



T.C.

SÜLEYMAN DEMİREL ÜNİVERSİTESİ

DİŞ HEKİMLİĞİ FAKÜLTESİ

PROTETİK DİŞ TEDAVİSİ ANABİLİM DALI

**PANORAMİK RADYOGRAFLAR ÜZERİNDE SABİT
BÖLÜMLÜ PROTEZLERİN TANIMLANMASINDA YAPAY
ZEKA ALGORİTMASININ BAŞARISININ
DEĞERLENDİRİLMESİ**

Yunus ÇETİN

UZMANLIK TEZİ

DANIŞMAN

Doç. Dr. Zeynep BAŞAĞAOĞLU DEMİREKİN

ISPARTA-2025

KABUL ve ONAY SAYFASI

Süleyman Demirel Üniversitesi Diş Hekimliği Fakültesi Dekanlığına;

Süleyman Demirel Üniversitesi Diş Hekimliği Fakültesi Protetik Diş Tedavisi Anabilim Dalı Uzmanlık programı çerçevesinde yürütülmüş olan bu çalışma, aşağıdaki jüri tarafından Uzmanlık Tezi olarak kabul edilmiştir.

Uzmanlık Tez Tarihi: 19.06.2025

Danışmanı : Doç. Dr. Zeynep BAŞAĞAOĞLU DEMİREKİN
Süleyman Demirel Üniversitesi
Diş Hekimliği Fakültesi- Protetik Diş Tedavisi Anabilim Dalı

Üye : Prof. Dr. Erdal EROĞLU
Süleyman Demirel Üniversitesi
Diş Hekimliği Fakültesi- Protetik Diş Tedavisi Anabilim Dalı

Üye : Doç. Dr. H. Cenker KÜÇÜKEŞMEN
Süleyman Demirel Üniversitesi
Diş Hekimliği Fakültesi- Protetik Diş Tedavisi Anabilim Dalı

Üye : Doç. Dr. Zeynep BAŞAĞAOĞLU DEMİREKİN
Süleyman Demirel Üniversitesi
Diş Hekimliği Fakültesi- Protetik Diş Tedavisi Anabilim Dalı

ONAY: Bu uzmanlık tezi, fakülte yönetim kurulunca belirlenen yukarıdaki jüri üyeleri tarafından uygun görülmüş ve fakülte yönetim kurulu kararıyla kabul edilmiştir.

Prof. Dr. Murat MADEN

Dekan

BEYAN

“Panoramik Radyograflar Üzerinde Sabit Bölümlü Protezlerin Tanımlanmasında Yapay Zekâ Algoritmasının Başarısının Değerlendirilmesi “adlı Uzmanlık tezi, Süleyman Demirel Üniversitesi Sağlık Bilimleri Enstitüsü Lisansüstü Tez Önerisi ve Tez Yazma Yönergesi ’ne uygun olarak hazırlanmıştır.

Bu tez çalışmasının kendi çalışmam olduğunu, tezin planlanmasından yazımına kadar bütün safhalarda etik dışı davranışımın olmadığını, bu tezdeki bütün bilgileri akademik ve etik kurallar içinde elde ettiğimi, bu tez çalışmayla elde edilmeyen bütün bilgi ve yorumlara kaynak gösterdiğimi ve bu kaynakları da kaynaklar listesine aldığımı, yine bu tezin çalışılması ve yazımı sırasında patent ve telif haklarını ihlal edici bir davranışımın olmadığını beyan ederim.

Hazırlayan

Yunus Çetin

Danışman

Doç. Dr. Zeynep BAŞAĞAOĞLU DEMİREKİN

İTHAF

Bu tez çalışmasını, kendi hayatından ve olanaklarından fedakarlıklar ederek bugünlere gelmemi sağlayan ve her zaman arkamda olan anneme ve babama ithaf ediyorum.

Saygılarımla... Isparta, 2025

TEŞEKKÜR

Uzmanlık eğitimim süresince, tezimin her aşamasında büyük bir sabırla ve titizlikle bana yol gösteren; mesleki ve mesleki olmayan konularda her zaman deneyimleri ve nasihatleri ile yolumu bulmamı sağlayan; her zaman anlayış ve hoşgörüsüyle desteğini yanımda hissettiğim; yanında çalışmaktan onur ve gurur duyduğum değerli tez danışmanım Sayın Doç. Dr. Zeynep BAŞAĞAOĞLU DEMİREKİN'e,

Uzmanlık eğitimim süresince kıymetli bilgi, birikim ve tecrübeleri ile her zaman yol gösterici ve destek olan Sayın Prof. Dr. Erdal EROĞLU, Doç. Dr. H.Cenker KÜÇÜKEŞMEN, Doç. Dr. Işın KÜRTÇÜOĞLU ve Dr. Öğr. Üyesi Özlem ÖZİŞÇİ'ye

Çalışmamızın yapılmasında değerli bilgilerini bizimle paylaşan ve yol gösteren Dr.Öğr.Üyesi Turgay AYDOĞAN'a,

İlk adımdan bu yana elimden tutan ve elimi asla bırakmayan; beni benden daha çok düşünüp, karşılaştığım her zorlukta, her kararında yanımda olan; bana güvenip, beni her zaman destekleyen canım aileme,

Tez sürecimde ve uzmanlık eğitimim boyunca her zaman yanımda olan, birlikte çalışmaktan büyük keyif aldığım, samimi dostlukları ve içten destekleriyle bu zorlu süreci benim için çok daha anlamlı ve güzel hale getiren sevgili arkadaşlarım Hilal UÇAK, Barış TATLICIOĞLU ve Furkan ÇETİNTÜRK'e

Beraber çalışmaktan her zaman keyif aldığım ve birlikte çok güzel anılar biriktirdiğim değerli çalışma arkadaşlarıma,

Bu akademik yolculuğumda her zaman yanımda olan; gösterdiği sabır, anlayış ve içten desteğiyle bu süreci daha verimli ve katlanılabilir kılan; zorluklar karşısında sakinliğiyle bana yol gösteren; moral ve motivasyonumu korumamda büyük payı olan yol arkadaşım Esra ŞİMŞEK'e tüm içtenliğimle teşekkür ederim.

Yunus ÇETİN

Isparta-2025

ÖZET

Panoramik Radyograflar Üzerinde Sabit Bölümlü Protezlerin Tanımlanmasında Yapay Zekâ Algoritmasının Başarısının Değerlendirilmesi

Amaç: Bu çalışmada, panoramik radyograflar üzerinde zirkonyum veneer ve metal destekli porselen veneer restorasyonların, yapay zekâ tabanlı bir model aracılığıyla otomatik olarak materyal bazında sınıflandırılması amaçlanmıştır. Literatürdeki restorasyon türü odaklı sınıflamalardan farklı olarak, bu çalışma materyal ayırımına odaklanarak klinik karar destek sistemlerine daha özgül bir katkı sağlamayı hedeflemiştir.

Yöntem: Bu araştırmada, Süleyman Demirel Üniversitesi Diş Hekimliği Fakültesi arşivinden elde edilen panoramik radyograflar kullanılmıştır. Görüntü kalitesi düşük olanlar ve eksik diş içeren radyograflar çalışma dışı bırakılmıştır. Ön işleme süreci sonunda, uzman hekim tarafından ImageJ yazılımı kullanılarak etiketlenen toplam 593 kırılmış ROI (Region of Interest) görüntüsü analiz kapsamına alınmıştır. Sınıf dengesizliğini azaltmak amacıyla yalnızca zirkonyum veneer sınıfındaki görüntüler için veri artırımı (data augmentation) uygulanmıştır. Döndürme, yansıma ve parlaklık değişimi gibi çeşitli görüntü işleme teknikleri kullanılarak zirkonyum sınıfındaki örnek sayısı artırılmış ve böylece her iki sınıf için birbirine yakın sayıda örnek ile dengeli bir veri seti elde edilmiştir. Model eğitimi için önceden eğitilmiş VGG16 mimarisi transfer öğrenme yöntemiyle kullanılmış ve son katmanlar yeniden eğitilerek ince ayar (fine-tuning) uygulanmıştır. Model, yalnızca sınıflandırma görevine odaklanacak şekilde yapılandırılmıştır. Tüm veri seti %70 eğitim, %20 doğrulama ve %10 test oranında rastgele ayrılmıştır. Modelin sınıflandırma başarımı doğruluk (accuracy), F1 skoru, duyarlılık (sensitivity) ve özgüllük (specificity) gibi temel performans metrikleri üzerinden değerlendirilmiştir.

Bulgular: Model, test veri setindeki 94 görüntüden 90'ını doğru sınıflandırarak %96 genel doğruluk oranına ulaşmıştır. Her iki sınıf için de precision, recall ve F1-skoru değerleri %95–96 aralığında ölçülmüştür. Ayrıca, ROC eğrisi altında kalan alan (AUC) değeri 0,994 ve Average Precision (AP) skoru 0,995 olarak hesaplanmıştır. Confusion matrix verilerine göre yalnızca 4 görüntü yanlış sınıflandırılmıştır (2 false positive, 2 false negative).

Sonuç: Çalışma sonucunda, geliştirilen yapay zekâ modelinin zirkonyum veneer ve metal destekli porselen veneer restorasyonları yüksek doğrulukla ayırt edebildiği görülmüştür. Materyal bazlı bu sınıflandırma yaklaşımı, literatürde ilklerden biri olarak hem teknik başarı hem de klinik uygulanabilirlik açısından dikkat çekicidir. Modelin ulaştığı performans değerleri, bu özgül görevde yapay zekânın anlamlı bir ayırt ediciliğe sahip olduğunu göstermektedir. Bu yönüyle çalışma, gelecekte geliştirilecek klinik karar destek sistemleri için özgün ve kullanılabilir bir temel sunmaktadır.

Anahtar Kelimeler: Yapay Zeka, Zirkonyum Veneer, Metal Destekli Porselen Veneer

ABSTRACT

Evaluating the Success of an Artificial Intelligence Algorithm in Identifying Fixed Partial Dentures on Panoramic Radiographs

Objective: This study aimed to automatically classify zirconia veneer and metal-supported porcelain veneer restorations on panoramic radiographs using an artificial intelligence-based model. Unlike previous studies that mainly focused on classifying types of restorations (e.g., crowns, fillings, implants), this research concentrated on material-based differentiation, aiming to provide a more specific contribution to clinical decision support systems.

Method: Panoramic radiographs obtained from the archive of Süleyman Demirel University, Faculty of Dentistry were used in this study. Radiographs with poor image quality and missing teeth were excluded from the study. At the end of the preprocessing process, a total of 593 cropped ROI (Region of Interest) images labelled by the expert using ImageJ software were included in the analysis. In order to reduce class imbalance, data augmentation was applied only for images in the zirconium veneer class. By using various image processing techniques such as rotation, reflection and brightness change, the number of samples in the zirconium class was increased and thus a balanced data set was obtained with a close number of samples for both classes. For model training, the pre-trained VGG16 architecture was used with transfer learning method and the final layers were retrained and fine-tuned. The model was configured to focus only on the classification task. The entire dataset was randomly split into 70% training, 20% validation and 10% testing. The classification performance of the model was evaluated based on key performance metrics such as accuracy, F1 score, sensitivity and specificity.

Results: The model correctly classified 90 out of 94 images in the test dataset, achieving an overall accuracy rate of 96%. For both classes, the precision, recall, and F1-score values were measured in the range of 95% to 96%. Additionally, the Area Under the Curve (AUC) of the ROC curve was calculated as 0.994, and the Average Precision (AP) score was determined to be 0.995. According to the confusion matrix results, only 4 images were misclassified, consisting of 2 false positives and 2 false negatives.

Conclusion: As a result of the study, it was observed that the artificial intelligence model developed in this study was able to distinguish zirconium veneers and metal-supported porcelain veneers with high accuracy. This material-based classification approach is remarkable in terms of both technical success and clinical applicability as one of the first in the literature. The performance values achieved by the model show that artificial intelligence has a significant discrimination in this specific task. In this respect, the study provides a unique and usable basis for future clinical decision support systems.

Keywords: Artificial Intelligence, Zirconium Veneer, Metal Supported Porcelain Veneer

İÇİNDEKİLER

	<u>Sayfa</u>
BEYAN.....	i
İTHAF	ii
TEŞEKKÜR	iii
ÖZET.....	iv
ABSTRACT	v
İÇİNDEKİLER	vi
TABLolar DİZİNİ	ix
RESİMLER DİZİNİ	x
GRAFİKLER DİZİNİ	xi
SİMGELER ve KISALTMALAR DİZİNİ	xii
1. GİRİŞ ve AMAÇ	1
2. GENEL BİLGİLER.....	3
2.1. Sabit Protezler	3
2.1.1. Diş Destekli Sabit Protezler	3
2.1.2. İmplant Destekli Sabit Protezler	3
2.2. Sabit Protezlerin Üretiminde Kullanılan Materyaller	4
2.2.1. Metal Alaşımları.....	4
2.2.1.1. Kıymetli Metal Alaşımlar.....	4
2.2.1.2. Kıymetsiz Metal Alaşımlar	4
2.2.2. Seramikler	4
2.2.2.1. Cam Matriks Seramikler	5
2.2.2.2. Polikristalin Seramikler.....	6
2.2.2.3. Rezin Matriks Seramikler	8
2.3. Metal Destekli Porselen Restorasyonların Tarihçesi.....	9
2.4. Metal-Porselen Restorasyonlarda Kullanılan Alaşımların Sahip Olması	
Gereken Özellikler	10
2.5. Metal Alt Yapılı Seramik Restorasyonlar	12
2.6. Zirkonya Seramikler	13
2.6.1. Zirkonyanın Tarihçesi	13

2.6.2. Zirkonyanın Mikroyapısı.....	14
2.6.3. Y-TZP Seramikler	17
2.7. Yapay Zeka Nedir ?.....	18
2.8. Yapay Zekânın Tarihçesi.....	18
2.9. Makine Öğrenmesi	20
2.10. Derin Öğrenme	23
2.10.1. Özellik Çıkarımı	25
2.10.2. Transfer Öğrenme.....	26
2.10.3. Uçtan Uca Öğrenme	28
2.11. Evrişimli Sinir Ağları (ESA).....	28
2.12. ESA Katmanları	30
2.12.1. Giriş Katmanı	30
2.12.2. Evrişim Katmanı	31
2.12.3. Toplu Normalizasyon Katmanı	32
2.12.4. Etkinleştirme (Aktivasyon) katmanı	33
2.12.5. Havuzlama Katmanı	34
2.12.6. Tam Bağlantılı Katman	35
2.12.7. DropOut Katmanı	36
2.12.8. Sınıflandırma Katmanı Çıkış katmanı	37
2.13. Evrişimli Sinir Ağı Modelleri.....	37
2.13.1. AlexNet	37
2.13.2. VGGNet	38
2.13.3. VGG16	38
2.13.4. VGG19	39
2.13.5. GoogleNet (Inception).....	39
2.13.6. U-Net Mimarisi	40
2.13.7. ResNet Mimarisi	40
2.13.8. ResUNet Mimarisi.....	40
2.14. Yapay Sinir Ağlarının Kullanım Alanları	41
2.15. Diş Hekimliğinde Yapay Zekâ	42
2.15.1. Restoratif Diş Hekimliğinde Yapay Zekâ	42
2.15.2. Endodontide Yapay Zekâ	43

2.15.3. Ortodontide Yapay Zekâ	43
2.15.4. Ağız, Diş ve Çene Cerrahisinde Yapay Zekâ.....	43
2.15.5. Periodontolojide Yapay Zekâ.....	44
2.15.6. Protetik Diş Hekimliğinde Yapay Zekâ	44
2.15.7. Çocuk Diş Hekimliğinde Yapay Zekâ	45
2.15.8. Ağız, Diş ve Çene Radyolojisinde Yapay Zekâ	45
3. GEREÇ ve YÖNTEM.....	46
3.1. Etik Onay.....	46
3.2. Çalışma Tasarımı.....	46
3.3. Örneklem Büyüklüğü ve G Power Hesaplaması	46
3.4. Görüntülerin Temini ve Seçimi	46
3.5. Verilerin Etiketlenmesi ve Kırılması.....	48
3.6. Veri Artırma (Data Augmentation) Süreci	49
3.7. Veri Setinin Bölünmesi ve Ön İşleme Süreci.....	51
3.8. Derin Öğrenme Modeli: VGG16 ve Transfer Öğrenme ile İnce Ayar Yaklaşımı	51
3.9. Modelin Eğitimi ve Görüntü İşleme Süreci	52
3.10. Sınıflandırma Performansının Değerlendirilmesi	52
3.11. Yazılım ve Donanım Altyapısı.....	53
4. BULGULAR	54
4.1. Performans Analizi.....	54
4.2. Sınıflama Doğruluğu	54
4.3. Karşıtlık Matrisi	55
4.4. TPR (True Positive Rate) ve FPR (False Positive Rate) Değerleri.....	56
4.5. Precision, Recall,F1 Skorunun Hesaplanması.....	58
4.6. ROC (Receiver Operating Characteristic Curve) Eğrisi Grafikleri ve AUC (Area Under Curve).....	59
4.7. Precision (Kesinlik) -Recall (Hassasiyet) Eğrisi (PR Eğrisi).....	61
5. TARTIŞMA	63
6. SONUÇ ve ÖNERİLER.....	70
KAYNAKLAR	72

TABLÖLAR DİZİNİ

	<u>Sayfa</u>
Tablo 3.1. Veri Setini Bölünmesi	51
Tablo 4.1. Yapay Zekâ Modeli İçin Doğruluk Matrisi da FP	53
Tablo 4.2. Sınıf Bazlı Değerlendirme.....	55
Tablo 4.3. Her Bir Sınıf İçin Hesaplanan Precision,Recall ve F1 Skoru Değerleri ...	59



RESİMLER DİZİNİ

	<u>Sayfa</u>
Resim 2.1. Seramiklerin Sınıflandırılması.....	5
Resim 2.2. Zirkonyumun Kristal Fazları ve Dönüşüm Sıcaklıkları	14
Resim 2.3. Çatlak Oluşumu İle Meydana Gelen Faz Dönüşümü	16
Resim 2.4. Turing Testi	19
Resim 2.5. Gerçek Verilerle Bir MÖ Modelinin Uygulanması.....	21
Resim 2.6. Görüntülerin İki Tarafından Özellik Çıkarma İşleminin Bir Örneği.....	26
Resim 2.7. ESA Model Mimarisi	30
Resim 2.8. Evrişim Katmanında Bir Filtre İle Birlikte Evrişimin Nasıl Gerçekleştiğini	32
Resim 2.9. Relu Aktivasyon Fonksiyonu Grafiği.....	34
Resim 2.10. 2×2 Filtre Boyutu ve 2×2 Adım ile Maksimum Havuzlama ve Ortalama	35
Resim 2.11. Tam Bağlantılı Katmanın Yapısı.....	36
Resim 2.12. Dropout Katmanının Şematik Diyagramı.....	37
Resim 3.1. Panoromik Görüntülerin Kırpılması.....	49
Resim 3.2. Veri Arttırma Yöntemleri	50
Resim 3.3. Model Başarımının Değerlendirilmesi Süreci.....	53
Resim 4.1. Karşıtlık Matrisi.....	56
Resim 4.2. TPR'nin Formülü(185)	57
Resim 4.3. TPR'nin Formülü(185)	57
Resim 4.4. Metal Destekli Porselen Veneer Sınıfına Ait TPR ve FPR Değerlerinin Hesaplanması	58
Resim 4.5. Zirkon Veneer Sınıfına Ait TPR Ve FPR Değerlerinin Hesaplanması ...	58
Resim 4.6. Precision Değerinin Hesaplanması.....	58
Resim 4.7. Recall Değerinin Hesaplanması(186).....	59
Resim 4.8. F1 Skorunun Hesaplanması(186)	59

GRAFİKLER DİZİNİ

	<u>Sayfa</u>
Grafik 4.1. ROC Eğrisi	60
Grafik 4.2. Precision-Recall (PR) Eğrisi.....	61



SİMGELER ve KISALTMALAR DİZİNİ

AP	: Average Precision
AUC	: Area Under Curve
Colab	: Google Colaboratory
CNN	: Convolutions Neural Network (Konvolüsyonel Sinir Ağları)
DÖ	: Derin öğrenme
DVM	: Destek vektör makineleri
ESA	: Evrişimli Sinir Ağları
FP	: False Positive (Yanlış Pozitif)
FN	: False Negative (Yanlış Negatif)
FPR	: False Positive Rate (Yanlış Pozitif Oranı)
Gpa	: Gigapascal
ILSVRC	: ImageNet Büyük Ölçekli Görsel Tanıma Yarışması
KIBT	: Konik Işınlı Bilgisayarlı Tomografi
KNN	: K-En Yakın Komşuluk
MÖ	: Makine öğrenmesi
MR	: Manyetik rezonans
PR	: Precision – Recall (Kesinlik - Hassasiyet)
PSZ	: Partially Stabilized Zirconia (Kısmen stabilize zirkonya)
ReLU	: Rectified Linear Unit (Düzeltilmiş Doğrusal Birim)
ResNet	: Residual Network
ROC	: Receiver Operating Characteristic
ROI	: Region of Interest (İlgilenilen Alan)
SBP	: Sabit bölümlü protez
SVM	: Destek vektör makineleri
TN	: True Negative (Gerçek Negatif)
TP	: True Positive (Gerçek Pozitif)
TPR	: True Positive Rate (Doğru Pozitif Oranı)
TZP	: Tetragonal Zirkonya Polikristali
USG	: Ultrasonografi
VGG16	: Visual Geometry Group 16
YOLOv4	: You Only Look Once version 4
YSA	: Yapay Sinir Ağları

YZ	: Yapay zeka
Zr	: Zirkonyum
ZrO₂	: Zirkonya
ZTA	: Zirkonya ile güçlendirilmiş alümina



1. GİRİŞ ve AMAÇ

Diş hekimliğinde radyografik görüntüler, hastalıkların belirlenmesi ve uygun tedavi planlarının oluşturulmasında kritik bir araç olarak kullanılmaktadır. Dental radyografiler, klinik muayene sırasında gözle fark edilemeyen patolojilerin saptanmasına olanak tanır. Klinik uygulamalarda tanısal amaçla panoramik, sefalometrik, el-bilek, periapikal, okluzal ve bite-wing gibi farklı radyografi türlerinden yaygın olarak yararlanılmaktadır(1). Doğrudan radyografilerin tanı koymada yetersiz kaldığı durumlarda, Konik Işınlı Bilgisayarlı Tomografi (KIBT), ileri düzey bir görüntüleme yöntemi olarak tanısal süreçlerde yaygın biçimde kullanılmaktadır (2). Panoramik radyografi, dişler ve çene yapıları hakkında genel bir değerlendirme yapılmasına imkân tanıyan ekstraoral bir görüntüleme tekniğidir. Bu yöntem; diş eksiklikleri, çürükler, periodontal hastalıklar ve gömülü dişler gibi çeşitli dental sorunların teşhisinde gerekli bilgileri sağlamaktadır (3).

Diş hekimliği uygulamalarında yaygın olarak kullanılan panoramik radyografilerin yorumlanması, belirli bir düzeyde klinik deneyim gerektiren karmaşık bir süreçtir. Ancak, mesleki tecrübesi ileri düzeyde olan diş hekimleri dahi bu görüntülerin değerlendirilmesinde bazı patolojileri gözden kaçırabilmektedir. Son yıllarda, birçok tıbbi sorunun çözümünde etkinliği artan ve derin öğrenme olarak bilinen yapay zekâ alanı, çok katmanlı yapay sinir ağları başta olmak üzere çeşitli makine öğrenimi algoritmalarını içeren geniş kapsamlı bir araştırma sahası hâline gelmiştir. Dental radyografilerin analizinde bu yöntemlerin kullanımı henüz sınırlı sayıda çalışmayla ve çoğunlukla iki boyutlu görüntüler üzerinde gerçekleştirilen uygulamalarla sınırlıdır. Bununla birlikte, eksik diş varlığı, kuron restorasyonları, diş çürükleri, periodontal hastalıklar ve periapikal lezyonlar gibi çeşitli dental durumlar, derin öğrenme algoritmaları ile eğitilmiş yapay zekâ sistemleri aracılığıyla tespit edilmeye başlanmıştır (4,5).

Günümüzde yapay zekâ, geçmiş dönemlerle kıyaslandığında çok daha geniş bir kullanım alanına ulaşmış olup, günlük yaşamdan akademik çalışmalara ve teknolojik uygulamalara kadar pek çok farklı alanda etkin bir şekilde kullanılmaktadır (6).

Yapay zekâ yöntemleri; yapıların belirlenmesi, görüntülerin segmentasyonu ve nesnelerin sınıflandırılması gibi çeşitli görevleri yerine getirme yeteneğine sahiptir(7). Bu tür görevlerin başarıyla yerine getirilebilmesi için yapay zekâ modellerinin, görüntü verileri ile bu görüntülere karşılık gelen etiketli veri setleri kullanılarak eğitilmesi gerekmektedir(8). Bu tarz işlevlerin etkin bir şekilde gerçekleştirilebilmesi, yapay zekâ modellerinin ilgili görüntüler ve bu görüntülere ait doğru etiketlemelerle eğitilmesini zorunlu kılmaktadır (9).

Bu çalışmanın amacı, derin öğrenme yöntemiyle eğitilmiş bir yapay zekâ modeli aracılığıyla, diş hekimliği pratiğinde yaygın olarak kullanılan iki boyutlu panoramik radyograflar üzerinde protetik restorasyonların otomatik olarak tespiti ve sınıflandırılmasını sağlamaktır. Dental restorasyonların bilgisayarlı algoritmalar ile panoramik görüntüler üzerinden belirlenmesi ve sınıflandırılması konusunda yapılan mevcut çalışmaların yetersiz kaldığı gözlemlenmiştir. Bu bağlamda, çalışma; sabit bölümlü protezlerin tespitine yönelik bir ilk adım olarak, panoramik radyografilerde dental restorasyonları otomatik analiz edebilen bir derin öğrenme algoritması geliştirmeyi hedeflemektedir.

Bu çalışmanın sıfır hipotezi, derin öğrenme tabanlı bir yapay zekâ modelinin panoramik radyografiler üzerinde metal destekli ve zirkonya esaslı dental restorasyonları ayırt etme konusunda istatistiksel olarak anlamlı bir doğruluk göstermediği ve gözlemlenen farklılıkların rastlantısal olabileceği yönündedir.

2. GENEL BİLGİLER

2.1. Sabit Protezler

Diş eksikliği durumlarında hem hekimler hem de hastalar tarafından yaygın biçimde tercih edilen sabit protezler, kaybedilen estetik, fonksiyonel ve fonetik işlevlerin yeniden kazandırılmasını sağlayan ve uzun süredir uygulanan protetik tedavi seçeneklerinden biridir. Geniş bir klinik kullanım alanına sahip olan bu protezler, tek diş kaybından tam dişsizlik vakalarına kadar uzanan durumlarda çözüm sunmakta olup; yapılarına göre diş destekli ve implant destekli olmak üzere iki ana gruba ayrılmaktadır (10).

2.1.1. Diş Destekli Sabit Protezler

Anatomik formunu, estetik görünümünü ve fonksiyonel özelliklerini kaybetmiş dişlerde, ilgili yapıları yeniden oluşturmak amacıyla dişi tamamen çevreleyen restorasyonlara kuron restorasyonu adı verilmektedir. Diş kaybının bulunduğu durumlarda ise, eksik diş ya da dişlerin yerini alacak şekilde planlanan; komşu sağlıklı dişlerin preparasyonu sonrasında tasarlanıp üretilen ve bu dişlere simante edilen restorasyon türü, sabit bölümlü protez (SBP) olarak tanımlanmaktadır. SBP'lerde kullanılan yapay diş sayısı, kaybedilen dişlerin sayısı ve konumuna bağlı olarak değişiklik göstermektedir (11).

2.1.2. İmplant Destekli Sabit Protezler

Diş kayıplarının bulunduğu olgularda ya da konjenital diş eksikliklerinin söz konusu olduğu durumlarda, implant destekli sabit protezler hem hastalar hem de klinisyenler tarafından sıkça tercih edilen tedavi alternatiflerindendir. İmplantlar, komşu dişlerin restorasyona dahil edilmesine gerek kalmadan sabit protez uygulanabilmesini sağladıkları gibi; mevcut dişlerin yetersiz olduğu ya da hiç bulunmadığı vakalarda da sabit tedavi seçeneklerini mümkün kılmaları nedeniyle modern diş hekimliğinde önemli bir yere sahiptir (12).

2.2. Sabit Protezlerin Üretiminde Kullanılan Materyaller

2.2.1. Metal Alaşımları

Diş hekimliğinde metaller genellikle alaşım formunda kullanılmakta olup, bu alaşımlar çeşitli klinik alanlarda geniş bir kullanım yelpazesine sahiptir. Protetik tedavilerde; inley, onley, kuron restorasyonları ile sabit bölümlü protezlerin üretiminde, implantolojide implant gövdeleri ve dayanak parçalarının yapımında, ortodontide ise teller ve braketlerin üretiminde yaygın olarak tercih edilmektedir. Söz konusu metal alaşımları, içeriklerine göre kıymetli (noble) ve kıymetsiz (base) alaşımlar olmak üzere iki ana grupta sınıflandırılabilir.

2.2.1.1. Kıymetli Metal Alaşımlar

Bileşiminde %25 veya daha fazla oranlarda soy metal içeren alaşımlar, kıymetli metal alaşımları olarak tanımlanmaktadır. Altın, platin, paladyum, radyum, rutenyum, iridyum, osmiyum ve gümüş gibi elementler soy metal grubunda yer almaktadır. Ancak bu metallerin yüksek maliyetli olmaları, klinik uygulamalarda kullanım sıklığını sınırlayan başlıca etkenlerden biridir.

2.2.1.2. Kıymetsiz Metal Alaşımlar


Kıymetsiz metal alaşımları olarak da adlandırılan bu materyaller, kıymetli metal alaşımlarına kıyasla hem ekonomik açıdan daha erişilebilir hem de belirli fiziksel özellikler bakımından daha üstün performans sergileyebilmektedir. Bu alaşımlar başlıca nikel-krom, kobalt-krom ve titanyum esaslı olmak üzere üç ana grupta sınıflandırılmaktadır (13).

2.2.2. Seramikler

Seramik materyaller, sahip oldukları üstün fiziksel dayanıklılık ve yüksek estetik uyum nedeniyle uzun yıllardır diş hekimliğinde sıklıkla tercih edilen temel restoratif malzemeler arasında yer almaktadır. Dental seramikler, temel olarak feldspat, kuvars ve kaolin bileşenlerinin birleşimiyle elde edilmektedir. Bu üç ana bileşenin yanı sıra, seramik yapılar; renk pigmentleri, opaklaştırıcı ajanlar gibi çeşitli

yardımcı maddeleri de içermekte olup, bu katkı maddeleri materyalin estetik ve optik özelliklerini optimize etmektedir(14). Günümüzdeki teknolojik gelişmelerle birlikte seramik materyaller; doğal diş rengine yakın görünüşleri, üstün optik özellikleri, renk stabilitesi, biyouyumlulukları, kimyasal inert yapıları, düşük ısı iletkenlikleri ve estetik açıdan tatmin edici sonuçlar sunmaları sayesinde metal destekli seramik sistemlere kıyasla daha avantajlı hâle gelmiştir(15). Seramik materyaller, kimyasal bileşimlerine göre üç temel sınıfa ayrılmaktadır: cam matriks seramikler, polikristalin seramikler ve rezin matriks seramikler (14).

Seramiklerin sınıflandırılması Resim 2.1’de verilmiştir.



Resim 2.1. Seramiklerin Sınıflandırılması (14)

2.2.2.1. Cam Matriks Seramikler

Cam matriks seramikler metalik olmayan inorganik seramik materyallerdir ve bir cam fazı içerirler (16). Cam matriks seramikler üç grupta incelenebilir (14,16).

Feldspatik Seramikler

Bu seramik grubu, kaolin, kuvars ve doğada doğal olarak bulunan alüminyum ile potasyum tuzlarının birleşimiyle oluşan feldspat adlı üç ana bileşeni içermektedir. Ancak, mekanik dayanımlarının yetersiz oluşu nedeniyle günümüzde genellikle metal ya da seramik altyapıların veneerlenmesinde kullanılmaktadır (14).

Sentetik Cam Seramikler

Sentetik olarak üretilen bu seramiklerin kimyasal içeriği üretici firmaya bağlı olarak farklılık gösterebilmekle birlikte; genellikle silisyum dioksit (SiO_2), potasyum oksit (K_2O), sodyum oksit (Na_2O) ve alüminyum oksit (Al_2O_3) gibi bileşenleri içermektedir. Bu materyaller, CAD/CAM teknolojisiyle işlenebildiği gibi ısı ile presleme yöntemleriyle de üretilmektedir. Geliştirilmiş mekanik dayanımları sayesinde; inley, onley, kuron restorasyonları ile anterior bölgede üç üyeli sabit bölümlü protezlerde klinik kullanım alanı bulmaktadır. Sentetik cam seramikler, yapılarına göre dört alt gruba ayrılmaktadır: lityum disilikat, lösit ile güçlendirilmiş seramikler, fluorapatit esaslı seramikler ve zirkonya ile güçlendirilmiş lityum silikatlar (14,16,17).

Cam İnfiltrasyon Seramikler

Cam infiltrasyon seramikler, birbirine geçmiş en az iki farklı fazdan oluşan kompozit yapıları materyallerdir. Bu seramikler, split-cast tekniği veya CAD/CAM teknolojisi kullanılarak üretilmektedir. Ancak üretim sürecinin karmaşıklığı ve zirkonya ile lityum disilikat temelli seramik materyallerin geliştirilmesi, bu grubun günümüzde klinik uygulamalarda tercih edilme sıklığını önemli ölçüde azaltmıştır (14).

2.2.2.2. Polikristalin Seramikler

Cam fazı içermeyen ve yalnızca kristalin yapıya sahip, metalik olmayan inorganik seramiklerdir. Bu seramiklerin içeriğinde bulunan kristaller, düzenli bir kristal örgüsü oluşturarak çatlakların materyal içinde ilerlemesini engeller; böylece yüksek mekanik dayanım ve kırılma direnci sağlarlar. Ancak bu düzenli kristal dizilimi, materyalin ışık geçirgenliğini sınırlayıcı bir etki yaratır. Polikristalin seramikler, içeriklerine göre başlıca alümina ve zirkonya temelli olmak üzere iki grupta incelenmektedir (14).

Alümina

Alümina temelli seramikler, %99,5 oranında alüminyum oksit (Al_2O_3) içermektedir. Alüminyum oksit doğada doğal olarak bulunan bir bileşiktir. Yüksek sertlik değerine (yaklaşık 17–20 GPa) ve diğer seramik türlerine kıyasla daha yüksek

bükölme direncine (yaklaşık 300 GPa) sahip olması, özellikle tüberkül düzeyinde kırık oluşumlarına yol açabilmektedir. Aşırı sert yapısı nedeniyle işlenmesinin zorluğu ve zirkonya esaslı materyallerin geliştirilmesi, bu seramiğin kullanımını günümüzde önemli ölçüde azaltmıştır.

Zirkonya (ZrO_2) ise doğada saf formda bulunmayan, genellikle bileşik hâlinde rastlanan zirkonyum (Zr) elementinin en yaygın bileşiklerinden biridir. Saf zirkonya, kararsız bir yapıya sahip olup sıcaklığa bağlı olarak üç farklı kristal fazda (monoklinik, tetragonal ve kübik) bulunabilmektedir (14).

Zirkonya, oda sıcaklığından yaklaşık 1170 °C'ye kadar monoklinik fazda bulunur; 1170 °C ile 2370 °C arasındaki sıcaklıklarda kübik faza geçiş yapar ve 2370 °C'den erime noktasına kadar olan aralıkta ise tetragonal fazda stabil kalır. Zirkonya yapısına seryum oksit (CeO_2), magnezyum oksit (MgO) veya itriyum oksit (Y_2O_3) gibi stabilize edici oksitlerin ilavesiyle, kısmen stabilize zirkonya (Partially Stabilized Zirconia – PSZ) elde edilir. PSZ, oda sıcaklığında çoğunlukla kübik kristallerden oluşan, az miktarda tetragonal ve monoklinik kristal fazları da içeren çok fazlı bir yapıdır. Öte yandan, yalnızca tetragonal kristallerden meydana gelen ve homojen bir faz içeren yapı ise tetragonal zirkonya polikristal (TZP) olarak adlandırılmaktadır (18).

Dental uygulamalarda kullanılan zirkonya, tetragonal zirkonya polikristali (TZP) yapısındadır ve genellikle %3 mol itriyum oksit (3Y-TZP) ile stabilize edilmiştir. Diş hekimliğinde bugüne kadar üç farklı zirkonya nesli geliştirilmiştir. İlk nesil 3Y-TZP materyalleri, yüksek opaklıkları nedeniyle estetik açıdan yetersiz kalmakta ve bu nedenle feldspatik seramik ile veneerlendirilme ihtiyacı doğmaktadır. Ancak, bu tür veneerlendirilmiş zirkonya restorasyonlarda en yaygın karşılaşılan klinik komplikasyon, orta ve uzun dönem kullanımda veneer seramiğin çatlaması ya da ayrılmasıdır. Bu sorunun üstesinden gelmek amacıyla, son yıllarda monolitik zirkonya restorasyonlar geliştirilmiş ve klinik uygulamalarda yer bulmuştur (15).

İkinci nesil 3Y-TZP zirkonyalar, birinci nesil materyallere kıyasla alümina içeriğinin azaltılması ve porozitenin ortadan kaldırılması sayesinde daha yüksek translüsent özellik sergilemektedir. Bu özellikleri sayesinde monolitik olarak kullanılabilmesi mümkün hâle gelmiş olsa da, estetik yeterlilik açısından özellikle

anterior bölgelerde hâlâ sınırlı bir performans sunmaktadırlar. Üçüncü nesil zirkonya materyalleri ise, itriyum oksit oranının (%4–5) ve dolayısıyla kübik faz bileşiminin artırılmasıyla geliştirilmiş olup, daha üstün optik özellikleri sayesinde ön bölgede estetik gereksinimleri karşılayabilmektedir. Ancak, artan kübik faz oranı nedeniyle mekanik dayanıklılık açısından önceki nesil zirkonyalara göre daha düşük mukavemet göstermektedir (19).

Zirkonya materyalleri, sinterlenmiş ya da pre-sinterlenmiş formda kullanılabilir. Pre-sinterlenmiş bloklar, daha düşük yoğunluğa sahip olduklarından frezeleme işlemi açısından daha avantajlıdır; frezeleme süresi kısaltmakta ve kullanılan kesici uçların ömrü uzamaktadır. Ancak bu materyaller, frezeleme sonrası sinterleme işlemi sırasında yaklaşık %20–25 oranında hacimsel küçülme gösterdiğinden, restorasyonların üretiminde bu küçülme göz önünde bulundurularak normalden daha büyük boyutlarda tasarım yapılması gerekmektedir. Uygun şekilde tasarlanan restorasyonlara, 1350–1500 °C sıcaklık aralığında sinterleme işlemi uygulanmaktadır. Bu işlem sırasında meydana gelen hacimsel küçülme, materyalin %99'un üzerinde bir yoğunluk kazanmasını sağlayarak, zirkonyanın nihai mekanik ve fiziksel özelliklerinin ortaya çıkmasına olanak tanımaktadır (15,20).

Zirkonya esaslı seramikler, tüm seramik materyaller içerisinde en yüksek kırılma direnci, Vickers sertliği ve mekanik dayanıklılığa sahip grubu oluşturmaktadır. Yaklaşık 900 MPa düzeyinde bükülme dayanımı ve 1200–1350 HVN aralığında Vickers sertliği sergileyerek klinik uygulamalarda üstün performans göstermektedirler(14–16,20). Zirkonya restorasyonlar, dijital diş hekimliğinde yaygın olarak kullanılan CAD/CAM teknolojisi ile üretilmektedir. Bu üretim yöntemi sayesinde elde edilen zirkonya restorasyonlar, marjinal ve internal adaptasyon açısından CAD/CAM sistemiyle üretilen pek çok diğer restoratif materyale kıyasla daha üstün uyum değerleri sunmaktadır (21–23).

2.2.2.3. Rezin Matriks Seramikler

Rezin matriks seramikler, polimer esaslı bir matriks içinde dağılmış inorganik seramik partiküllerini içeren hibrit restoratif materyaller olarak tanımlanmaktadır. Bu

malzemeler, seramiklerin yüksek dayanıklılık ve renk stabilitesi gibi avantajlarını; rezin kompozitlerin frezeleme kolaylığı, yeterli bükülme direnci, sinterleme ihtiyacı bulunmaması ve düşük aşındırıcılık özellikleri ile bir araya getirmektedir. Klinik uygulamalarda özellikle inley ve onley restorasyonlarda, anterior ve posterior bölgelerdeki tek üyeli sabit protezlerde tercih edilebilmektedirler (14,16,24). Üç gruba ayrılırlar;

Rezin Nanoseramikler

Yaklaşık %80 oranında reçine matriks içerisinde yer alan nanoseramik partiküllerle güçlendirilmiş olan bu materyaller, yüksek performanslı hibrit seramik sınıfına girmektedir. CAD/CAM teknolojisi ile üretilebilmeleri ve yapısal içeriklerindeki özgünlük sayesinde, geleneksel kompozit malzemelere kıyasla daha üstün aşınma direnci, kırılma tokluğu ve yaklaşık 200 MPa düzeyinde bükülme direnci sergilemektedirler. İçerdikleri nanopartiküller sayesinde, hem cilalanabilirlikleri hem de estetik açıdan istenen optik özellikleri sağlayan bir materyal özelliği göstermektedirler (14,16).

Rezin İnfiltr Edilmiş Cam Seramikler

Feldspatik seramik ağ ile polimer ağın bir araya getirilmesiyle oluşturulan bu materyaller, yapısal olarak hibrit bir kompozisyon sergilemektedir. Ağırlıkça yaklaşık %86'sı feldspatik seramik, %14'ü ise polimer fazdan oluşan bu yapılar, üretici firmalar tarafından "hibrit seramik" olarak adlandırılmaktadır (14,16).

Rezin İnfiltr Edilmiş Zirkonya-Silika Seramikler

Rezin infiltr edilmiş zirkonya-silika seramikler, BisGMA, UDMA ve TEGDMA gibi çeşitli organik polimer matrislerine; silika partikülleri, zirkonyum silikat ve renk pigmentleri gibi inorganik bileşenlerin eklenmesiyle elde edilen kompozit yapıları materyallerdir (14,16).

2.3. Metal Destekli Porselen Restorasyonların Tarihçesi

Diş hekimliği alanında bilimsel temellere dayanan ilk porselen kuron örneği, 1903 yılında Dr. Charles Land tarafından tanıtılmıştır. Dr. Land, kendi geliştirdiği düşük sıcaklıkta pişirilebilen porseleni platin folyo üzerine uygulayarak, ağız içi

kuvvetlere karşı direnç açısından zayıf olan ilk porselen jaket kuruunu üretmiştir. Land'ın bu jaket kuruonlara ilişkin aldığı patent ve sonrasında gerçekleştirdiği fiziksel ve mekanik dayanıklılığı artırmaya yönelik çalışmalar, protetik diş hekimliğinde önemli bir dönüm noktası olarak kabul edilmekte; aynı zamanda metal destekli porselen restorasyonların geliştirilmesine de önemli ölçüde katkı sağlamıştır (25).

Düşük ısıda pişirilen porselenlerde yapılan çeşitli kimyasal modifikasyonlar ve uzun yıllar süren klinik araştırmalar sonucunda, 1956 yılında Dr. S. Charles Brecker'in öncülüğünde metal destekli porselen restorasyonlar literatürde yerini almıştır. Brecker, altın alaşımları ile porselenin başarılı bir şekilde birleşmesini sağlayarak, jaket kuruonların uygulanmasının uygun olmadığı durumlar için alternatif bir sabit protetik tedavi seçeneği sunmuştur (25).

Metal destekli porselen restorasyonların uzun dönemli klinik başarı ve estetik performans göstermesiyle yaygın kullanımına, 1962 yılında gerçekleşen iki önemli bilimsel gelişme öncülük etmiştir. Bu gelişmelerden ilki, M. Weinstein, S. Katz ve A. B. Weinstein tarafından geliştirilen ve metal alaşımların termal genleşme katsayısıyla uyumlu olacak şekilde formüle edilen porselen sistemlerdir. İkinci önemli buluş ise, yine M. Weinstein ve A. B. Weinstein tarafından patenti alınan; dental alaşımların üretiminde kullanılan ve feldspatik porselenlerle kimyasal bağ oluşturabilen özel bileşenlerin geliştirilmesidir. Bu teknolojik ilerlemelerin yanı sıra, çeşitli yeni ürünlerin de pazara sunulmasıyla birlikte, metal destekli porselen restorasyonlar protetik diş hekimliğinde temel tedavi yaklaşımlarından biri haline gelmiştir (26).

2.4. Metal-Porselen Restorasyonlarda Kullanılan Alaşımların Sahip Olması Gereken Özellikler

Metal destekli porselen restorasyonların başarısı, büyük ölçüde alt yapıda kullanılan metalin tasarım özelliklerine, mekanik ve fiziksel dayanıklılığına ve metal ile porselen arasındaki bağlanma kalitesine bağlıdır. Bu nedenle, alt yapı materyali olarak tercih edilecek metal alaşımının yapısal ve fonksiyonel özelliklerinin ayrıntılı olarak bilinmesi ve alaşım seçiminin bu doğrultuda dikkatli biçimde yapılması klinik başarı açısından büyük önem taşımaktadır (27).

Biyouyumluluk: Tercih edilen metal alařımı, ağız ii sıvıların kimyasal etkilerine karřı direnli olmalı ve oral ortamda toksik, alerjik ya da insan saėlıėına zararlı herhangi bir madde salınımına neden olmamalıdır (28).

Lekelenme ve korozyona diren: Lekelenme, alařım yüzeyinde zamanla ince bir film tabakasının birikmesiyle oluřurken; korozyon, ağız ii sıvıların kimyasal etkisiyle metal yüzeyinde meydana gelen iyon özünmesi sonucu ortaya ıkar. Soy metal alařımları, bu tür yüzey bozulmalarına karřı en yüksek düzeyde korozyon ve lekelenme direnci gösteren materyaller arasında yer almaktadır (26).

Isısal genleşme katsayısı: Metal ve porselenin ısısal genleşme katsayılarının birbiriyle uyumlu olması, restorasyonun başarısı açısından büyük önem taşır. Genellikle, metalin ısısal genleşme katsayısının porselene kıyasla ok az bir farkla daha yüksek olması tercih edilir; bu durum, piřirme iřlemi sonrasında oluřabilecek ısısal streslerin minimum seviyeye indirilmesini saėlar (26,29).

Dökülebilirlik: Erime ařamasındaki alařım, revetman yüzeyleriyle kimyasal reaksiyona girmeksizin, tüm boşlukları porozite oluřturmadan doldurabilmelidir. Alařımın iyi bir dökülebilirliėe sahip olması, özellikle restorasyonun ince detaylarının eksiksiz şekilde şekillenebilmesi açısından büyük önem arz etmektedir (30).

Oksit formasyonu: Porselen veneer materyali ile güçlü bir kimyasal baė oluřabilmesi için, metal ile porselen arasındaki temas yüzeyinde ince ve kararlı bir oksit tabakasının gelişmesi gereklidir. Ancak bu tabakanın kontrolsüz şekilde kalınlaşması, metal-porselen arasındaki baėın zayıflamasına yol aar ve restorasyonun estetik başarısını olumsuz etkileyerek renk deėişimlerine neden olabilir (29).

Reziliens: Materyalin plastik deformasyona uğramadan mekanik enerjiyi absorbe edebilme kapasitesi olarak tanımlanmaktadır. Metal-porselen restorasyonlarda kullanılan metal alařımlarının yüksek reziliens modülüne sahip olmaları, iėneme sırasında ortaya ıkan kuvvetlere karřı minimum şekil deėişikliėi göstererek yapısal bütünlüklerini korumalarını saėlar. Bu durum, kırılğan porselen materyalin etkin şekilde desteklenmesi açısından kritik bir rol oynar (26,29).

Elastiklik modülü: Birim yüzeye uygulanan gerilme kuvveti karřısında materyalin gösterdiėi elastik deformasyon miktarı, o materyalin elastik esnemeye karřı direncini; bir bařka deyiřle rijiditesini ve katılıėını belirleyen önemli bir fiziksel

özelliğidir(26,29). Özellikle uzun gövde içeren protetik restorasyonlarda, yüksek rijiditeye sahip alaşımların tercih edilmesi, yapısal stabilitenin korunması ve deformasyon riskinin azaltılması açısından önemlidir (31).

Yorulma direnci: Materyale, elastik sınırının altında ancak sürekli şekilde uygulanan kuvvetler sonucunda stres döngüsü meydana gelir ve bu döngüye bağlı olarak zamanla yorgunluk oluşur. Oluşan bu yorgunluk, protez yapılarında kırılmalara yol açabilir. Özellikle çiğneme sırasında tekrarlayan streslerin gözlemlendiği ağız ortamında, kullanılan metal alaşımların yüksek yorulma direncine sahip olması, restorasyonun uzun ömürlülüğü açısından büyük önem taşır (30,32).

Akma direnci (Yield strength): Materyalde elastik deformasyonun sona erdiği ve kalıcı deformasyonun başladığı nokta, akma direnci olarak tanımlanır. Akma direnci, materyalin geri dönüşümsüz biçim değişikliğine uğramasına neden olan stres seviyesini ifade eder. Bu değerin üzerinde uygulanan gerilme, materyalde kalıcı deformasyonlara yol açar (26,29). Soy olmayan metal alaşımları, yüksek akma dayanıklılık değerlerine sahip olmaları nedeniyle özellikle ince marjinli preparasyonlarda ve uzun köprü uzantılı restorasyonlarda tercih edilmektedir (31).

Sertlik: Metal-porselen restorasyonlarda kullanılan alaşımların yüksek sertliğe sahip olması, aşındırma ve polisaj gibi laboratuvar işlemlerinin uygulanabilirliğini zorlaştırmakta; bu durum ise restorasyonun klinik başarısını olumsuz yönde etkileyebilmektedir. İnce marjinli preparasyonlar ve uzun köprü uzantıları açısından alaşımlarda sertlik arzu edilen bir özellik olsa da(31), aşırı sertlik gösteren alaşımların karşıt diş dokularında veya mevcut restorasyon yüzeylerinde aşınmalara yol açabileceği bildirilmektedir (26,30).

2.5. Metal Alt Yapılı Seramik Restorasyonlar

Seramik materyaller, çeşitli avantajları nedeniyle dental restoratif uygulamalarda yaygın olarak tercih edilmektedir. Bu materyallerin ışık geçirgenliğine sahip olmaları, doğal diş morfolojisini ve optik özelliklerini taklit edebilmeleri, ağız içi sıvılardan etkilenmemeleri, yumuşak dokularla biyolojik uyumluluk göstermeleri, yüksek aşınma direnci sunmaları, renk stabiliteleri ve doğal diş dokusuna benzer termal genleşme katsayısına sahip olmaları başlıca üstünlükleri arasında yer

almaktadır (33). Bu üstün özellikleri sayesinde seramikler, günümüzde diş hekimliğinde en sık tercih edilen restoratif materyaller arasında yer almaktadır (34). Seramik materyallerin mekanik dayanıklılığını ve gerilme streslerine karşı direncini artırmak amacıyla, bu yapılar sıklıkla metal alt yapılarla güçlendirilmektedir. Örneğin, tek başına yaklaşık 70 MPa gerilme direncine sahip olan feldspatik seramikler, metal destekli sistemlerle birlikte kullanıldığında bükülme direnci yaklaşık 550 MPa düzeyine ulaşmaktadır (35). Pişirme işlemi sırasında metal yüzeyinde oluşan oksit tabakası, seramik ile kimyasal bağlanmayı mümkün kılar. Bu kimyasal etkileşim, seramik yapı içerisinde oluşabilecek mikroçatlakların ilerlemesini engelleyerek restorasyonun dayanıklılığını artırır. Fırınlama sürecinde feldspatik seramikler hacimsel olarak yaklaşık %30–38, doğrusal olarak ise %11–15 oranında büzülme göstermektedir. Bu boyutsal değişim, seramiğin metal bir alt yapı ile desteklenmesi sayesinde kontrol altına alınabilir; böylece restorasyonun marjinal uyumu daha öngörülebilir ve stabil hâle gelir (35). Metal alt yapının ideal kalınlığı en az 0,5 mm olmalıdır. Bu değerin altında kalan kalınlıklarda, metal yapı uygulanan basınç karşısında deformasyona uğrayabilir ve bu durum, altyapının uyumunu olumsuz yönde etkileyerek restorasyonun stabilitesini azaltabilir (36).

2.6. Zirkonya Seramikler

2.6.1. Zirkonyanın Tarihçesi

Zirkon, tarihsel süreçte değerli bir taş olarak tanınmış ve mücevher yapımında kullanılmış bir mineraldir. “Zirkonyum” isminin kökeni, Arapça’da “altın renkli” anlamına gelen “Zargun” sözcüğüne dayanmaktadır. Bu terim, Farsça “zar” (altın) ve Arapça “gun” (renk) kelimelerinin birleşiminden türemiştir (37). Zirkonya, zirkonyum elementinin kristal yapılı dioksit formudur. Zirkonyum oksit, tıbbi alanda ilk kez 1969 yılında ortopedik uygulamalarda kullanılmak üzere geliştirilmiştir (38).

Diş hekimliğinin gelişmeye başladığı dönemlerden itibaren, özellikle metal alerjisi bulunan hastalar ve estetik beklentileri ön planda tutan klinik yaklaşımlar doğrultusunda, diş hekimleri metal içermeyen ve doğal diş dokusuna benzer renkte restorasyonlar geliştirme arayışında olmuşlardır. Bu doğrultuda, biyouyumlu dental

seramikler 20. yüzyılın son çeyreğinden itibaren önemli bir araştırma ve uygulama alanı hâline gelmiştir (39).

2.6.2. Zirkonyanın Mikroyapısı

Zirkonya, temel olarak üç farklı kristal fazda bulunabilir: monoklinik, tetragonal ve kübik faz. Saf zirkonya, oda sıcaklığında monoklinik fazda karardır ve bu yapı 1170 °C'ye kadar stabilitesini korur. Bu sıcaklığın üzerinde ise, erime noktası olan 2370 °C'ye kadar tetragonal faza dönüşür (Resim 2.2). Erime noktasının aşılmasının ardından zirkonya, kübik faza geçiş yapar. Soğuma sürecinde ise, tetragonal faz yaklaşık 100 °C ile 1070 °C arasındaki sıcaklıklarda yeniden monoklinik faza dönüşür. Bu faz dönüşümü sırasında oluşan yapısal değişim, yaklaşık %3–4 oranında bir hacim artışına neden olmaktadır (37). Bu istenmeyen hacimsel değişim nedeniyle, saf zirkonya dental ve medikal uygulamalarda sınırlı kullanıma sahiptir (40). Bununla birlikte, oda sıcaklığında metastabil bir kübik florit yapısında katı çözelti elde edilebilmesi için zirkonyuma belirli oranlarda MgO, CaO, Y₂O₃ veya nadir toprak elementlerine ait metal oksitlerin ilave edilmesiyle, faz geçişine bağlı olumsuz etkilerin giderilebileceğine dair çeşitli bilimsel bulgular bulunmaktadır (41). Zirkonyum oksidin CaO, MgO, Y₂O₃ gibi stabilizan oksitlerle modifiye edilmesi, yapının daha kararlı hâle gelmesini sağlar ve bu şekilde elde edilen zirkonya türü literatürde "Parsiyel Stabilize Zirkonya (PSZ)" olarak adlandırılır. Bu zirkonya bileşikleri, ağırlıklı olarak kübik kristal fazda bulunmaktadır (42).



Resim 2.2. Zirkonyumun Kristal Fazları ve Dönüşüm Sıcaklıkları (43)


Garvie ve Nicholson, 1972 yılında yaptıkları çalışmada, Parsiyel Stabilize Zirkonya'nın (PSZ) mekanik dayanımının, monoklinik fazın kübik matris içerisinde homojen ve ince taneli bir dağılım göstermesiyle arttığını ortaya koymuştur (44).

Zirkonya yapısında meydana gelen faz dönüşümleri çeşitli dış etkenler tarafından tetiklenebilir. Bu dönüşümler genellikle şu faktörlerle ilişkilidir;

- Termal yaşlanma sürecinde ortaya çıkan içsel gerilimler (45)
- Aşındırıcı işlemler sırasında uygulanan mekanik stresler (46)
- Kumlama gibi yüzey işlemleriyle oluşan mikro yapısal değişiklikler (47)

Zirkonyum oksidin bir mühendislik malzemesi olarak kullanımıyla birlikte, mekanik özelliklerini optimize edebilmek amacıyla tetragonal-monoklinik faz dönüşümünün nasıl gerçekleşmesi gerektiği üzerine çeşitli araştırmalar yapılmıştır. Elde edilen bulgular, kübik matris içerisinde dağılmış metastabil tetragonal fazların, malzeme içinde oluşan bir çatlak nedeniyle monoklinik faza dönüştüğünü göstermektedir. Bu faz dönüşümüne eşlik eden hacim artışı, çatlak ucunda gerilme alanı oluşturarak mevcut çekme gerilmelerine ters yönde etki eder ve böylece çatlak ilerlemesini yavaşlatır. Çatlağın yayılması sırasında ortaya çıkan enerji, hem faz dönüşümünü başlatmak hem de dönüşümle oluşan hacim artışına bağlı sıkıştırma gerilmelerini dengelemek için kullanıldığından, malzemenin kırılma tokluğu ve sertliğinde artış meydana gelir (48). Buna “dönüşüm sertleşmesi” denir.

Çatlak oluşumu ile meydana gelen faz dönüşümü Resim 2.3’de şematize edilmiştir.



Resim 2.3. Çatlak Oluşumu İle Meydana Gelen Faz Dönüşümü (37,49)

Dönüşüm sertleşmesinde temel doğrudan mekanizma, stres kaynaklı faz dönüşümüdür ve bu dönüşüme bağlı olarak çatlak sapması da gözlenebilmektedir. En önemli dolaylı mekanizma ise büyük olasılıkla stres etkisiyle meydana gelen mikro çatlak oluşumudur. Stres kaynaklı dönüşüm, parsiyel stabilize zirkonya (PSZ), tetragonal zirkonya polikristalleri (TZP) ve ZrO_2 içeren dispersiyonla güçlendirilmiş seramiklerde, sertlik ve kırılma tokluğunu artıran başlıca mekanizma olarak kabul edilmektedir (50). Ancak, faz dönüşümüne bağlı hacim artışı zirkonya yapısının elastik limitini aşarsa, bu durum çatlak ilerlemesini hızlandırabilir ve ikincil mikro çatlakların oluşumunu tetikleyebilir. Bu nedenle, zirkonya içindeki monoklinik faz oranının kontrol altında tutulması büyük önem taşır. Literatürde kabul edilen maksimum monoklinik faz oranı yaklaşık %25'tir; bu değerin üzerinde gerçekleşen faz dönüşümleri, yapının mekanik stabilitesini olumsuz etkileyerek istenmeyen yapısal bozulmalara yol açabilir (46,51).

Zirkonya yüzeyindeki tetragonal tanecikler, çevreleyen matris tarafından yeterli düzeyde kısıtlanmadığından, bazı koşullarda kararlılıklarını kaybedebilir. Bu nedenle, yüzeyin belirli bir derinliğinde oluşan aşınmaya bağlı kompresif gerilmeler

ya da spontane yapısal değişimler sonucunda bu tanecikler monoklinik faza dönüşebilir (37,52).

Zirkonya içeren birçok seramik türü mevcut olmakla birlikte, diş hekimliğinde klinik uygulama alanı bulan başlıca üç form bulunmaktadır: İtiryum ile stabilize edilmiş tetragonal zirkonya polikristalleri (Y-TZP), magnezyum içeren parsiyel stabilize zirkonya (Mg-PSZ) ve zirkonya ile güçlendirilmiş alümina (ZTA). Bu üç yapı, zirkonyanın mekanik dayanımı ve biyouyumluluğu sayesinde protetik restorasyonlarda yaygın olarak tercih edilmektedir (53). Y_2O_3 ile stabilize edilen ZrO_2 sistemlerinde, oda sıcaklığında tamamen tetragonal fazda kararlı olan zirkonya seramikleri elde edilebilmektedir. Bu tür yapılar, literatürde “Tetragonal Zirkonya Polikristalleri (TZP)” olarak adlandırılmaktadır (37).

2.6.3. Y-TZP Seramikler

İtiryumla stabilize edilmiş tetragonal zirkonya polikristalleri (Y-TZP), zirkonya bazlı seramik sistemler arasında en yaygın kullanılan formdur. Son yıllarda, hem üstün mekanik dayanımı hem de tatmin edici optik özellikleri nedeniyle diş hekimliğinde önemli ölçüde tercih edilir hâle gelmiştir. Ayrıca, CAD-CAM teknolojileri ile işlenebilir olmaları sayesinde, metal içermeyen restorasyonlarda estetik açıdan başarılı bir alternatif sunmaktadır(54,55). Bu sistemlerde Y_2O_3 içeriği genellikle %3–4 mol düzeyindedir ve elde edilen tetragonal faz, nanometre ölçeğinde yüzlerce ince taneli kristal yapıdan oluşur (37).

Tetragonal fazın materyal içerisindeki oranı; itiryum oksit (Y_2O_3) miktarına, tanecik boyutlarına ve bu taneciklerin matris yapısı tarafından ne ölçüde kısıtlandığına bağlı olarak değişkenlik göstermektedir (37).

Tetragonal faz taneleri yarı stabil bir özellik gösterir. İtiryum içeriğine bağlı olarak, tetragonalden monoklinik faza kendiliğinden dönüşümün gerçekleştiği özgül bir tanecik boyutu vardır. Bu faz değişimi, çok küçük tanecik boyutlarında meydana gelmez (56). Bu nedenle, tetragonal taneciklerin çaplarının küçültülmesiyle malzemenin sertliği ve dayanımı artırılabilir (57).

2.7. Yapay Zeka Nedir ?

Zekâ; öğrenme becerisi, kavrama yetisi ve mantıksal düşünme temelinde değerlendirme yapma veya görüş geliştirme kapasitesi olarak tanımlanmaktadır (58). İnsanların, hızlı karar alma yetenekleri ve hayatta kalmak için karmaşık araçlar geliştirme becerileri, en yüksek düzeyde zekâyâ sahip olmalarıyla ilişkilendirilmektedir. Temel olarak düşünme ve akıl yürütme kapasitesi, insanları diğer hayvan türlerinden ayıran en belirgin özelliklerden biri olarak kabul edilir. Binlerce yıl boyunca insanlar çevrelerine karşı ilgi duymuş, çeşitli deneyler yapmış ve yeni fikirler üretmiştir. Bilgisayar bilimi ve mühendislik alanındaki gelişmeler, İkinci Dünya Savaşı'nın hemen ardından, 1950'li yıllarda yapay zekâ (YZ) kavramının ortaya çıkmasına zemin hazırlamış ve bu alan, tarihin en devrimsel yaklaşımlarından biri olma potansiyelini kazanmıştır (59). McCarthy, 1955 yılında yayımladığı çalışmada yapay zekâyı, “Zeki makineler, özellikle zeki bilgisayar programları geliştirme bilimi ve mühendisliği” olarak tanımlamıştır (60). 1970'li yıllarda matematikçi Richard Bellman, yapay zekâyı; öğrenme, karar verme, problem çözme ve insan benzeri düşünce geliştirme yeteneklerinin otomatik biçimde gerçekleştirilmesi olarak tanımlamıştır (61). Yapay zekâ kavramı, farklı bakış açılarına göre çeşitli şekillerde tanımlandığından, tek bir tanım üzerinde uzlaşmak çoğu zaman güç olabilmektedir.

Yapay zekâ, son yıllarda birçok alanda uygulama imkânı bulmuştur. Bu alanlar arasında YZ tabanlı dijital asistanlar (62), meteorolojik tahmin sistemleri (63), otonom araç teknolojileri(64), oyun endüstrisi(65), mühendislikte iş çizelgeleme uygulamaları (66), dolandırıcılığı tespit ve önlemeye yönelik sistemler(67) ve sağlık hizmetleri (68) yer almaktadır.

2.8. Yapay Zekânın Tarihçesi


Günümüzde kullanılan modern bilgisayarların ve teknolojik sistemlerin temelinde, Aristoteles'in ortaya koyduğu mantık ilkeleri yatmaktadır. Süper bilgisayarların gelişiminde önemli bir dönüm noktası ise, 1950 yılında İngiliz matematikçi Alan Turing tarafından şifreli mesajları çözmek amacıyla geliştirilen bir makineyle yaşanmıştır. Bu cihazın geliştiricisi olan Turing, aynı zamanda bir

bilgisayarın insan düşünme biçimini ne ölçüde taklit edebildiğini değerlendiren ve makinelerin zekâya sahip olup olmadığını belirlemede kullanılan “Turing Testi”nin de fikir babasıdır (69,70).

Turing, makinelerin insan zekâsını taklit edip edemeyeceği sorusunu ortaya koymuş ve bu doğrultuda yapay zekânın değerlendirilmesine yönelik bir test geliştirmiştir (71). (Resim 2.4).

Turing Testi olarak bilinen bu değerlendirme yöntemi, tarafsız bir sorgulayıcının hem bir insan hem de bir makineyle etkileşime geçerek onları sorgulamasını esas alır. Sorgulayıcının temel amacı, yanıtların hangi kaynağa —insan ya da makine— ait olduğunu belirlemektir. Eğer sorgulayıcı, makine tarafından verilen yanıtları insan yanıtlarından ayırt edemez ve bu ayrımı yalnızca rastlantısal düzeyde yapabiliyorsa, ilgili makinenin Turing Testini geçmiş olduğu kabul edilir (71).

Model zekâ kavramını ele alan ilk çalışmalardan biri, Alan Turing tarafından Ekim 1950’de “Computing Machinery and Intelligence” başlığıyla yayımlanmıştır (72).



Resim 2.4. Turing Testi(73)

1956 yılında gerçekleştirilen Dartmouth Konferansı, yapay zekânın resmen bir disiplin olarak tanındığı ve hem adını hem de araştırma misyonunu kazandığı dönüm noktası olarak kabul edilmektedir (74). Bu konferans, Marvin Minsky, John McCarthy, Claude Shannon ve IBM’den Nathan Rochester tarafından organize edilmiştir ve yapay zekâ alanının başlangıç noktası olarak kabul edilmektedir.

Konferansta, “öğrenmenin her yönü ile zekânın diğer herhangi bir özelliğinin, bir makine tarafından simüle edilebilecek kadar kesin biçimde tanımlanabileceği” yönündeki iddia, alanın temel varsayımlarından biri olarak öne sürülmüştür (71).

Hesaplama kapasitesindeki artış ve sinir ağlarının geliştirilmesine yönelik çalışmaların hız kazanmasıyla birlikte, 1990’ların ortalarına doğru yapay zekâya olan ilgi yeniden artış göstermiştir.

Mikrobilgisayar devrimi ile Moore Yasası, bu dönemde yapay zekâ alanındaki ilerlemeleri yavaşlatan geleneksel Lisp makinelerinin yerini modern bilgisayar sistemlerinin almasını mümkün kılan teknolojik gelişmeleri tanımlamaktadır.


Yeterli düzeyde hesaplama gücüyle desteklenen yapay zekâ sistemlerinin potansiyeli, 1997 yılında IBM tarafından geliştirilen satranç oynayan süper bilgisayar Deep Blue ile somut biçimde ortaya konmuştur. Deep Blue’nun dünya satranç şampiyonu Garry Kasparov’u mağlup etmesi, kamuoyunun yapay zekâya olan ilgisini yeniden canlandırmış; bu gelişme, çok sayıda akademik yayına ve belgesel niteliğinde yapımlara konu olmuştur (75,76).

2.9. Makine Öğrenmesi

Makine öğrenmesi (MÖ), bilgisayarların veri örneklerinden öğrenerek bu veriler doğrultusunda tahminlerde bulunmasını veya kararlar almasını sağlayan algoritma ve modellerin geliştirilmesine odaklanan bir teknoloji alanıdır (77). Geleneksel programlama yöntemleri, sorunları çözmek için önceden tanımlanmış sabit kuralların uygulanmasına dayanırken; makine öğrenmesi (MÖ) sistemleri, geniş veri kümeleri üzerinden belirli bir görevin nasıl yerine getirileceğine ilişkin örüntülerin çıkarılmasına odaklanır. Bu sistemler, istenilen çıktıya en etkili biçimde nasıl ulaşılacağını, sunulan veri örnekleri aracılığıyla öğrenir (78). Makine öğrenmesi (MÖ), yapay zekânın öğrenme odaklı yönünü temsil eder ve veri kümelerini en iyi şekilde modelleyebilecek algoritmaların geliştirilmesine odaklanır (79). Veriye erişimin artması, makine öğrenmesi sistemlerinin daha geniş ve çeşitli örneklem kümeleri üzerinde eğitilmesine imkân tanırken; bilgisayarların artan işlem kapasitesi, bu sistemlerin analitik performansını önemli ölçüde desteklemektedir (80). Makine öğrenmesi günümüzde birçok sektörde uygulanmakta olup, kullanım alanları sürekli

genişlemektedir. Nesne tanıma, sesin metne dönüştürülmesi ve kullanıcı ilgi alanlarıyla içerik eşleştirme gibi uygulamalar, bu teknolojinin öne çıkan kullanım örnekleri arasında yer almaktadır (81).

Makine öğrenmesi (MÖ), verilerden anlamlı bir model oluşturmak amacıyla kullanılan bir yöntemdir. Bu veriler; belgeler, ses kayıtları, görüntüler gibi çeşitli bilgi türlerini içerebilir. MÖ sürecinin çıktısı olan model, öğrenme işleminin nihai ürünüdür. Modelin oluşturulmasında kullanılan verilere “eğitim verileri” adı verilir. MÖ süreci, öncelikle eğitim verileriyle modelin inşa edilmesini, ardından bu modelin gerçek dünya verilerine uygulanmasını kapsar. Bu sürecin genel yapısı Resim 2.5’te sunulmuştur. Şekildeki dikey yönlü akış, öğrenme aşamasını; yatay yönlü akış ise eğitilen modelin gerçek veriler üzerinde uygulanmasını temsil etmektedir (82).



Resim 2.5. Gerçek Verilerle Bir MÖ Modelinin Uygulanması(82)

Makine öğrenmesi algoritmaları, kullanılan öğrenme yöntemine bağlı olarak iki temel gruba ayrılmaktadır. Bunlardan ilki, gelecekteki çıktıları öngörebilmek amacıyla etiketli giriş ve çıkış verileri üzerinden modelin eğitildiği denetimli öğrenme yöntemidir. Diğeri ise, yalnızca giriş verilerini kullanarak bu verilerdeki gizli kalıpları veya içsel yapıları ortaya çıkarmayı amaçlayan denetimsiz öğrenme yöntemidir.

Denetimli öğrenme, makine öğrenmesi sisteminin etiketli örnek verilerle eğitildiği ve bu verilere dayanarak belirli çıktıları tahmin etmeyi amaçladığı bir öğrenme yöntemidir (83). Bu yöntemde sistem, veri kümelerini analiz edebilmek ve her bir örnek hakkında çıkarımda bulunabilmek amacıyla etiketli verileri kullanarak bir model geliştirir (84). Eğitim ve modelleme süreci tamamlandıktan sonra, modelin

doğruluğunu ve genellenebilirliğini değerlendirmek amacıyla test verileri kullanılarak performans analizi gerçekleştirilir. Denetimli öğrenmenin temel amacı, giriş verilerini karşılık gelen çıkış verileriyle doğru şekilde eşleştirmektir. Örneğin, bir metnin ait olduğu sınıf etiketini veya duygusal yönelimini tahmin etmek, yani metin sınıflandırması yapmak, denetimli öğrenme yaklaşımına örnek olarak gösterilebilir. Denetimli öğrenme algoritmaları, genel olarak sınıflandırma ve regresyon olmak üzere iki ana gruba ayrılır. Sınıflandırma algoritmaları, verileri önceden tanımlanmış sınıflara ayırarak kategorik etiketlemeye olanak sağlar (85). Bu yöntemler, etiketlenmiş röntgen görüntülerinden patolojik bulguların saptanması (88) ve genetik hastalıkların tanınmasına yönelik genetik verilerin sınıflandırılması (86) ve genetik hastalıkların teşhisi için genetik verilerin sınıflandırılması (87) gibi tıbbi uygulamalarda; ayrıca konuşma tanıma gibi farklı alanlarda da yaygın biçimde kullanılmaktadır (88). Regresyon yaklaşımında ise, değişkenler arasındaki ilişkiler analiz edilerek geleceğe yönelik eğilimlerin tahmin edilmesi hedeflenir (85). Bu yöntemler, pilin şarj seviyesi, elektrik yükü tahmini (89) ve finansal varlıkların fiyat öngörülmesi (90) gibi sürekli değişkenlerin tahmininde kullanılmaktadır. Tıp alanında regresyon yöntemine örnek olarak, hastalık progresyonunun öngörülmesi verilebilir. Örneğin, diyabet hastalarında zaman içinde kan şekeri düzeylerinin değişimini tahmin etmek amacıyla regresyon tekniklerinden yararlanılabilir. Bu tür tahminler, hastaların önceki glukoz ölçümlerine dayalı olarak gelecekteki değerlerin öngörülmesine olanak tanır ve böylece tedavi planlarının optimize edilmesini ve erken müdahale fırsatlarının değerlendirilmesini mümkün kılar (91).

Denetimsiz öğrenme, herhangi bir dış denetim veya etiketli veri olmaksızın gerçekleştirilen bir öğrenme yöntemidir. Bu yöntemde makine, etiketlenmemiş veri setleri üzerinde eğitilir ve verilerdeki örüntüleri ya da yapısal ilişkileri kendi başına keşfetmesi beklenir (92). Denetimsiz öğrenme algoritmaları, etiketlenmemiş veri kümelerini giriş verileri arasındaki benzerlikler, farklılıklar ve örüntüler doğrultusunda gruplandırmayı hedefler (93). Denetimsiz öğrenme yöntemleri arasında en yaygın uygulama alanları; kümeleme, yoğunluk tahmini, özellik çıkarımı, boyut indirgeme, birliktelik kuralları keşfi ve anormallik tespiti olarak sıralanabilir. Kümeleme, bir veri kümesindeki örnekleri, belirli özellik kombinasyonlarına göre birbirine benzeyen gruplar hâlinde sınıflandırmayı amaçlar. Örneğin, müşterilerin satın alma

davranışlarına göre segmentlere ayrılması, bu yöntemin uygulamalarından biridir. Birliktelik kuralı algoritmaları ise büyük ölçekli veri kümeleri içerisindeki değişkenler arasındaki tipik ilişkileri belirlemeye yöneliktir. Bu algoritmalar, farklı veri ögeleri arasındaki bağımlılık yapılarını analiz eder ve birlikte görülen değişken kümelerini haritalandırır. Web kullanıcı davranışlarının incelenmesi ve pazarlama verilerinin analizi gibi alanlarda yaygın olarak kullanılmaktadır. Denetimsiz öğrenme algoritmalarının sağlık alanındaki önemli bir uygulama örneği, tıbbi görüntüleme verilerinde anormallik tespittir. Örneğin, beyin manyetik rezonans (MR) görüntülerinde, sağlıklı dokulardan farklılık gösteren anomalilerin otomatik olarak tespit edilmesi mümkündür. Bu yöntem, özellikle beyin tümörleri gibi ciddi hastalıkların erken teşhisinde klinik sürece önemli katkılar sağlayabilmektedir (81).

2.10. Derin Öğrenme

Derin öğrenme (DÖ), ham girdi verilerinden daha üst düzeyde özelliklerin çıkarılmasını sağlayan ve çok katmanlı yapılar üzerinden öğrenme gerçekleştiren bir makine öğrenmesi algoritması türüdür (94).

Bu algoritmalar, katmanlı bir mimariye sahip olan Yapay Sinir Ağları (YSA) yapısını temel alır. YSA'da her bir yapay nöron, biyolojik sinir sistemindeki nöronlara benzer şekilde modellenmiştir. Yapay Sinir Ağları, kendi kendine öğrenme yeteneğine sahip olup, öğrenilen bilgilere dayanarak bağımsız kararlar verebilir (95). Derin öğrenme (DÖ) ağları; bir girdi katmanı, bir çıktı katmanı ve bir ya da birden fazla gizli katmandan oluşan çok katmanlı yapılardır. Gizli katmanlar, birbirine bağlı ağırlıklı düğümler ya da yapay nöronlardan meydana gelir. “Derin” ifadesi, ağ yapısındaki gizli katmanların sayısına atıfta bulunur. Geleneksel yapay sinir ağlarında gizli katman sayısı genellikle iki veya üç ile sınırlıyken, derin öğrenme modellerinde bu sayı daha fazladır. Bu durum, derin öğrenme algoritmalarının büyük ve karmaşık veri kümelerini öğrenme ve işleme kapasitesini artırmaktadır (96). Derin öğrenme algoritmaları, veriyi çok katmanlı bir yapıda işler; her bir katman, belirli özellikleri kademeli olarak çıkarır ve bu bilgileri bir sonraki katmana aktarır. Bu yapı içerisinde, her katman bir önceki katmanın çıktısını girdi olarak alır. Ağın ilk katmanları daha basit ve düşük düzeyli özellikleri öğrenirken, sonraki katmanlar bu bilgileri birleştirerek daha karmaşık ve soyut temsiller oluşturan hiyerarşik bir yapı meydana getirir (97).

Derin öğrenme, makine öğrenmesinin temsili öğrenme veya özellik çıkarımı alanına dayanmaktadır. Bir gözlem, piksel yoğunluklarının oluşturduğu bir vektör şeklinde ya da kenarlar ve belirli geometrik desenler gibi daha soyut yapılar aracılığıyla temsil edilebilir. Derin öğrenmenin en önemli katkılarından biri, denetimsiz veya yarı denetimli öğrenme yöntemleriyle, geleneksel olarak elle tanımlanan özelliklerin yerini otomatik ve katmanlı biçimde çıkarılabilen özelliklerle değiştirebilmesidir (98). Bu yönüyle derin öğrenme, yapılandırılmamış verilerle çalışırken çok sayıda özelliği aynı anda işleyebilme kapasitesi sayesinde, geleneksel makine öğrenmesi yöntemlerine kıyasla daha üstün bir performans sergilemektedir (99). Makine öğrenmesi algoritmalarında problem çözme süreci, genellikle problemi alt bileşenlere ayırarak her birini ayrı ayrı çözmeyi ve elde edilen sonuçları birleştirerek nihai sonuca ulaşmayı gerektirir. Buna karşın, derin öğrenme yaklaşımları problemi doğrudan uçtan uca ele alarak, tüm süreci tek bir model yapısı içerisinde çözümleyebilir (81). Derin sinir ağı, makine öğrenmesinde elde edilen nihai model olarak işlev görürken; öğrenme kuralı ise, eğitim verilerinden bu modeli oluşturan algoritma olarak tanımlanır. Derin sinir ağlarının önemi, bilgiyi katmanlı ve hiyerarşik bir biçimde işleyebilen karmaşık doğrusal olmayan yapıları ve bu yapılar aracılığıyla sistematik bir öğrenme yaklaşımını mümkün kılmalarıyla öne çıkmaktadır (82).

Derin öğrenme yöntemleri, uçtan uca öğrenme yaklaşımıyla özelliklerin otomatik olarak çıkarılmasını ve doğrudan sınıflandırılmasını mümkün kılar. Son on yılda, derin sinir ağlarının bir türü olan Evrişimli Sinir Ağları (ESA), örüntü tanıma alanındaki çeşitli görevlerde dikkat çekici başarılar elde etmiştir. İnsan görsel korteksinden ilham alınarak geliştirilen ESA'lar, özellikle görüntü tanıma problemlerinde farklı sınıfların ayrımında yüksek doğruluk oranları sergilemektedir (100,101). Ancak, Evrişimli Sinir Ağları (ESA) genellikle yüksek doğrulukla çalışabilmeleri için büyük miktarda eğitim verisine ihtiyaç duyar. Bu nedenle, tıbbi görüntü analizi gibi veri kısıtlı alanlarda ESA'nın kullanımı; ya ağın sıfırdan eğitilmesiyle, ya önceden eğitilmiş bir modelin doğrudan yeniden kullanılmasıyla ya da önceden eğitilmiş bir ağın hedef veri kümesine uyarlanarak yeniden eğitilmesiyle gerçekleştirilmektedir (102). Bu zorluğun aşılabilmesi amacıyla, ImageNet gibi geniş ölçekli görüntü veri setleri üzerinde eğitilmiş ESA modellerinden edinilen bilgileri yeni görev alanlarına aktaran transfer öğrenme yaklaşımı geliştirilmiştir (103). Bu


yöntemde, modelin ilk katmanları genellikle sabitlenir (kilitlenir) veya yalnızca küçük ayarlamalara tabi tutulurken, son katmanlar hedef veri kümesine özgü olacak şekilde yeniden eğitilir. Kaynak ve hedef veri kümeleri farklı olsa da, model görüntüleri değerlendirirken çoğunlukla ortak olan düşük seviyeli özellikleri (kenar, doku, renk farkı gibi) çıkarmaya devam eder. Bu sayede, modeli sıfırdan eğitmek için büyük miktarda etiketli veriye duyulan ihtiyaç azaltılır. Transfer öğrenme yaklaşımı, hem eğitim süresini kısaltmakta hem de işlem maliyetlerini önemli ölçüde düşürmektedir (104).

2.10.1. Özellik Çıkarımı

Özellik çıkarımı, veri setlerinin karmaşıklığını azaltmak, algoritmaların öğrenmesini kolaylaştırmak ve örüntüleri daha belirgin hâle getirmek amacıyla, alan bilgisi kullanılarak özellik çıkarıcıların oluşturulmasını içeren bir süreçtir. Bu süreç, zaman alıcı olmasının yanı sıra yüksek düzeyde uzmanlık gerektiren ve maliyetli bir adımdır. Uygulanan birçok özellik, ilgili alandaki uzmanlar tarafından tanımlanmalı ve ardından makine öğrenmesinde kullanılan veri türüne ve probleme özgü olarak manuel şekilde kodlanmalıdır. Bu özellikler; piksel yoğunlukları, şekil, doku, konum ve yönelim gibi çeşitli öznitelikleri içerebilir. Makine öğrenmesi algoritmalarının başarımı, büyük ölçüde bu özelliklerin doğruluğu ve uygunluğu ile doğrudan ilişkilidir. Derin öğrenme algoritmaları ise, verilerden yüksek düzeyde soyutlanmış özellikleri otomatik olarak çıkararak bu süreci büyük ölçüde otomatize eder. Bu da, geleneksel makine öğrenmesine kıyasla derin öğrenmenin temel avantajlarından biridir. Sonuç olarak, derin öğrenme yöntemleri her yeni problem için manuel olarak özellik çıkarıcı geliştirme gereksinimini azaltır ve verilerden daha anlamlı yüksek seviyeli temsiller elde edilmesini sağlar (81).

Derin özellik çıkarma, genellikle ImageNet gibi büyük ölçekli veri kümeleri üzerinde önceden eğitilmiş bir Evrişimli Sinir Ağı (ESA) modelinden elde edilen özelliklerin çıkarılmasına dayanmaktadır (103). Bu özellikler, evrişimli katmanlar aracılığıyla çıkarılarak bir özellik vektörü elde edilir. Elde edilen bu vektörler, yeni bir görev kapsamında makine öğrenmesi sınıflandırıcılarına —örneğin Destek Vektör Makineleri (DVM), K-En Yakın Komşuluk (KNN)— ya da tam bağlantılı katmanlardan oluşan bir softmax sınıflandırıcısına iletilir. Bu yöntemde, tüm derin

öğrenme modelinin yeniden eğitilmesi yerine yalnızca son sınıflandırıcı katman eğitilir. Bu yaklaşımın temel avantajı, önceden eğitilmiş modelin her eğitim döngüsünde çalıştırılmasına gerek kalmadan yalnızca yeni veriler üzerinde işlem yapılmasıdır; bu da eğitim sürecini önemli ölçüde hızlandırır (105). Resim 2.6’da, derin bir sinir ağına giriş olarak verilen bir görüntüden, düşük seviyeli özneteliklerden başlayarak yüksek seviyeli temsillere kadar çıkarılan özelliklerin, görüntü tanıma sürecinde nasıl kullanıldığına ilişkin örnek bir uygulama sunulmaktadır.



Resim 2.6. Görüntülerin İki Tarafından Özellik Çıkarma İşleminin Bir Örneği(106)

2.10.2. Transfer Öğrenme

Transfer öğrenimi, bir modelin bir görevde edindiği bilgileri başka bir görevde yeniden kullanılmasına olanak tanıyan bir makine öğrenmesi tekniğidir. Bu yaklaşım, genellikle geniş ve kapsamlı bir veri kümesi üzerinde önceden eğitilmiş bir modelin, daha küçük veya farklı bir veri kümesine uyarlanması amacıyla tercih edilir. Transfer öğrenimi, modelin daha kısa sürede eğitilmesini sağlarken, hesaplama maliyetlerini de önemli ölçüde azaltır. Ayrıca, büyük bir veri kümesinden öğrenilen temsillerin, sınırlı sayıda etiketlenmiş örnek içeren yeni bir veri kümesindeki model performansını artırabileceği gösterilmiştir. Derin öğrenme modellerinin son katmanları genellikle eğitildikleri veri kümesine özgü bilgileri barındırdığından, bu katmanların hedef veri kümesine göre yeniden yapılandırılması, modelin yeni verilere etkin biçimde uyum sağlamasını mümkün kılar. Bu yönüyle transfer öğrenimi, önceden eğitilmiş bir

modelin sahip olduđu bilgi ve deneyimi, farklı görevlerde yeniden kullanıma sunarak verimlilik sağlar (107).

Sınıflandırma problemleri için kullanılabilecek birçok önceden eğitilmiş transfer öğrenme modeli bulunmaktadır. Bu modeller, benzer yapıya sahip görevleri çözmek amacıyla daha önce geliştirilmiş ve geniş veri kümeleri üzerinde eğitilmiş yapılardır. Genellikle sınıflandırma problemleri büyük ölçekli veri setleriyle eğitildiğinden, benzer bir problemi çözmek için sıfırdan bir model geliştirmek yerine, daha önce eğitilmiş bir modelden faydalanmak verimli bir başlangıç noktası sunar. Hedef alandaki veri miktarına bağlı olarak, modelin tüm katmanları yeniden eğitilebileceği gibi yalnızca son, tam bağlantılı (fully connected) katman da yeniden yapılandırılabilir. Bu yaklaşım, kaynak veri kümesinden öğrenilen düşük seviyeli ve genel geçer özelliklerin yeniden kullanılmasına olanak tanıyarak, sinir ağlarının daha küçük veri kümeleriyle yeni görevler üzerinde etkili biçimde eğitilmesini mümkün kılar (108,109).

Her derin öğrenme modelinin başarımı, büyük ölçüde mevcut eğitim verilerinin niceliği ve niteliğine bağlıdır. Geniş veri kümeleri, modelin daha etkin öğrenmesini sağlayarak doğruluk oranlarını artırabilir. Ancak, sağlık alanındaki uygulamalarda hasta mahremiyeti ve veri gizliliğine ilişkin kısıtlamalar nedeniyle, büyük ölçekli etiketli veri setlerine erişim her zaman mümkün olmamaktadır. Bu tür durumlarda, veri yetersizliğini aşmak amacıyla transfer öğrenme yöntemi yaygın olarak kullanılmaktadır. Bu yaklaşımda, daha önce büyük bir veri kümesi üzerinde eğitilmiş bir modelin ağırlıkları kullanılarak, model yeni hedef görev için uyarlanmakta ve yeniden eğitilmektedir (107,110).

Transfer öğrenme sürecinde genellikle iki temel yaklaşım benimsenir. İlk yaklaşımda, aktarılan modelin çıktı katmanı hedef veri kümesindeki sınıf sayısına göre yeniden yapılandırılır ve ardından model üzerinde bazı katmanların dondurulması gibi ince ayarlamalar (fine-tuning) gerçekleştirilir. İkinci yaklaşımda ise, önceden eğitilmiş model, yalnızca bir özellik çıkarıcı olarak kullanılır ve bu modelden elde edilen çıktı veriler, başka bir sınıflandırıcı algoritmayla değerlendirilir (111).

2.10.3. Uçtan Uca Öğrenme

Uçtan uca derin öğrenme, herhangi bir manuel özellik mühendisliğine ihtiyaç duymadan, ham girdi verilerinden doğrudan çıktı üretebilen ve karmaşık görevler için tek bir sinir ağı modelinin eğitildiği bir makine öğrenmesi yaklaşımıdır. Bu yöntem, büyük ölçekli veri kümelerinin oluşturulmasıyla birlikte konuşma tanıma, makine çevirisi ve yüz algılama gibi çeşitli alanlarda önemli ilerlemelere olanak sağlamıştır. Geleneksel makine öğrenmesi yöntemlerinde ise, eğitim süreci genellikle iki temel aşamadan oluşur: İlk aşamada, ham veri girişlerinden ayrıştırıcı özellikler çıkarılır. Bu işlem, görevle en ilişkili öznitelikleri belirleyebilmek için uzmanlık bilgisine dayalı olarak gerçekleştirilir. İkinci aşamada ise, elde edilen bu özellikler kullanılarak model tahminleri üretilir. Ancak bu yöntem hem zaman alıcıdır hem de belirli bir alana özgü bilgi gerektirir (112).

Uçtan uca derin öğrenme, manuel olarak çıkarılmış özelliklere ihtiyaç duymadan, giriş ve çıkış arasındaki ilişkiyi doğrudan verilerden öğrenen bir yaklaşımdır. Bu yöntemde, genellikle büyük ölçekli veri kümeleri üzerinde eğitilmiş olan geniş yapıları bir sinir ağına ham girdi verileri aktarılır. Ağ, bu verileri işleyerek tahminler üretmek için gerekli olan anlamlı özellikleri otomatik olarak çıkarır. Bu süreç, geleneksel yöntemlerde gerekli olan manuel özellik mühendisliğini ortadan kaldırarak önemli ölçüde zaman ve emek tasarrufu sağlar. Bu tekniğin başarısı, büyük miktarda veriye dayalı eğitim süreci ve sinir ağlarının çok sayıda örnek üzerinden yüksek seviyeli temsil ve ilişkileri öğrenme kapasitesiyle doğrudan ilişkilidir (113).

2.11. Evrişimli Sinir Ağları (ESA)


Evrişimli Sinir Ağları (ESA), görüntülerdeki örüntüleri tanımak amacıyla öğrenilebilir filtreler ya da çekirdekler kullanan bir derin öğrenme algoritmasıdır (114). Bu filtreler, görüntülerdeki kenar, doku, renk ve şekil gibi temel öznitelikleri belirlemek amacıyla kullanılır. Evrişimli Sinir Ağları (ESA), biyolojik sinir sistemlerinden esinlenerek tasarlanmış ve paralel biçimde çalışan basit hesaplama birimlerinden oluşan çok katmanlı doğrusal olmayan yapıları bir araya getirir. ESA mimarisi genellikle çok sınıflı sınıflandırma problemleri için kullanılmakta olup, en önemli özelliklerinden biri, geleneksel yöntemlerde olduğu gibi el ile tasarlanmış bir

özellik çıkarıcıya ihtiyaç duymamasıdır. Bunun yerine, özellik çıkarmı süreci modelin eğitim aşamasına entegre edilmiştir. Özellikleri çıkaran yapılar, doğrudan eğitim sırasında optimize edilen özel sinir ağı katmanlarından oluşur. Bu durum, ESA'nın özellik çıkarmı sürecini otomatikleştirmesini sağlar ve onu geleneksel yöntemlere kıyasla daha esnek ve verimli hâle getirir (82).

Bir Evrişimli Sinir Ağı (ESA), temel olarak özellik çıkarma ağı ile sınıflandırma ağı arasında ardışık bir bağlantıdan oluşan bir yapıya sahiptir. Girdi olarak alınan görüntü ilk olarak özellik çıkarma ağına aktarılır; bu aşamada görüntüden anlamlı öznitelikler çıkarılır ve elde edilen özellik temsilleri sınıflandırma ağına iletilir. Sınıflandırma ağı, bu özniteliklere dayanarak görüntünün ait olduğu sınıfı belirleyerek çıktı üretir.

Özellik çıkarma bölümü, genellikle evrişim katmanı, aktivasyon fonksiyonu ve havuzlama katmanının oluşturduğu birimlerden oluşur. Evrişim katmanları, görüntü üzerinde evrişim işlemi uygulayarak çeşitli dijital filtreler aracılığıyla belirli yapısal öğeleri (örneğin kenarlar, köşeler, dokular) algılar. Ardından gelen havuzlama (pooling) katmanı, komşu pikselleri özetleyerek görüntünün boyutunu küçültür ve böylece hem hesaplama yükünü azaltır hem de modelin genel örüntüleri öğrenme kabiliyetini artırır. Bu katman yapısı, derin ağ mimarilerinde onlarca hatta yüzlerce kez tekrarlanarak, her seviyede daha soyut ve karmaşık özelliklerin öğrenilmesini sağlar.

Özellik çıkarmı sürecinden sonra, ESA mimarisi sınıflandırma aşamasına geçer. Bu aşamada yer alan tam bağlantılı (fully connected) katman, ağın tahmin edebileceği sınıf sayısı kadar bir çıktı üretir; bu çıktı, her bir sınıfa ilişkin olasılıkları içeren K boyutlu bir vektördür. Son katmanda yer alan softmax aktivasyon fonksiyonu, bu olasılık vektörünü normalize ederek görüntünün hangi sınıfa ait olduğunu belirlemeye yönelik bir olasılık dağılımı oluşturur. Bu yapı, ESA'nın görüntü sınıflandırma görevlerinde etkili bir şekilde kullanılmasını sağlar (115,116).



Resim 2.7. ESA Model Mimarisi(117)

2.12. ESA Katmanları

2.12.1. Giriş Katmanı

ESA mimarisinde ilk basamağı oluşturan giriş katmanı, ağına doğrudan ham verileri aldığı yapıdır. Bu katmanda, sistemin işlemeye başlayacağı veri seti doğrudan modele sunulur. Örneğin, giriş verisi bir görüntü olduğunda, bu görüntü her pikselin renk yoğunluğunu temsil eden sayısal değerlerle tanımlanır ve çok boyutlu tensörler şeklinde modele aktarılır. Tensörler, görüntünün boyutlarına ve renk kanallarına (örneğin RGB) göre yapılandırılarak sinir ağına bilgi sağlayan temel veri formatını oluşturur (115). Tensörler, farklı boyutlara sahip çok boyutlu matris yapılarıdır ve bu boyutlar genellikle görüntü verisinin yüksekliği, genişliği ve kanal sayısına göre belirlenir. Derin öğrenme mimarilerinde giriş katmanına sunulan görüntünün boyutu, modelin genel performansı üzerinde doğrudan etkilidir. Geniş boyutlara sahip giriş verileri, bellekte daha fazla yer kaplamakta ve modelin parametre sayısını artırarak işlem süresini uzatabilmektedir. Ancak, bu durum aynı zamanda daha ayrıntılı özelliklerin çıkarılmasına olanak tanıyarak sınıflandırma performansını artırabilir. Buna karşılık, daha küçük boyutlardaki giriş verileri bellek kullanımını azaltır ve daha az parametre gerektirdiğinden işlem süresi açısından avantaj sağlar. Fakat bu durum,


çıkarılabilecek özniteliklerin sınırlı olması nedeniyle modelin başarımını olumsuz etkileyebilir. Dolayısıyla, giriş verisinin boyutu; ağıın hızını, bellek tüketimini ve genel doğruluk düzeyini etkileyen kritik bir parametre olarak değerlendirilmelidir (118).

2.12.2. Evrişim Katmanı

Evrişim katmanları, Evrişimli Sinir Ağı (ESA) mimarisinin temel yapı taşları olup, giriş verisi üzerinden anlamlı özniteliklerin çıkarılmasını sağlayan birincil katmanlardır. Bu katmanlar, öğrenilebilir ağırlıklara sahip filtreler (çekirdekler) aracılığıyla giriş görüntüsünü tarayarak, belirli desenleri, kenarları, dokuları ve diğer görsel öğeleri tanımlayan özellik haritalarını (feature maps) oluştururlar. Her bir filtre, görüntünün farklı bir yönünü tanımaya yönelik olarak eğitilir ve bu sayede model, görüntüdeki karmaşık yapıları daha soyut düzeylerde temsil edebilir. Evrişim işlemi, görüntüdeki yerel örüntülerin korunmasını sağlarken, aynı zamanda parametre sayısının azaltılmasına da olanak tanır. Bu özellik, ESA mimarilerinin yüksek doğrulukla ve verimli şekilde çalışmasına katkı sağlar (119). Evrişim katmanlarında kullanılan filtreler çeşitli boyutlarda olabilir; en yaygın olarak tercih edilen boyutlar 2×2 , 3×3 veya 5×5 gibi küçük matrislerdir. Bu filtreler, giriş görüntüsüne evrişim (convolution) işlemi uygulanarak özellik haritalarının oluşturulmasını sağlar. Evrişim işlemi, filtre matrisinin giriş verisi üzerinde belirli bir adım (stride) ile kaydırılması ve her konumda filtre ile örtüşen değerlerin çarpımlarının toplamının alınması esasına dayanır. Bu işlem, görüntüdeki yerel örüntülerin tespit edilmesine olanak tanıyan temel bir doğrusal dönüşüm sürecidir (115). Evrişim katmanlarının eğitim sürecinde, her bir öğrenme döngüsünde (iterasyon) filtre katsayıları güncellenir. Bu güncellemeler, ağıın giriş verilerinden anlamlı özellikleri daha etkin bir biçimde çıkarabilmesini sağlar ve dolayısıyla ağıın öğrenme kapasitesine doğrudan katkıda bulunur (118). Giriş verilerinden elde edilen özellikler; köşe ve kenar yapıları, bölgesel yoğunluk farkları, eğrisel formlar, dokusal desenler, şekiller ve diğer soyut örüntüleri içerebilir. Bu özelliklerin çıkarılması, yapay sinir ağının hedeflenen görevi öğrenmesi ve yeni verilere genelleme yetisini kazanması açısından kritik öneme sahiptir (115).

Her filtre, giriş görüntüsü üzerinde uygulanan işlem sonucunda belirli özellikleri algılayarak bir çıktı üretir. Bu çıktılar, bir matris yapısında düzenlenerek

özellik haritalarını oluşturur. Katmanda bulunan filtre sayısı kadar özellik haritası elde edilir. Elde edilen bu haritalar, görüntüdeki belirgin yapısal bilgileri temsil eder ve bir sonraki katmana iletilir. Özellik haritaları, ağı öğrenme sürecinde önemli rol oynayan verileri barındırır. Aktivasyon fonksiyonlarının uygulanmasıyla birlikte bu haritalar, sinir hücrelerinin çıktılarının görselleştirilmiş hâli olan aktivasyon haritalarına dönüşür. Böylece model, her katmanda görüntüden yeni bilgiler çıkararak öğrenme sürecini derinleştirir (120).



Resim 2.8. Evrişim Katmanında Bir Filtre İle Birlikte Evrişim İşleminin Gösterimi (120)


2.12.3. Toplu Normalizasyon Katmanı

Toplu normalizasyon katmanı (Batch Normalization), bir sinir ağı katmanının girişlerini her kanal için ayrı ayrı olacak şekilde, belirli bir mini veri kümesi (mini-batch) üzerinden normalize etmeyi amaçlayan bir yöntemdir. Bu yaklaşım, ağı her bir katmanına giren verilerin ortalamasını sıfıra, standart sapmasını bire yaklaştırarak eğitim sürecini dengeler. Böylece, öğrenme süreci hızlanır ve ağı daha stabil bir şekilde eğitilmesi sağlanır. Eğitim esnasında, her girdi değişkeni için hesaplanan istatistiksel değerler (ortalama ve standart sapma) kullanılarak veriler yeniden ölçeklendirilir. Toplu normalizasyonun, derin öğrenme modellerinin doğruluk oranlarını iyileştirdiği ve özellikle derin sinir ağı yapılarında daha hızlı yakınsama sağladığı gösterilmiştir. Bu yöntem, farklı derin öğrenme mimarileriyle uyumlu olarak yaygın şekilde kullanılmaktadır (121). Araştırmalar, toplu normalizasyon katmanlarının derin sinir ağlarının eğitim sürecini önemli ölçüde hızlandırdığını ortaya koymuştur. Öyle ki, aynı doğruluk düzeyine ulaşmak için gereken eğitim adımı

sayısının yaklaşık 14 kat azaltılabileceği bildirilmektedir. Bu nedenle, Evrişimli Sinir Ağı (ESA) mimarilerinde eğitim sürecini hızlandırmak ve başlangıç performansını iyileştirmek amacıyla, evrişim katmanları ile doğrusal olmayan aktivasyon fonksiyonları—özellikle Düzeltilmiş Doğrusal Birim (ReLU)—arasına toplu normalizasyon katmanlarının eklenmesi yaygın bir uygulamadır. Bu yapılandırma, ağı daha hızlı ve kararlı bir şekilde öğrenmesini sağlamakta, aynı zamanda aşırı büyük ağırlık değerlerinin neden olabileceği problemleri azaltmaktadır (121,122).

2.12.4. Etkinleştirme (Aktivasyon) katmanı


Aktivasyon katmanları, ESA'nın temel bileşenlerinden biridir ve modele doğrusal olmayanlık kazandırmak amacıyla kullanılır. Evrişim katmanından sonra gelir ve elde edilen çıktıyı sınırlandırarak öğrenme sürecine katkı sağlar (123). Bu katmanın temel amacı, evrişim katmanından elde edilen doğrusal çıktıları doğrusal olmayan yapılara dönüştürerek ağı öğrenme kapasitesini artırmaktır. Aktivasyon fonksiyonları olarak bilinen bu işlemler farklı türlerde olabilir. ESA yapılarında en sık kullanılan aktivasyon fonksiyonu ReLU'dur. ReLU, matematiksel olarak $f(x) = \max(0, x)$ şeklinde tanımlanır ve negatif girdileri sıfıra çevirirken, pozitif değerleri olduğu gibi bırakır (124). Bu fonksiyonun temel avantajı, negatif girişlerde çıktının sıfır olması, pozitif girişlerde ise giriş değeriyle aynı kalmasıdır. Bu özelliği sayesinde ReLU'nun türevi (gradyanı) her zaman 0 veya 1 olur. Böylece, özellikle derin sinir ağlarında karşılaşılan gradyan sönümlenmesi (vanishing gradient) probleminin önüne geçilmesine katkı sağlar (125). ReLU'nun bir diğer önemli avantajı, hesaplama açısından oldukça verimli olmasıdır. Bu fonksiyon, diğer aktivasyon fonksiyonlarına göre daha basit bir matematiksel işleme sahip olduğundan, ağı eğitim sürecinde daha düşük hesaplama maliyetiyle çalışmasını sağlar (126)(Resim 2.9). Aktivasyon fonksiyonu, özellik haritasındaki her bir düğüme uygulanarak doğrusal olmayan bir çıktı elde edilmesini sağlar. Bu işlemde pozitif girdiler aynı şekilde korunurken, negatif değerler belirli bir eşik altında sıfırlanır. Özellikle ReLU gibi fonksiyonlar, negatif değerleri sıfıra indirerek doğrultulmuş bir özellik haritası üretir. Bu durum, ağı daha karmaşık yapıları tanımasını ve genelleme yeteneğinin artmasını destekler (127).



Resim 2.9. Relu Aktivasyon Fonksiyonu Grafiği(125)

2.12.5. Havuzlama Katmanı


Havuzlama işlemi ya da havuzlama katmanı, genellikle ESA mimarilerinde yer alır ve çoğunlukla modelin parametre sayısını azaltmak ve işlem süresini kısaltmak amacıyla kullanılır. Bu katmanlar, bir sonraki evrişim katmanına iletilen verinin boyutunu küçültürken, derinliği yani kanal sayısını sabit tutar. Havuzlama, giriş verisini küçük alt bölgelere ayırarak, her bölgeden yalnızca belirli bir değeri (örneğin en büyük ya da ortalama) seçerek örnekleme işlemini gerçekleştirir. Bu şekilde veri boyutu azaltılırken, önemli özellikler korunmuş olur (118). Havuzlama işlemlerinde en sık kullanılan iki yöntem, maksimum havuzlama ve ortalama havuzlama katmanlarıdır (Resim 2.10). Maksimum havuzlama işlemi, alt matris içerisindeki en yüksek değeri seçerek örnekleme gerçekleştirirken; ortalama havuzlama, ilgili alt matrisin aritmetik ortalamasını alır. Literatürde yapılan çalışmalar, maksimum havuzlamanın özellikle nesne sınıflandırma gibi görevlerde ortalama havuzlamaya kıyasla daha başarılı sonuçlar verdiğini ortaya koymuştur. Bu nedenle, maksimum havuzlama uygulamada daha yaygın olarak tercih edilmektedir (128).



Resim 2.10. 2×2 Filtre Boyutu ve 2×2 Adım ile Maksimum Havuzlama ve Ortalama(129)

2.12.6. Tam Bağlantılı Katman


Tam bağlantı katmanları, ESA mimarisinde evrişim, ReLU ve havuzlama katmanlarının ardından gelen yapılar olup, genellikle sınıflandırma veya segmentasyon gibi görevlerin gerçekleştirilmesinde kullanılır. Bu katmanlarda, önceki katmanlardan elde edilen çok boyutlu özellik haritaları, düzleştirme işlemiyle tek boyutlu bir vektöre dönüştürülür. Tüm düğümlerin birbirine bağlı olması nedeniyle bu yapıya “tam bağlantı katmanı” adı verilir. Bu katmanlar, modelin elde edilen özellikleri kullanarak veriyi uygun sınıflara ayırmasını sağlar (130). Evrişimli ve havuzlama katmanlarından elde edilen çıktı, giriş görüntüsünün temel özelliklerini yansıtan üst düzey özniteliklerden oluşur. Tam bağlantı katmanlarının temel işlevi, bu öğrenilmiş öznitelikleri kullanarak görüntünün ait olduğu sınıfı veya etiketini tahmin etmektir. Bu katmanlar, tüm nöronların birbirine bağlı olması nedeniyle yüksek sayıda parametreye ve yoğun hesaplama gereksinimine sahiptir. Ağda tam bağlantı katmanlarının bulunmaması, modelin karmaşık özellikleri yeterince işleyememesine ve genel performansın belirgin şekilde azalmasına yol açabilir (115).



Resim 2.11. Tam Bağlantılı Katmanın Yapısı(131)

2.12.7. DropOut Katmanı

Dropout, derin sinir ağlarında sıkça kullanılan ve aşırı öğrenmeyi (overfitting) önlemeye yönelik etkili bir düzenleme yöntemidir. Genellikle tam bağlantı katmanlarında uygulanır. Aşırı öğrenme, modelin eğitim verilerini ezberleyerek yeni veriler üzerinde düşük performans göstermesine neden olur. Dropout tekniğinde, eğitim sırasında ağdaki bazı nöronlar rastgele devre dışı bırakılır. Bu işlem, her bir eğitim adımında belirli bir olasılık (örneğin %30) ile yapılır. Böylece ağ, her eğitim turunda farklı bir yapıda çalışmış olur. Devre dışı bırakılan nöronlar geçicidir; bir sonraki adımda tekrar aktif olabilirler. Bu yöntem, modelin tüm nöronlara aşırı bağımlı kalmasını önler, nöronların daha bağımsız çalışmasını teşvik eder ve genelleme yeteneğini artırır. Sonuç olarak, ağ daha sade ve sağlam bir yapı öğrenir, bu da genel performansa olumlu yansır (132).



Resim 2.12. Dropout Katmanının Şematik Diyagramı(133)

2.12.8. Sınıflandırma Katmanı Çıkış katmanı

ESA'nın son katmanı, ağı öğrenildiği bilgileri kullanarak nihai tahminleri yaptığı bölümdür. Bu katman, genellikle önceki katmanla tüm nöronları bağlantılı olan bir tam bağlantı katmanı şeklindedir. Çıkış katmanındaki nöron sayısı, sınıflandırma problemlerinde sınıf sayısına, regresyon problemlerinde ise tahmin edilecek değer sayısına göre belirlenir. Sınıflandırma görevlerinde sıkça kullanılan softmax aktivasyon fonksiyonu, ağı çıktısını her sınıf için bir olasılık değeri hâline getirir. Böylece, model hangi sınıfa ait olduğunu belirlemek için bu olasılıkları kullanır (115). Softmax fonksiyonu, modelin çıkış değerlerini normalize ederek bunları 1'e toplanan bir olasılık dağılımına çevirir. Bu özellik, sınıflandırma problemlerinde en yüksek olasılığa sahip sınıfın belirlenmesini mümkün kılar. Bu sayede, ESA'nın çıkış katmanı, önceki katmanlarda elde edilen özellikleri kullanarak giriş verisine ait en olası sınıfı tahmin eder. Böylece, girişin sınıflandırılması ya da regresyon çıktılarının üretilmesi bu son katman aracılığıyla gerçekleştirilir (123).

2.13. Evrişimli Sinir Ağı Modelleri

2.13.1. AlexNet

AlexNet, 2012 yılında ImageNet Büyük Ölçekli Görsel Tanıma Yarışması'nı (ILSVRC) kazanarak derin öğrenme alanında önemli bir dönüm noktası olmuştur. Bu modelin mimarisi, beş evrişim katmanı ile üç tam bağlantılı katmandan oluşmaktadır. Doğrusal olmayanlığı sağlamak amacıyla ReLU (Rectified Linear Unit) aktivasyon

fonksiyonu tercih edilmiştir. ReLU, pozitif girişleri olduğu gibi geçirirken, negatif girişleri sıfıra indirir. Ayrıca, modelde aşırı öğrenmeyi önlemek amacıyla dropout tekniği uygulanmış ve bu sayede modelin genelleme yeteneği artırılmıştır (134).

2.13.2. VGGNet

VGGNet, 2014 yılında düzenlenen ILSVRC yarışmasında öne çıkan başarılı performansı ile dikkat çekmiş ve sade, sistematik mimarisiyle tanınmıştır. 16 ve 19 katmandan oluşan iki farklı versiyonu bulunan model, her biri 3x3 boyutunda küçük evrişim filtrelerinden oluşan yapı bloklarıyla tasarlanmıştır. Özellik çıkarımı işlemi ReLU aktivasyon fonksiyonu ve maksimum havuzlama katmanlarıyla gerçekleştirilir. Bu mimari, özellikle türev hesaplamalarının basitliği ve düzenli yapısı nedeniyle birçok derin öğrenme çalışmasında tercih edilmektedir (135,136).

2.13.3. VGG16

VGG16, Oxford Üniversitesi'nden Karen Simonyan ve Andrew Zisserman tarafından geliştirilen ve "Very Deep Convolutional Networks for Large-Scale Image Recognition" adlı çalışmada sunulan derin bir evrişimli sinir ağı modelidir. Bu model, ILSVRC 2014 yarışmasında kullanılmış ve ImageNet veri seti üzerinde yaklaşık %92.7 doğruluk oranı ile önemli bir başarı elde etmiştir. ImageNet, 1000 farklı sınıfı kapsayan ve 14 milyondan fazla etiketli görüntüden oluşan geniş kapsamlı bir veri kümesidir.

VGG16 mimarisi, büyük boyutlu filtreler yerine art arda yerleştirilmiş 3x3 boyutundaki küçük filtreleri kullanarak daha derin ve verimli bir özellik çıkarımı gerçekleştirmektedir. Giriş olarak 224x224 piksel boyutunda görüntüler kabul eden bu model, toplamda 16 katmandan oluşur: 13'ü evrişim (konvolüsyon) katmanı ve 3'ü tam bağlantılı (fully connected) katmandır. Bu yapı, modelin hem hesaplama açısından verimli hem de yüksek doğrulukta sonuçlar üretmesini sağlar.

VGG16 mimarisinde, her konvolüsyon katman bloğunun ardından yer alan maksimum havuzlama katmanları, görüntü boyutlarını aşamalı olarak küçültürken temel özelliklerin korunmasına olanak tanır. Başlangıçta 64 filtre ile yapılandırılan model, katmanlar derinleştikçe filtre sayısını 128, 256 ve son olarak 512'ye kadar

artırır. Bu düzen, toplamda yaklaşık 138 milyon parametrelilik oldukça büyük bir model oluşturur. Her ne kadar bu yüksek parametre sayısı eğitim sürecini zaman açısından zorlayıcı hale getirse de, VGG16'nın düzenli ve tekrar eden yapısı sayesinde anlaşılması ve uygulanması oldukça kolaydır. Bu da onu hem araştırma hem de uygulama alanlarında tercih edilen bir mimari haline getirmiştir (136).

2.13.4. VGG19

VGG19, VGG16'nın daha derinleştirilmiş bir versiyonu olup aynı mimari prensipleri temel alır. Toplamda 19 katmandan oluşur; bunların 16'sı konvolüsyon ve 3'ü tam bağlantılı katmandır. VGG16'ya kıyasla üç ek konvolüsyon katmanı içermesi, modelin daha karmaşık yapısal ve görsel örüntüleri öğrenebilmesine olanak tanır. Bu ek derinlik, modelin temsil gücünü artırmakla birlikte, eğitim sürecini daha zaman alıcı ve kaynak tüketici hâle getirebilir.

Katman sayısındaki artış, modelin daha soyut ve karmaşık özellikleri öğrenmesini sağlayarak genellikle doğruluk oranını artırabilir. Ancak, bu artış her zaman daha iyi sonuçlar doğurmaz; çünkü model, eğitim verisine fazlasıyla uyum sağlayarak aşırı öğrenme (overfitting) gösterebilir. Bu nedenle, modelin başarısı yalnızca derinliğiyle değil, aynı zamanda kullanılan veri kümesinin genişliği ve çeşitliliği ile uygun eğitim stratejilerinin uygulanmasıyla doğrudan ilişkilidir.

VGG19'un mimarisi, VGG16 ile benzer şekilde homojen bir yapıya sahiptir. Katmanların sıralanışı, kullanılan 3×3 boyutundaki filtreler ve maksimum havuzlama işlemleri büyük oranda aynıdır. Bu düzenli yapı sayesinde model, farklı görevlerde kolayca uygulanabilir hale gelir. VGG19, özellikle görüntü sınıflandırma, nesne tanıma ve transfer öğrenme gibi görsel görevlerde yaygın olarak tercih edilmektedir(136).

2.13.5. GoogleNet (Inception)

GoogleNet, 2014 yılında geliştirilen ve "Inception" mimarisi ile öne çıkan bir derin öğrenme modelidir. Bu mimari, farklı boyutlardaki evrişim filtrelerinin aynı anda, paralel olarak çalışmasına imkân tanır. Böylece ağ, çeşitli ölçeklerdeki özellikleri eşzamanlı olarak öğrenebilir. Bu yaklaşım, modelin hem geniş hem de derin

bilgi temsilleri oluřturmasını saęlar. GoogleNet, sınıflandırma görevlerinde genellikle softmax katmanıyla çıktıyı üretir (137).

2.13.6. U-Net Mimarisi

U-Net, 2015 yılında Ronneberger ve çalışma arkadaşları tarafından, özellikle medikal görüntü segmentasyonu için geliştirilmiş bir derin öğrenme mimarisidir. Bu model, sınırlı sayıda etiketli veriyle yüksek doğrulukta segmentasyon yapabilme yeteneęiyle dikkat çeker (138). U-Net'in karakteristik U şeklindeki simetrik yapısı, kodlayıcı (encoder) ve çözücü (decoder) olmak üzere iki ana bölümden oluşur. Kodlayıcı bölümde, ardışık konvolüsyon ve maksimum havuzlama katmanları ile görüntü boyutu azaltılırken, temel özellikler çıkarılır. Çözücü bölümde ise, dekonvolüsyon (up-convolution) katmanları ile görüntü boyutu yeniden artırılır. Bu sırada, kodlayıcı aşamasındaki karşılık gelen katmanlardan gelen özellik haritaları "skip connection" adı verilen bağlantılarla çözücü bölüme aktarılır. Bu aktarım, konumsal bilgilerin korunmasına katkı saęlar ve segmentasyon doğruluęunu önemli ölçüde artırır. Böylece U-Net, sınırlı sayıda etiketli veriye rağmen yüksek doğrulukta segmentasyon gerçekleştirebilir (138).

2.13.7. ResNet Mimarisi

ResNet (Residual Network), 2015 yılında Kaiming He ve ekibi tarafından tanıtılmıştır (139). Derin aęlarda eğitimin zorlaşması problemini çözmek amacıyla geliştirilen bu mimari, residual learning (artıklı öğrenme) yaklaşımını benimser. Her katmana bir kısayol bağlantısı (skip connection) eklenerek, önceki katmanlardan gelen bilgiler daha derin katmanlara doğrudan aktarılır. Böylece, modelin daha derin yapılandırılması saęlanır ve öğrenme kapasitesi artırılır. Bu mimari, günümüzde görüntü sınıflandırma başta olmak üzere birçok görevde başarıyla kullanılmaktadır (139).

2.13.8. ResUNet Mimarisi

ResUNet, ResNet ve U-Net mimarilerinin birleşiminden oluşan gelişmiş bir yapıdır (140,141). ResNet'in sunduęu derin öğrenme kapasitesi ile U-Net'in ayrıntılı segmentasyon başarısı, ResUNet modelinde bir araya getirilmiştir. Bu modelde,

kodlayıcı kısım evrişim ve havuzlama katmanlarıyla verinin boyutunu kademeli olarak küçültürken, çözücü kısım dekonvolüsyon işlemleriyle bu boyutları yeniden eski hâline getirir. Kodlayıcı ve çözücü arasında yer alan köprü katmanı, üst düzey özelliklerin korunmasını sağlayarak öğrenme sürecinin devamlılığını destekler. Ayrıca, residual bloklar sayesinde ağ içindeki bilgi, daha derin katmanlara etkili bir biçimde aktarılır. Bu mimari yapı sayesinde ResUNet, yüksek çözünürlüklü özellik çıkarımı, başarılı segmentasyon sonuçları, sınırlı veriyle bile yüksek doğruluk ve bellek kullanımında verimlilik gibi önemli avantajlar sunar (141–144). Bu nedenle, özellikle tıbbi görüntü segmentasyonu uygulamalarında öne çıkmaktadır.

2.14. Yapay Sinir Ağlarının Kullanım Alanları

Yapay sinir ağları, özellikle örnek tanıma ve tahmin yapmada yoğun olarak kullanılmaktadır. Günümüzde, yapay sinir ağları aşağıdaki birçok alanda uygulanmaktadır:

- Bilgisayar ve elektronik mühendisliğinde
- İnşaat ve endüstri mühendisliğinde
- Robotik uygulamalar ve imalat süreçlerinde
- Kalite kontrol ve üretim işlem kontrolünde
- İktisat ve ekonomi alanlarında
- Otomasyon sistemlerinde
- Elektronik devre tasarımında
- Askeri radar sinyallerinin tespitinde, silah üretiminde, hedef tanıma ve izleme teknolojilerinde
- Kaynak kullanımının optimizasyonunda ve uzaktan algılamada
- Hava yolları ve ücret düzenlemelerinde
- Çeşitli zekâ problemlerinin çözümünde
- Kredi riski değerlendirmesinde
- Optik algılama gibi alanlarda (145).

2.15. Diş Hekimliğinde Yapay Zekâ

Yapay zekâ, pek çok bilim dalında olduğu gibi diş hekimliği alanında da hızla gelişen ve artan bir kullanım alanına sahiptir. Diş hekimliğinde yapay zekâ uygulamaları, ağırlıklı olarak tanı koyma, tedavi planlaması ve hastalığın gidişatını değerlendirme gibi temel klinik işlemlere entegre edilmektedir. Özellikle tanı aşamasında, yapay zekâ algoritmaları; radyolojik görüntülerin otomatik analizi, patolojik yapıların erken tespiti gibi görevlerde etkin biçimde kullanılmakta, böylece hem tanı doğruluğunu artırmakta hem de klinisyenlerin iş yükünü azaltmaktadır. Diş hekimliği bilgi sistemlerindeki ilerlemeler, klinik karar destek mekanizmalarının yapay zekâ temelli araçlarla zenginleşmesini sağlamıştır. Bu sistemler, makine öğrenimi ve gelişmiş algoritmalar sayesinde giderek daha hassas ve güvenilir hale gelmektedir. Yapay zekâyâ yönelik araştırmaların diş hekimliğinin farklı uzmanlık alanlarında da yaygınlaşması, bu teknolojinin klinik uygulamalardaki rolünü her geçen gün daha da önemli hâle getirmektedir (146–148).

2.15.1. Restoratif Diş Hekimliğinde Yapay Zekâ

Diş çürükleri, en sık karşılaşılan ağız ve diş sağlığı problemleri arasında yer almakta olup, erken evrede tespit edilmeleri büyük önem arz etmektedir. Geleneksel tanı yöntemlerinde çürükler, genellikle diş hekimleri tarafından görsel muayene ve sondalama gibi araçlarla değerlendirilmektedir. Ancak bu yaklaşımlar büyük ölçüde hekimin klinik tecrübesine dayandığı için subjektif farklılıklar içerebilir. Ayrıca, özellikle dişlerin birbirine temas ettiği aproksimal yüzeyler gibi erişilmesi güç bölgelerde çürük tespiti daha da zorlaşmakta, bu da yöntemin etkinliğini sınırlayan önemli bir faktör olarak öne çıkmaktadır (149,150). Günümüzde yapay zekâ destekli sinir ağı modelleri, diş çürüklerinin daha hızlı ve doğru bir şekilde tespit edilmesini sağlamak amacıyla kullanılmaya başlanmıştır. Yapılan çeşitli araştırmalarda, yapay sinir ağlarının çürük saptama sürecinde yüksek doğruluk oranları sunduğu ve geleneksel yöntemlere kıyasla daha tutarlı sonuçlar verdiği ortaya konmuştur. Bu gelişmeler, tanı süreçlerinin otomatikleştirilmesine katkı sağlamakta ve klinik karar destek sistemlerinin güvenilirliğini artırmaktadır (151). Bunun yanı sıra YZ, diş restorasyonlarının tanımlanması ve sınıflandırılmasında da etkili bir araç olarak

kullanılmaktadır (152). Bu teknolojiler, tanı ve tedavi aşamalarının seçilmesinde önemli bir katkı sağlamaktadır.

2.15.2. Endodontide Yapay Zekâ

YZ'nin endodontideki rolü her geçen gün daha da önem kazanmaktadır. Yapılan çeşitli araştırmalar, YZ'nin periapikal patolojilerin ve kök kırıklarının belirlenmesi, kök kanalı morfolojisinin analiz edilmesi, pulpa kök hücrelerinin canlılık durumunun tahmini, kanal boyunun belirlenmesi ve yeniden tedavi uygulamalarının başarı olasılığının öngörülmesi gibi birçok alanda etkili bir şekilde kullanılabileceğini ortaya koymaktadır (153–155). YZ, endodonti alanında yalnızca görüntüleme verilerinin değerlendirilmesinde değil, aynı zamanda genetik analizlerde de önemli bir potansiyele sahiptir. Yapılan bir araştırmada, YZ algoritmaları kullanılarak radiküler kistler ile periapikal granülomlar arasındaki gen ekspresyon farklılıkları incelenmiş ve bu iki lezyonun birbirinden farklı biyolojik mekanizmalarla geliştiği ortaya konmuştur (156).

2.15.3. Ortodontide Yapay Zekâ

YZ'nin ortodonti alanındaki uygulamaları giderek yaygınlaşmaktadır. Diş çekimi ihtiyacının öngörülmesi, maksimum ankraj gereksiniminin tahmini, sınıf II ve III maloklüzyonların tedavi sonuçlarının kestirilmesi, temporomandibular eklem osteoartritinin teşhisi, sefalometrik ölçümler ile iskeletsel analizlerin yapılması ve bireylerin büyüme-gelişim dönemlerinin saptanması gibi birçok alanda YZ destekli sistemlerden yararlanılmaktadır (157–161). Bu araştırmalar, YZ'nin ortodontik tedavi planlaması ve teşhis süreçlerinde etkili bir yardımcı olduğunu ortaya koymakta; aynı zamanda klinisyenlerin iş yükünü hafifleterek daha doğru ve öngörülebilir kararlar alınmasını sağladığını göstermektedir.

2.15.4. Ağız, Diş ve Çene Cerrahisinde Yapay Zekâ

Yapay zekânın ağız, diş ve çene cerrahisindeki kullanımı giderek yaygınlaşmakta ve çeşitli klinik uygulamalara entegre edilmektedir. Literatürdeki bulgular, YZ'nin özellikle ortognatik cerrahi sonrasındaki görüntü tahminlerini geliştirme ve yüz estetiğiyle ilgili değerlendirmelerde klinisyenlere destek sağlama

potansiyeline sahip olduğunu göstermektedir. Bu tarz simülasyonlar, hem tedavi sürecinin planlanmasını kolaylaştırmakta hem de hastaların sürece aktif katılımını teşvik etmektedir (162,163). Yapay zekâ, aynı zamanda üçüncü molar diş çekimi gibi sık karşılaşılan cerrahi işlemlerde, sinir parestezisi riskinin öngörülmesinde de kullanılmaktadır. Bu konudaki araştırmalar, panoramik radyografilerden elde edilen verilerle YZ algoritmaları yardımıyla sinir hasarı olasılığının başarıyla tahmin edilebildiğini ortaya koymuştur (164). Ayrıca, odontojenik lezyonların belirlenmesi de YZ'nin öne çıkan uygulama alanlarından biridir. Ameloblastom ve odontojenik keratokist gibi tümörlerin panoramik radyografiler aracılığıyla tespitinde YZ tabanlı sistemlerin etkili sonuçlar verdiği gösterilmiştir. Bu tür lezyonların erken dönemde saptanması, tedavi sürecinin daha verimli yürütülmesini sağlamak ve potansiyel komplikasyon risklerini azaltmaktadır (165). YZ'nin implantoloji alanındaki uygulamaları da giderek yaygınlaşmaktadır. İmplant planlamasında, dental implant sistemlerinin tanımlanmasında ve osteointegrasyon kalitesinin değerlendirilmesinde etkili bir araç olarak kullanılmaktadır. Özellikle peri-implant kemik kaybının nicel olarak belirlenmesi ve osteointegrasyon sürecindeki olası problemlerinin erken fark edilmesi gibi durumlarda YZ, cerrahi sürecin daha isabetli ve başarılı bir şekilde yürütülmesine olanak tanımaktadır (166).

2.15.5. Periodontolojide Yapay Zekâ

Yapay zekâ, periodontoloji alanında giderek daha fazla benimsenmekte ve klinik uygulamalara entegre edilmektedir. Periodontitisin erken evrede teşhisi ve tedavi planının oluşturulmasında YZ, diş hekimleri için değerli bir destek aracı haline gelmiştir. Özellikle periodontal kemik kaybının belirlenmesi konusunda, YZ tabanlı sistemlerin yüksek hassasiyet ve doğrulukla değerlendirme yapabildiği gösterilmiştir. Panoramik ve periapikal radyografiler üzerinde yapılan çeşitli araştırmalarda, YZ algoritmaları periodontal ve peri-implant kemik kaybını tespit etmede başarılı sonuçlar vermiştir (167–170).

2.15.6. Protetik Diş Hekimliğinde Yapay Zekâ

YZ, protetik diş hekimliğinde teşhis, tedavi planlaması ve üretim süreçlerinde kullanılmaktadır(171). Özellikle implant planlaması (172), protezlerin hazırlanması

(173), eksikliklerinin sınıflandırılması (174) gibi alanlarda YZ'den yararlanılmaktadır. YZ, bu alanlarda hataları azaltma ve doğruluğu artırma potansiyeline sahiptir (171).

2.15.7. Çocuk Diş Hekimliğinde Yapay Zekâ

YZ'nin çocuk diş hekimliğine uyarlanması, doğru teşhis ve tedavi planlamasında klinisyenlere önemli avantajlar sunar (175). YZ, çocukların diş sağlığını değerlendirmek (176), dental plak tespiti yapmak (177), süt dişlerini sınıflandırmak (178) ve erken çocukluk çürüklerini önceden tahmin etmek(179) gibi alanlarda kullanılmaktadır. YZ, özellikle çocukların iş birliğini artırarak diş tedavilerinin başarısını artırmakta, aynı zamanda çocukların oral sağlık programlarında eğitim almasına da yardımcı olmaktadır (175).

2.15.8. Ağız, Diş ve Çene Radyolojisinde Yapay Zekâ

Yapay zekâ, ağız, diş ve çene radyolojisinde geniş bir uygulama yelpazesine sahiptir ve bu teknolojilerin günlük klinik kullanıma entegrasyonu hızla artmaktadır. Panoramik radyografiler, intraoral görüntüler, konik ışınlı bilgisayarlı tomografi (KIBT) ve ultrasonografi (USG) gibi çeşitli görüntüleme yöntemleri üzerinde yapılan çalışmalar, bu görüntülerin analizinde önemli gelişmeler ortaya koymuştur. YZ destekli sistemler, anatomik yapıların ve patolojik oluşumların segmentasyonu, diş çürükleri ile periodontal hastalıkların saptanması, görüntü iyileştirme ve adli diş hekimliği uygulamaları gibi birçok alanda etkin bir şekilde kullanılmaktadır (180).

3. GEREÇ ve YÖNTEM

3.1. Etik Onay

Bu çalışma, Süleyman Demirel Üniversitesi Tıp Fakültesi Etik Kurulu'nun 13.01.2025 tarihli ve E.924324 sayılı kararı ile etik onay alınarak yürütülmüştür. Çalışmada kullanılan panoramik radyografiler, Süleyman Demirel Üniversitesi Diş Hekimliği Fakültesi Protetik Diş Tedavisi Anabilim Dalı'nın arşivinden retrospektif olarak temin edilmiştir. Tüm veriler anonimleştirilmiş, hastalara ait kimlik bilgileri kaydedilmemiştir.

3.2. Çalışma Tasarımı

Bu tez çalışması retrospektif, kesitsel ve deneysel bir araştırma olup, panoramik radyograflar üzerinde yer alan sabit protetik restorasyonların (zirkonyum veneer ve metal destekli porselen veneer kron) derin öğrenme temelli bir model ile otomatik sınıflandırılmasını hedeflemektedir.

3.3. Örneklem Büyüklüğü ve G Power Hesaplaması

Çalışmada kullanılacak örneklem büyüklüğü, G*Power 3.1.9.7 yazılımı kullanılarak belirlenmiştir. Etki büyüklüğü 0.3, alfa değeri 0.05 ve istatistiksel güç (power) 0.90 olacak şekilde yapılan hesaplamalar sonucunda minimum örneklem büyüklüğü 750 olarak hesaplanmıştır. Görüntüler iki gruba eşit dağıtılmıştır:

- 375 adet zirkonyum veneer
- 375 adet metal destekli porselen (veneer kron)

3.4. Görüntülerin Temini ve Seçimi

Bu çalışmada değerlendirilen panoramik radyografiler, 2015–2025 yılları arasında Süleyman Demirel Üniversitesi Diş Hekimliği Fakültesi'nde tedavi gören hastaların dijital arşiv kayıtlarından temin edilmiştir. Tüm radyografiler, Planmeca Promax marka cihaz ile 66–68 kVp, 7–13 mA ve 16 saniye pozlama süresi parametreleri kullanılarak dijital ortamda elde edilmiştir. Çalışma kapsamında

yalnızca görüntü kalitesi yeterli ve içerdği restorasyon yapıları ayırt edilebilir nitelikte olan radyografiler değerlendirmeye alınmıştır.

Belirlenen dahil ve dışlama kriterleri doğrultusunda 2926 hasta görüntüsü taranmıştır. Bu tarama sonucunda, ağızda sabit bölümlü restorasyon (zirkonyum veya metal destekli) uygulaması yapılan ve tedavi sonrası panoramik radyografisi arşivde kayıtlı olan 269 hasta tespit edilmiştir. Bu hastaların panoramik radyografileri üzerinde yapılan detaylı incelemede, sabit restorasyonları içeren bölgeler seçilmiştir. Seçim aşamasında, restorasyonların birbirinden bağımsız olması gözetilmiştir; yani restorasyonlar aynı köprü yapısı içinde ardışık dişleri kapsayan bir bütünlük sergilememeli, her biri ayrı bir değerlendirme birimi olacak şekilde tanımlanabilmelidir. Bu doğrultuda, bazı görüntüler yalnızca tek bir kuron restorasyonu içerirken, bazıları birden fazla (iki ya da üç) restorasyonu barındıran bölgeleri içerecek şekilde kırpılmıştır.

Restorasyon bölgelerinin tespiti ve kırılması işlemleri, ImageJ yazılımı kullanılarak gerçekleştirilmiştir. İlgili restorasyonların yer aldığı alanlar, yapay zekâ modelinin eğitimi için uygun olacak şekilde 200 × 300 piksel boyutlarında ROI (Region of Interest) olarak tanımlanarak kırılmıştır. Görüntü kırma işlemi, her bir restorasyonun yapısal özelliklerinin net olarak ayırt edilebileceği şekilde yapılmıştır. Bu sayede, modelin eğitimi için gerekli olan, homojen ve analitik olarak değerlendirilebilir bir görüntü veri seti oluşturulmuştur.

Sonuç olarak, çalışmaya toplam 426 adet metal destekli porselen restorasyonu ve 167 adet zirkonyum restorasyonu temsil eden, her biri restorasyon bölgesinden elde edilen kesitsel görüntüler (ROI – Region of Interest) olmak üzere toplam 593 kırılmış görüntü dahil edilmiştir.

Dahil Olma Kriterleri:

- Tedavi sonrası panoramik radyografi arşivde mevcut olmalı,
- Görüntüde ilgili restorasyon bölgesi net ve ayırt edilebilir olmalı,
- Ağızda sabit bölümlü restorasyon (metal destekli porselen veneer veya zirkonyum veneer) bulunmalı.
- Tedavinin Süleyman Demirel Üniversitesi Diş Hekimliği Fakültesi'nde gerçekleştirilmiş olması.

Dışlama Kriterleri:

- Görüntü kalitesi yetersiz olan radyografiler (bulanıklık, artefakt, pozisyonlama hatası vb.),
- İmplant üstü restorasyonlar, kanal tedavili dişler veya yalnızca dolgu materyali içeren dişler

3.5. Verilerin Etiketlenmesi ve Kırılması

Etiketleme işlemi, protetik diş tedavileri alanında deneyimli tek bir uzman gözlemci tarafından gerçekleştirilmiştir. Bu süreçte yalnızca zirkonyum veneer ve metal destekli porselen veneer restorasyonları içeren bölgeler belirlenmiştir. İmplant üstü restorasyonlar, dolgu materyali içeren dişler ve kanal tedavili dişler çalışmanın kapsamı dışındaki yapılara sahip bölgeler dışlanmıştır.

Uzman gözlemci tarafından panoramik radyografiler üzerinde restorasyonlar, radyolojik yoğunluk ve morfolojik özelliklerine göre manuel olarak etiketlenmiştir. Belirlenen restorasyon bölgeleri, ImageJ yazılımı kullanılarak Region of Interest (ROI) şeklinde tanımlanmış ve 200×300 piksel boyutlarında kırılmıştır. Kırpma işlemi sırasında bazı görüntülerde birden fazla restorasyon (iki ya da üç adet) bulunması durumunda, bu bölgeler aynı ROI içerisinde yer alacak şekilde uygun biçimde dahil edilmiştir. Aşağıdaki görselde, panoramik radyografi üzerinde restorasyon bölgesinin nasıl belirlendiği ve 200×300 piksel boyutlarında ROI (Region of Interest) şeklinde nasıl kırıldığı görsel olarak gösterilmektedir.



Resim 3.1. Panaromik Görüntülerin Kırpılması

Tüm bu işlemler sonucunda toplam 593 adet kırılmış görüntü elde edilmiştir. Bu görüntülerden 426'sı metal destekli porselen, 167'si ise zirkonyum veneer restorasyonları içermektedir.

3.6. Veri Artırma (Data Augmentation) Süreci

Çalışmamızda sınıflar arası dengesizliği azaltmak ve modelin aşırı öğrenme (overfitting) riskini minimize etmek amacıyla veri artırımı (data augmentation) tekniğine başvurulmuştur. Veri artırımı, özellikle görüntü sınıflandırma problemlerinde sıkça kullanılan, eğitim verisinin çeşitliliğini artırarak modelin genellenebilirliğini iyileştiren bir yöntemdir. Bu bağlamda, zirkonyum restorasyon sınıfında bulunan 167 adet görüntü üzerinde çeşitli dönüşüm işlemleri uygulanarak, bu sayı 501 adede çıkarılmıştır. Böylece, 426 adet görüntüye sahip olan metal destekli porselen restorasyon sınıfı ile veri sayısı bakımından denge sağlanmıştır.


Veri artırımı işlemi aşağıda belirtilen adımlarla gerçekleştirilmiştir:

- **Döndürme (Rotation):** Her bir orijinal zirkonyum görüntüsü rastgele bir açı ile -20° ile $+20^{\circ}$ arasında döndürülerek yeni bir görüntü elde edilmiştir.
- **Rastgele Görüntü Filtreleme:** Orijinal 167 görüntünün her biri için, aşağıdaki yöntemlerden rastgele biri seçilmiş ve uygulanmıştır:
 - **Flip (Yansıma):** Görüntü, rastgele olarak yatay (horizontal) veya dikey (vertical) ekseninde çevrilmiştir.

- **Crop (Kırpma):** Görüntünün %80 ile %95'i arasında kalan bir bölgesi rastgele seçilerek kırpılmıştır.
- **Noise (Gürültü):** Görüntüye, rastgele seçilen 5 ile 15 arasında bir gürültü seviyesi ile Gauss tipi gürültü eklenmiştir.
- **Blur (Bulanıklık):** Görüntüye, rastgele olarak seçilen 3x3 veya 5x5 çekirdek boyutuna sahip bulanıklık (Gaussian blur) filtresi uygulanmıştır.
- **Shift (Kaydırma):** Görüntüler, -10 ile +10 piksel arasında rastgele bir değerde yatay (tx) ve dikey (ty) eksenlerde kaydırılmıştır.

Bu dönüşümler sonucunda, her orijinal görüntüden iki adet yeni türetilmiş görüntü oluşturulmuş ve toplamda 334 yeni görüntü, orijinal 167 görüntü ile birleştirilerek zirkonyum sınıfı için 501 görüntüye ulaşılmıştır. Tüm artırılan görüntüler, orijinal veri setine eklenerek modelin eğitimi bu yeni veri seti ile gerçekleştirilmiştir.

Bu yöntem, hem sınıf dengesi sağlamış hem de modelin farklı varyasyonlara karşı daha dayanıklı hale gelmesine katkı sunmuştur.



Resim 3.2. Veri Arttırma Yöntemleri

3.7. Veri Setinin Bölünmesi ve Ön İşleme Süreci

Model eğitimi için hazırlanan toplam 927 adet kırılmış panoramik görüntü, derin öğrenme modelinin eğitilmesi, doğrulanması ve test edilmesi amacıyla üç alt gruba ayrılmıştır. Bu bölünme, modelin genelleme yeteneğini artırmak ve aşırı öğrenmeyi (overfitting) önlemek amacıyla dengeli bir dağılım prensibiyle gerçekleştirilmiştir:

Tablo 3.1. Veri Setini Bölünmesi

Veri Setinin Eğitim, Doğrulama ve Test Olarak Dağılımı

Veri Seti	Oran (%)	Görüntü Sayısı
Eğitim	70	648
Doğrulama	20	185
Test	10	94

Her bir alt veri grubunda, sınıf dengesi korunacak şekilde 426 metal destekli porselen ve 501 zirkonyum veneer restorasyon görüntüsü eşit oranlarda dağıtılmıştır. Böylece modelin her iki sınıfı da eşit temsille öğrenmesi sağlanmıştır.

Tüm görüntüler, modelin giriş katmanına uyumlu hale getirilmek üzere 200×300 piksel boyutlarına yeniden ölçeklendirilmiştir. Bu işlem sırasında, görüntülerin orantılı yapısının korunması için interpolasyon tekniği uygulanmıştır. Görüntülerin piksel yoğunlukları ise $[0, 1]$ aralığına normalize edilmiştir. Bu normalizasyon işlemi, modelin daha hızlı, kararlı ve verimli öğrenmesini sağlamak amacıyla gerçekleştirilmiştir.

Yukarıda belirtilen ön işleme adımları tamamlandıktan sonra elde edilen veri seti, VGG16 mimarisine dayalı derin öğrenme modelinin eğitimi için kullanıma hazır hale getirilmiştir.

3.8. Derin Öğrenme Modeli: VGG16 ve Transfer Öğrenme ile İnce Ayar Yaklaşımı

Bu çalışmada, görsel sınıflandırma problemi için derin öğrenme mimarilerinden biri olan VGG16 (Visual Geometry Group 16) modeli kullanılmıştır.

VGG16, Oxford Üniversitesi Visual Geometry Group tarafından geliştirilen ve ImageNet veri kümesi üzerinde eğitilmiş bir evrişimli sinir ağı (Convolutional Neural Network - CNN) modelidir. 16 katmandan oluşan bu mimari, 13 evrişim (convolutional) ve 3 tam bağlantılı (fully connected) katman içerir. Model, görüntü sınıflandırma problemlerinde yüksek performansı ve düzenli yapısı nedeniyle tercih edilmektedir. Bu tez çalışmasında, transfer öğrenme ile ince ayar yöntemi benimsenmiştir. Bu kapsamda, model eğitimi için transfer öğrenme yaklaşımıyla önceden ImageNet veri seti üzerinde eğitilmiş VGG16 mimarisi kullanılmıştır. Modelin ilk katmanları sabit tutulmuş, son 30 katmanı yeniden eğitime açılarak ince ayar (fine-tuning) uygulanmıştır. Bu süreçte, BatchNormalization katmanları sabit bırakılmış ve yalnızca uygun katmanların ağırlıkları güncellenmiştir. Böylece hem önceden öğrenilen genelleştirilebilir özelliklerden faydalanılmış, hem de uygulamaya özel ince ayar yapılmıştır. Model, iki sınıflı (zirkonyum veneer ve metal destekli porselen veneer kron) çıktı üretecek şekilde yapılandırılmıştır.


3.9. Modelin Eğitimi ve Görüntü İşleme Süreci

Modelin eğitilmesi aşamasında, tüm görüntüler ön işleme tabi tutulmuştur. İlk olarak tüm ROI görüntüleri, VGG16 modelinin giriş boyutlarına uyumlu olacak şekilde 200x300 piksel çözünürlüğe yeniden boyutlandırılmış ve pikseller 0-1 aralığına normalize edilmiştir. Eğitim sırasında modelin genellenebilirliğini artırmak amacıyla veri artırma (data augmentation) teknikleri uygulanmıştır. Modelin eğitim sürecinde, kayıp fonksiyonu olarak binary crossentropy, optimizasyon algoritması olarak ise Adam tercih edilmiştir. Adam optimizasyon algoritmasının öğrenme oranı 0,00001 (1e-5) olarak belirlenmiştir. Eğitim 50 epoch boyunca, 32 batch size ile gerçekleştirilmiştir.

3.10. Sınıflandırma Performansının Değerlendirilmesi

Eğitilen modelin başarımı, ayrılan test veri seti üzerinde değerlendirilmiştir. Modelin sınıflandırma performansı, yaygın olarak kullanılan istatistiksel ölçütlerle analiz edilmiştir. Bu kapsamda; doğruluk (accuracy), duyarlılık (recall), hassasiyet (precision) ve F1 skoru gibi metrikler hesaplanmıştır. Ayrıca, sınıflandırma hatalarının analizi için karışıklık matrisi (confusion matrix) oluşturulmuş ve sınıflandırma başarısı

görsel olarak değerlendirilmiştir. Modelin genel ayırt edici gücü ise ROC (Receiver Operating Characteristic) eğrisi ve AUC (Area Under the Curve) değeri ile desteklenmiştir. Bu metrikler, modelin restorasyon türlerini doğru bir şekilde tanıma kapasitesini ortaya koymuştur.



Resim 3.3. Model Başarımının Değerlendirilmesi Süreci

3.11. Yazılım ve Donanım Altyapısı

Tüm modelleme ve analiz süreçleri Python 3.8 programlama dili kullanılarak gerçekleştirilmiştir. Derin öğrenme modelinin oluşturulması ve eğitilmesi aşamasında TensorFlow ve Keras kütüphanelerinden yararlanılmıştır. Görüntü işleme ve etiketleme işlemleri ise ImageJ yazılımı yardımıyla yapılmıştır. Modelin eğitimi ve test süreci, Google tarafından ücretsiz sunulan ve GPU desteği sağlayan bulut tabanlı bir platform olan Google Colaboratory (Colab) ortamında gerçekleştirilmiştir. Bu platform, yerel donanıma ihtiyaç duymadan yüksek hesaplama kapasitesi sunmakta ve özellikle derin öğrenme projelerinde zaman ve kaynak verimliliği sağlamaktadır. Ayrıca, sınıflandırma sonrası analizler ve istatistiksel hesaplamalar için Scikit-learn, NumPy ve Matplotlib gibi açık kaynaklı Python kütüphaneleri kullanılmıştır. Bu yazılım ve platform altyapısı sayesinde geliştirilen derin öğrenme modeli etkin, erişilebilir ve güvenilir bir şekilde uygulanabilmektedir.

4. BULGULAR

Bu çalışmada, panoramik radyografler üzerinde zirkonyum veneer ve metal destekli porselen veneer restorasyonlarının yapay zekâ ile sınıflandırılması amaçlanmıştır. Sınıflandırma işlemi için önceden eğitilen ve sınıflandırmada yüksek başarı sağlayan VGG16 modeli kullanılmıştır. Transfer öğrenme ile bu tez çalışmasındaki probleme göre yapılan sınıflandırma işleminin performansı doğruluk, F1 skoru, ROC eğrisi ,AUC değeri ve PR eğrisi üzerinden değerlendirilmiştir.

4.1. Performans Analizi

Model performansı, çeşitli metrikler kullanılarak değerlendirildi.

Panoramik radyografler üzerinde sabit protetik restorasyonların materyal bazlı sınıflandırmasına yönelik bir yapay zekâ modeli geliştirilmiştir. Model eğitimi için 927 kırılmış görüntüden oluşan etiketli veri seti kullanılmış ve eğitim süreci toplam 50 epoch(eğitim tur sayısı) boyunca gerçekleştirilmiştir. Eğitim ve doğrulama işlemleri tamamlandıktan sonra model, daha önce hiç görmediği 94 test görüntüsü üzerinde değerlendirilmiş ve sınıflandırma performansı ölçülmüştür.

4.2. Sınıflama Doğruluğu

Çalışmada iki sınıflı bir sınıflandırma problemi ele alınmış olup, her bir sınıf (Metal destekli porselen veneer ve Zirkonyum veneer) ayrı ayrı pozitif sınıf olarak kabul edilerek değerlendirilmiştir.

Metal desteki porselen sınıfı pozitif olarak alındığında, doğru şekilde metal olarak sınıflanan örnek sayısı (True Positive, TP) 41, doğru şekilde zirkon olarak sınıflanan örnek sayısı (True Negative, TN) 49'dur. Yanlış şekilde metal olarak sınıflanan zirkon örnekleri (False Positive, FP) 2, yanlış şekilde zirkon olarak sınıflanan metal örnekleri (False Negative, FN) ise 2 olarak bulunmuştur.

Zirkonyum veneer sınıfı pozitif kabul edildiğinde ise bu değerler simetrik olarak değişmektedir: TP 49, TN 41, FP 2, FN 2. Bu sonuçlar, modelin her iki sınıf için de yüksek doğrulukla tahmin yaptığını ve sınıflar arasında dengeli bir başarı sağlandığını göstermektedir. Ayrıca, her iki sınıf için benzer FP ve FN değerlerinin

olması, modelin tarafsız ve tutarlı bir şekilde çalıştığını da desteklemektedir (Tablo 4.1).

Tablo 4.1. Yapay Zekâ Modeli İçin Doğruluk Matrisi (Confusion Matrix)(181)

	TAHMİN	
	YOK	VAR
	TN	FP*
GERÇEK	FN*	TP


*Hatalı tahminler

Tablo 4.2. Sınıf Bazlı Değerlendirme (Her Sınıf Ayrı Ayrı Pozitif Kabul Edilerek)

		TAHMİN	
		METAL	ZİRKON
GERÇEK	METAL	41	2
	ZİRKON	2	49

4.3. Karşıtlık Matrisi

Karşıtlık (karmaşıklık) matrisi, sınıflandırma modelinin gerçek ve tahmin edilen etiketler arasındaki uyumunu görsel olarak sunmaktadır. Resim 4.2’de görüldüğü üzere, model 43 metal destekli porselen örneğinden 41’ini doğru şekilde “metal destekli porselen” olarak, 51 zirkonyum venner örneğinden 49’unu doğru şekilde “zirkonyum veneer” olarak sınıflandırmıştır. Ancak 2 metal destekli porselen örneği yanlışlıkla zirkonyum veneer olarak; 2 zirkonyum veneer örneği de metal destekli porselen olarak sınıflandırılmıştır. Bu durum, modelin genel olarak yüksek doğrulukla çalıştığını ancak küçük bir hata payı taşıdığını göstermektedir. Matrisin çapraz dışındaki küçük değerler (2’şer adet hata) sınıflar arasında belirgin bir karışıklığın olmadığını, modelin her iki sınıfı da oldukça başarılı şekilde ayırt edebildiğini ortaya koymaktadır.



Resim 4.1. Karşıtlık Matrisi

4.4. TPR (True Positive Rate) ve FPR (False Positive Rate) Değerleri

Modelin sınıflandırma performansını değerlendirmek için kullanılan TPR (True Positive Rate) ve FPR (False Positive Rate) değerleri sınıf bazında hesaplanmıştır. TPR, modelin gerçek pozitif örnekleri ne kadar doğru yakaladığını gösterirken, FPR ise gerçek negatif örnekler arasından yanlış pozitif olarak sınıflandırılanların oranını belirtir.

TPR (True Positive Rate) ve FPR (False Positive Rate), sınıflandırma modellerinin başarımını değerlendirmek için kullanılan temel istatistiksel ölçütlerdir. Özellikle ROC (Receiver Operating Characteristic) eğrisinin oluşturulmasında bu iki oran kritik öneme sahiptir (181–183).

TPR (True Positive Rate): Gerçek pozitiflerin (TP), tüm gerçek pozitif örneklerle (TP + FN) oranıdır (Resim 4.2). Yani modelin gerçekten olumlu (pozitif) olanları ne oranda doğru tespit ettiğini gösterir. Duyarlılık (Recall, Sensitivity) olarak da bilinir (184).

$$TPR = \frac{TP}{TP + FN}$$

Resim 4.2. TPR'nin Formülü(184)

FPR (False Positive Rate): Gerçekte negatif olan örneklerden (TN + FP), modelin yanlış şekilde pozitif sınıfa atadığı örneklerin (FP) oranıdır (Resim 4.3). Yani, aslında olumsuz (negatif) olan örneklerden ne kadarı yanlışlıkla pozitif olarak sınıflandırılmıştır (184).

$$FPR = \frac{FP}{FP + TN}$$

Resim 4.3. FPR'nin Formülü(184)

Bu çalışmada kullanılan sınıflandırma modelinin performansı, her bir sınıf (metal destekli porselen ve zirkonyum veneer) için ayrı ayrı değerlendirilmiş ve ilgili sınıflara ait Doğru Pozitif Oranı (True Positive Rate, TPR) ile Yanlış Pozitif Oranı (False Positive Rate, FPR) değerleri hesaplanmıştır. TPR, modelin ilgili sınıfa ait pozitif örnekleri ne ölçüde doğru sınıflandırabildiğini; FPR ise negatif sınıfa ait örnekleri yanlışlıkla pozitif olarak sınıflandırma eğilimini göstermektedir. Bu metrikler, özellikle ROC eğrisi gibi model başarımlar analizlerinde önemli rol oynamakta ve sınıflar arası ayırt ediciliğin nicel olarak değerlendirilmesini sağlamaktadır (181–183).

Aşağıda, her bir sınıfa ait TPR ve FPR değerlerine ilişkin hesaplamalar Resim 4.4 ve 4.5'te verilmiştir.

$$TPR = Recall = \frac{TP}{TP + FN} = 0.95$$

$$FPR = \frac{FP}{FP + TN} = \frac{2}{2 + 49} = \frac{2}{51} \approx 0.039$$

Resim 4.4. Metal Destekli Porselen Veneer Sınıfına Ait TPR ve FPR Değerlerinin Hesaplanması

$$TPR = Recall = 0.96$$

$$FPR = \frac{2}{2 + 41} = \frac{2}{43} \approx 0.0465$$

Resim 4.5. Zirkon Veneer Sınıfına Ait TPR Ve FPR Değerlerinin Hesaplanması

4.5. Precision, Recall, F1 Skorunun Hesaplanması

- Precision (Kesinlik / Doğruluk Oranı): Modelin pozitif sınıf olarak tahmin ettiği örneklerin gerçekten ne kadarının doğru pozitif olduğunu gösterir. Yani model “bu pozitif” dediğinde ne kadar haklıdır?(Resim 4.6)(185).

$$Precision = \frac{TP}{TP + FP}$$

Resim 4.6. Precision Değerinin Hesaplanması

- Recall (Duyarlılık / TPR - True Positive Rate):Gerçekten pozitif olan örneklerin ne kadarını model doğru şekilde tespit etmiş olduğunu gösterir. Yani model gerçek pozitifleri ne kadar iyi yakalıyor?(Resim 4.7)(185).

$$\text{Recall} = \frac{TP}{TP + FN}$$

Resim 4.7. Recall Değerinin Hesaplanması(185)

- F1-Skoru (F1-Score) : Precision ve recall arasındaki dengeyi ölçen harmonik ortalamadır. Tek başına hem yanlış pozitifleri hem de kaçırılan pozitifleri dikkate alan bir başarı ölçütüdür (Resim 4.8)(185).

$$\text{F1-Score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}}$$

Resim 4.8. F1 Skorunun Hesaplanması(185)

Modelin sınıflandırma performansı, metal destekli porselen ve zirkonyum veneer restorasyonlar olmak üzere iki ayrı sınıf için ayrı ayrı değerlendirilmiştir. Metal sınıfı için doğruluk (precision), duyarlılık (recall) ve F1 skoru değerleri %95 olarak hesaplanırken; zirkon sınıfında bu değerler %96 seviyesinde bulunmuştur.(Tablo 4.2) Her iki sınıfta da yüksek başarı oranları elde edilmiş olup, modelin iki restorasyon türünü ayırt etme konusunda dengeli ve güvenilir bir performans sergilediği gözlemlenmiştir (185).


Tablo 4.3. Her Bir Sınıf İçin Hesaplanan Precision,Recall ve F1 Skoru Değerleri

SINIF	PRECİSİON	RECALL	F1-SKORU	GÖRÜNTÜ SAYISI
METAL	0,95	0,95	0,95	43
ZİRKON	0,96	0,96	0,96	51

4.6. ROC (Receiver Operating Characteristic Curve) Eğrisi Grafikleri ve AUC (Area Under Curve)

Performans değerlendirme ölçütü olan ROC eğrisi ve AUC değerleri hesaplanarak yapay zekâ modelinin gösterdiği performans değerlendirilmesi yapıldı.

ROC eğrisi doğru pozitif oranının (TPR), yanlış pozitif oranına (FPR) bölümü ile hesaplanan bir sınıflandırma başarısı ölçütüdür (186).




Grafik 4.1. ROC Eğrisi

Grafik 4.1’de gösterilen ROC (Receiver Operating Characteristic) eğrisi, sınıflandırma modelinin pozitif ve negatif sınıfları ayırt etme yeteneğini görsel olarak değerlendirmek amacıyla kullanılır. Yatay ekseninde Yanlış Pozitif Oranı (False Positive Rate), dikey ekseninde ise Doğru Pozitif Oranı (True Positive Rate) yer alır. Eğrinin altında kalan alan (AUC - Area Under the Curve), modelin sınıflandırmadaki başarısını sayısal olarak ifade eder (184). Bu örnekte AUC değeri 0,99’dur; bu da modelin neredeyse kusursuz bir ayırım gücüne sahip olduğunu göstermektedir.

ROC eğrisi, modelin farklı eşik (threshold) değerlerinde duyarlılık (sensitivity) ile özgüllük ($1 - \text{specificity}$) arasında nasıl bir denge kurduğunu gösterir. Bu eğri şu şekilde hesaplanır: Modelin tahmin olasılıkları farklı eşik değerlerine göre sınıflandırılır; her eşik için doğru pozitif oranı ($\text{TPR} = \text{TP} / (\text{TP} + \text{FN})$) ve yanlış pozitif oranı ($\text{FPR} = \text{FP} / (\text{FP} + \text{TN})$) hesaplanarak eğri çizilir. Eğri ne kadar sol üst köşeye yakınsa, modelin başarısı o kadar yüksektir. Düz siyah kesikli çizgi, rastgele sınıflandırmanın temsidir ($\text{AUC} = 0,5$); dolayısıyla mavi eğrinin bu çizgiden uzaklaşması, modelin güçlü bir tahmin yeteneğine sahip olduğunu gösterir (184).

4.7. Precision (Kesinlik) -Recall (Hassasiyet) Eğrisi (PR Eğrisi)

Kesinlik-Hassasiyet (PR) eğrisi çok önemli olan pozitif sınıfın performansına odaklanmaktadır. PR eğrisindeki amaç sağ üst köşede (1,1) olmaktır. Bu nokta tüm pozitifleri pozitif olarak sınıflandırdığımız anlamına gelir (doğruluk oranı artar) (187).



Grafik 4.2. Precision-Recall (PR) Eğrisi

Grafik 4.2, bir Precision-Recall (PR) eğrisidir ve özellikle dengesiz veri setlerinde model performansını değerlendirmek için ROC eğrisine kıyasla daha duyarlıdır. PR eğrisinde, yatay ekseninde Recall (Duyarlılık), dikey ekseninde ise Precision (Kesinlik) gösterilir. Grafik, modelin pozitif sınıfları ne kadar doğru şekilde tahmin ettiğini ve yanlış pozitiflerden ne kadar kaçındığını görselleştirir (185).

Bu egride görülen AP (Average Precision) değeri 0,99'dur, bu da modelin yüksek doğrulukta ve tutarlılıkla pozitif sınıfları tanımladığını gösterir.

Bu eğri, modelin farklı eşik (threshold) değerleri için precision ve recall değerlerinin hesaplanmasıyla oluşturulur. Eğri alanının (AP) geniş olması, modelin pozitif sınıfı tespit etme konusunda çok başarılı olduğunu belirtir. Bu durum, özellikle

pozitif sınıfın nadir olduđu durumlarda (örneğin hastalık tespiti, sahtekarlık algılama gibi) oldukça önemlidir. Bu grafik, ROC eğrisinden farklı olarak sadece pozitif sınıf performansına odaklanır (185).



5. TARTIŞMA

Bu çalışmada amaçlanan, panoramik radyografiler üzerinde yer alan sabit restorasyonlardan zirkonyum veneer ve metal destekli porselen veneer türlerini, yapay zekâ (YZ) temelli bir derin öğrenme modeli aracılığıyla materyal bazında otomatik olarak sınıflandırabilmektir. Literatürde restorasyonların genellikle yalnızca varlığına ya da genel türüne (kuron, dolgu, implant vb.) odaklanıldığı göz önünde bulundurulduğunda, bu çalışma materyal özelliklerine göre sınıflama yaparak alana özgün bir katkı sunmayı hedeflemiştir.

Bu doğrultuda çalışmaya başlanmadan önce test edilen sıfır hipotezi (H_0), yapay zekâ modelinin zirkonyum ve metal destekli porselen veneer restorasyonları birbirinden rastgele tahmin düzeyinin ötesinde ayırt edemeyeceği, yani sınıflandırma başarısının istatistiksel olarak anlamlı olmayacağı yönündeydi. Ancak elde edilen sonuçlar, bu hipotezin açıkça reddedilmesini sağlamıştır. Model, panoramik radyografilerde her iki materyali birbirinden ayırt etmede %96 genel doğruluk oranına ulaşmış; zirkonyum restorasyonlar için F1-skoru 0,96, metal destekli porselen restorasyonlar için ise 0,95 olarak hesaplanmıştır. Bu değerler, %50 düzeyindeki rastlantısal başarı oranının çok üzerinde olup, modelin sınıflandırma yeteneğinin anlamlı ve güvenilir olduğunu göstermektedir. Dolayısıyla “model ayırt edemez” varsayımına dayanan sıfır hipotezi geçersiz kalmış ve modelin performansının istatistiksel olarak anlamlı düzeyde başarılı olduğu ortaya konmuştur.

Aşağıda detaylandırılan tartışma kapsamında, bu sonuçlar hem benzer çalışmalardan elde edilen verilerle karşılaştırılmış hem de yapay zekâ tabanlı klinik uygulamalar açısından yorumlanmıştır.

Yapay zekâ, yapılmasını istediğimiz işlemlerin makine ve yazılımlarla insan beynini taklit ederek, daha kısa sürede aynı sonuca vararak yapabilen sistemlerin genel tanımıdır (188,189).

Diş hekimliğinde ise YZ genellikle teşhis ve verilerin yönetimi ile planlamasını daha hızlı ve basit hale dönüştüren yazılımları tasarlamak için kullanılmaktadır(190). YZ tarafından geliştirilen uygulamaların diş hekimliğindeki etkileri birçok avantajı beraberinde getirmektedir. Bu uygulamalar, diş hekimliği alanındaki iş gücünü ve

monoton rutin görevleri azaltarak daha geniş bir nüfusa sağlık hizmetlerini daha düşük maliyetlerle ulaştırılabilir. Bu gelişmeler, sonunda kişiselleştirilmiş, öngörücü ve daha etkileşimli diş hekimliği uygulamalarını teşvik ederek diş bakımını daha düzenli ve etkili bir hale getirmektedir (190).

YZ modelleri öğrenimini insanların tecrübe ve bilgi birikimlerinden tamamlar. Bu nedenle, YZ uygulamaları, diş hekimlerine klinik vakaların çeşitli aşamalarında destek sağlayan değerli bir araç olarak kabul edilmektedir. Bu teknoloji, deneyim ve bilgiye dayalı olarak geliştirilen modellerle birlikte kullanılarak, diş hekimlerine daha kapsamlı bir karar alma sürecinde yardımcı olabilir (146).

Periapikal ve bite-wing radyograflarda YZ uygulamaları çoğunlukla diş tespiti (191), çürük tespiti(192–195), anatomik landmark tespiti(196), restorasyon tespiti (197,198) gibi alanlarda kullanılmaktadır. Pauwels ve ark. (199) periapikal radyograflarda apikal lezyon tespiti üzerine yaptıkları çalışmada YZ'nin radyologlara göre lezyon tespitinde daha duyarlı olduğunu bildirmişlerdir. Cantu ve ark. (200) ise geliştirdikleri derin öğrenme yöntemine dayalı modellerinde bite-wing radyograflardan çürük teşhisinde, hekimlere nazaran YZ'nin daha başarılı sonuçlar verdiğini raporlamışlardır (200). Cha ve ark. (169) periapikal radyograflarda implant çevresindeki kemik kaybını ölçen bir YZ modeli geliştirmişler ve model ile hekimler arasında fark izlenmediği sonucuna varmışlardır. Buradan da anlaşılacağı üzere YZ diş hekimliği alanında yapılan çalışmalarda tıpkı bir diş hekimi gibi dişleri, anatomik yapıları, lezyon bölgelerini, restorasyonları öğrenebilmekte ve bu süreç klinikte bizlere zaman kazancı sağlayabilmektedir.

Literatürde diş hekimliğinde yapay zekâ temelli analizlerle restorasyonların varlığı veya türüne ilişkin birçok çalışma bulunmasına karşın, 2025 yılı itibarıyla PubMed, EBSCO, ProQuest, Google Scholar, Scopus, Cochrane ve Web of Science gibi önde gelen bilimsel veri tabanlarında yapılan kapsamlı taramalarda, restoratif materyal türünün (örneğin metal destekli porselen veneer ve zirkonyum veneer) sınıflandırılmasına yönelik herhangi bir çalışmaya rastlanmamıştır. Bu bağlamda, sunulan çalışma yalnızca teknik yeterliliğiyle değil, aynı zamanda materyal bazlı restoratif ayırım yapabilen ilk örneklerden biri olmasıyla da literatüre anlamlı ve özgün bir katkı sunmaktadır.

Panoramik radyografilerde dental restorasyonların otomatik tespiti ve sınıflandırılması konusunda literatürde giderek artan sayıda yapay zekâ uygulaması bulunmaktadır. Özellikle sabit protetik restorasyonların (kron, köprü, implant vb.) tespitine odaklanan çalışmalar bizim çalışmamızla benzerlik taşımaktadır (201,202).

Abdalla-Aslan ve ark. (2020) yaptıkları çalışmada toplam 83 panoramik görüntüde 738 restorasyon (dolgu, kuron, kanal tedavisi, implant vb. 11 farklı kategori) analizi yapmışlardır. Çalışma sonucunda sınıflandırma doğruluğu %93,6 olarak raporlanmıştır. Ancak bu çalışmada restorasyon türleri materyal bazında ayrılmamış, tüm restoratif unsurlar tek bir sınıflama sürecine dahil edilmiştir (152). Bizim çalışmamızda ise yalnızca sabit restorasyonlar incelenmiş ve bunlar zirkonyum veneer ile metal destekli porselen veneer olarak iki farklı materyal sınıfında değerlendirilmiş; %96 genel doğruluk ile materyal bazlı ayırım başarıyla gerçekleştirilmiştir.

Basaran ve ark. (2022) Faster R-CNN Inception v2 modelini kullanarak 1084 panoramik filmde kron tespiti gerçekleştirmiştir. Bu çalışmada kron tespiti için F1 skoru yaklaşık 0,91 olarak bildirilmiştir (203). Ancak yine materyal farklılığı dikkate alınmamıştır. Bizim çalışmamızda zirkonyum veneer için $F1=0,96$ ve metal destekli porselen veneer için $F1=0,95$ değerleriyle benzer bir performans elde edilmiş; ayrıca iki farklı materyalin ayırt edilmesi hedeflenmiştir. Bu açıdan çalışmamız daha özgül bir sınıflama yapısıyla literatüre katkı sunmuştur.

Vinayahalingam ve ark çalışmasında, 2000 panoramik radyografide çeşitli restorasyonların (ör. dolgu, kanal tedavisi, kuron) tespiti yapılmıştır. Bu çalışmada kron sınıfı için F1 skoru 0,94 olarak bildirilmiştir. Ancak çalışmada restorasyonların materyaline dair bir ayırım yapılmamış; sadece varlık-yokluk temelli sınıflama gerçekleştirilmiştir (204). Bizim çalışmamızda ise materyal bazında ayırım yapılmış ve zirkonyum veneer ile metal destekli porselen veneer kronlar F1 skorları sırasıyla 0,96 ve 0,95 ile başarılı şekilde sınıflanmıştır.

Yurttaş ve ark. (2024) çalışmasında YOLOv5x modeli kullanılarak panoramik radyografilerde kron, implant, pontik gibi nesnelerin tespiti gerçekleştirilmiştir. Bu çalışmada tüm sınıflar için F1 skoru yaklaşık 0,99 gibi oldukça yüksek bir seviyede raporlanmıştır(205).Ancak yine materyal farklılığı gözetilmemiştir.Bizim

çalışmamızda daha spesifik olarak yalnızca sabit kron restorasyonları ve onların materyal özellikleri hedef alınmış, VGG16 mimarisi ile %96 genel doğruluk sağlanmıştır. Ayrıca Yurttaş ve arkadaşlarının tespit ettiği kron sınıfı tüm materyalleri kapsarken, bizim modelimiz zirkonyum veneer ve metal destekli porselen veneer olmak üzere iki radyopak materyali ayırt etmiştir. Bu ayırt etme görevi, sınıf içi benzerlik nedeniyle daha zorlayıcı olup %96 doğruluk bu açıdan oldukça başarılı bir değerdir. Literatürdeki bu ileri düzey çalışma da, yapay zekânın panoramik radyografilerde sabit restorasyonları yüksek doğrulukla sınıflayabildiğini desteklemektedir.

Bonfanti-Gris ve ark. (2022) çalışmalarında, ticari bir web tabanlı yapay zekâ yazılımı olan Denti.AI'nin panoramik radyografilerdeki dental yapı ve tedavileri tespit etme başarısı, deneyimli iki diş hekiminin altın standart olarak belirlenen bulgularıyla karşılaştırılmıştır. 300 panoramik görüntüde; metal restorasyonlar, rezin esaslı restorasyonlar, endodontik tedaviler, kuronlar ve implantlar gibi yapılar değerlendirilmiştir. İmplant tespitinde %100, kuronlarda ise %89,5 duyarlılık ve %95,8 spesifite elde edilmiştir ($AUC \approx 0,93$). Metal restorasyonlarda AUC değeri 0,869; kompozit restorasyonlarda ise duyarlılık %41 ve AUC 0,672 olarak belirlenmiştir(206). Bu bulgular, yapay zekânın radyopak materyallerde daha yüksek başarı gösterdiğini ortaya koymaktadır. Bizim çalışmamızda değerlendirilen her iki restorasyon tipi de radyopak seramik/metal içerikli olduğundan, benzer şekilde yüksek doğruluk elde edilmiştir. Çalışmamız sonucunda elde edilen AUC değeri 0,99 olarak bulunmuş olup, bu oran literatürde gerçekleştirilen benzer çalışmalarda rapor edilen değerlere kıyasla oldukça yüksektir.

Literatürdeki birçok çalışma restorasyonların türüne (kron, dolgu, implant vb.) göre sınıflama yaparken, materyal bazlı ayırım yapmamıştır. Bu yönüyle çalışmamız, daha özgül bir yaklaşım sunarak klinik karar destek sistemleri açısından işlevsel ve yenilikçi bir katkı sağlamaktadır.

Dental radyografilerin yorumlanmasında yapay zekâ sistemlerinin performansının diş hekimlerinininkiyle karşılaştırılması, literatürde giderek önem kazanan bir konudur. Özellikle yapay zekânın tanısal doğruluğunun uzman seviyesine yaklaşıp yaklaşmadığı birçok çalışmada incelenmiştir. Genel eğilim, uygun eğitilmiş

bir yapay zekâ modelinin belirli dar görevlerde en azından deneyimli bir klinisyen kadar başarılı olabileceği yönündedir(207).

Nitekim derlemeler, çürük tespiti gibi görevlerde son model yapay zekâ algoritmalarının ~%91 doğruluklara ulaştığını, periodontal kemik kaybı tespiti veya diş tanımlamada %93'lere varan yüksek doğruluklar elde edildiğini bildirmektedir . Bu oranlar çoğu çalışma için uzman diş hekimlerinin performans aralığına denk düşmektedir. Örneğin, yakın tarihli bir çalışmada yapay zekâ yazılımı, panoramik filmlerde çürük ve periapikal lezyon teşhisinde yeni mezun diş hekimlerine kıyasla daha yüksek doğruluk sergilemiştir . Söz konusu çalışmada AI modeli, diş çürüklerini tespitte %90'ın üzerinde duyarlılık yakalarken, deneyimsiz hekimlerden birinin duyarlılığı %49 gibi çok daha düşük kalmıştır(208).

Güneç ve ark. çalışmalarında yapay zekâ sistemleri ile diş hekimlerinin panoramik görüntülerde periapikal lezyon tespiti performansı karşılaştırılmıştır. Yapay zekâ %97,3 duyarlılıkla en yüksek başarıyı gösterirken, genç diş hekimlerinin duyarlılığı %75,8'de kalmıştır. Bu örnek, yapay zekânın belirli tanı alanlarında hekim performansını aşabileceğini göstermektedir(208). Benzer şekilde, bizim çalışmamızda da %96 doğruluk ile zirkonyum veneer ve metal destekli porselen veneer restorasyonlar ayırt edilebilmiştir. Bu durum, yapay zekânın klinik tanısal görevlerde kullanılabilirliğini desteklemektedir.

Altan ve ark. (2022) YOLOv4 tabanlı bir modelle 5126 panoramik görüntüde restorasyon tespiti yapmıştır. Kronlar için %74 precisyon değeri bildirilmiştir. Bu düşüklük, görüntü kalitesindeki çeşitlilik, artefaktlar ve restorasyonların üst üste binmesi gibi faktörlere bağlanmıştır. Altan ve ark.'nın kullandığı YOLOv4 modeli, büyük veri setlerinde dahi daha düşük başarı göstermiştir(209). Buna karşılık bizim çalışmamızda, daha az sayıda ancak kalite açısından homojenleştirilmiş ve görüntüleme parametreleri optimize edilmiş bir veri kümesi ile çalışılmış, literatürde klinik dental görüntülerde sıklıkla kullanılan ve sınıflandırma başarısı yüksek olan VGG16 mimarisi tercih edilmiştir. Elde edilen F1 skorları ve doğruluk oranları, daha kompleks yapay zeka modellerine kıyasla yalın ancak etkili mimarilerin de başarılı olabileceğini göstermektedir.

Sukegawa ve ark. yaptıkları çalışmada panoramik radyograflerde 11 farklı dental implant sistemini sınıflandırmak için VGG16 ve VGG19 mimarileri kullanılmıştır. İnce ayar yapılmış VGG16 modeli, diğer modellerle karşılaştırıldığında en yüksek sınıflandırma performansını göstermiştir. Bu, VGG16'nın dental implant sınıflandırmasında etkili bir model olduğunu ortaya koymaktadır(210).

Kats ve ark. (2021), küçük bir dental X-ray veri setinde farklı görüntü modalitelerini ayırt etmek için VGG16 tabanlı transfer öğrenme yaklaşımı uygulamış ve neredeyse %100 doğruluk elde etmişlerdir(211). Bu, transfer öğrenme ile önceden eğitilmiş VGG16 ağıının dental radyograflerde ne denli güçlü özellikler çıkarabildiğini göstermektedir. Yine Tuzoff ve ark. (2019), panoramik radyograflerde diş tespiti görevinde %99'un üzerinde duyarlılık ve kesinlik ile oldukça yüksek bir başarı göstermiştir(212). Bu örnekler, VGG16'nın dental görüntülerde yüksek performanslı sonuçlar verebildiğini kanıtlamaktadır.

Benzer şekilde, literatürde yapılan çok sayıda çalışmada VGG16 mimarisinin görüntü sınıflandırma görevlerinde yüksek doğruluk oranlarıyla başarılı sonuçlar verdiği bildirilmiştir. Özellikle dental radyografler üzerinde yapılan çalışmalarda, VGG16 modelinin diş çürüğü tespiti, implant sınıflandırması ve restoratif unsurların ayrımı gibi çeşitli görevlerde etkin bir şekilde kullanıldığı görülmektedir(213–215). Bu bağlamda, çalışmamızda VGG16 modelinin tercih edilmesinin temel gerekçesi; literatürdeki kanıtlarla da desteklenen bu yüksek sınıflandırma başarısı ve medikal görüntü analizlerinde sağladığı istikrarlı performanstır. Ayrıca modelin transfer öğrenme stratejileriyle kolayca adapte edilebilir olması, görece sınırlı örneklem büyüklüğüyle çalışılan klinik araştırmalarda avantaj sağlamaktadır. Bu nedenlerle, panoramik radyograflerde zirkonyum veneer ve metal destekli porselen veneer restorasyonları materyal bazında ayırt etme görevinde, VGG16 mimarisi uygun bir seçim olarak değerlendirilmiş ve uygulanmıştır.

Elde edilen bulgular, yalnızca deneysel düzeyde değil, klinik pratik açısından da dikkate değer sonuçlar ortaya koymaktadır. Özellikle restorasyonların materyal temelli sınıflandırılmasına yönelik geliştirilen bu model, panoramik radyografler üzerinden doğru ve hızlı bir ön tanı desteği sağlayarak, hekimin karar sürecine katkı sunma potansiyeline sahiptir. Literatürde restoratif unsurların çoğunlukla tür (kuron,

dolgu, implant vb.) bazında sınıflandığı çalışmaların aksine, bu tezde materyal ayırımına odaklanması, daha özgül bir yaklaşım ortaya koymakta ve klinik uygulamalarda ihtiyaç duyulan ayrıntılı karar destek sistemlerinin gelişimine katkı sağlamaktadır. Ayrıca, yalnızca iki benzer radyografik görünüme sahip restoratif materyalin ayırımı hedeflenmiş olmasına rağmen, ulaşılan yüksek doğruluk değerleri modelin bu özgül sınıflandırma görevinde etkili çalışabildiğini göstermektedir. Bu yönüyle çalışma, mevcut literatüre yenilikçi bir bakış açısı kazandırmakta ve yapay zekâ temelli sistemlerin restoratif diş tedavilerinde daha işlevsel kullanım alanları için temel oluşturmaktadır.



6. SONUÇ ve ÖNERİLER

Günümüzde yapay zekâ teknolojileri, sağlık alanında olduğu gibi diş hekimliği pratiğinde de giderek daha fazla yer bulmaktadır. Bu çalışmada, panoramik radyografiler üzerinde yer alan sabit protetik restorasyonların materyal bazında ayrımını gerçekleştirebilecek bir yapay zekâ temelli sınıflandırma modeli geliştirilmiştir. Derin öğrenme ve geleneksel makine öğrenmesi yaklaşımlarının birlikte kullanıldığı bu modelde, sınıflar arası ayırt etme gücü yüksek düzeyde performans sergilemiştir. Elde edilen bulgular, bu tür teknolojilerin dental görüntü analizi süreçlerine entegrasyonunun mümkün olduğunu ve klinik karar mekanizmalarına anlamlı katkılar sağlayabileceğini göstermektedir.

Bu bağlamda yapay zekâ teknolojilerinin, diş hekimliği uygulamalarında özellikle tanısal süreçlerin hızlandırılması, gözden kaçabilecek restorasyonların tespiti, veri odaklı tedavi planlaması gibi birçok alanda katkı sunabileceği açıktır. Klinik karar verme sürecinin dijital destekle pekiştirilmesi, hem zaman yönetimi hem de tedavi doğruluğu açısından önemli avantajlar sağlayabilir. Bu çalışmanın bulguları, yapay zekânın dental görüntü analizine entegrasyonunun mümkün ve etkili olduğunu ortaya koymakta; bu yönüyle gelecekte yapılacak araştırmalara yol gösterici nitelik taşımaktadır.

Ancak çalışmanın bazı sınırlılıkları da mevcuttur. İlk olarak, sınıflandırılan görüntüler yalnızca iki restoratif materyali (zirkonyum veneer ve metal destekli porselen veneer) içermektedir. Bu durum, modelin diğer sabit protez türlerini kapsayacak şekilde genellenebilirliğini kısıtlamaktadır. Ayrıca kullanılan veri seti, tek merkezli ve retrospektif olarak oluşturulmuştur; dolayısıyla farklı kliniklerden gelen daha çeşitli ve geniş veri kümeleriyle modelin performansı tekrar test edilmelidir. Görüntüler üzerindeki restorasyonların sayısı, tipi ve lokalizasyonları gibi faktörler ayrıntılı olarak dikkate alınmamıştır; bu parametreler gelecekteki çalışmalarda sınıflandırma başarımını daha da derinlemesine değerlendirmeye olanak sağlayabilir.

Bu bağlamda, ilerleyen çalışmalar için şu önerilerde bulunulabilir:

1. Farklı materyal türleri (örneğin: lityum disilikat, monolitik zirkonya, hibrit seramikler) eklenerek modelin kapsamı genişletilmelidir.

2. Modelin eğitiminde çok merkezli ve daha büyük veri setleri kullanılmalı, böylece genellenebilirlik artırılmalıdır.
3. Sadece restorasyon tespiti değil, lokasyon tespiti, restorasyon yaşı, marjinal uyum durumu gibi alt parametrelerin de otomatik analizi hedeflenmelidir.
4. Derin öğrenme modellerine açıklanabilirlik (explainability) ilkeleri entegre edilerek modelin karar verme süreci daha şeffaf hâle getirilmelidir.
5. Geliştirilen algoritmaların, klinik karar destek sistemlerine entegre edilerek hekim-yapay zekâ iş birliğini güçlendiren uygulamalar geliştirilmesi teşvik edilmelidir.

Sonuç olarak, bu çalışma yapay zekâ tabanlı görüntü sınıflandırma yöntemlerinin dental radyografiler üzerinde sabit protetik materyallerin ayrımında etkili bir biçimde kullanılabileceğini ortaya koymaktadır. Elde edilen bulgular, hem yapay zekânın klinik diş hekimliğine entegrasyonu açısından umut verici bir örnek teşkil etmekte hem de ileri düzey dijital tanı sistemlerinin geliştirilmesine ışık tutmaktadır.

KAYNAKLAR

1. Chen H, Zhang K, Lyu P, Li H, Zhang L, Wu J, vd. A deep learning approach to automatic teeth detection and numbering based on object detection in dental periapical films. *Sci Rep.* 2019;9(1):3840.
2. Lee JS, Adhikari S, Liu L, Jeong HG, Kim H, Yoon SJ. Osteoporosis detection in panoramic radiographs using a deep convolutional neural network-based computer-assisted diagnosis system: a preliminary study. *Dentomaxillofacial Radiol.* 2019;48(1):20170344.
3. Johari M, Esmaeili F, Andalib A, Garjani S, Saberhari H. Detection of vertical root fractures in intact and endodontically treated premolar teeth by designing a probabilistic neural network: an ex vivo study. *Dentomaxillofacial Radiol.* 2017;46(2):20160107.
4. Gore JC. Artificial intelligence in medical imaging. C. 68, Magnetic resonance imaging. Elsevier; 2020. s. A1-4.
5. Lee SM, Kim HP, Jeon K, Lee SH, Seo JK. Automatic 3D cephalometric annotation system using shadowed 2D image-based machine learning. *Phys Med Biol.* 2019;64(5):055002.
6. Hiraiwa T, Aiji Y, Fukuda M, Kise Y, Nakata K, Katsumata A, vd. A deep-learning artificial intelligence system for assessment of root morphology of the mandibular first molar on panoramic radiography. *Dentomaxillofacial Radiol.* 2019;48(3):20180218.
7. Casalegno F, Newton T, Daher R, Abdelaziz M, Lodi-Rizzini A, Schürmann F, vd. Caries Detection with Near-Infrared Transillumination Using Deep Learning. *J Dent Res.* Ekim 2019;98(11):1227-33.
8. Schwendicke F, Golla T, Dreher M, Krois J. Convolutional neural networks for dental image diagnostics: A scoping review. *J Dent.* 2019;91:103226.
9. LeCun Y, Bengio Y, Hinton G. Deep learning. *nature.* 2015;521(7553):436-44.
10. Özkömür A, Ekren O. Döküm tekniğinin sabit protetik diş tedavisinde kullanılan Co-Cr alaşımlarının mikrosertlik ve mikroyapı özellikleri üzerine etkisi. *Cukurova Med J.* 30 Eylül 2018;43(3):539-44.
11. Shillingburg HT, editör. Fundamentals of fixed prosthodontics. 3. ed. Chicago, Ill.: Quintessence Publ; 1997. 582 s. (Quintessence books).
12. Misch CE, Resnik RR. Medical evaluation of the dental implant. *Contemp Implant Dent Mosby Elsevier St Louis.* 2007;421.
13. Roberts HW, Berzins DW, Moore BK, Charlton DG. Metal-Ceramic Alloys in Dentistry: A Review. *J Prosthodont.* Şubat 2008;18(2):188-94.

14. Gracis S, Thompson VP, Ferencz JL, Silva NRFA, Bonfante EA. A new classification system for all-ceramic and ceramic-like restorative materials. *Int J Prosthodont.* 2015;28(3):227-35.
15. Zarone F, Russo S, Sorrentino R. From porcelain-fused-to-metal to zirconia: clinical and experimental considerations. *Dent Mater Off Publ Acad Dent Mater.* Ocak 2011;27(1):83-96.
16. Bajraktarova-Valjakova E, Korunoska-Stevkovska V, Kapusevska B, Gigovski N, Bajraktarova-Misevska C, Grozdanov A. Contemporary Dental Ceramic Materials, A Review: Chemical Composition, Physical and Mechanical Properties, Indications for Use. *Open Access Maced J Med Sci.* 25 Eylül 2018;6(9):1742-55.
17. Ho GW, Matinlinna JP. Insights on Ceramics as Dental Materials. Part I: Ceramic Material Types in Dentistry. *Silicon.* Temmuz 2011;3(3):109-15.
18. Li RWK, Chow TW, Matinlinna JP. Ceramic dental biomaterials and CAD/CAM technology: State of the art. *J Prosthodont Res.* 01 Ekim 2014;58(4):208-16.
19. Pontevedra P, Lopez-Suarez C, Pelaez J, Garcia-Serdio S, Suarez MJ. Prospective Clinical Evaluation of Posterior Monolithic Zirconia Fixed Partial Dentures Using a Complete Digital Workflow: Two-Year Follow-Up. *J Prosthodont.* 2021;30(4):298-304.
20. Zhang Y, Lawn BR. Novel Zirconia Materials in Dentistry. *J Dent Res.* Şubat 2018;97(2):140-7.
21. Gohary M, Fawzy M, Shokry T. Evaluation of Vertical Marginal Gap of Long Span Implant Supported Fixed Dental Prostheses Fabricated with different CAD/CAM Materials. 22 Ekim 2024;
22. Kara R. Comparison of Marginal and Internal Fit of Different CAD/CAM Copings. *Int J Dent Sci Res.* 20 Haziran 2020;8(4):105-11.
23. Zeighami S, Ghodsi S, Sahebi M, Yazarloo S. Comparison of Marginal Adaptation of Different Implant-Supported Metal-Free Frameworks Before and After Cementation. *Int J Prosthodont.* 2019;32(4):361-3.
24. Awada A, Nathanson D. Mechanical properties of resin-ceramic CAD/CAM restorative materials. *J Prosthet Dent.* Ekim 2015;114(4):587-93.
25. Naylor WP. Introduction to metal-ceramic technology. 2018 [a.yer 16 Mart 2025]; Erişim adresi: <https://lomalinda.elsevierpure.com/en/publications/introduction-to-metal-ceramic-technology-third-edition-2>
26. Anusavice KJ, Shen C, Rawls HR. Phillips' science of dental materials. Elsevier Health Sciences; 2012.

27. Shillingburg HT. Fundamentals of Fixed Prosthodontics. 4th ed. USA, Quintessence Publishing Company, 2012.
28. Wataha JC. Biocompatibility of dental casting alloys: a review. J Prosthet Dent. 2000;83(2):223-34.
29. Sakaguchi RL, Powers JM. Craig's Restorative Dental Materials. 13th ed. USA, Elsevier Health Sciences, 2012.
30. Zaimoğlu A, Can G, Ersoy E, Aksu L. Diş hekimliğinde maddeler bilgisi. AÜ Basımevi Ank. 1993;515.
31. Mclean JW. The Science and Art of Dental Ceramics. Vol:I The Nature of Dental Ceramics and their Clinical Use, 1st ed. USA, Quintessence Publishing Co Inc, 1979.
32. O'Brien WJ. Dental Materials and Their Selection. 4th ed. Quintessence Publishing Co Inc, 2008.
33. Hondrum SO. A review of the strength properties of dental ceramics. J Prosthet Dent. Haziran 1992;67(6):859-65.
34. Pol CWP, Kalk W. A systematic review of ceramic inlays in posterior teeth: an update. Int J Prosthodont. 2011;24(6):566-75.
35. McLean JW. Evolution of dental ceramics in the twentieth century. J Prosthet Dent. Ocak 2001;85(1):61-6.
36. Bayramoğlu E. İmplant üstü üç ve dört üyeli köprülerde metal üzerine preslenmiş porselen ile zirkonyum üzerine preslenmiş tam seramik ve konvansiyonel metal seramik restorasyonların marjinal ve internal uyum açısından karşılaştırılması.
37. Piconi C, Maccauro G. Zirconia as a ceramic biomaterial. Biomaterials. Ocak 1999;20(1):1-25.
38. Helmer JD, Driskell TD. Research on bioceramics. Presented at: Symposium on Use of Ceramics as Surgical Implants; 1969. İçinde.
39. Madfa AA, Al-Sanabani FA, Al-Qudami NH, Al-Sanabani JS, Amran AG. Use of zirconia in dentistry: An overview. Open Biomater J. 2014;5(1):1-9.
40. Borik MA, Bublik VT, Kulebyakin AV, Lomonova EE, Milovich FO, Myzina VA, vd. Phase composition, structure and mechanical properties of PSZ (partially stabilized zirconia) crystals as a function of stabilizing impurity content. J Alloys Compd. 2014;586:S231-5.
41. Ruff O, Ebert F. Allgemeine und Anorganische Chemie. 1929;180:19-41.
42. Heuer AH, Hobbs LW. Advances in Ceramics. Vol. 3. Science and Technology of Zirconia. Cleveland (OH): 1981.

43. Koidis P, Strub JR. Spiridon Oumvertos Koutayas, Dr Med Dent, DDS, CDT. Clin Res. 2009;4(2).
44. Garvie RC, Nicholson PS. Structure and Thermomechanical Properties of Partially Stabilized Zirconia in the CaO-ZrO₂ System. J Am Ceram Soc. Mart 1972;55(3):152-7.
45. Chevalier J, Cales B, Drouin JM. Low-Temperature Aging of Y-TZP Ceramics. J Am Ceram Soc. Ağustos 1999;82(8):2150-4.
46. Kosmač T, Oblak C, Jevnikar P, Funduk N, Marion L. The effect of surface grinding and sandblasting on flexural strength and reliability of Y-TZP zirconia ceramic. Dent Mater. 1999;15(6):426-33.
47. Porter DL, Heuer AH. Mechanisms of toughening partially stabilized zirconia (PSZ). J Am Ceram Soc United States. 1977;60.
48. Garvie RC, Hannink RH, Pascoe RT. Ceramic Steel? İçinde: Sōmiya S, Moriyoshi Y, editörler. Sintering Key Papers. Dordrecht: Springer Netherlands; 1990. s. 253-7.
49. Butler EP. Transformation-toughened zirconia ceramics. Mater Sci Technol. Haziran 1985;1(6):417-32.
50. Claussen N, Heuer AH. Transformation toughening. İçinde: Concise Encyclopedia of Advanced Ceramic Materials. Elsevier; 1991. s. 494-7.
51. Turp V, Sen D, Tuncelli B, Goller G, Özcan M. Evaluation of air-particle abrasion of Y- TZP with different particles using microstructural analysis. Aust Dent J. Haziran 2013;58(2):183-91.
52. Reed JS, Lejus AM. Affect of grinding and polishing on near-surface phase transformations in zirconia. Mater Res Bull. 1977;12(10):949-54.
53. Hannink RHJ, Kelly PM, Muddle BC. Transformation Toughening in Zirconia-Containing Ceramics. J Am Ceram Soc. Mart 2000;83(3):461-87.
54. Boudrias P. The yttrium tetragonal zirconia polycrystals (Y-TZP) infrastructure: The new chapter in the search for a metal framework replacement. J Dent Québec. 2005;42:172-6.
55. Guazzato M, Albakry M, Ringer SP, Swain MV. Strength, fracture toughness and microstructure of a selection of all-ceramic materials. Part II. Zirconia-based dental ceramics. Dent Mater. 2004;20(5):449-56.
56. Theunissen GSAM, Bouma JS, Winnubst AJA, Burggraaf AJ. Mechanical properties of ultra-fine grained zirconia ceramics. J Mater Sci. Ağustos 1992;27(16):4429-38.

57. Ersoy NM, Aydoğdu HM, Değirmenci BÜ, Çökük N, Sevimay M. The effects of sintering temperature and duration on the flexural strength and grain size of zirconia. *Acta Biomater Odontol Scand*. 23 Aralık 2015;1(2-4):43-50.
58. Cambridge University Press & Assessment [Internet]. The Cambridge Dictionary of Philosophy 3rd Edition.
59. Russell S, Norvig P. Artificial Intelligence: A Modern... - Google Akademik.
60. McCarthy J. A Proposal for the Dartmouth Summer Research Project on Artificial Intelligence.
61. Bellman RE. Artificial intelligence: can computers think? 1978; Erişim adresi: <https://cir.nii.ac.jp/crid/1130282270499133440>
62. Balakrishnan J, Dwivedi YK. Conversational commerce: entering the next stage of AI-powered digital assistants. *Ann Oper Res*. Şubat 2024;333(2-3):653-87.
63. Dewitte S, Cornelis JP, Müller R, Munteanu A. Artificial Intelligence Revolutionises Weather Forecast, Climate Monitoring and Decadal Prediction. *Remote Sens*. 2021;13(16).
64. Khayyam H, Javadi B, Jalili M, Jazar RN. Artificial Intelligence and Internet of Things for Autonomous Vehicles. İçinde: Jazar RN, Dai L, editörler. *Nonlinear Approaches in Engineering Applications*. Cham: Springer International Publishing; 2020. s. 39-68.
65. Yakan SA. Analysis of development of artificial intelligence in the game industry. *Int J Cyber IT Serv Manag*. 2022;2(2):111-6.
66. Beer A, Gartner J, Musliu N, Schafhauser W, Slany W. An AI-Based Break-Scheduling System for Supervisory Personnel. *IEEE Intell Syst*. Mart 2010;25(2):60-73.
67. Vyas B. Java in Action: AI for Fraud Detection and Prevention. *Int J Sci Res Comput Sci Eng Inf Technol*. 2023;9(6):58-69.
68. Rajpurkar P, Chen E, Banerjee O, Topol EJ. AI in health and medicine. *Nat Med*. Ocak 2022;28(1):31-8.
69. Miladinovic M, Mihailovic B, Mladenovic D, Duka M, Zivkovic D, Mladenovic S, vd. Artificial intelligence in clinical medicine and dentistry. *Vojnosanit Pregl*. 2017;74(3):267-72.
70. Khanna DSS, Dhaimade PA. Artificial Intelligence: Transforming Dentistry Today. 6(3).
71. Forghani R. Machine Learning and Other Artificial Intelligence Applications, An Issue of Neuroimaging Clinics of North America, E-Book: Machine Learning and

Other Artificial Intelligence Applications, An Issue of Neuroimaging Clinics of North America, E-Book. Elsevier Health Sciences; 2020. 192 s.

72. Turing AM. Computing Machinery and Intelligence. İçinde: Epstein R, Roberts G, Beber G, editörler. Parsing the Turing Test. Dordrecht: Springer Netherlands; 2009. s. 23-65.
73. Arslan K. Eğitimde Yapay Zeka ve Uygulamaları Artificial Intelligence and Applications in Education.
74. Stone P, Brooks R, Brynjolfsson E, Calo R, Etzioni O, Hager G, vd. Artificial Intelligence and Life in 2030: The One Hundred Year Study on Artificial Intelligence. 2022.
75. Campbell M, Hoane AJ, Hsu F hsiung. Deep Blue. Artif Intell. 01 Ocak 2002;134(1):57-83.
76. Schaeffer J, Plaat A. Kasparov versus Deep Blue: The Rematch. ICGA J. 01 Haziran 1997;20(2):95-101.
77. Teng X, Gong Y. Research on Application of Machine Learning in Data Mining. IOP Conf Ser Mater Sci Eng. Temmuz 2018;392(6):062202.
78. AI Based Diagnosis of Pneumonia | Wireless Personal Communications [İnternet]. [a.yer 14 Mayıs 2025]. Erişim adresi: <https://link.springer.com/article/10.1007/s11277-022-09885-7>
79. Bellinger C, Mohamed Jabbar MS, Zaiane O, Osornio-Vargas A. A systematic review of data mining and machine learning for air pollution epidemiology. BMC Public Health. 28 Kasım 2017;17(1):907.
80. Sarker IH. Machine Learning: Algorithms, Real-World Applications and Research Directions. SN Comput Sci. 22 Mart 2021;2(3):160.
81. Tiwari T, Tiwari T, Tiwari S. How Artificial Intelligence, Machine Learning and Deep Learning are Radically Different? Int J Adv Res Comput Sci Softw Eng. 06 Mart 2018;8(2):1.
82. Kim P. MATLAB Deep Learning. Berkeley, CA: Apress; 2017.
83. Han J, Kamber M, Pei J. Data mining: Concepts and. Tech Walth Morgan Kaufmann Publ. 2012;
84. Sarker IH, Kayes ASM, Badsha S, Alqahtani H, Watters P, Ng A. Cybersecurity data science: an overview from machine learning perspective. J Big Data. Aralık 2020;7(1):41.
85. Benke K, Benke G. Artificial intelligence and big data in public health. Int J Environ Res Public Health. 2018;15(12):2796.

86. Huang S, Yang J, Fong S, Zhao Q. Artificial intelligence in cancer diagnosis and prognosis: Opportunities and challenges. *Cancer Lett.* 2020;471:61-71.
87. De La Vega FM, Chowdhury S, Moore B, Frise E, McCarthy J, Hernandez EJ, vd. Artificial intelligence enables comprehensive genome interpretation and nomination of candidate diagnoses for rare genetic diseases. *Genome Med.* 14 Ekim 2021;13(1):153.
88. Ran D, Yingli W, Haoxin Q. RETRACTED: Artificial intelligence speech recognition model for correcting spoken English teaching. *J Intell Fuzzy Syst.* 02 Şubat 2021;40(2):3513-24.
89. Chandran V, Patil CK, Karthick A, Ganeshaperumal D, Rahim R, Ghosh A. State of Charge Estimation of Lithium-Ion Battery for Electric Vehicles Using Machine Learning Algorithms. *World Electr Veh J. Mart* 2021;12(1):38.
90. Sehgal N, Pandey KK. Artificial intelligence methods for oil price forecasting: a review and evaluation. *Energy Syst.* Kasım 2015;6(4):479-506.
91. Ahmed A, Aziz S, Qidwai U, Abd-Alrazaq A, Sheikh J. Performance of artificial intelligence models in estimating blood glucose level among diabetic patients using non-invasive wearable device data. *Comput Methods Programs Biomed Update.* 2023;3:100094.
92. Deo RC. *Machine Learning in Medicine.*
93. Ceselli A. *Information Management course.*
94. Richards BA, Lillicrap TP, Beaudoin P, Bengio Y, Bogacz R, Christensen A, vd. A deep learning framework for neuroscience. *Nat Neurosci.* Kasım 2019;22(11):1761-70.
95. Schaefer M, Michelin L, Kepner J. Naming Schema for a Human Brain-Scale Neural Network. *arXiv*; 2021.
96. Aggarwal K, Mijwil MM, Al-Mistarehi AH, Alomari S, Gök M, Alaabdin AMZ, vd. Has the future started? The current growth of artificial intelligence, machine learning, and deep learning. *Iraqi J Comput Sci Math.* 2022;3(1):115-23.
97. Mathew A, Amudha P, Sivakumari S. Deep Learning Techniques: An Overview. İçinde: Hassanien AE, Bhatnagar R, Darwish A, editörler. *Advanced Machine Learning Technologies and Applications.* Singapore: Springer Singapore; 2021. s. 599-608. (*Advances in Intelligent Systems and Computing*; c. 1141).
98. Ongsulee P. Artificial intelligence, machine learning and deep learning. İçinde: 2017 15th international conference on ICT and knowledge engineering (ICT&KE). IEEE; 2017. s. 1-6.
99. Sebastian N, Ankayarkanni B. Deep Learning applications to detect pneumonia on chest X-ray: A systematic study. İçinde: 2022 International Conference on

Advanced Computing Technologies and Applications (ICACTA). IEEE; 2022. s. 1-5.

100. Kim J, Sangjun O, Kim Y, Lee M. Convolutional neural network with biologically inspired retinal structure. *Procedia Comput Sci.* 2016;88:145-54.
101. Krizhevsky A, Sutskever I, Hinton GE. ImageNet Classification with Deep Convolutional Neural Networks. İçinde: *Advances in Neural Information Processing Systems*. Curran Associates, Inc.; 2012.
102. Shallu, Mehra R. Breast cancer histology images classification: Training from scratch or transfer learning? *ICT Express.* 01 Aralık 2018;4(4):247-54.
103. Deng J, Dong W, Socher R, Li LJ, Li K, Fei-Fei L. ImageNet: A large-scale hierarchical image database. İçinde: *2009 IEEE Conference on Computer Vision and Pattern Recognition*. 2009. s. 248-55.
104. Morid MA, Borjali A, Del Fiol G. A scoping review of transfer learning research on medical image analysis using ImageNet. *Comput Biol Med.* 2021;128:104115.
105. Hadhrami EA, Mufti MA, Taha B, Werghi N. Transfer learning with convolutional neural networks for moving target classification with micro-Doppler radar spectrograms. İçinde: *2018 International Conference on Artificial Intelligence and Big Data (ICAIBD)*. 2018. s. 148-54.
106. Ahmad I. A Hybrid Rule-Based and Machine Learning System for Arabic Check Courtesy Amount Recognition. *Sensors.* 25 Nisan 2023;23(9):4260.
107. Nalluri S, Sasikala R. A deep neural architecture for SOTA pneumonia detection from chest X-rays. *Int J Syst Assur Eng Manag.* Ocak 2024;15(1):489-502.
108. Acharya UK, Ali MT, Ahmed MK, Siddiqui MT, Gupta H, Kumar S, vd. Hybrid deep neural network for automatic detection of COVID-19 using chest x-ray images. *Int J Imaging Syst Technol.* Temmuz 2023;33(4):1129-43.
109. Baltruschat IM, Steinmeister L, Ittrich H, Adam G, Nickisch H, Saalbach A, vd. When does bone suppression and lung field segmentation improve chest x-ray disease classification? İçinde: *2019 IEEE 16th International Symposium on Biomedical Imaging (ISBI 2019)*. IEEE; 2019. s. 1362-6.
110. Deniz E, Şengür A, Kadiroğlu Z, Guo Y, Bajaj V, Budak Ü. Transfer learning based histopathologic image classification for breast cancer detection. *Health Inf Sci Syst.* Aralık 2018;6(1):18.
111. Yaman S, Işılçay Ünlü E, Güler H, Sengur A, Rajendra Acharya U. Application of novel DIRF feature selection algorithm for automated brain disease detection. *Biomed Signal Process Control.* 01 Ağustos 2023;85:105006.

112. Lee W, Jo O, Kim M. Application of End-to-End Deep Learning in Wireless Communications Systems [Internet]. 2018 [a.yer 24 Mayıs 2025]. Erişim adresi: <http://arxiv.org/abs/1808.02394>
113. O'Mahony N, Campbell S, Carvalho A, Harapanahalli S, Hernandez GV, Krpalkova L, vd. Deep Learning vs. Traditional Computer Vision. İçinde: Arai K, Kapoor S, editörler. Advances in Computer Vision. Cham: Springer International Publishing; 2020. s. 128-44. (Advances in Intelligent Systems and Computing; c. 943).
114. Kanawade B, Zaware S, Nandre J, Mahale Y, Dhake K. A deep learning approach for pneumonia detection from X-ray images. Int J Intell Syst Appl Eng. 2023;11(2):262-6.
115. Singh N, Sabrol H. Convolutional Neural Networks-An Extensive arena of Deep Learning. A Comprehensive Study. Arch Comput Methods Eng. Aralık 2021;28(7):4755-80.
116. Çallı E, Sogancioglu E, van Ginneken B, van Leeuwen KG, Murphy K. Deep learning for chest X-ray analysis: A survey. Med Image Anal. 2021;72:102125.
117. Yun J, Cho YH, Lee SM, Hwang J, Lee JS, Oh YM, vd. Deep radiomics-based survival prediction in patients with chronic obstructive pulmonary disease. Sci Rep. 26 Temmuz 2021;11(1):15144.
118. İnık Ö, Ülker E. Derin öğrenme ve görüntü analizinde kullanılan derin öğrenme modelleri. Gaziosmanpaşa Bilimsel Araşt Derg. 2017;6(3):85-104.
119. Jiang S, Qin S, Pulsipher JL, Zavala VM. Convolutional neural networks: Basic concepts and applications in manufacturing. İçinde: Artificial Intelligence in Manufacturing. Elsevier; 2024. s. 63-102.
120. Kimura N, Yoshinaga I, Sekijima K, Azechi I, Baba D. Convolutional Neural Network Coupled with a Transfer-Learning Approach for Time-Series Flood Predictions. Water. 2020;12(1).
121. Ioffe S, Szegedy C. Batch normalization: Accelerating deep network training by reducing internal covariate shift. İçinde: International conference on machine learning [Internet]. pmlr; 2015 [a.yer 26 Mayıs 2025]. s. 448-56. Erişim adresi: <http://proceedings.mlr.press/v37/ioffe15.html>
122. Barhoom AMA. Diagnosis of Pneumonia Using Deep Learning. 2022;6(2).
123. Albawi Shadi, Mohammed Tareq Abed, Al-Zawi Saad. Understanding of a convolutional neural network. İçinde IEEE; 2017.
124. Hochreiter S. The Vanishing Gradient Problem During Learning Recurrent Neural Nets and Problem Solutions. Int J Uncertain Fuzziness Knowl-Based Syst. Nisan 1998;06(02):107-16.

125. Pauly L, Hogg D, Fuentes R, Peel H. Deeper networks for pavement crack detection. İçinde: Proceedings of the 34th ISARC. IAARC; 2017. s. 479-85.
126. Alzubaidi L, Zhang J, Humaidi AJ, Al-Dujaili A, Duan Y, Al-Shamma O, vd. Review of deep learning: concepts, CNN architectures, challenges, applications, future directions. J Big Data. 31 Mart 2021;8(1):53.
127. Byers B, Sheta A. Design of convolutional neural networks for fish recognition and tracking. Artif Intell Mach Learn AIML. 22(1):1-9.
128. Hutchison D, Kanade T, Kittler J, Kleinberg JM, Mattern F, Mitchell JC, vd. Evaluation of Pooling Operations in Convolutional Architectures for Object Recognition. İçinde: Diamantaras K, Duch W, Iliadis LS, editörler. Artificial Neural Networks – ICANN 2010. Berlin, Heidelberg: Springer Berlin Heidelberg; 2010. s. 92-101. (Lecture Notes in Computer Science; c. 6354).
129. Guissous AE. Skin Lesion Classification Using Deep Neural Network [Internet]. 2019 [a.yer 02 Haziran 2025]. Erişim adresi: <http://arxiv.org/abs/1911.07817>
130. Guo Y, Liu Y, Oerlemans A, Lao S, Wu S, Lew MS. Deep learning for visual understanding: A review. Neurocomputing. 2016;187:27-48.
131. Zhu J, Song J. An Intelligent Classification Model for Surface Defects on Cement Concrete Bridges. Appl Sci. 02 Şubat 2020;10(3):972.
132. Srivastava N, Hinton G, Krizhevsky A, Sutskever I, Salakhutdinov R. Dropout: a simple way to prevent neural networks from overfitting. J Mach Learn Res. 2014;15(1):1929-58.
133. Al-Janabi AA, Al-Janabi STF, Al-Khateeb B. Secure Data Computation Using Deep Learning and Homomorphic Encryption: A Survey. Int J Online Biomed Eng. 01 Kasım 2023;19(11):53-82.
134. Krizhevsky A, Sutskever I, Hinton GE. ImageNet classification with deep convolutional neural networks. Commun ACM. 24 Mayıs 2017;60(6):84-90.
135. BAŞARAN E. TİMPANİK MEMBRAN GÖRÜNTÜ ANALİZİ VE YAPAY ZEKA KULLANILARAK SANAL OTİTİS MEDİA TANI SİSTEMİNİN GELİŞTİRİLMESİ [PhD Thesis]. Karabük Üniversitesi; 2020.
136. Simonyan K, Zisserman A. Very Deep Convolutional Networks for Large-Scale Image Recognition [Internet]. arXiv; 2015 [a.yer 25 Mayıs 2025]. Erişim adresi: <http://arxiv.org/abs/1409.1556>
137. Szegedy C, Liu W, Jia Y, Sermanet P, Reed S, Anguelov D, vd. Going deeper with convolutions. İçinde: Proceedings of the IEEE conference on computer vision and pattern recognition. 2015. s. 1-9.
138. Ronneberger O, Fischer P, Brox T. U-Net: Convolutional Networks for Biomedical Image Segmentation. İçinde: Navab N, Hornegger J, Wells WM,

- Frangi AF, editörler. Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015. Cham: Springer International Publishing; 2015. s. 234-41. (Lecture Notes in Computer Science; c. 9351).
139. He K, Zhang X, Ren S, Sun J. Deep residual learning for image recognition. İçinde: Proceedings of the IEEE conference on computer vision and pattern recognition. 2016. s. 770-8.
 140. Jha D, Smedsrud PH, Riegler MA, Johansen D, De Lange T, Halvorsen P, vd. Resunet++: An advanced architecture for medical image segmentation. İçinde: 2019 IEEE international symposium on multimedia (ISM). IEEE; 2019. s. 225-2255.
 141. Zhang Z, Liu Q, Wang Y. Road extraction by deep residual u-net. IEEE Geosci Remote Sens Lett. 2018;15(5):749-53.
 142. Rahman H, Bukht TFN, Imran A, Tariq J, Tu S, Alzahrani A. A deep learning approach for liver and tumor segmentation in CT images using ResUNet. Bioengineering. 2022;9(8):368.
 143. Diakogiannis FI, Waldner F, Caccetta P, Wu C. ResUNet-a: A deep learning framework for semantic segmentation of remotely sensed data. ISPRS J Photogramm Remote Sens. 2020;162:94-114.
 144. Yang J, Zhu J, Wang H, Yang X. Dilated MultiResUNet: Dilated multiresidual blocks network based on U-Net for biomedical image segmentation. Biomed Signal Process Control. 2021;68:102643.
 145. Uçak H, Başağaoğlu Demirekin Z. Yapay Zekâ [İnternet]. Konya, Turkey: All Science Academy; 2025. Erişim adresi: <https://zenodo.org/records/15127929>
 146. Ding H, Wu J, Zhao W, Matinlinna JP, Burrow MF, Tsoi JK. Artificial intelligence in dentistry—A review. Front Dent Med. 2023;4:1085251.
 147. Schleyer TK, Thyvalikakath TP, Spallek H, Torres-Urquidy MH, Hernandez P, Yuhaniak J. Clinical computing in general dentistry. J Am Med Inform Assoc. 2006;13(3):344-52.
 148. Chae YM, Yoo KB, Kim ES, Chae H. The adoption of electronic medical records and decision support systems in Korea. Healthc Inform Res. 2011;17(3):172-7.
 149. Olsen GF, Brilliant SS, Primeaux D, Najarian K. An image-processing enabled dental caries detection system. İçinde: 2009 ICME International Conference on Complex Medical Engineering. IEEE; 2009. s. 1-8.
 150. Beltrán-Aguilar ED, Barker LK, Canto MT, Dye BA, Gooch BF, Griffin SO, vd. Surveillance for dental caries, dental sealants, tooth retention, edentulism, and enamel fluorosis—United States, 1988-1994 and 1999-2002. MMWR Surveill Summ. 2005;54(3):1-43.

151. Geetha V, Aprameya KS, Hinduja DM. Dental caries diagnosis in digital radiographs using back-propagation neural network. *Health Inf Sci Syst. Aralık* 2020;8(1):8.
152. Abdalla-Aslan R, Yeshua T, Kabla D, Leichter I, Nadler C. An artificial intelligence system using machine-learning for automatic detection and classification of dental restorations in panoramic radiography. *Oral Surg Oral Med Oral Pathol Oral Radiol.* 2020;130(5):593-602.
153. Ekert T, Krois J, Meinhold L, Elhennawy K, Emara R, Golla T, vd. Deep learning for the radiographic detection of apical lesions. *J Endod.* 2019;45(7):917-22.
154. Saghiri MA, Asgar K, Boukani KK, Lotfi M, Aghili H, Delvarani A, vd. A new approach for locating the minor apical foramen using an artificial neural network. *Int Endod J. Mart* 2012;45(3):257-65.
155. Aminoshariae A, Kulild J, Nagendrababu V. Artificial intelligence in endodontics: current applications and future directions. *J Endod.* 2021;47(9):1352-7.
156. de Oliveira Poswar F, Farias LC, de Carvalho Fraga CA, Bambirra Jr W, Brito-Júnior M, Sousa-Neto MD, vd. Bioinformatics, interaction network analysis, and neural networks to characterize gene expression of radicular cyst and periapical granuloma. *J Endod.* 2015;41(6):877-83.
157. Kök H, Izgi MS, Acilar AM. Determination of growth and development periods in orthodontics with artificial neural network. *Orthod Craniofac Res. Aralık* 2021;24(S2):76-83.
158. Muraev AA, Tsai P, Kibardin I, Oborotistov N, Shirayeva T, Ivanov S, vd. Frontal cephalometric landmarking: humans vs artificial neural networks. *Int J Comput Dent.* 2020;23(2).
159. Bianchi J, de Oliveira Ruellas AC, Gonçalves JR, Paniagua B, Prieto JC, Styner M, vd. Osteoarthritis of the temporomandibular joint can be diagnosed earlier using biomarkers and machine learning. *Sci Rep.* 2020;10(1):8012.
160. Auconi P, Scazzocchio M, Cozza P, McNamara Jr JA, Franchi L. Prediction of Class III treatment outcomes through orthodontic data mining. *Eur J Orthod.* 2015;37(3):257-67.
161. Li P, Kong D, Tang T, Su D, Yang P, Wang H, vd. Orthodontic treatment planning based on artificial neural networks. *Sci Rep.* 2019;9(1):2037.
162. Patcas R, Timofte R, Volokitin A, Agustsson E, Eliades T, Eichenberger M, vd. Facial attractiveness of cleft patients: a direct comparison between artificial-intelligence-based scoring and conventional rater groups. *Eur J Orthod.* 2019;41(4):428-33.

163. Patcas R, Bernini DA, Volokitin A, Agustsson E, Rothe R, Timofte R. Applying artificial intelligence to assess the impact of orthognathic treatment on facial attractiveness and estimated age. *Int J Oral Maxillofac Surg*. 2019;48(1):77-83.
164. Kim BS, Yeom HG, Lee JH, Shin WS, Yun JP, Jeong SH, vd. Deep learning-based prediction of paresthesia after third molar extraction: A preliminary study. *Diagnostics*. 2021;11(9):1572.
165. Liu Z, Liu J, Zhou Z, Zhang Q, Wu H, Zhai G, vd. Differential diagnosis of ameloblastoma and odontogenic keratocyst by machine learning of panoramic radiographs. *Int J Comput Assist Radiol Surg*. Mart 2021;16(3):415-22.
166. Sukegawa S, Yoshii K, Hara T, Matsuyama T, Yamashita K, Nakano K, vd. Multi-task deep learning model for classification of dental implant brand and treatment stage using dental panoramic radiograph images. *Biomolecules*. 2021;11(6):815.
167. Chang HJ, Lee SJ, Yong TH, Shin NY, Jang BG, Kim JE, vd. Deep learning hybrid method to automatically diagnose periodontal bone loss and stage periodontitis. *Sci Rep*. 2020;10(1):7531.
168. Lee C, Kabir T, Nelson J, Sheng S, Meng H, Van Dyke TE, vd. Use of the deep learning approach to measure alveolar bone level. *J Clin Periodontol*. Mart 2022;49(3):260-9.
169. Cha JY, Yoon HI, Yeo IS, Huh KH, Han JS. Peri-implant bone loss measurement using a region-based convolutional neural network on dental periapical radiographs. *J Clin Med*. 2021;10(5):1009.
170. Krois J, Ekert T, Meinhold L, Golla T, Kharbot B, Wittemeier A, vd. Deep learning for the radiographic detection of periodontal bone loss. *Sci Rep*. 2019;9(1):8495.
171. Pareek M, Kaushik B. Artificial intelligence in prosthodontics: a scoping review on current applications and future possibilities. *Int J Adv Med*. 2022;9(3):367-70.
172. Roongruangsilp P, Khongkhunthian P. The learning curve of artificial intelligence for dental implant treatment planning: a descriptive study. *Appl Sci*. 2021;11(21):10159.
173. Kong HJ, Kim YL. Application of artificial intelligence in dental crown prosthesis: a scoping review. *BMC Oral Health*. 13 Ağustos 2024;24(1):937.
174. Chen SL, Chen TY, Huang YC, Chen CA, Chou HS, Huang YY, vd. Missing teeth and restoration detection using dental panoramic radiography based on transfer learning with CNNs. *IEEE Access*. 2022;10:118654-64.

175. Vishwanathaiah S, Fageeh HN, Khanagar SB, Maganur PC. Artificial intelligence its uses and application in pediatric dentistry: a review. *Biomedicines*. 2023;11(3):788.
176. Wang Y, Hays RD, Marcus M, Maida CA, Shen J, Xiong D, vd. Developing Children's Oral Health Assessment Toolkits Using Machine Learning Algorithm. *JDR Clin Transl Res*. Temmuz 2020;5(3):233-43.
177. You W, Hao A, Li S, Wang Y, Xia B. Deep learning-based dental plaque detection on primary teeth: a comparison with clinical assessments. *BMC Oral Health*. Aralık 2020;20(1):141.
178. Kılıc MC, Bayrakdar IS, Çelik Ö, Bilgir E, Orhan K, Aydın OB, vd. Artificial intelligence system for automatic deciduous tooth detection and numbering in panoramic radiographs. *Dentomaxillofac Radiol*. 2021;50(6):20200172.
179. Karhade DS, Roach J, Shrestha P, Simancas-Pallares MA, Ginnis J, Burk ZJ, vd. An automated machine learning classifier for early childhood caries. *Pediatr Dent*. 2021;43(3):191-7.
180. AYDIN KC. Ağız, Diş ve Çene Radyolojisinde Yapay Zekâ Uygulamaları Neler Yapabiliyor? *Türk Klin Oral Maxillofac Radiol-Spec Top*. 2023;9(1):9-15.
181. Zweig MH, Campbell G. Receiver-operating characteristic (ROC) plots: a fundamental evaluation tool in clinical medicine. *Clin Chem*. 1993;39(4):561-77.
182. Pinchi V, Pradella F, Vitale G, Rugo D, Nieri M, Norelli GA. Comparison of the diagnostic accuracy, sensitivity and specificity of four odontological methods for age evaluation in Italian children at the age threshold of 14 years using ROC curves. *Med Sci Law*. Ocak 2016;56(1):13-8.
183. Davis J, Goadrich M. The relationship between Precision-Recall and ROC curves. İçinde: *Proceedings of the 23rd international conference on Machine learning - ICML '06*. Pittsburgh, Pennsylvania: ACM Press; 2006. s. 233-40.
184. Fawcett T. An introduction to ROC analysis. *Pattern Recognit Lett*. 01 Haziran 2006;27(8):861-74.
185. Saito T, Rehmsmeier M. The Precision-Recall Plot Is More Informative than the ROC Plot When Evaluating Binary Classifiers on Imbalanced Datasets. *PLOS ONE*. 04 Mart 2015;10(3):e0118432.
186. Zweig MH, Campbell G. Receiver-operating characteristic (ROC) plots: a fundamental evaluation tool in clinical medicine. *Clin Chem*. 01 Nisan 1993;39(4):561-77.
187. The Relationship Between Precision-Recall and ROC Curves [İnternet]. [a.yer 05 Haziran 2025]. Erişim adresi:

https://www.researchgate.net/publication/215721831_The_Relationship_Between_Precision-Recall_and_ROC_Curves

188. Moor J. The Dartmouth College Artificial Intelligence Conference: The Next Fifty Years.
189. McCarthy J, Minsky ML, Rochester N, Shannon CE. A proposal for the dartmouth summer research project on artificial intelligence, august 31, 1955. *AI Mag.* 2006;27(4):12-12.
190. Schwendicke F, Samek W, Krois J. Artificial Intelligence in Dentistry: Chances and Challenges. *J Dent Res.* Temmuz 2020;99(7):769-74.
191. Yasa Y, Çelik Ö, Bayrakdar IS, Pekince A, Orhan K, Akarsu S, vd. An artificial intelligence proposal to automatic teeth detection and numbering in dental bite-wing radiographs. *Acta Odontol Scand.* 19 Mayıs 2021;79(4):275-81.
192. Lee JH, Kim DH, Jeong SN, Choi SH. Detection and diagnosis of dental caries using a deep learning-based convolutional neural network algorithm. *J Dent.* 2018;77:106-11.
193. Devito KL, de Souza Barbosa F, Felipe Filho WN. An artificial multilayer perceptron neural network for diagnosis of proximal dental caries. *Oral Surg Oral Med Oral Pathol Oral Radiol Endodontology.* 2008;106(6):879-84.
194. Gakenheimer DC. The efficacy of a computerized caries detector in intraoral digital radiography. *J Am Dent Assoc.* 2002;133(7):883-90.
195. Wenzel A, Hintze H, Kold LM, Kold S. Accuracy of computer-automated caries detection in digital radiographs compared with human observers. *Eur J Oral Sci.* Haziran 2002;110(3):199-203.
196. Kyventidis N, Angelopoulos C. Intraoral radiograph anatomical region classification using neural networks. *Int J Comput Assist Radiol Surg.* Mart 2021;16(3):447-55.
197. Fadel HT, Abu-Hammad O, Ghulam OA, Dar-Odeh N. Are artificial neural networks useful for predicting overhanging dental restorations? a cross-sectional study. *World.* 2020;11(2):100.
198. Karatas O, Cakir NN, Ozsariyildiz SS, Kis HC, Demirbuga S, Gurgan CA. A deep learning approach to dental restoration classification from bitewing and periapical radiographs. *Quintessence Int.* 2021;52(7):568-74.
199. Pauwels R, Brasil DM, Yamasaki MC, Jacobs R, Bosmans H, Freitas DQ, vd. Artificial intelligence for detection of periapical lesions on intraoral radiographs: Comparison between convolutional neural networks and human observers. *Oral Surg Oral Med Oral Pathol Oral Radiol.* 2021;131(5):610-6.

200. Cantu AG, Gehrung S, Krois J, Chaurasia A, Rossi JG, Gaudin R, vd. Detecting caries lesions of different radiographic extension on bitewings using deep learning. *J Dent*. 2020;100:103425.
201. Çelik B, Çelik ME. Automated detection of dental restorations using deep learning on panoramic radiographs. *Dentomaxillofacial Radiol*. 2022;51(8):20220244.
202. Yeshua T, Mandelbaum Y, Abdalla-Aslan R, Nadler C, Cohen L, Zemour L, vd. Automatic detection and classification of dental restorations in panoramic radiographs. *Issues Informing Sci Inf Technol*. 2019;16:221-34.
203. Başaran M, Çelik Ö, Bayrakdar IS, Bilgir E, Orhan K, Odabaş A, vd. Diagnostic charting of panoramic radiography using deep-learning artificial intelligence system. *Oral Radiol*. Temmuz 2022;38(3):363-9.
204. Vinayahalingam S, Goey R shan, Kempers S, Schoep J, Cherici T, Moin DA, vd. Automated chart filing on panoramic radiographs using deep learning. *J Dent*. Aralık 2021;115:103864.
205. Detection of the Fixed Prostheses on Panoramic Images: An Artificial Intelligence Based Study. *J Coll Physicians Surg Pak*. 01 Ağustos 2024;34(08):922-6.
206. Bonfanti-Gris M, Garcia-Cañas A, Alonso-Calvo R, Salido Rodriguez-Manzaneque MP, Pradies Ramiro G. Evaluation of an Artificial Intelligence web-based software to detect and classify dental structures and treatments in panoramic radiographs. *J Dent*. Kasım 2022;126:104301.
207. Dave M. EBD spotlight: Artificial intelligence and dental panoramic radiography. *BDJ Team*. Haziran 2024;11(6):244-5.
208. Güneç HG, Ürkmez EŞ, Danacı A, Dilmaç E, Onay HH, Cesur Aydın K. Comparison of artificial intelligence vs. junior dentists' diagnostic performance based on caries and periapical infection detection on panoramic images. *Quant Imaging Med Surg*. 01 Kasım 2023;13(11):7494-503.
209. Altan B, Gunec HG, Cinar S, Kutal S, Gulum S, Aydın KC. Detecting Prosthetic Restorations Using Artificial Intelligence on Panoramic Radiographs. *Sci Program*. 2022;1.
210. Sukegawa S, Yoshii K, Hara T, Yamashita K, Nakano K, Yamamoto N, vd. Deep Neural Networks for Dental Implant System Classification. *Biomolecules*. Temmuz 2020;10(7):984.
211. Kats L, Vered M, Kharouba J, Blumer S. Transfer Deep Learning for Dental and Maxillofacial Imaging Modality Classification: A Preliminary Study. *J Clin Pediatr Dent*. 01 Ekim 2021;45(4):233-8.

212. Tuzoff DV, Tuzova LN, Bornstein MM, Krasnov AS, Kharchenko MA, Nikolenko SI, vd. Tooth detection and numbering in panoramic radiographs using convolutional neural networks. Dento Maxillo Facial Radiol. Mayıs 2019;48(4):20180051.
213. Park W, Huh JK, Lee JH. Automated deep learning for classification of dental implant radiographs using a large multi-center dataset. Sci Rep. 24 Mart 2023;13(1):4862.
214. Balakrishnan J, Dwivedi YK. Conversational commerce:...
215. Atas I. Human Gender Prediction Based on Deep Transfer Learning from Panoramic Radiograph Images. Trait Signal. 30 Kasım 2022;39(5):1585-95.

