, dentin tübül tıkanıklıkları 1 ile 5 arasında görsel bir puanlama indeksi kullanılması kararlaştırılmıştır [95–97]. Puanlama indeksine göre: L1 tıkanmamış (%0, tübül tıkanıklığı yok); L2 az miktar tıkanmış (tübüllerin <%25'i tıkalı); L3 kısmen tıkalı (tübüllerin %25–<50'si tıkalı); L4 çoğunlukla tıkalı (tübüllerin %50–<100'ü tıkalı); L5 tıkalı (tübüllerin %100'ü tıkalı) şeklindedir.






Daha sonra, tüm gruplardaki dentin tübül tıkanıklıkları, iki bağımsız uzman tarafından beş sınıfta değerlendirilmiştir. Uzmanlar arasındaki uyumu niteliksel olarak ölçmek için Cohen's kappa testi yapılmıştır. Araştırmacılar, >0.80'lik bir uyum göstererek, güçlü bir uyum düzeyine işaret etmiştir [98]. Derin öğrenme yöntemleri ile doğru bir sınıflandırma yapabilmek için sınıfların veri dağılımının birbiriyle dengelenmesi gerekir. Aksi takdirde, doğru sınıflandırma sağlamak için çoğu standart algoritmanın performansı önemli ölçüde azalır [99]. Örneklem azaltma, bu sorunun üstesinden gelmenin çözümlerinden biridir. Bu çalışmada dentin disklerinden elde edilen görüntüler diğer üç sınıfa göre yüksek sayıda L1 ve L5 verisine sahiptir. Bu nedenle, veri sayısını diğer sınıflara göre dengelemek için 560 tanesi L1 ve L5 sınıflarından rastgele seçilmiştir. L2, L3 ve L4'ün diğer sınıflara ait veri sayısı sırasıyla 558, 558, 559 görüntüyü içermektedir. Daha sonra veri seti eğitim (%85) ve test seti (%15) olarak ikiye ayrılmıştır.


6.2 VERİ ARTIRMA

Sınırlı veri kümeleri, derin öğrenme modellerinin genelleme performansını düşüren zorluklardan biridir. Büyük veri sağlandığında, CNN ile görüntü analizi görevleri, özellikle tıp alanında çok güçlüdür [100,101]. Veri artırma, bu sorunu çözmeye yardımcı olan tekniklerden biridir. Bu teknikte, eğitim veri kümesinin çeşitliliğini ve veri miktarını artırmak için orijinal verilerin biraz değiştirilmiş kopyaları oluşturulur. Böylece model daha fazla özellik çıkarabilir ve öğrenme oranını iyileştirebilir.

Basit görüntü tabanlı veri büyütme genellikle iyi performans gösterir ve bilgisayarla görme uygulamalarının performansını artırır [102]. Bu çalışmada, dentin tübülü görüntülerinin sayısını artırmak için çeşitli geometrik dönüşümler (Döndürme, Kesme, Çevirme, Ölçekleme) uygulanmıştır (Şekil 6.1). Veri artırma işlemi ile toplam 10700 görüntü elde edilmiş ve CNN'in eğitiminde kullanılmıştır. Her sınıfa ait örnek görüntüler ve her sınıfa ait oluşturulan veri kümesinin özellikleri Çizelge 6.1'de verilmiştir.

Çizelge 6.1. Üretilen veri setinin özellikleri.

Özellik\Sınıf	L1	L2	L3	L4	L5	Toplam
Örnek Görüntü						
Görüntü Sayısı	560	558	558	559	560	2795
Eğitim Seti	428	427	427	428	427	2137
Veri Artırma	2140	2140	2140	2140	2140	10700
Validasyon Seti	48	47	47	47	49	237
Test Seti	84	84	84	84	84	420
Kanal Sayısı				1		
Çözünürlük				48 × 48		



Şekil 6.1. Veri artırma işleminden sonra oluşturulan örnek görüntüler.


6.3 ÖNERİLEN CNN MİMARİSİ

Belirli bir problem için en iyi performans gösteren CNN'i seçmek oldukça zordur ve ağıın başarısını doğrudan etkiler. Örneğin, daha geniş bir ağı daha anlamlı sonuçlara yol açabilir, ancak hesaplama açısından çok daha masraflıdır. Öte yandan, ağı çok sığsa, doğru özellikler öğrenilemeyebilir. Hesaplama yükünü kabul edilebilir kılmak için, ağı tasarlanırken konvolüsyon katmanlarının sayısı, adımların uzunluğu ve filtrelerin boyutu dikkate alınır. Elde edilen görüntüler üzerinde en iyi sınıflandırma performansını gösteren CNN mimarisini tasarlamak ve sinir ağıının hiperparametrelerini uygun şekilde ayarlamak için veriler üzerinde birçok model eğitmek gerekmektedir. Veriler üzerindeki en iyi performans gösteren ağı oluşturmak için ağıda kullanılacak katmanlara karar verilmeli ve hiperparametrelerin uygun şekilde ayarlanması gereklidir. Görüntü verisetimizde ağı tarafından örüntülerin daha iyi anlaşılabilmesi için konvolüsyon katmanları kullanıldı. Konvolüsyon katmanları özellikle görüntü sınıflandırma konusunda da oldukça kullanışlıdır. Az sayıda konvolüsyon katmanı kullanmak görüntü üzerindeki gerekli bilgileri tam olarak çıkaramayabilirken, fazla sayıda katman kullanmak ağıın görüntüleri ezberlemesine (over-fitting) yol açabilir. Bu bakımdan VGG ağıında da kullanılan konvolüsyon-konvolüsyon-havuzlama tipi ağı yapısı ile ana hatlar oluşturulup doğruluk değerleri incelenmiştir. Bölüm 7 Deneysel Sonuçlar ve Tartışma kısmında ağıın geliştirilirken yapılan araştırmalarla ilgili süreç, hiperparametreler ve sonuçlar ayrıntılarıyla paylaşılmıştır. Bu süreçte K-fold çapraz doğrulama yöntemi kullanılarak ağıın veri setinin tamamında başarılı sonuçlar elde edip etmediğı gözlemlenirken, hiperparametrelerin optimum değerine ayarlanması için alan taraması (GS) tekniğı kullanılmıştır. GS tercih edilmesinin sebebi, olabilecek bütün hiperparametre kombinasyonlarının denenerek en iyi modelin ayarlanmasıdır. Bu yöntemde bütün kombinasyonlar deneneceğı için yoğun bir tarama gerçekleştirilir, bu durum da

maliyetlidir ve oldukça zaman alır. Yapılan taramanın ardından elde edilen ağ parametrelerinin önerilen yapısının ayrıntıları Çizelge 6.2'de ve Şekil 6.2'de paylaşılmıştır.

Çizelge 6.2. 48x48 gri skala görüntülerin kullanıldığı önerilen CNN mimarisi.

Layer Type	Kernel	Stride	Padding	Activation	Rate	Output Shape	Parameters
Convolution	3×3	1	same	ReLU	-	$48 \times 48 \times 16$	160
Convolution	3×3	1	same	ReLU	-	$48 \times 48 \times 16$	2320
Max-Pooling	3×3	3	-	-	-	$16 \times 16 \times 16$	-
Dropout	-	-	-	-	0.2	$16 \times 16 \times 16$	-
Convolution	5×5	1	same	ReLU	-	$16 \times 16 \times 32$	12,832
Convolution	5×5	1	same	ReLU	-	$16 \times 16 \times 32$	25,632
Max-Pooling	2×2	2	-	-	-	$8 \times 8 \times 32$	-
Dropout	-	-	-	-	0.8	$8 \times 8 \times 32$	-
Flatten	-	-	-	-	-	$1 \times 1 \times 2048$	-
Fully-Connected	-	-	-	-	-	$1 \times 1 \times 256$	524,544
Dropout	-	-	-	-	0.5	$1 \times 1 \times 256$	-
Fully-Connected	-	-	-	SoftMax	-	$1 \times 1 \times 5$	1285



Şekil 6.2 Önerilen CNN mimarisi katmanları

Birinci ve ikinci konvolüsyon katmanlarında, geniş alıcı alan elde etmek amacıyla 48x48 tek kanallı gri tonlamalı görüntüler 16 farklı 3 x 3 çekirdek ve 1 adım ile taranmıştır. Daha fazla katman ile küçük çekirdek boyutu, daha büyük bir çekirdek ile daha az katmana göre daha karmaşık özelliklerin haritalanmasını sağlar. Dolgu değeri, görüntülerin kenarında yer alan daha fazla bilgiyi çıkarmak için tüm konvolüsyonel katmanlar için aynı olarak belirlenmiştir. ReLU aktivasyon fonksiyonu tüm konvolüsyon katmanlarının ardından uygulanmıştır.

Konvolüsyon işlemi katmanlarından sonra maksimum havuzlama katmanı parametre sayısını düşük tutarak aktivasyon haritalarını özetlemiştir. Böylece 16 farklı 16 x 16 özellik haritası elde edilmiş ve 0.2 oranındaki dropout katmanı, seçilen nöronları rastgele aktive ve deaktive ederek aşırı öğrenmeyi önlemeye gelmiştir. Önerilen mimarinin başlangıcında olduğu gibi, beşinci ve altıncı katmanlar da 5 x 5 çekirdek boyutu ve ReLU aktivasyon fonksiyonu ile benzer konvolüsyon işlemi içermektedir. Bu işlem, alıcı alanı ve elde edilen özellik sayısını artırırken sabit sayıda parametre sağlar[103] . Ayrıca, konvolüsyon işleminin tekrar tekrar uygulanması VGG16 [103] ve AlexNet[44] gibi birçok son teknoloji modelde kullanılmıştır.

Yedinci katman maksimum havuz işlemi içermektedir ve özellik haritalarının boyutu tekrar azaltılmıştır. İkinci maksimum havuzlama katmanından sonra 0.8 oranında dropout uygulanmıştır. Mimarinin sınıflandırma kısmında, elde edilen çekirdekler düzleştirilmiş ve 0.5'lik bir dropout oranıyla 256 tam bağlı nörona bağlanmış ve ardından beş farklı oklüzyon seviyesini sınıflandırmak için beş nörona bağlanmıştır.

Optimize edici, ağırlıkları değiştirerek ve yerel minimumdan kaçınarak önleyerek modeli mümkün olan en doğru şekilde getirmeye çalışır. Adaptive Moment Estimation (ADAM) [104] optimize edicisi, 0.001 sabit öğrenme oranı ile global minimum değeri bulmak için kullanılmıştır. Bu çalışmada ikiden fazla sınıf etiketi sınıflandırması gerektiğinden, ağın çıkış katmanında SoftMax aktivasyon fonksiyonu seçilmiştir.

Fonksiyon, [0,1] aralığındaki her sınıf için normalleştirilmiş olasılıkları hesaplamak üzere bir girdi vektörü x alır. Bir çıktı vektörünün elemanları 1'e toplanır ve j sınıf sayısını temsil eder. Bu şekilde, tahmin edilen sınıf tüm sınıflar arasında en yüksek olasılık değerine sahip olacaktır. Tek sıcak kodlu hedef vektörler (One hot-encoded vector), her sınıf için beklenen çok terimli olasılığı temsil eder (bizim durumumuzda beş). Kodlanmış vektör doğru etiket için 1, diğer sınıflar için 0 değerini alır. Toplam kaybı elde etmek için, beklenen ve tahmin edilen çıktı arasındaki hata oranı Eşitlik 6.1'de sunulan çapraz entropi fonksiyonu kullanılarak hesaplanmıştır. t , temel gerçek vektörünü temsil eder. Hata oranı, daha iyi tahminler için ağınc güncellenmesine yardımcı olur.

$$CE = - \sum_1 t_i \log(\sigma(\hat{x}_i)) \quad (6.1)$$

Yığın boyutu (Batch Size), ağı eğitirken kullanılan diğer hiperparametredir. Bu değer, her bir ileri/geri iterasyondaki eğitim görüntülerinin sayısını ifade eder. Büyük bir yığın boyutu kayıp değerini düşürebilse de, daha küçük değerler eğitim sürecinde bir gürültü maliyeti ile hızlı bir şekilde yakınsamaya yol açar. Yığın boyutu ve epok sayısı sırasıyla 256 ve 300 olarak tanımlanmıştır. Bir epok, tüm veri kümesinin hem ileri hem de geri için bir kez geçirildiğini ifade eder. Her ileri yayılımdan sonra, her set için toplam hata hesaplanmış ve ağırlık güncellemeleri geri yayılım yoluyla yapılmış ve optimize edici yakınsama olana kadar kaybı en aza indirmeye çalışmıştır. Ayrıca, eğitim için k-fold doğrulama yöntemi kullanılmıştır ve $k=10$ seçilmiştir. Test seti haricindeki bütün veriler eğitim ve validasyona katılmışlardır ve böylelikle daha doğru bir model seçimi yapmamıza ve hiperparametreleri ayarlamamıza olanak sağlamıştır. Ayrıca ağı, modeli eğitmek için her bir epokta 256'lık setler halinde görüntü geçmektedir. En iyi modeli seçmek için başarı oranı göz önünde bulundurularak hem eğitim ardından çıkan sonuçlar hem de test verisi sonuçları dikkate alınmıştır.

BÖLÜM 7

DENEYSEL SONUÇLAR VE TARTIŞMA

7.1. ÖNERİLEN CNN MODELİ

Dentin tübüllerinin en yüksek doğrulukta sınıflandırılabilmesi için oluşturulacak ağın hiperparametrelerinin de en yüksek başarıyı sağlayacak şekilde optimize edilmesi gereklidir. Optimum hiperparametreleri bulmak için kullandığımız GS algoritması Çizelge 7.1’de verilmiştir.

1.		Start
2.		for KKHK in [1,2,3]
3.		for TBK [1,2,3]
4.		for FS [8,16,32]
5.		for FB [2,3,4,5]
6.		for AF [ReLU, LRelu]
7.		model = CNN_train(train_data, KKHK,TBK,FS,FB,AF)
8.		score = CNN_predict (test_data,model)
9.		cv_list.insert(score)
10.		scores_list.insert(mean(cv_list), KKHK,TBK,FS,FB,AF)
11.		return max (scores_list)

Çizelge 7.1. Optimum hiperparametreleri bulmak için kullanılan GS algoritması (KKHK- Konv.Konv. Havuzlama katmanlar, TBK-Tamamen Bağlı Katman, FS – Filtre Sayısı, FB – Filtre Boyutu, AF – Aktivasyon fonksiyonu)


Eğitim k-fold çapraz doğrulama yöntemi kullanılarak yapılmıştır. K-fold çapraz doğrulama, makine öğrenme modellerinin yetenek ve performansını tahmin etmek için kullanılan istatistiksel bir yöntemdir. İlgili problem için makine öğrenmesi modellerini karşılaştırmak ve en uygun olanı seçmek için kullanılmaktadır. k değeri 10 seçilmiştir ve her devirde eğitim ve doğrulama veriseti karıştırılmıştır. Modelin

veriye genelleme yapma yeteneğinin ölçülmesinde k-fold çapraz doğrulama yöntemi, verinin direk eğitim/test seti olarak ayrılmasından daha güvenilir sonuç elde edilmesini sağlar. Daha güvenilir olma sebebi ise modelin farklı veri kesitleri üzerinde eğitilmesi ve test edilmesi ile aşırı uyum olup olmadığı konusunda fikir vermesidir. İlk adımda veriseti karıştırılır ve k adet eşit büyüklükte alt kümeye bölünür. Her bir katman sırasıyla test verisi olarak kullanılırken diğer katmanlar birleştirilerek eğitim verisi olarak kullanılır. Bu işlem k kez tekrarlanır ve her katman için modelin performans ölçümleri yapılır. Bu sonuçların ortalaması modelin genel performansının daha güvenilir bir sonucunu ortaya çıkarır [105]. Eğitilen modeller arasından en başarılı sonuçları üreten ağın optimum değerleri kaydedilmiştir. Bu değerler Çizelge 7.2’de paylaşılmıştır.

Çizelge 7.2 GS kullanılarak elde edilen optimum hiperparametre değerleri


Parametreler	Aralık	Optimum değer
Konvolüsyon ve Havuzlama katman sayısı	[1, 2, 3]	2
Tam Bağlı Katman sayısı	[1, 2, 3]	2
Filtre sayısı	[16, 24, 32, 64, 128, 256]	16,32
Filtre boyutu	[2, 3, 4, 5]	3,5
Aktivasyon fonksiyonu	[ReLU, Leaky Relu]	ReLU
Batch boyutu	[16, 32, 64, 128]	64
Öğrenme Hızı	[0.001, 0.005, 0.0001, 0.0005]	0.0005
Optimize Edici	[ADAM, SGD]	ADAM

Optimum değerler ile elde edilen ağın k-fold çapraz doğrulama sonuçları Şekil 7.1’de paylaşılmıştır. Burada doğrulama verileri üzerinde ortalama %89.82’lik başarı ve 0.475 standart sapma değerine ulaşılmıştır.




Şekil 7.1 K-fold çapraz doğrulama sonucu her devirde elde edilen doğruluk grafiği

İyi eğitilmiş bir ağın validasyon doğruluğunu en üst düzeye çıkarması gerektiği gibi kayıp eğrisinde de düşüş şekli olmalıdır (Şekil 7.2). Validasyon doğruluğu azalmaya başlarsa, eğitilen ağ eğitim verilerine aşırı uyum sağlar, yani model genelleme yeteneğini kaybeder.



Şekil 7.2 Doğruluk ve kayıp eğrileri

Ağın etkinliği, test verileriyle ağa danışılarak incelenmiş ve genel sınıflandırma doğruluğu %89.76 olmuştur. Şekil 7.3'de görülebileceği gibi, ağın performansını duyarlılık, özgüllük, kesinlik ve doğruluk açısından istatistiksel metriklerle analiz etmek için gerçek / tahmin edilen sınıfların kombinasyonlarını görselleştiren konfüzyon matrisleri oluşturulmuştur. Elde edilen sınıflandırma raporu Çizelge 7.3'de verilmiştir.



Şekil 7.3 Normalize edilmiş ve edilmemiş konfüzyon matrisleri


Çizelge 7.3. Test verisinin sınıflandırma sonuçları.

Tübül Tipi	Duyarlılık (%)	Özgüllük (%)	Hassasiyet (%)	Doğruluk (%)
L1	97.62	99.11	96.47	98.8
L2	89.29	97.62	90.36	95.48
L3	82.14	95.54	82.14	92.37
L4	84.52	96.44	85.54	93.81
L5	95.24	98.51	94.12	97.8

Sonuçlar, modelin uygun olduğunu ve sınıflandırma görevleri için iyi performans gösterdiğini ortaya koymuştur. Karışıklık matrisi sonuçlarının da doğruladığı gibi, modelin ürettiği yanlış tahminler çoğunlukla L3 sınıfına aittir. Toplam 420 dentin tübülü görüntüsünden 43'ü yanlış sınıflandırılmıştır. Ancak, bu yanlış sınıflandırılmış görüntüler ayrıntılı olarak incelendiğinde, tahmin edilen sınıfa nispeten yakın oldukları görülmüştür.

7.2. TRANSFER ÖĞRENME

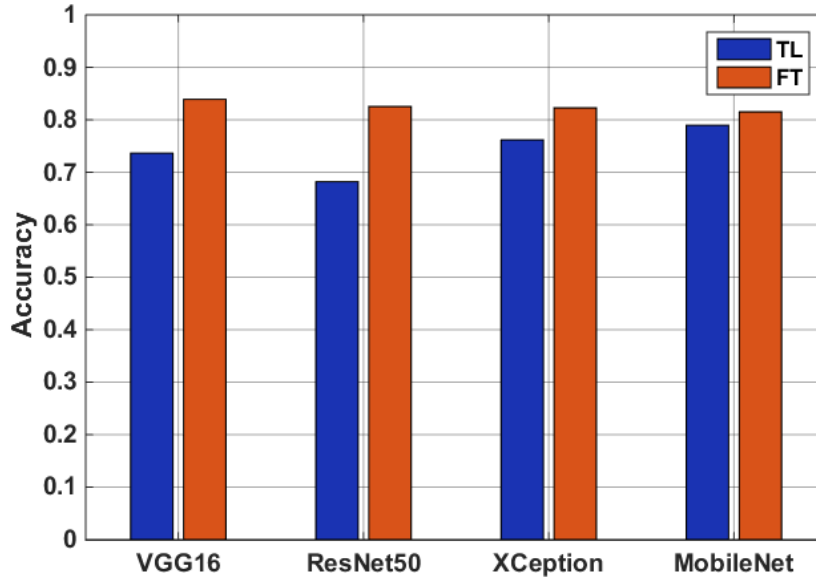
Transfer Öğrenme (TL) yöntemi ise daha önceden oluşturulmuş başarılı ve ağırlıkları belli olan ağları farklı amaçlarla kullanmaktır. Bizim örneğimizde olduğu üzere dentin tübüllerindeki farkları ayırt etmek ve otomatik sınıflandırmak amacıyla VGG16[103], ResNet50[106], Xception[107] ve MobileNet[108] gibi ağlarda tübülleri ayırt etme yetenekleri değerlendirilmiştir. Bu değerlendirmeyi yapabilmek için oluşturduğumuz veri setini modellere uygun hale dönüştürmemiz gerekmektedir. Bu dönüştürme işleminde uygulanan adımlar Şekil 7.4’te görselleştirilmiştir.



Şekil 7.4 TL ve FT tekniklerinin verisetimiz üzerinde uygulama aşamaları.

TL tekniği için uygulanacak modeller resimleri üç kanalda almaktadırlar. Bizim resimlerimiz ise gri skalada olduğu için aynı kopyalarını üç kanala da yansıtarak verisetinin uygun olmasını sağladık. TL yönteminde istediğimiz sonuçları alabilmek için ağırlık en son katmanı da bizim istediğimiz katmanlarda olmalıdır. Bu yüzden son iki katman 256 ve 5 olacak şekilde iki adet katman oluşturulmuştur ve bu katmanlar eğitime katılmışlardır. Bu son iki katman dışındakilerin ağırlıkları ise dondurulmuş

olup eğitime dahil edilmemektedir ve bu şekilde çıktı alınmaktadır. Fine Tuning metodunda ise TL ile eğitime katmadığımız sondan bazı katmanlar da eğitime katılmıştır. VGG16 [103], ResNet50[93] , Xception[107] ve MobileNet[108] ile denemeler yapıldıktan sonra Şekil 7.5 oluşturularak, aralarında karşılaştırma yapılmıştır. Bu karşılaştırma içerisinde VGG-16 en başarılı performansı göstererek %84.16 kesinlik değeri ortaya çıkmıştır.



Şekil 7.5 TL ve FT yöntemleri ile elde edilen sonuçlar.

7.3. TARTIŞMA

Doğru, tekrarlanabilir ve tutarlı sınıflandırma sonuçları üretmek, istatistiksel analizin güvenilirliği için çok önemlidir. Görüntü işleme teknikleri ve makine öğrenimi algoritmaları da dentin tübüllerini değerlendirmek için yararlı olabilir, ancak başarı oranları büyük ölçüde seçilen parametrelere bağlıdır. Öte yandan, derin öğrenme, özellikle CNN, sınıflandırma görevleri için mükemmel performans göstermiştir.

Bu çalışmada, farklı seviyelerde dentin oklüzyon görüntülerini dahil etmek için dentin disklerine farklı diş hassasiyeti önleyici ürünler uygulanmıştır. Veri artırma, eğitim verilerinde çeşitlilik sağlamıştır. Görüntü değişkenliği yalnızca öğrenme performansını artırmakla kalmaz, aynı zamanda ağın genelleme yeteneğini de

geliştirir. Her piksel temel özellikleri içerdiğinden, önerilen CNN mimarisi, her özellikten mümkün olduğunca yararlanmak için dört katlı evrişim işlemi içermektedir. Görsellerdeki bu özellikler sınıflar arası ayrımı, dolayısıyla başarı oranını etkileyen en önemli faktör olmuştur. Ancak veri artırma tekniği orijinal görüntülere çeşitli dönüşümler uygulayarak yeni veriler ürettiği için başarı oranı ancak belirli bir düzeye ulaşabilmiştir. Tüm dentin tübül görüntüleri sınıflarını içeren test veri setini, %89.76 doğrulukla beş sınıfta sınıflandırdı. Bu görüntüler daha önce ağ tarafından görülmediği için sınıflandırma konusunda objektif sonuçlar vermektedir.

Boş (L1) veya tamamen tıkalı (L5) dentin tübüllerini tahmin etmek diğer üç sınıfa göre daha iyi sonuçlar ortaya çıkarmıştır, beklendiği gibi görüntüler arasındaki en fazla fark da bu sınıflar arasındadır. Şekil 7.3'deki metriklerde de L1 ve L5 sınıflarının performanslarının diğerlerinden daha yüksek olduğunu göstermektedir. Öte yandan, çoğunlukla tıkalı olmayan (L2) kısmen tıkalı (L3) ve çoğunlukla tıkalı (L4) sınıfları birbirinden ayırmak nispeten daha zordu çünkü komşu sınıflardaki görüntüler çok benzerdir. Bu nedenle, daha fazla ayırt edici özelliklere sahip daha fazla orijinal veri ile eğitim, her sınıfın başarı oranını artırmaya yardımcı olacaktır.

Veri kümesi küçük olduğunda, TL yöntemleri kullanışlı olabilir ve yeni verileri yüksek başarı oranlarıyla etkili bir şekilde yeni veri setine uyarlanabilir [109]. TL'de, önceki bir görevden kazanılan bilgiyi, farklı ama benzer sorunu çözmek için yeniden kullanılır. Evrişimli katmanların ağırlık değerleri, özellik çıkarma aşamasında korunur ve yeni bir veri kümesini sınıflandırmak için değiştirilmiş sayıda çıktı katmanına bağlanır. Böylece farklı bir veri setinden elde edilen ağırlıklar ve önceden öğrenilen öznitelik çıkarma yeteneği yeni bir göreve aktarılabilir. Öte yandan, hassas ayar (FT), TL yöntemine bir yaklaşımdır. Bu yöntemde, katmanların bir kısmı veya tüm evrişim katmanları yeniden eğitilir ve ağı yeni veri kümesine daha iyi uyarlamak için eğitilebilir katmanların ağırlıkları her epokta güncellenir.

Bu şekilde, veri setimiz ile performanslarını incelemek için önceden eğitilmiş dört model olan VGG16 [103], ResNet50 [110], Xception [107] ve MobileNet [108] ile

gerçekleştirdik. Verilen modellerin katmanları üç kanallı görüntüler için düzenlendiğinden, kalan iki kanal için mevcut kanaldaki veriler çoğaltılmış ve veri seti belirtilen giriş boyutları için yeniden boyutlandırılmıştır. Veri setinin hazırlanmasından sonra, önceden eğitilmiş modellerin uygulanması için iki yöntem benimsenmiştir. Yöntemlerin tüm başlangıç ağırlık değerleri için ImageNet [111] veri seti kullanıldı. TL yönteminde, evrişimsel taban dondurularak tüm öznelik çıkarım katmanları korunmuştur. Nihai evrişimli katman daha sonra düzleştirildi ve 256 ve 5 nöron içeren iki yoğun katmana bağlandı.

FT yönteminde başlangıç katmanları tekrar dondurularak tutulmuş ancak daha sonra konvolüsyonel katmanlar daha ayırt edici özellikler tespit ettikleri için eğitim sürecine dahil edilmiştir. Nihai konvolüsyonel katman daha sonra vektörize edildi ve tekrar 256 ve 5 nöron içeren iki yoğun katmana bağlandı. FT yöntemi, eğitilebilir katmanlardaki artış nedeniyle yeni örneklere TL yönteminden daha iyi uyum sağladı. En iyi doğrulama doğruluğu %84,16 ile FT ile VGG-16 mimarisinden elde edilmiştir. Öte yandan, TL yöntemlerinin hiçbiri FT yöntemini geçemedi. FT yöntemi daha yüksek doğrulama oranları elde etmesine rağmen, tüm sonuçlar sıfırdan eğitilmiş önerilen CNN yönteminin gerisinde kaldı. Öğrenme oranındaki performans düşüşünün temel nedeni, negatif aktarım olarak da adlandırılan kaynak veri setinden ilgisiz örneklerin dahil edilmesiyle açıklanabilir. Hedef alan ile ImageNet veri seti arasındaki benzerliğin azalması öğrenmeyi olumsuz etkilemiştir.

BÖLÜM 8

SONUÇLAR VE DEĞERLENDİRMELER

Dentin tübüleri üzerinde yapılan incelemeler diş bakımındaki ve tedavisindeki gelişmeler için çok önemlidir. Dentin tübüleri üzerinde yapılan analizler sayesinde, uygulanan ürünün etkisini incelemek ve araştırma yapmak mümkündür. Bu bağlamda, dentin tübüllerinin oklüzyon derecesinin ölçülmesi, uygulanan ürün hakkında önemli bilgiler verir. Dentin tübüllerinin sınıflandırılmasında hala manuel değerlendirme teknikleri kullanılsa da, bu zaman alıcı bir süreçtir ve sonuçlar büyük ölçüde incelemeyi yapan kişiye bağlıdır. Bu nedenle, bu olumsuz etkileri azaltmak için otomatik analiz bu alanda kritik bir gerekliliktir. Görüntü işleme teknikleri doğru parametrelerle iyi sınıflandırma sonuçları elde edebilir, ancak görüntüdeki kirlilik veya gürültüden kolayca etkilenebilir ve bu da daha düşük doğruluk oranlarına neden olur.

Derin öğrenme, özellikle de konvolüsyonel nöral ağlar, bahsedilen sorunların üstesinden gelmek ve dentin tübüllerinin değerlendirme sürecini otomatikleştirmek için mükemmel bir seçimdir. Ayrıca, otomatik analiz, zaman açısından verimli olmasının yanı sıra bir denetçiden bağımsız olmanın avantajlarından da faydalanır. Konvolüsyonel nöral ağlar geniş bir veri yelpazesini öğrenip sınıflandırabildiğinden, gürültülü görüntüler de yüksek doğrulukla sınıflandırılabilir.

Bu çalışmada, dentin tübül oklüzyonlarının sınıflandırılması için yeni bir konvolüsyonel sinir ağı mimarisi sunulmuştur. 2795 bölütlenmiş dentin tübülü görüntüsü %85 eğitim ve %15 test veri kümesi olacak şekilde iki parçaya ayrılmıştır. Veri artırma tekniği, her görüntüden daha fazla özellik çıkarmak için yalnızca eğitim veri kümesine uygulanmıştır. K-fold çapraz doğrulama metodu kullanılarak eğitim gerçekleştirilmiştir. Eğitim sürecinden sonra, ağ tarafından hiç görülmeyen test verileri, eğittiğimiz modele girdi olarak verilmiştir ve genel doğruluk %89.76 olarak

bulunmuştur. Önerilen mimari, dentin tübül oklüzyonlarının belirli özelliklerini yakalama ve bunları buna göre sınıflandırma yeteneğini göstermiştir. Genel olarak önerilen yöntem zaman verimliliği, objektiflik ve yüksek sınıflandırma doğruluğu oranları açısından pratiktir.

KAYNAKLAR

1. Miglani, S., Aggarwal, V., and Ahuja, B., "Dentin hypersensitivity: Recent trends in management", *Journal Of Conservative Dentistry*, 13 (4): (2010).
2. West, N. X., Sanz, M., Lussi, A., Bartlett, D., Bouchard, P., and Bourgeois, D., "Prevalence of dentine hypersensitivity and study of associated factors: A European population-based cross-sectional study", *Journal Of Dentistry*, 41 (10): (2013).
3. Costa, R. S. A., Rios, F. S., Moura, M. S., Jardim, J. J., Maltz, M., and Haas, A. N., "Prevalence and Risk Indicators of Dentin Hypersensitivity in Adult and Elderly Populations From Porto Alegre, Brazil", *Journal Of Periodontology*, 85 (9): (2014).
4. Addy, M., "Tooth brushing, tooth wear and dentine hypersensitivity - Are they associated?", *International Dental Journal*, 55 (4 SUPPL. 1): (2005).
5. "Textbook of Endodontology", Second. Ed., **WILEY-BLACKWELL**, (2010).
6. Orchardson, R. and Gillam, D. G., "Managing dentin hypersensitivity", *The Journal Of The American Dental Association*, 137 (7): 990–998 (2006).
7. Shetty, D., Rajesh, K., Hedge, S., and Arun Kumar, M., "Evaluation of the efficacy of a 5% calcium sodium phosphosilicate (Novamin[®]) containing dentifrice for the relief of dentinal hypersensitivity: A clinical study", *Indian Journal Of Dental Research*, 23 (3): 363 (2012).
8. Cummins, D., "Recent advances in dentin hypersensitivity: clinically proven treatments for instant and lasting sensitivity relief.", *American Journal Of Dentistry*, 23 Spec No A: 3A-13A (2010).
9. Ayad, F., Ayad, N., Delgado, E., Zhang, Y. P., DeVizio, W., Cummins, D., and Mateo, L. R., "Comparing the efficacy in providing instant relief of dentin hypersensitivity of a new toothpaste containing 8.0% arginine, calcium carbonate, and 1450 ppm fluoride to a benchmark desensitizing toothpaste containing 2% potassium ion and 1450 ppm fluoride, and to a control

- toothpaste with 1450 ppm fluoride: a three-day clinical study in Mississauga, Canada.", *The Journal Of Clinical Dentistry*, 20 (4): 115–22 (2009).
10. Kapferer, I., Pflug, C., Kisielewsky, I., Giesinger, J., Beier, U. S., and Dumfahrt, H., "Instant dentin hypersensitivity relief of a single topical application of an in-office desensitizing paste containing 8% arginine and calcium carbonate: A split-mouth, randomized-controlled study", *Acta Odontologica Scandinavica*, 71 (3–4): 994–999 (2013).
 11. Sharma, D., Hong, C. X., and Heipp, P. S., "A novel potassium oxalate-containing tooth-desensitising mouthrinse: A comparative in vitro study", *Journal Of Dentistry*, 41: S18–S27 (2013).
 12. C. CHOW, L., "Next generation calcium phosphate-based biomaterials", *Dental Materials Journal*, 28 (1): 1–10 (2009).
 13. Thanatvarakorn, O., Nakashima, S., Sadr, A., Prasansuttiorn, T., Ikeda, M., and Tagami, J., "In vitro evaluation of dentinal hydraulic conductance and tubule sealing by a novel calcium-phosphate desensitizer", *Journal Of Biomedical Materials Research Part B: Applied Biomaterials*, 101B (2): 303–309 (2013).
 14. Arrais, C. A. G., Chan, D. C. N., and Giannini, M., "Effects of desensitizing agents on dentinal tubule occlusion", *Journal Of Applied Oral Science*, 12 (2): 144–148 (2004).
 15. Yilmaz, N. A., Ertas, E., and Orucoğlu, H., "Evaluation of Five Different Desensitizers: A Comparative Dentin Permeability and SEM Investigation In Vitro", *The Open Dentistry Journal*, 11 (1): 15–33 (2017).
 16. Mohan, V. K., R, R., and Gunasekaran, S., "A COMPARATIVE STUDY OF DENTINAL TUBULES IN ATTRITED AND NORMAL TEETH USING LIGHT MICROSCOPE AND POLARIZED LIGHT MICROSCOPE", *INTERNATIONAL JOURNAL OF SCIENTIFIC RESEARCH*, 1–3 (2020).
 17. Zhou, Z., Ge, X., Bian, M., Xu, T., Li, N., Lu, J., and Yu, J., "Remineralization of dentin slices using casein phosphopeptide–amorphous calcium phosphate combined with sodium tripolyphosphate", *BioMedical Engineering OnLine*, 19 (1): 18 (2020).
 18. Kawle, S., Gawande, H., Gupte, J., Jadhav, A., Raut, S., and Sinha, S., "The combined occluding effect of sodium fluoride varnish and erbium: Yttrium-

- aluminium-garnet laser irradiation on dentinal tubules – CLSM and SEM study", *Advances In Human Biology*, 12 (2): 138 (2022).
19. Santiago, S. L., Pereira, J. C., and Martineli, A. C. B. F., "Effect of commercially available and experimental potassium oxalate-based dentin desensitizing agents in dentin permeability: influence of time and filtration system", *Brazilian Dental Journal*, 17 (4): 300–305 (2006).
 20. Jones, S. B., Parkinson, C. R., Jeffery, P., Davies, M., Macdonald, E. L., Seong, J., and West, N. X., "A randomised clinical trial investigating calcium sodium phosphosilicate as a dentine mineralising agent in the oral environment", *Journal Of Dentistry*, 43 (6): (2015).
 21. West, N. X., Seong, J., Hellin, N., Macdonald, E. L., Jones, S. B., and Creeth, J. E., "Assessment of tubule occlusion properties of an experimental stannous fluoride toothpaste: A randomised clinical in situ study", *Journal Of Dentistry*, 76: (2018).
 22. Ciocca, L., Gallina, I., Navacchia, E., Baldissara, P., and Scotti, R., "A new method for quantitative analysis of dentinal tubules", *Computers In Biology And Medicine*, 37 (3): (2007).
 23. Olley, R. C., Parkinson, C. R., Wilson, R., Moazzez, R., and Bartlett, D., "A novel method to quantify dentine tubule occlusion applied to in situ model samples", *Caries Research*, 48 (1): (2014).
 24. Claydon, N. C. A., Addy, M., MacDonald, E. L., West, N. X., Maggio, B., Barlow, A., Parkinson, C., and Butler, A., "Development of an in situ methodology for the clinical evaluation of dentine hypersensitivity occlusion ingredients.", *The Journal Of Clinical Dentistry*, 20 (5): 158–66 (2009).
 25. Ker, J., Wang, L., Rao, J., and Lim, T., "Deep Learning Applications in Medical Image Analysis", *IEEE Access*, 6: (2017).
 26. Svihus, B., "Function of the digestive system1 1Presented as a part of the Informal Nutrition Symposium “From Research Measurements to Application: Bridging the Gap” at the Poultry Science Association’s annual meeting in San Diego, California, July 22–25, 2013.", *Journal Of Applied Poultry Research*, 23 (2): 306–314 (2014).
 27. Internet: The Editors of Encyclopaedia, "Tooth", <https://www.britannica.com/science/tooth-anatomy> (2023).

28. Goldberg, M., "Dentin structure composition and mineralization", *Frontiers In Bioscience*, E3 (2): 281 (2011).
29. lo Giudice, G., Cutroneo, G., Centofanti, A., Artemisia, A., Bramanti, E., Militi, A., Rizzo, G., Favalaro, A., Irrera, A., lo Giudice, R., and Cicciù, M., "Dentin Morphology of Root Canal Surface: A Quantitative Evaluation Based on a Scanning Electronic Microscopy Study", *BioMed Research International*, 2015: 1–7 (2015).
30. Addy, M., "Dentine hypersensitivity: New perspectives on an old problem", *International Dental Journal*, 52 (5): 367–375 (2002).
31. Pamir, T., Ozyazici, M., Baloglu, E., and Onal, B., "The efficacy of three desensitizing agents in treatment of dentine hypersensitivity", *Journal Of Clinical Pharmacy And Therapeutics*, 30 (1): 73–76 (2005).
32. McCormack, K. and Davies, R., "The enigma of potassium ion in the management of dentine hypersensitivity: is nitric oxide the elusive second messenger?", *Pain*, 68 (1): 5–11 (1996).
33. Lilja, J., Nordenvall, K. J., and Brännström, M., "Dentin sensitivity, odontoblasts and nerves under desiccated or infected experimental cavities. A clinical, light microscopic and ultrastructural investigation.", *Swedish Dental Journal*, 6 (3): 93–103 (1982).
34. West, N. X., Lussi, A., Seong, J., and Hellwig, E., "Dentin hypersensitivity: pain mechanisms and aetiology of exposed cervical dentin", *Clinical Oral Investigations*, 17 (S1): 9–19 (2013).
35. Brännström, M., Lindén, L. A., and Aström, A., "The hydrodynamics of the dental tubule and of pulp fluid. A discussion of its significance in relation to dentinal sensitivity.", *Caries Research*, 1 (4): (1967).
36. Brännström, M., "Etiology of dentin hypersensitivity.", *Proceedings Of The Finnish Dental Society. Suomen Hammaslaakariseuran Toimituksia*, 88 Suppl 1: 7–13 (1992).
37. Krizhevsky, A., Sutskever, I., and Hinton, G. E., "ImageNet classification with deep convolutional neural networks", *Communications Of The ACM*, 60 (6): (2017).

38. Vasvani A., Shazeer N., Parmar N., Uszkoreit J., Jones L., Gomez A. N., and Polosukhin I., "Attention is all you need", *Advances In Neural Information Processing Systems*, 5998–6008 (2017).
39. Hinton, G., Deng, L., Yu, D., Dahl, G., Mohamed, A., Jaitly, N., Senior, A., Vanhoucke, V., Nguyen, P., Sainath, T., and Kingsbury, B., "Deep Neural Networks for Acoustic Modeling in Speech Recognition: The Shared Views of Four Research Groups", *IEEE Signal Processing Magazine*, 29 (6): 82–97 (2012).
40. Silver, D., Huang, A., Maddison, C. J., Guez, A., Sifre, L., van den Driessche, G., Schrittwieser, J., Antonoglou, I., Panneershelvam, V., Lanctot, M., Dieleman, S., Grewe, D., Nham, J., Kalchbrenner, N., Sutskever, I., Lillicrap, T., Leach, M., Kavukcuoglu, K., Graepel, T., and Hassabis, D., "Mastering the game of Go with deep neural networks and tree search", *Nature*, 529 (7587): 484–489 (2016).
41. Goodfellow, I. J., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A., and Bengio, Y., "Generative Adversarial Networks", (2014).
42. Kingma, D. P. and Welling, M., "Auto-Encoding Variational Bayes", (2013).
43. Sarker, I. H., "Deep Learning: A Comprehensive Overview on Techniques, Taxonomy, Applications and Research Directions", *SN Computer Science*, 2 (6): 420 (2021).
44. Alom, M. Z., Taha, T. M., Yakopcic, C., Westberg, S., Sidike, P., Nasrin, M. S., van Esesn, B. C., Awwal, A. A. S., and Asari, V. K., "The History Began from AlexNet: A Comprehensive Survey on Deep Learning Approaches", (2018).
45. Balakrishnama, S. and Ganapathiraju, A., "Linear discriminant analysis-a brief tutorial", *Institute For Signal And Information Processing*, 18 (1998): 1–8 (1998).
46. Hearst, M. A., Dumais, S. T., Osuna, E., Platt, J., and Scholkopf, B., "Support vector machines", *IEEE Intelligent Systems And Their Applications*, 13 (4): 18–28 (1998).
47. Meyer, D. and Wien, F. T., "Support vector machines", *R News*, 1 (3): 23–26 (2001).

48. Chalapathy, R. and Chawla, S., "Deep Learning for Anomaly Detection: A Survey", (2019).
49. Sermanet, P., Eigen, D., Zhang, X., Mathieu, M., Fergus, R., and LeCun, Y., "OverFeat: Integrated Recognition, Localization and Detection using Convolutional Networks", (2013).
50. Zaharchuk, G., Gong, E., Wintermark, M., Rubin, D., and Langlotz, C. P., "Deep Learning in Neuroradiology", *American Journal Of Neuroradiology*, 39 (10): 1776–1784 (2018).
51. Middlebrooks, E. H., ver Hoef, L., and Szaflarski, J. P., "Neuroimaging in Epilepsy", *Current Neurology And Neuroscience Reports*, 17 (4): 32 (2017).
52. Hubel, D. H. and Wiesel, T. N., "Receptive fields, binocular interaction and functional architecture in the cat's visual cortex", *The Journal Of Physiology*, 160 (1): (1962).
53. Sermanet, P., Eigen, D., Zhang, X., Mathieu, M., Fergus, R., and LeCun, Y., "Overfeat: Integrated recognition, localization and detection using convolutional networks", (2014).
54. Girshick, R., Donahue, J., Darrell, T., and Malik, J., "Rich feature hierarchies for accurate object detection and semantic segmentation", (2014).
55. Ren, S., He, K., Girshick, R., and Sun, J., "Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks", *IEEE Transactions On Pattern Analysis And Machine Intelligence*, 39 (6): (2017).
56. Alzubaidi, L., Zhang, J., Humaidi, A. J., Al-Dujaili, A., Duan, Y., Al-Shamma, O., Santamaría, J., Fadhel, M. A., Al-Amidie, M., and Farhan, L., "Review of deep learning: concepts, CNN architectures, challenges, applications, future directions", *Journal Of Big Data*, 8 (1): 53 (2021).
57. Logan, R., Williams, B. G., Ferreira da Silva, M., Indani, A., Schcolnicov, N., Ganguly, A., and Miller, S. J., "Deep Convolutional Neural Networks With Ensemble Learning and Generative Adversarial Networks for Alzheimer's Disease Image Data Classification.", *Frontiers In Aging Neuroscience*, 13: 720226 (2021).
58. Internet: Prakhar Ganesh, "Types of Convolution Kernels : Simplified", <https://towardsdatascience.com/types-of-convolution-kernels-simplified-f040cb307c37> (2023).

59. Internet: Prabhu, "Understanding of Convolutional Neural Network (CNN) — Deep Learning", <https://medium.com/@RaghavPrabhu/understanding-of-convolutional-neural-network-cnn-deep-learning-99760835f148> (2023).
60. "Convolutional Neural Networks (CNNs / ConvNets)", <https://cs231n.github.io/convolutional-networks/#add> (2023).
61. Albawi, S., Mohammed, T. A., and Al-Zawi, S., "Understanding of a convolutional neural network", (2017).
62. Sabri, N., "A Comparison between Average and Max-Pooling in Convolutional Neural Network for Scoliosis Classification", *International Journal Of Advanced Trends In Computer Science And Engineering*, 9 (1.4): 689–696 (2020).
63. Internet: Bharath Krishnamurthy, "An Introduction to the ReLU Activation Function", <https://builtin.com/machine-learning/relu-activation-function> (2023).
64. Lee, H., Grosse, R., Ranganath, R., and Ng, A. Y., "Convolutional deep belief networks for scalable unsupervised learning of hierarchical representations", (2009).
65. Olah, C., Mordvintsev, A., and Schubert, L., "Feature Visualization", *Distill*, 2 (11): (2017).
66. Harley, A. W., "An Interactive Node-Link Visualization of Convolutional Neural Networks", (2015).
67. Wong, J., Manderson, T., Abrahamowicz, M., Buckeridge, D. L., and Tamblyn, R., "Can Hyperparameter Tuning Improve the Performance of a Super Learner?", *Epidemiology*, 30 (4): 521–531 (2019).
68. Ghawi, R. and Pfeffer, J., "Efficient Hyperparameter Tuning with Grid Search for Text Categorization using kNN Approach with BM25 Similarity", *Open Computer Science*, 9 (1): 160–180 (2019).
69. Diaz, G. I., Fokoue-Nkoutche, A., Nannicini, G., and Samulowitz, H., "An effective algorithm for hyperparameter optimization of neural networks", *IBM Journal Of Research And Development*, 61 (4/5): 9:1-9:11 (2017).
70. Shekar, B. H. and Dagnew, G., "Grid search-based hyperparameter tuning and classification of microarray cancer data", (2019).

71. Liashchynskiy, P. and Liashchynskiy, P., "Grid Search, Random Search, Genetic Algorithm: A Big Comparison for NAS", (2019).
72. Olof, S. S., .
73. Ilievski, I., Akhtar, T., Feng, J., and Shoemaker, C., "Efficient hyperparameter optimization for deep learning algorithms using deterministic rbf surrogates", (2017).
74. Elhani, D., Megherbi, A. C., Zitouni, A., Dornaika, F., Sbaa, S., and Taleb-Ahmed, A., "Optimizing convolutional neural networks architecture using a modified particle swarm optimization for image classification", *Expert Systems With Applications*, 229: 120411 (2023).
75. Claesen, M., Simm, J., Popovic, D., Moreau, Y., and De Moor, B., "Easy Hyperparameter Search Using Optunity", (2014).
76. Bergstra, J. and Bengio, Y., "Random search for hyper-parameter optimization.", *Journal Of Machine Learning Research*, 13 (2): (2012).
77. Witt, C., "Worst-case and average-case approximations by simple randomized search heuristics", (2005).
78. Zöllner, M.-A. and Huber, M. F., "Benchmark and Survey of Automated Machine Learning Frameworks", (2019).
79. Injadat, M., Salo, F., Nassif, A. B., Essex, A., and Shami, A., "Bayesian Optimization with Machine Learning Algorithms Towards Anomaly Detection", (2018).
80. Hazan, E., Klivans, A., and Yuan, Y., "Hyperparameter Optimization: A Spectral Approach", (2017).
81. Luo, G., "A review of automatic selection methods for machine learning algorithms and hyper-parameter values", *Network Modeling Analysis In Health Informatics And Bioinformatics*, 5 (1): 18 (2016).
82. Bottou, L., "Large-scale machine learning with stochastic gradient descent", (2010).
83. Zhang, S., Xu, J., Huang, E., and Chen, C.-H., "A new optimal sampling rule for multi-fidelity optimization via ordinal transformation", (2016).
84. Gogna, A. and Tayal, A., "Metaheuristics: review and application", *Journal Of Experimental & Theoretical Artificial Intelligence*, 25 (4): 503–526 (2013).

85. Eggensperger, K., Feurer, M., Hutter, F., Bergstra, J., Snoek, J., Hoos, H., Leyton-Brown, K., and others, "Towards an empirical foundation for assessing bayesian optimization of hyperparameters", (2013).
86. Yao, Q., Wang, M., Chen, Y., Dai, W., Li, Y.-F., Tu, W.-W., Yang, Q., and Yu, Y., "Taking Human out of Learning Applications: A Survey on Automated Machine Learning", (2018).
87. Hutter, F., Kotthoff, L., and Vanschoren, J., "Automated Machine Learning: Methods, Systems, Challenges", *Springer Nature*, (2019).
88. Lecun, Y., Bottou, L., Bengio, Y., and Haffner, P., "Gradient-based learning applied to document recognition", *Proceedings Of The IEEE*, 86 (11): 2278–2324 (1998).
89. Krizhevsky, A., Sutskever, I., and Hinton, G. E., "ImageNet Classification with Deep Convolutional Neural Networks", (2012).
90. Zeiler, M. D. and Fergus, R., "Visualizing and Understanding Convolutional Networks", (2013).
91. Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., and Rabinovich, A., "Going Deeper with Convolutions", (2014).
92. Simonyan, K. and Zisserman, A., "Very Deep Convolutional Networks for Large-Scale Image Recognition", (2014).
93. He, K., Zhang, X., Ren, S., and Sun, J., "Deep Residual Learning for Image Recognition", (2016).
94. Internet: François Chollet, "Transfer Learning", https://keras.io/guides/transfer_learning/ (2023).
95. Chen, C. L., Parolia, A., Pau, A., and Celerino De Moraes Porto, I. C., "Comparative evaluation of the effectiveness of desensitizing agents in dentine tubule occlusion using scanning electron microscopy", *Australian Dental Journal*, 60 (1): (2015).
96. Olley, R. C., Pilecki, P., Hughes, N., Jeffery, P., Austin, R. S., Moazzez, R., and Bartlett, D., "An in situ study investigating dentine tubule occlusion of dentifrices following acid challenge", *Journal Of Dentistry*, 40 (7): (2012).
97. Kunam, D., Manimaran, S., Sampath, V., and Sekar, M., "Evaluation of dentinal tubule occlusion and depth of penetration of nano-hydroxyapatite

- derived from chicken eggshell powder with and without addition of sodium fluoride: An in vitro study", *Journal Of Conservative Dentistry*, 19 (3): (2016).
98. McHugh, M. L., "Interrater reliability: The kappa statistic", *Biochemia Medica*, 22 (3): (2012).
 99. He, H. and Garcia, E. A., "Learning from imbalanced data", *IEEE Transactions On Knowledge And Data Engineering*, 21 (9): (2009).
 100. Gulshan, V., Peng, L., Coram, M., Stumpe, M. C., Wu, D., Narayanaswamy, A., Venugopalan, S., Widner, K., Madams, T., Cuadros, J., Kim, R., Raman, R., Nelson, P. C., Mega, J. L., and Webster, D. R., "Development and validation of a deep learning algorithm for detection of diabetic retinopathy in retinal fundus photographs", *JAMA - Journal Of The American Medical Association*, 316 (22): (2016).
 101. Esteva, A., Kuprel, B., Novoa, R. A., Ko, J., Swetter, S. M., Blau, H. M., and Thrun, S., "Dermatologist-level classification of skin cancer with deep neural networks", *Nature*, 542 (7639): (2017).
 102. Shorten, C. and Khoshgoftaar, T. M., "A survey on Image Data Augmentation for Deep Learning", *Journal Of Big Data*, 6 (1): (2019).
 103. Simonyan, K. and Zisserman, A., "Very deep convolutional networks for large-scale image recognition", (2015).
 104. Kingma, D. P. and Ba, J. L., "Adam: A method for stochastic optimization", (2015).
 105. Rodriguez, J. D., Perez, A., and Lozano, J. A., "Sensitivity analysis of k-fold cross validation in prediction error estimation", *IEEE Transactions On Pattern Analysis And Machine Intelligence*, 32 (3): 569–575 (2009).
 106. He, K., Zhang, X., Ren, S., and Sun, J., "Deep residual learning for image recognition", (2016).
 107. Chollet, F., "Xception: Deep Learning with Depthwise Separable Convolutions", (2016).
 108. Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., Andreetto, M., and Adam, H., "MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications", (2017).

109. Tajbakhsh, N., Shin, J. Y., Gurudu, S. R., Hurst, R. T., Kendall, C. B., Gotway, M. B., and Liang, J., "Convolutional Neural Networks for Medical Image Analysis: Full Training or Fine Tuning?", *IEEE Transactions On Medical Imaging*, 35 (5): 1299–1312 (2016).
110. He, K., Zhang, X., Ren, S., and Sun, J., "Deep Residual Learning for Image Recognition", (2015).
111. Deng, J., Dong, W., Socher, R., Li, L.-J., Kai Li, and Li Fei-Fei, "ImageNet: A large-scale hierarchical image database", (2009).

ÖZGEÇMİŞ

Anday DURU; 2009 yılında Yeditepe Üniversitesi Mühendislik Fakültesi Biyomedikal Mühendisliği Bölümünde burslu öğrenime başlayıp 2014 yılında iyi derece ile mezun oldu. 2018 yılında ise Karabük Üniversitesi Biyomedikal Mühendisliği Yüksek Lisans programından mezun oldu. Aynı yıl Karabük Üniversitesi Bilgisayar Mühendisliği bölümünde doktora eğitimine başladı. 2014 yılında Karabük Üniversitesi – Biyomedikal Mühendisliği bölümünde göreve başladı ve halen devam etmektedir.