

T.C.
ZONGULDAK BÜLENT ECEVİT ÜNİVERSİTESİ
DİŞ HEKİMLİĞİ FAKÜLTESİ
AĞIZ, DİŞ VE ÇENE RADYOLOJİSİ ANABİLİM DALI

PANORAMİK RADYOGRAFİDE DİŞ
ÇÜRÜKLERİ TESPİTİNDE DERİN ÖĞRENME
SİSTEMLERİNİN DEĞERLENDİRİLMESİ

UZMANLIK TEZİ

DT. HATİCE BİLTEKİN

ZONGULDAK

2022

T.C.
ZONGULDAK BÜLENT ECEVİT ÜNİVERSİTESİ
DİŞ HEKİMLİĞİ FAKÜLTESİ
AĞIZ, DİŞ VE ÇENE RADYOLOJİSİ ANABİLİM DALI

PANORAMİK RADYOGRAFİDE DİŞ
ÇÜRÜKLERİ TESPİTİNDE DERİN ÖĞRENME
SİSTEMLERİNİN DEĞERLENDİRİLMESİ

DT. HATİCE BİLTEKİN

UZMANLIK TEZİ

TEZ DANIŞMANI
DR. ÖĞR. ÜYESİ GEDİZ GEDUK

ZONGULDAK

2022

TEŞEKKÜR

Çalışmanın yürütülmesi sırasında ve uzmanlık eğitimim süresince desteklerini esirgemeyen değerli hocalarım Dr.Öğr.Üyesi Gediz Geduk, Dr.Öğr.Üyesi Çiğdem Şeker ve Doç. Dr. Murat İçen'e, maddi ve manevi her zaman yanımda olan ve destek olan aileme, uzmanlık eğitimim esnasında yanımda olan çalışma arkadaşlarıma sonsuz teşekkürlerimi sunarım.

Hatice BİLTEKİN

Ocak 2022, Zonguldak



ÖZET

Hatice Biltekin, Panoramik Radyografide Diş Çürükleri Tespitinde Derin Öğrenme Sistemlerinin Değerlendirilmesi, Zonguldak Bülent Ecevit Üniversitesi, Diş Hekimliği Fakültesi, Ağız, Diş ve Çene Radyolojisi Anabilim Dalı, Uzmanlık Tezi, Zonguldak, 2022

Çalışmanın amacı diş çürükleri tespitinde geleneksel tanı yöntemleri ile yapay zekanın alt dalı olan derin öğrenme yöntemlerinin karşılaştırılması ve çürük teşhisinin yapay zeka yöntemi ile etkinliğinin değerlendirilmesidir. Çalışmada 101 hastanın panoramik radyografisi Ağız, Diş ve Çene Radyolojisi alanında uzmanlığını almış iki hekim ve Ağız, Diş ve Çene Radyolojisi uzmanlık eğitimini sürdüren bir araştırma görevlisi tarafından oluşturulan ortak bir konseyde dişlerde “çürük var/yok” şeklinde seçildi ve dişler sağlıklı ve çürük olarak etiketlendi. Elde edilen 5000 veri %80 eğitim ve %20 test verisi olarak ayrıldı. Model oluşturmak için ResNet50 sinir ağı mimarisi uygulandı. Derin öğrenme modelimiz 0.82 doğruluk gösterdi. Modelin performans metriklerinden PPV değeri %75.8, NPV değeri %92, sensitivitesi %94 ve spesifitesi %70 olarak bulundu. AUC değeri ise %82 olarak bulundu. Panoramik radyografilerde çürük lezyonlarının tespitinde evrimsel sinir ağı modelimiz yeterli performans gösterdi.

Anahtar kelimeler: Derin öğrenme, Diş çürüğü, Panoramik röntgen, Sinir ağı, Yapay zeka.

ABSTRACT

Hatice Biltekin, Evaluation of Deep Learning Systems in Detection of Dental Caries in Panoramic Radiography , Zonguldak Bülent Ecevit University, Faculty of Dentistry, Dentomaxillofacial Radiology Department, Master's Thesis, Zonguldak, 2022.

The aim of the study is to compare traditional diagnostic methods and deep learning methods, which is a subbranch of artificial intelligence, in the detection of dental caries and to evaluate the effectiveness of caries diagnosis with artificial intelligence method. In the study, panoramic radiographs of 101 patients were selected as "caries/no caries" in a joint council formed by two physicians specialized in Oral and Maxillofacial Radiology and a research assistant continuing their education in Oral and Maxillofacial Radiology, and the teeth were labeled as healthy and caries. The 5000 data obtained were divided into 80% training and 20% test data. ResNet50 neural network architecture was applied to build the model. Our deep learning model showed an accuracy of 0.82. Among the performance metrics of the model, the PPV value was 75.8%, the NPV value was 92%, the sensitivity was 94%, and the specificity was 70%. The AUC value was found to be 82%. Our convolutional neural network model performed efficiently in detecting caries lesions on panoramic radiographs.

Keywords: Artificial intelligence, Deep learning, Dental caries, Neural network, Panoramic radiography.

İÇİNDEKİLER

Sayfa

TEŞEKKÜR.....	iv
ÖZET	v
ABSTRACT.....	vi
İÇİNDEKİLER.....	vii
SİMGELER VE KISALTMALAR.....	ix
ŞEKİLLER DİZİNİ.....	x
TABLolar DİZİNİ.....	xi
1.GİRİŞ.....	1
2.GENEL BİLGİLER.....	2
2.1.Yapay Zeka.....	2
2.1.1.Yapay zekanın tarihi	2
2.2.Makine Öğrenimi	4
2.2.1.Denetimli öğrenme	5
2.2.2.Denetimsiz öğrenme	6
2.2.3.Yarı denetimli öğrenme	7
2.2.4.Pekiştirmeli öğrenme	7
2.3.Derin Öğrenme	7
2.3.1.Derin öğrenme yöntemleri	9
2.4.Yapay Sinir Ağları.....	9
2.4.1.Sinir ağlarının tarihi	9
2.4.2.Yapay sinir ağı	10
2.4.4.Evrişimsel sinir ağı \ Convolutional neural network (CNN)	13
2.5.Derin Öğrenme Modeli Oluşturma.....	21
2.6.Tıbbi Görüntülemelerde Derin Öğrenme	29
2.6.1.Görüntü sınıflandırma.....	31
2.6.2.Nesne algılama.....	31
2.6.3.Semantik segmentasyon.....	32
2.6.4.Örnek segmentasyon.....	32
2.7.Diş Hekimliğinde Yapay Zeka	33
2.8.Derin Öğrenmenin Sınırlamaları	34

2.9.Diş Çürüğü	35
2.9.1.Çürük lezyonların tespiti.....	37
2.10.Diş Çürüğü Tespitinde Kullanılan Radyografik Görüntüleme Yöntemleri ...	38
2.10.1.Görüntü reseptörleri.....	40
2.10.2.Çürük tespitinde kullanılan dijital görüntüleme yöntemleri.....	44
3. MATERYAL METOD	50
3.1. Veri Kümeleri.....	51
3.2. Ön İşleme ve Görüntü Büyütme.....	51
3.3. Derin Evrişimsel Sinir Ağı Algoritmasının Mimarisi	54
3.4.ResNet50 Mimarisi.....	54
3.5.Sınıflandırma Modellerinin Başarımının Ölçümü.....	55
3.6.İstatistik Analiz.....	56
4.BULGULAR.....	56
5.TARTIŞMA	60
6.SONUÇ	66
7.KAYNAKLAR.....	67
8. EKLER	74
9.ÖZGEÇMİŞ	78

SİMGELER VE KISALTMALAR

BT	Bilgisayarlı tomografi
CAD	Bilgisayar destekli tanı
DÖ	Derin öğrenme
ESA	Evrişimsel sinir ağı
YSA	Yapay sinir ağı
GPU	Grafik işlem birimi
KIBT	Konik ışınlı bilgisayarlı tomografi
MÖ	Makine öğrenimi
ReLU	Rektifiye (Doğrultulmuş) doğrusal birim
RNN	Tekrarlayan sinir ağı
TBK	Tam bağlantılı katman
YZ	Yapay zeka

ŞEKİLLER DİZİNİ

Şekil	Sayfa
Şekil 1: Yapay zeka.....	2
Şekil 2: Ultrasonografi görüntüsünün piksel bazında görünümü.....	5
Şekil 3: Biyolojik nöron modeli :.....	11
Şekil 4: Yapay bir nöronun şematik gösterimi:	11
Şekil 5: a.Yapay sinir ağının şematik gösterimi b. Biyolojik sinir ağı	12
Şekil 6: Evrişimli sinir ağı mimarisine ve eğitim sürecine genel bir bakış:	14
Şekil 7: Dijital görüntülerin piksel değerinde görüntüsü	15
Şekil 8: Görüntüleri işlemek için çekirdekleri kullanma:	17
Şekil 9: Tensör ve özellik haritaları:	18
Şekil 10: Havuzlama işlemi	19
Şekil 11: Tek boyutlu bir girdi için basit bir evrişim ağının çizimi.	20
Şekil 12: Sınıflandırma, tespit etme ve segmentasyon.....	21
Şekil 13: Dental panoramik radyografinin karmaşık etiketleme örneği.	23
Şekil 14: Periapikal görüntülerde veri büyütme örneği.	23
Şekil 15: Sinir ağı modeli.....	26
Şekil 16: Epoch, batch ve iterasyon	27
Şekil 17: Aşırı uyumu tanımak için rutin bir kontrol, eğitim yinelemesi sırasında eğitim ve doğrulama setlerindeki kayıp	28
Şekil 18: Verilerdeki uyum diyagramı	28
Şekil 19: Görüntü sınıflandırma.....	31
Şekil 20: Nesne algılama.....	31
Şekil 21: Semantik segmentasyon.....	32
Şekil 22: Örnek segmentasyon.....	32
Şekil 23: Bitewing radyografide sınıflandırma, tespit etme, segmentasyon.....	33
Şekil 24: Çalışmada kullanılan panoramik cihazı	49
Şekil 25: Çalışmada uygulanan işlem adımlarını içeren akış diyagramı.	50
Şekil 26: Etiketli sağlıklı ve çürük dişler ayrı ayrı jpg formatında kaydedilmiştir.	52
Şekil 27: ResNet50 mimarisi	55
Şekil 28: Karışıklık Matrisi	56
Şekil 29: Model eğitiminde her epoch için ortalama kayıp ve ortalama doğrulama kaybı değişimi	58
Şekil 30: Karışıklık matrisinin oluşturulması	59
Şekil 31: ROC eğrisi ve AUC	59

TABLÖLAR DİZİNİ

<u>Tablo</u>	<u>Sayfa</u>
Tablo 1: Bir evrişimli sinir ağındaki parametrelerin ve hiperparametrelerin listesi	16
Tablo 2: Açığortay tekniği ile periapikal radyografisi alırken merkezi ışın açısı	46
Tablo 3: Örnek 24 nolu görüntü için etiketlenen sağlıklı dişler birbirinden ayrılarak jpg formatında kaydedilmiştir.	52
Tablo 4: Örnek 24 nolu görüntü için etiketlenen çürük dişler birbirinden ayrılarak jpg formatında kaydedilmiştir.	53
Tablo 5: Model eğitiminde her epoch için ortalama kayıp ve ortalama doğrulama kaybı değişimi	57
Tablo 6: ESA Modelinin Başarım Ölçütleri	60



1.GİRİŞ

Diş çürüğü, besinlerin bakteriler tarafından fermentasyonu ile oluşan asidik ürünlerinin diş sert dokularında yıkıma neden olmasıdır. Tüm dünyada her yaş grubundan bireyleri etkileyen önlenabilir, kronik enfeksiyöz bir hastalıktır.(1)

Diş çürüğünün tedavisi için çeşitli restorasyon ve tedavi yöntemleri geliştirilmiştir. Ancak çürük tespiti sıkı interproksimal temaslar, dişin anatomik morfolojisine bağlı zorluklar, ikincil çürük oluşumu nedeniyle zorlaşabilmekte, çürük tespiti madde kaybının çok olduğu ileri evrelerde ancak yapılabilmektedir.(2)

Diş çürüğü tespiti için görsel muayene, sondlama, intraoral ve ekstraoral radyograf sıklıkla kullanılan geleneksel yöntemlerdir. Görsel olarak belirgin olmayan veya sondla ulaşılamayan interproksimal çürüklerin tanısında radyograflardan faydalanılmaktadır. (3)

Diş hekimliğinde çürük tespiti, çene kırığı içeren travmalar, üçüncü molar konumu, diş ve kemik hastalıkları ve lezyonları, diş gelişimi ve sürmesi, gelişimsel anomalilerin tespitinde sıklıkla kullanılan panoramik radyografi x ışını kaynağı ve görüntü reseptörünün hasta etrafında döndürülmesiyle görüntünün oluştuğu ekstraoral bir radyografik görüntülemedir.(3, 4) Düşük radyasyon dozu, uygulama kolaylığı, daha kısa sürmesi ve hasta konforunun daha fazla olması nedeniyle kullanımı giderek artmaktadır.(5)


Son zamanlarda, yapay zeka ve alt sınıfındaki derin öğrenme ve evrimsel sinir ağı (ESA) kullanılarak tıp alanında bölümlendirme ve tanı, görüntü işleme ve görüntü tanıma ile ilgili çalışmalar yapılmıştır ve diş hekimliği alanında da çalışmalar giderek artmaktadır.(6) Yapılan çalışmalar arasında evrimsel sinir ağının ve derin öğrenmenin kullanıldığı dental radyograflardan çürük tespiti(7-10), apikal patoloji tespiti(11), periodontal kemik kaybı(12), diş segmentasyonu(13), lateral sefalometrik radyograflarda servikal vertebral olgunlaşma değerlendirmesi(14), maksiller sinüzit tespiti(6), osteoporoz tespiti(15) vb bulunmaktadır.

Bu tez çalışmasının amacı diş çürükleri tespitinde geleneksel tanı yöntemleri ile yapay zekanın alt dalı olan derin öğrenme yöntemlerinin karşılaştırılması ve çürük teşhisinin yapay zeka yöntemi ile etkinliğinin değerlendirilmesidir.

2.GENEL BİLGİLER

2.1.Yapay Zeka

Yapay zeka (YZ), normalde insan zekası gerektiren görevleri gerçekleştirmek için sistemler oluşturmaya adanmış bilgisayar bilimi alt alanıdır. Makine öğrenimi, derin öğrenme, evrimsel sinir ağları (Şekil 1) gibi çok çeşitli alt alanları ve teknikleri kapsayan geniş bir şemsiye terimdir.(16)



Şekil 1: Yapay zeka

2.1.1.Yapay zekanın tarihi

Yapay zeka gibi araçların oluşumunda bilgi teknolojisinin ve veri işlemenin hızlı gelişimi rol oynamıştır. YZ terimi, insan bilgisini taklit etmek, genişletmek ve hatta geliştirmek için makineleri kullanan teknik çalışmaları ve yenilikleri içermektedir.(17)

Bilim ve araştırmadaki YZ alanı, Alan Turing'in (birçoğu tarafından "YZ'nin babası" olarak kabul edilir) dönüm noktası niteliğindeki makalesinde şu soruyu sorduğu 1950 yılına kadar izlenebilir: "Makineler düşünebilir mi?" (18) Ayrıca "Entscheidungs problemine bir Uygulama ile Hesaplanabilir Sayılar Üzerine" başlıklı bir makalesi genellikle bilgisayar çağının kurucu belgesi olarak kabul edilmektedir. Turing ve Princeton'daki meslektaşısı Alonzo Church, "algoritma" adı

verilen hesaplama modelinin temeli haline gelen "etkili hesaplanabilirlik" kavramını tanımlamak için kalkülüsü kullanmıştır.(19)

Yapay zeka tanımı resmi olarak ilk kez 1956 Dartmouth Konferansında (Dartmouth College, Hanover, 1956) John McCarthy ve meslektaşları tarafından kullanıldı ve önerileri “Öğrenmenin her yönü veya zekanın diğer herhangi bir özelliği o kadar kesin bir şekilde tanımlanabilir ki, onu simüle etmek için bir makine yapılabilir. Makinelerin dili kullanmasını, soyutlamalar ve kavramlar oluşturmalarını, artık insanlara özgü sorunları çözmesini ve kendilerini geliştirmesini sağlamaya çalışılacaktır.” şeklindeydi. (18) Aynı on yılda, Frank Rosenblatt tarafından yapılan çalışma, makine öğrenimi ve sinir ağları ilkeleri ilkelerine dayanan, görüntü tanıma amaçlı bir makine olan “algılayıcının (perceptron)” inşasına öncü oldu.(20)

“Makine öğrenimi” 1959 yılında Arthur Samuel tarafından ortaya konmuştur.(21)

1970'lerin başında, tıp araştırmacıları YZ'nin yaşam bilimlerinde uygulanabilirliğini keşfettiler. Bununla birlikte, teknolojiye sınırlama YZ'nin uygulanmasını da kısıtladı.(22)

Yapay zeka sistemlerine gerçekçi olmayan yüksek beklentiler, veri erişilebilirliği ve karmaşık sorunları çözmek için gereken bilgi işlem gücü açısından o dönemin sınırlamalarından dolayı 1974–1980 ve 1987–1993 yıllarında “yapay zeka kışı” olarak adlandırılan yapay zekaya fon ve ilginin azaldığı gerileme dönemi yaşanmıştır.(23)

Gelişmiş donanım ve yazılım teknolojileri nedeniyle son yirmi yılda bilgi işlem gücündeki ilerlemeler, YZ'nin mevcut tıbbi uygulamaları iyileştirme potansiyelini fark edilmesini sağlamıştır.(24)

Üç tür yapay zeka vardır: yapay süper zeka, yapay genel zeka ve yapay dar zeka. (25)

Yapay Süper Zeka : Bu, zeki bir ajanın, en parlak ve en yetenekli insan zihinlerini önemli ölçüde aşan bir zekaya sahip olma varsayımsal yeteneğidir. Şu anda süper zeka özelliklerine sahip makineler üretmek teknolojik olarak mümkün değildir. (25)

Yapay Genel Zeka: Öğrenebilen ve kendinin farkında olan ve çeşitli görevleri yerine getirebilen bir varlığa atıfta bulunan yapay zekadır.(26)


Yapay Dar Zeka: Zayıf YZ olarak da bilinen yapay dar zeka, günümüzde en yaygın olanıdır.(25) Genellikle denetimli öğrenme kullanılarak eğitilen algoritmaları kullanır; insan zekasının yerini almaktan ziyade güçlendiren yardımcı bir rol oynadığı için artırılmış zeka olarak adlandırılır.(26)

Dar YZ, ister araba sürmek, ister satranç oynamak, isterse sözlü veya yazılı kelimeleri tanımak olsun, tek bir görevi yerine getirebilir. Yapay dar zeka sistemleri, görevlerine gerçek zamanlı olarak odaklanmak üzere tasarlanmıştır. Çevrelerinden sürekli öğrenerek zamanla bilgi inşa ederler ve kendilerine verilen görevleri yerine getirmede uzmanlaşırlar. Ancak bu sistemler, tasarlandıkları tek görev ortamının dışındaki görevleri gerçekleştiremezler.(25)

2.2.Makine Öğrenimi

Makine öğrenimi (MÖ), algoritmaların, açık programlama yerine verilerden kalıpları öğrenerek görevleri gerçekleştirmek için eğitildiği yapay zekanın alt alanıdır. (27) Klasik makine öğreniminde, uzman insanlar verilerde ayırt edici görünen özellikleri ayırt eder ve kodlar. Daha sonra verileri bu özellikler temelinde düzenlemek veya ayırmak için istatistiksel teknikler kullanılır. Örneğin, bir görüntüyü analiz etmek amacıyla, bir görüntü işleme uzmanı, girdi görüntülerini kenarlar, gradyanlar ve dokuların temel öğelerine ayıştırmak için bir algoritma programlayabilir. Belirli bir görüntüde bu özelliklerin varlığının istatistiksel analizi daha sonra görüntüyü sınıflandırmak veya yorumlamak için kullanılabilir.(16)

Birçok karmaşık bilgisayarlı görsel görev için, bir makine öğrenimi algoritmasının kullanması için en uygun görüntü özelliklerinin nasıl tanımlanacağı bir uzman için bile net değildir. Örneğin, piksel parlaklığı temelinde bir bilgisayara bir organı tanımanın nasıl öğretileceği açık olmayabilir (Şekil 2). Bu nedenle, bir bilgisayar sisteminin sadece özelliklerin istenen çıktılara eşlenmesini öğrenmesi değil, aynı zamanda özelliklerin kendisini öğrenmesi ve optimize etmesi istenebilir.(16)



Şekil 2: Ultrasonografi görüntüsünün piksel bazında görünümü.

Bir uzman bu görüntüyü kolayca sağ böbreğin görüntüsü olarak sınıflandırır. Bilgisayar, gri tonları yerine piksel parlaklığını temsil eden bir sayı matrisini görür. Bilgisayarla görme, tipik olarak, bu matriste sayısal modellerin (özelliklerin) varlığının hesaplanmasını ve ardından görüntüleri bu özelliklere göre ayırt etmek için makine öğrenimi algoritmalarının uygulanmasını içerir.

Bir makine öğrenimi modelinin nasıl eğitildiğine bağlı olarak, öğrenme stratejileri genellikle denetimli öğrenme, denetimsiz öğrenme, yarı denetimli öğrenme ve pekiştirmeli öğrenme olarak ayrılır. Aynı sınıflandırma, makine öğreniminin bir alt kategorisi olduğu için derin öğrenmenin öğrenme stratejilerine de uygulanabilir.(28)

2.2.1.Denetimli öğrenme

Denetimli öğrenme, tipik olarak, örnek girdi-çıkı çiftlerine dayalı olarak bir girdiyi bir çıktıya eşleyen bir işlevi öğrenmek için kullanılan öğrenme türüdür.(29) Genel olarak, denetimli makine öğrenimi platformları, nitel veya nicel bir çıktı elde etmek için "etiketlenmiş" eğitim veri kümelerini kullanır. Eğitim aşamasında değerlendirilen verilerin etiketli yapısı, makine öğrenimi modelinin nihayetinde uzmanın girdi verilerini taklit etmesine izin verdiği için bu yöntemin önemli bir özelliğidir. Sonuç olarak, MÖ modeli, önceki eğitim parametrelerine dayalı olarak bilinmeyen bir girdiyi ayırt edebilir. (30)

En yaygın denetlenen görevler, verileri ayıran "sınıflandırma" ve verilere uyan "regresyon"dur. Regresyon algoritmaları, sürekli bir sonucu (örneğin, kan basıncı veya ölüm riski) tahmin etmeyi amaçlarken, sınıflandırma algoritmaları (veya sınıflandırıcılar) kategorik sonuçları (örneğin, pozitif veya negatif, iyi huylu veya kötü huylu) tahmin etmeyi amaçlar (31).

Girdi verilerinin türü, analiz adımına yaklaşımı ve kullanılması gereken algoritma türünü değiştirebilir. Benzer algoritmalar farklı veri türlerine uygulanabilse de, sağlık bilimlerinde yaygın olarak kullanılan veri türleri arasında sırasıyla görsel tanıma platformlarından ve doğal dil işleme çerçevelerinden yararlanan görüntü ve metin yer almaktadır. Bu ayarların her ikisinde de derin öğrenme sinir ağı algoritmaları artık yaygın olarak kullanılmaktadır. Derin sinir ağları, görüntü sınıflandırması için altın standart haline gelmiştir. Bununla birlikte, sinir ağları makine öğrenimi içindeki tek algoritma değildir ve görüntü dışı verileri (örn. sayısal laboratuvar verileri) kullanırken her zaman en uygun yöntem olmayabilir (30).

Yaygın olarak kullanılan denetimli öğrenme algoritmaları, hem evrimsel sinir ağlarını hem de çeşitli sinirsel olmayan ağ algoritmalarını içermektedir. Kullanılan en yaygın sinirsel olmayan ağ algoritmalarından bazıları lineer regresyon, lojistik regresyon, saf Bayes, karar ağacı, k-en yakın komşu (k-NN), destek vektör makinesi (SVM) ve topluluk karar ağacı algoritması rastgele ormanı (27, 30).

2.2.2.Denetimsiz öğrenme

Denetimsiz öğrenme, analiz adımından önce kullanıcı tarafından bilinmeyen, paylaşılan benzerliklere sahip varlık gruplarını veya kümelerini veren etiketlenmemiş veri kümelerinin agnostik toplanması ve analiz edilmesidir.(30) Bu, üretken özelliklerin çıkarılması, anlamlı eğilimlerin ve yapıların belirlenmesi, sonuçlardaki gruplamalar ve keşif amaçları için yaygın olarak kullanılır. Çeşitli denetimsiz makine öğrenimi yöntemlerinin sonuçları (örneğin, bir temel bileşen analizinin sonuçları) genellikle belirli denetimli öğrenme MÖ metodolojilerinin performansını tamamlayabilir ve böylece performansını artırabilir.(30) En yaygın denetimsiz öğrenme görevleri, kümeleme, yoğunluk tahmini, özellik öğrenme, boyutluluk azaltma, birliktelik kuralları bulma, anormallik algılama vb. (32) Tümör segmentasyonu için kümeleme, sınıflandırma için boyut azaltma, hata tespiti ve

kalite güvencesi, görüntü kaydı radyoloji alanındaki denetimsiz öğrenme uygulamalarıdır.(33)

2.2.3.Yarı denetimli öğrenme

Yarı denetimli öğrenme, hem etiketli hem de etiketsiz veriler üzerinde çalıştığından, yukarıda bahsedilen denetimli ve denetimsiz yöntemlerin bir melezlenmesi olarak tanımlanabilir.(29, 34) Dolayısıyla denetimsiz öğrenme ile denetimli öğrenme arasında kalır. Gerçek dünyada, etiketli veriler çeşitli bağlamlarda nadir olabilir ve etiketlenmemiş veriler, yarı denetimli öğrenmenin yararlı olduğu çok sayıdadır.(35) Yarı denetimli bir öğrenme modelinin nihai amacı, modelden yalnızca etiketlenmiş veriler kullanılarak üretilenden daha iyi bir tahmin sonucu sağlamaktır. Yarı denetimli öğrenmenin kullanıldığı bazı uygulama alanları arasında makine çevirisi, dolandırıcılık tespiti, etiketleme verileri ve metin sınıflandırması sayılabilir. (32)

2.2.4.Pekiştirmeli öğrenme

Pekiştirmeli öğrenme, yazılım araçlarının ve makinelerin, verimliliğini artırmak için belirli bir bağlamda veya ortamda en uygun davranışı otomatik olarak değerlendirmesini sağlayan bir tür makine öğrenimi algoritmasıdır. Bu tür öğrenme, ödül veya cezaya dayalıdır. Amaç ödülü artırmak veya riski en aza indirmek için harekete geçmek için çevre aktivistlerinden elde edilen içgörülerini kullanmaktır. Robotik, otonom sürüş görevleri, üretim ve tedarik zinciri lojistiği gibi karmaşık sistemlerin otomasyonunu artırmaya veya operasyonel verimliliğini optimize etmeye yardımcı olabilecek YZ modellerini eğitmek için güçlü bir araçtır, ancak temel veya doğrudan sorunları çözmek için kullanılması tercih edilmez.(32) Medikal alanda tedavi adaptasyonu ve planlama optimizasyonu için kullanılabilmektedir.(33)

2.3.Derin Öğrenme

Derin öğrenme (DÖ), birçok katmana sahip yapay sinir ağlarının kullanılmasıyla karakterize edilen bir makine öğrenimi algoritmaları sınıfıdır. Grafik işleme birimlerine (GPU'lar) dayalı güçlü paralel bilgi işlem donanımının ortaya çıkması ve büyük veri kümelerinin mevcudiyeti ile derin öğrenme, bilgisayarlı görmede son teknoloji bir teknik haline gelmiştir.(16)

Derin öğrenme, radyologlar tarafından gerçekleştirilen lezyon tespiti, segmentasyon, sınıflandırma, izleme ve ayrıca genellikle yazılım olmadan elde edilemeyen tedavi yanıtının tahmini gibi çeşitli zaman alıcı görevlerin otomasyonu için kullanılabilir.(36)

Derin öğrenmenin geleneksel makine öğreniminden farkı özellikle tıbbi görüntüleme açısından çok önemlidir. Geleneksel makine öğreniminde, ilk adım tipik olarak özellik çıkarmadır. Bu, bir nesneyi sınıflandırmak için, bir nesnenin hangi özelliklerinin önemli olacağına algoritma için karar vermeli ve bu özellikleri yakalayabilen algoritmaları uygulamalıdır. Bu amaç için bilgisayarla görme alanında bir dizi karmaşık algoritma önerilmiş ve çeşitli boyut, şekil, doku ve diğer özellikler çıkarılmıştır. Derin öğrenmede, özellik çıkarma ve karar verme süreci birleştirilmiştir ve eğitilebilir. Bu nedenle hangi özelliklerin çıkarılması gerektiğine ilişkin herhangi bir seçim yapılmasına gerek yoktur; buna eğitim sürecinde ağ tarafından karar verilir. Ancak, sinir ağının kendi özelliklerini seçmesine izin vermenin maliyeti, çok daha büyük eğitim veri setleri için bir gerekliliktir.(37)

Derin öğrenme algoritmalarının çoğu, yapay sinir ağlarına (YSA) dayanır. Evrişimsel sinir ağı, girdilerin görüntü olduğu açık varsayımını yapan yapay sinir ağının bir alt kategorisidir. Son birkaç yılda ESA teknolojisi, bilgisayarla görme alanındaki en etkili yeniliklerden bazılarının temeli olmuştur.(16, 38)

ESA, klasik makine öğrenimi algoritmalarının yetersiz kaldığı yüksek boyutlu verileri, yani çok sayıda özelliğe sahip verileri işleyebilmektedir. Geleneksel olarak makine öğrenimi algoritmaları, özellik sayısı az olduğunda verileri analiz etmek için tasarlanmıştır. Bununla birlikte, görüntü verileri doğal olarak yüksek boyutludur çünkü her görüntü normalde nitelik olarak binlerce piksel içermektedir.(39)

Dört genel derin öğrenme yöntemi aşağıdaki gibidir:(40)

- Tekrarlayan sinir ağları (Recurrent neural networks (RNNs))
- Otomatik kodlayıcılar (Autoencoders)
- Üretken rakip ağlar (Generative adversarial networks (GANs))
- Evrişimsel sinir ağları (Convolutional neural networks (CNNs))

2.3.1.Derin öğrenme yöntemleri

2.3.1.1.Tekrarlayan sinir ağları

Geri besleme döngüleriyle ağa bellek oluşturan, yani bir nöronun çıktısını kendisine girdi olarak geri besleyen sinir ağlarıdır.(40) Dil, konuşma ve zaman serisi verileri gibi sıralı girdileri işlemede etkilidir. Radyolojik alanda, RNN, radyolojik raporlar da dahil olmak üzere elektronik sağlık kayıtları gibi alanlarda uygulanabilir.(41)

1.3.1.2.Otomatik kodlayıcılar

Otomatik kodlayıcılar, denetimsiz temsil öğrenme ilkesini örnekleyen derin öğrenme modellerinden biridir. Girdi verileri etiketli verilere kıyasla daha fazla sayıda etiketlenmemiş veriye sahip olduğunda kullanışlıdır.(42) Otomatik kodlayıcıların arkasındaki mantık, çıktı verilerinin mümkün olduğunca girdi verilerine benzer olması gerektiğidir. Yani otomatik kodlayıcı modelleri, girdiler ve çıktılar farklı olduğunda modeli cezalandıran bir maliyet işlevi içerir.(43) Yüksek boyutlu verilerin düşük boyutlu bir temsili veya kodunu oluşturmak için kullanılabilir.(44)

1.3.1.3.Üretken rakip ağlar

Üreticinin ve ayrımcının iki sinir ağının birbiriyle rekabet ettiği ve işbirliği yaptığı başka bir derin öğrenme algoritmasıdır. (45) Bu sinir ağı orijinal görüntüleri yakından taklit eden sentetik görüntüler üretebilir.(46) Radyoloji alanında, gerçekçi tıbbi görüntüleri sentezlemek için uygulanmıştır.(45)

2.4.Yapay Sinir Ağları

2.4.1.Sinir ağlarının tarihi

1940'ların başında nörofizyolog Warren McCulloch ve matematikçi Walter Pitts biyolojik yapıya dayanan ilkel bir sinir ağını geliştirmiştir.(47) 1958'de Frank Rosenblatt'ın ikili sınıflandırma görevi için algılayıcı olarak adlandırılan sinir ağının yapısını tanımladığı makalesi dönüm noktası niteliğinde olmuştur.(20)

1962'de Windrow, tasarımlarını donanımsal olarak uygulayan Adaptif Lineer Nöron (ADALINE) adlı bir cihazı tanıttı. Eğitim amaçları için hataların geri yayılım kavramı Werbose 1974'te tartışılmıştır. 1979'da Fukushima, Neocognitron adı verilen, çoklu havuzlama ve evrişim katmanlarına sahip yapay sinir ağı tasarladı. Derin öğrenmedeki en önemli atılımlardan biri, 2006'da Hinton ve arkadaşlarının, Sınırlı Boltzmann Makineleri'nin birkaç katmanını Derin İnanç Ağı'na uyguladıkları ve her seferinde bir katmanı gözetimsiz bir şekilde hırsla öğrettikleri zaman meydana geldi. (46)

1989'da LeCun ve arkadaşlarının bir geri yayılım algoritması kullanarak verilerden kendi kendine öğrenen bir derin sinir ağını tanıttıktan sonra, derin öğrenme, tahminlerin eğitim setine çok yakın karşılık geldiği aşırı uyum sorununun çözülmesi, yüksek performanslı grafik işleme birimlerinin kullanılması ve büyük verilerin artan kullanılabilirliği nedeniyle patlayıcı bir şekilde gelişti. (44, 48)

2.4.2. Yapay sinir ağı


Biyolojik sinir sistemlerinden esinlenen yapay sinir ağıları, yapay nöronlar adı verilen çoklu hesaplama birimlerinden oluşur (Şekil 3). (38) Yani yapay sinir ağının temel birimi olan yapay nöron veya düğüm, biyolojik nörona bulunan temel mekanizmayı taklit eden basitleştirilmiş bir modeldir. (16)

Yapay bir nöron , ağırlıklar (ω) olarak adlandırılan sinapsların gücüyle çarpılan $x_1, x_2, \dots, x_n$ giriş sinyallerini alır. Hücredeki aksiyon potansiyeli ateşlemesine paralel olarak, aktivasyon fonksiyonu çıktısı, girdisinin ağırlıklı toplamına dayalı olarak nöronların ateşlenmesini belirler. Girdilerin ve ağırlıkların çarpımının ($\sum x \omega$) toplamına doğrusal olmayan bir etkinleştirme işlevi f uygulanır. Şu anda en popüler doğrusal olmayan fonksiyon, doğrultulmuş doğrusal birim (ReLU) fonksiyonudur, z veya 0'ın maksimumunu seçen ve $f(z) = \max(0, z)$ olarak gösterilen bir matematiksel formüldür (şekil 4) (38).



Şekil 3: Biyolojik nöron modeli :

Biyolojik nöron tipik olarak üç bölümden oluştuğunu varsayar: dendritler, hücre gövdesi ve akson. Nöronlar, dendritler aracılığıyla giriş sinyallerini alır ve hücre gövdesinde bir “fonksiyon” gerçekleştirilir. Nihai toplam belirli bir eşiğin üzerindeyse, nöron, aksonu boyunca bir artış göndererek bir aksiyon potansiyeli üretir. Çoğu sinapsta sinyaller bir nöronun aksonundan diğerinin dendritine gönderilir(38).




Şekil 4: Yapay bir nöronun şematik gösterimi:

Veri girişi, genellikle yapay nöronda ağırlıklar olarak adlandırılan dendritler aracılığıyla alınır. Her girdi, karşılık gelen ağırlığı ile çarpılır ve tüm çarpımlar toplanır (nokta çarpımı). Sonuç üzerinde doğrusal olmayan bir matematiksel formül gerçekleştirilir. Günümüzde en yaygın olarak kullanılan formül, doğrultulmuş doğrusal birim (ReLU) işlevidir. Nöronun çıktısı, bir sonraki nöron katmanında girdi görevi görür. W=ağırlık, X=giriş, Y=çıkış.(38)

Sinir ağlarının inşası için nöronlar arasındaki bağlantı örüntüsü (mimari), bağlantı üzerindeki ağırlıkları belirleme yöntemi (eğitim veya öğrenme) ve aktivasyon fonksiyonu gibi parametreler gereklidir. (46)

Yapay sinir ağı, bazı nöronların çıktılarının diğer nöronlara girdi haline gelebildiği, döngüsel olmayan bir grafikte birbirine bağlanan nöron koleksiyonları olarak modellenir. Nöronlar, bitişik katmanlardaki nöronların tam ikili bağlantılara sahip olduğu, ancak bir katmandaki nöronların bağlı olmadığı çoklu gizli katmanlarda düzenlenir. İleri beslemeli sinir ağı sabit boyutlu bir girdiyi (örneğin bir görüntü) sabit boyutlu bir çıktıya (örneğin birkaç kategorinin her biri için bir olasılık) eşlemeyi öğrenir.(38)

Tek bir yapay nöron basit olmasına rağmen, binlerce nörondan oluşan çok katmanlı algılayıcılar olarak adlandırılan sinir ağı mimarileri, çok karmaşık doğrusal olmayan fonksiyonları temsil edebilir. Bu çok katmanlı algılayıcılar, tipik olarak, bir katman oluşturmak için birden fazla nöronun bir araya getirilmesi ve bu katmanların istiflenmesi, bir katmanın çıktısının bir sonraki katmanın girişine bağlanmasıyla oluşturulur. Derin öğrenmenin “derin” yönü, çok katmanlı algılayıcıların çok katmanlı mimarisini ifade eder (Şekil 5). Giriş katmanı olarak adlandırılan ilk katman, bireysel piksel yoğunlukları gibi girdi verilerini temsil ederken, çıktı katmanı, sınıflandırma sonucu gibi hedef değerleri üretir. Çok katmanlı algılayıcıların ara katmanlarına gizli katmanlar denir, çünkü bunlar doğrudan görünür istenen çıktıları üretmezler, bunun yerine çıkarım sürecinde yararlı olan girdi özelliklerinin ara temsillerini hesaplarlar. (16)



a.

b.

Şekil 5: a.Yapay sinir ağının şematik gösterimi (16) b. Biyolojik sinir ağı

a.Bu örnekte üç giriş düğümü, iki gizli katman (her biri dört düğümlü) ve iki çıkış düğümü vardır.

Aktivasyon Fonksiyonu

Aktivasyon işlevi ESA'nın önemli bileşenlerinden biri olup yapay nöronların bilgiyi işlediği ve aktardığı mekanizmadır.(49) Uygulamanın özelliğine göre sinir ağlarında kullanılabilecek çeşitli aktivasyon fonksiyonları vardır. (46) . Daha önce sigmoid veya hiperbolik tanjant işlevleri kullanılmış olsa da, en yaygın doğrusal olmayan aktivasyon işlevi, doğrultulmuş (rektifiye) doğrusal birim (ReLU) işlevidir.(50) ReLU katmanı, negatif giriş değerlerini sıfıra ayarlayan bir etkinleştirme işlevidir. Bu, hesaplamaları ve eğitimi basitleştirip hızlandırarak kaybolan gradyan sorununun önlenmesine yardımcı olur.(43)


2.4.4.Evrişimsel sinir ağı \ Convolutional neural network (CNN)

ESA, hayvan görsel korteksinin organizasyonundan ilham alan, grid modeline sahip görüntüler gibi verileri işlemek için kullanılan bir tür derin öğrenme modelidir.(51) ESA, diğer sinir ağlarından farklı olarak evrişimsel bir katman ile karakterize edilebilen yapay sinir ağlarından biridir.(52)

ESA, tipik olarak üç tür katmandan (veya yapı taşlarından) oluşan matematiksel bir yapıdır:

- Evrişim katmanı
- Havuzlama katmanı
- Tamamen bağlantılı katmanlar

Tipik bir mimari, birkaç evrişim katmanı ve bir havuzlama katmanından oluşan bir yığının tekrarından ve ardından bir veya daha fazla tam bağlantılı katmandan oluşur. Girdi verilerinin bu katmanlar aracılığıyla çıktıya dönüştürüldüğü adım, ileri yayılma olarak adlandırılır. (51)




Şekil 6: Evrişimli sinir ağı mimarisine ve eğitim sürecine genel bir bakış:

Bir ESA, birkaç yapı taşından oluşan bir yığından oluşur: evrişim katmanları, havuzlama katmanları (örneğin, maksimum havuzlama) ve tam bağlantılı katmanlar (TBK). Bir modelin belirli çekirdekler ve ağırlıklar altındaki performansı, bir eğitim veri kümesi üzerinde ileriye doğru yayılım yoluyla bir kayıp fonksiyonu ile hesaplanır ve öğrenilebilir parametreler, yani çekirdekler ve ağırlıklar, gradyan iniş optimizasyon algoritması ile geri yayılım yoluyla kayıp değerine göre güncellenir (51).

Evrişim ve havuzlama katmanları, öznel çıkarma işlemini gerçekleştirirken, tamamen bağlantılı bir katman çıkarılan öznelikleri sınıflandırma gibi nihai çıktıya eşler. Bir evrişim katmanı, özel bir doğrusal işlem türü olan evrişim gibi bir dizi matematiksel işlemden oluşan ESA'nda önemli bir rol oynar.

Dijital görüntülerde, piksel değerleri iki boyutlu (2B) bir ızgarada, yani bir dizi sayı içinde depolanır (Şekil 7) ve çekirdek adı verilen küçük bir parametre ızgarası, optimize edilebilir bir özellik çıkarıcı, her görüntü pozisyonuna uygulanır. Bu da ESA'ları görüntü işleme için oldukça verimli kılar, çünkü bir özellik görüntünün herhangi bir yerinde ortaya çıkabilir. Bir katman çıktısını bir sonraki katmanı besledikçe, çıkarılan özellikler hiyerarşik ve aşamalı olarak daha karmaşık hale gelebilir. (51)



Şekil 7: Dijital görüntülerin piksel değerinde görüntüsü

Parametre ve Hiperparametre

Bir parametre, model eğitimi sırasında otomatik olarak ayarlanan bir değişkeni ifade eder. Genel olarak ağırlık, parametre ile aynı terim olarak kullanılır. (50)

Hiperparametre, derin öğrenme modelini tasarlamak için kullanılan bir değişkendir ve modeli eğitmeden önce ayarlanması gereken bir değişkendir. (50) Bir "çekirdek", evrişim işlemlerinde uygulanan öğrenilebilir parametre kümelerini ifade eder. Bir "ağırlık" genellikle "parametre" ile birbirinin yerine kullanılır; bununla birlikte, bu terimi, evrişim katmanlarının dışındaki bir parametreye, yani, örneğin tam bağlantılı katmanlardaki bir çekirdek için de kullanılmıştır.(51)


Ardışık iki çekirdek konumu arasındaki mesafeye adım denir ve bu da evrişim işlemini tanımlar. Çekirdekler, evrişim katmanındaki eğitim süreci sırasında otomatik olarak öğrenilen parametrelerdir; Öte yandan, çekirdeklerin boyutu, çekirdek sayısı, dolgu ve adım, eğitim süreci başlamadan önce ayarlanması gereken hiperparametrelerdir (Tablo 1).(51)

Tablo 1: Bir evrişimli sinir ağındaki parametrelerin ve hiperparametrelerin listesi (51)

	Parametreler	Hiperparametreler
Evrişim katmanı	çekirdekler	Çekirdek boyutu, çekirdek sayısı, adım, dolgu, etkinleştirme işlevi
Havuzlama katmanı	Hiçbiri	Havuzlama yöntemi, filtre boyutu, adım, dolgu
Tam bağlantılı katman	Ağırlıklar	Ağırlık sayısı, aktivasyon fonksiyonu
Diğerleri		Model mimarisi, optimize edici, öğrenme hızı, kayıp işlevi, mini parti boyutu, dönemler, düzenlileştirme, ağırlık başlatma, veri kümesi bölme

Evrişim Katmanı


Bir evrişim katmanı, tipik olarak doğrusal ve doğrusal olmayan işlemlerin bir kombinasyonundan, yani evrişim işlemi ve etkinleştirme işlevinden oluşan özellik çıkarımını gerçekleştiren ESA mimarisinin temel bir bileşenidir.(51) Başka bir ifadeyle evrişim, üçüncü bir işlev üretmek için iki işlevin matematiksel birleşimini ifade eder. Bir ESA'da kullanıldığında, evrişim, bir özellik haritası üretmek için giriş verilerine bir çekirdeğin (veya filtre = küçük matris) uygulanması anlamına gelir. Evrişim işlemi, kenar algılama, keskinleştirme, bulanıklaştırma vb. (Şekil 8) gibi görüntü işlemede yaygın olarak kullanılan bir işlemdir.(50)



Şekil 8: Görüntüleri işlemek için çekirdekleri kullanma:

Çekirdekler, evrişimli sinir ağlarının özüdür. Bunlar, görüntüleri keskinleştirme ve bulanıklaştırma gibi belirli görevler için özelleştirilmiş önceden tanımlanmış matrislerdir. Evrişimsel sinir ağlarında fikir, birden fazla çekirdeği öğrenmek ve bunları giriş görüntülerinden bilgilendirici özellikler çıkarmak için kullanmaktır. (53)

Evrişim, öznitelik çıkarma için kullanılan, tensör adı verilen bir sayı dizisi olan girdi boyunca çekirdek adı verilen küçük bir sayı dizisinin uygulandığı özel bir doğrusal işlem türüdür. Çekirdeğin her bir elemanı ile giriş tensörü arasındaki eleman bazında bir ürün, tensörün her konumunda hesaplanır ve özellik haritası olarak adlandırılan çıkış tensörünün karşılık gelen konumunda çıkış değerini elde etmek için toplanır (Şek. 9a-c). Bu prosedür, girdi tensörlerinin farklı özelliklerini temsil eden, rastgele sayıda özellik haritası oluşturmak için birden çok çekirdek uygulanarak tekrarlanır; farklı çekirdekler bu nedenle farklı öznitelik çıkarıcılar olarak kabul edilebilir (Şekil 9d). Evrişim işlemini tanımlayan iki anahtar hiperparametre, boyut ve çekirdek sayısıdır. İlki tipik olarak 3×3 'tür, ancak bazen 5×5 veya 7×7 'dir. İkincisi keyfidir ve çıktı özelliği haritalarının derinliğini belirler.(51)



Şekil 9: Tensör ve özellik haritaları:


a – c. Çekirdek boyutu 3×3 olan, dolgusuz ve 1 adımlı bir evrişim işlemi örneği. tensör her konumda hesaplanır ve öznitelik haritası olarak adlandırılan çıkış tensörünün karşılık gelen konumundaki çıkış değerini elde etmek için toplanır.

d. Evrişim katmanlarındaki çekirdeklerin bir giriş tensöründen özellikleri nasıl çıkardığına ilişkin örnekler gösterilmektedir. Birden çok çekirdek, yatay kenar algılayıcı (üst), dikey kenar algılayıcı (orta) ve anahat algılayıcı (47) gibi farklı özellik çıkarıcılar olarak çalışır. Soldaki görüntü bir girdi, ortadaki çekirdek ve sağdakiler çıktı özellik haritaları.(51)

Havuzlama Katmanı


Havuzlama katmanının ana görevi, özellik haritalarının alt örneklenmesidir. Evrişim işlemleri takip edilerek daha küçük özellik haritaları oluşturmak için büyük boyutlu özellik haritalarının küçültülmesi sağlanır. Eşzamanlı olarak, havuzlama aşamasının her adımında baskın bilgilerin (veya özelliklerin) çoğunluğunu korur. Evrişim işlemine benzer şekilde, hem adım hem de çekirdek, havuzlama işlemi yürütülmeden önce başlangıçta boyut atanır. Çeşitli havuzlama katmanlarında kullanım için farklı havuzlama yöntemleri mevcuttur. (54) Ortalama havuzlama ve

maksimum havuzlama yöntemleri en yaygın iki havuzlama yöntemidir. Ortalama havuzlama, hedef alandaki ortalama değeri hesaplarken, maksimum havuzlama, hedef alandaki maksimum değeri kullanır (Şekil 10).(50)



Şekil 10: Havuzlama işlemi

Maksimum havuzlama (51) a. 2×2 filtre boyutu, dolgu yok ve giriş tensörlerinden 2×2 yamaları çıkararak, her yamada maksimum değeri veren ve diğer tüm değerleri atan 2 adımlı bir maksimum havuzlama işlemi örneği, bir giriş tensörünün düzlem içi boyutunun 2 kat aşağı örneklenmesiyle sonuçlanır. b Şekil 9'daki aynı görüntüler üzerinde maksimum havuzlama işlemi örnekleri. Üst sıradaki görüntülerin 26×26 'dan 13×13 'e 2 faktörlüyle alt örneklenmesi



Şekil 11: Tek boyutlu bir girdi için basit bir evrişim ağının çizimi.

Burada gösterilen iki benzersiz katman türü, evrişim katmanı ve havuz katmanıdır. Evrişim katmanının özel özelliği, aynı filtrelerin farklı konumlarda uygulanmasını içermesidir. Bu ağdaki evrişim katmanı, girdiyi iki özellik haritasına dönüştüren iki filtre içerir. Yukarıda gösterilen havuzlama katmanı, önceki katmandaki nöronların maksimum aktivasyonunu basitçe hesaplayan bir maksimum havuzlama katmanıdır. Aynı fikirler iki boyutlu ve üç boyutlu girdilere kolayca genelleştirilebilir.(55)

Yoğun veya Tam Bağlantılı Katman

Genellikle bu katman, her bir ESA mimarisinin sonunda bulunur. Bu katmanın içinde, her nöron, tam bağlantılı katman yaklaşımı olarak adlandırılan bir önceki katmanın tüm nöronlarına bağlanır. ESA sınıflandırıcı olarak kullanılır. Bir tür ileri beslemeli YSA olduğu için geleneksel çok katmanlı algılayıcı sinir ağının temel yöntemini izler. Tam bağlantılı katmanının girişi, son havuzlama veya evrişim katmanından gelir. Bu girdi, düzleştirmeden sonra özellik haritalarından oluşturulan bir vektör biçimindedir. Tam bağlantılı katmanının çıktısı, son ESA çıktısını temsil eder.(54)

Özellik Haritaları


Özellik haritası, evrişim ve aktivasyon fonksiyonu işlemlerinin sonuç çıktısıdır. Ortaya çıkan özellik haritalarının boyutları, kullanıcı tanımlı üç hiperparametre (derinlik, adım ve sıfır dolgu) tarafından kontrol edilir ve bu hiperparametreler, herhangi bir evrişim işlemi gerçekleştirmeden önce belirtilir. Buradaki derinlik, evrişim çekirdeklerinin sayısına karşılık gelir (derinlik bazen

ağdaki toplam katman sayısı için de kullanılır). Adım, çekirdeğin her adımda girdi görüntüsü üzerinde kaydırıldığı piksel sayısıdır ve bireysel çıktı pikselleri arasındaki örtüşmeyi belirler. Sıfır doldurma, evrişim işlemleri tarafından üretilen çıktı görüntü boyutundaki küçülmeyi önlemek için kullanılır (giriş görüntüsünü sınırlarda sıfırlarla doldurma).(40)

2.5.Derin Öğrenme Modeli Oluşturma

Klinik soru: Radyologların deneyimlerine dayanır ve pratik ihtiyaçlardan üretilir. Klinik soru seçilirken, bunun derin öğrenme çözümüne uygulanabilir olması gerekmektedir.

Bilgisayarla görme görevleri: Radyoloji alanına özellikle uygulanabilir olan yaygın bilgisayarla görme görevleri, sınıflandırma, saptama ve segmentasyonu içerir (Şekil 12).(16) Sınıflandırma, bir görüntüyü belirli bir sınıfa ayırma veya etiketleme işlemidir. Örneğin, göğüs radyografilerini normal olarak sınıflandırmak veya tüberkülozun özelliklerini göstermek vs. Tespit etme, lezyonların, organların veya diğer ilgilenilen nesnelerin konumunun belirlenmesine olanak tanır. Örneğin, hepatik kitlelerin x, y koordinatlarının lokalize edilmesi. Segmentasyon, bir organın veya patolojik özelliğin piksel bazında kesin sınırlarını tanımlamak için uygulanır. Görüntü optimizasyonu, görüntü çözünürlüğünün geliştirilmesi gibi görevlerin yanı sıra sentetik görüntü girdisinin formülasyonunu içerir. (56)



Şekil 12: Sınıflandırma, tespit etme ve segmentasyon


Veri toplama: Derin ağların eğitimi, büyük veri kümelerine dayanır. Radyolojide derin öğrenmeyi kullanan çalışmalar, ya özel bir veri setine ya da halka açık bir veri setine dayanmaktadır. Kamuya açık bir veri tabanının kullanılması, akademik topluluktaki araştırmacılar arasında işbirliği fırsatı sunmaktadır. (38)

Mevcut veriler üç alt gruba ayırmak standart bir uygulamadır: bir eğitim seti, bir doğrulama seti ve bir test seti. Eğitim seti, sinir ağının parametrelerini eğitmek ve optimize etmek için kullanılır. Bu eğitim, eğitim görüntülerinin tekrar tekrar çalıştırılmasını ve ağ bağlantılarının ağırlıklarını ayarlamak için hataların kullanılmasını içerir. Doğrulama seti, eğitim sürecinde modelin performansını izlemek için kullanılır; bu veri seti, model seçimi yapmak için de kullanılmalıdır. Doğrulama verileri, test setindeki model performansı hakkında bilgi verir. Modelin tüm parametreleri sabitlendikten sonra test setinde performansını ölçülür. Test veri seti, yalnızca bir çalışmanın en sonunda, nihai model performansını raporlamak için kullanılır.(16, 50)

Verilerin ön işlenmesi: Tıbbi görüntü analizinde önemli bir nokta veri hazırlamadır. Manuel etiketleme ve açıklama ekleme zaman alıcıdır. Veri hazırlama süreci için çeşitli seçenekler kullanılabilir ve artan karmaşıklık sırasına göre aşağıdakileri içerir:

- Görüntü etiketleme (örneğin, "tüberküloz içeren radyografi")
- Kare veya dairesel ROI'ler gibi ilgi alanı (9) işaretleri
- Piksel bazında segmentasyon


Farklı bilgisayarla görme görevleri, farklı açıklamalar gerektirir. Örneğin, organ veya patolojik özellik segmentasyonu zahmetli piksel bazında segmentasyon gerektirirken, göğüs radyografilerini tüberküloz veya normal olarak sınıflandırmak yalnızca görüntü etiketlemeyi gerektirir ve bu nedenle potansiyel olarak daha büyük bir kohortun kullanılmasına izin verebilir.



Şekil 13: Dental panoramik radyografinin karmaşık etiketleme örneği.

Yapıların üst üste geldiği iki boyutlu radyografilerde, üç boyutlu anatomik yapıları net bir şekilde ayırt etmek ve ana hatlarını çizmek genellikle zordur. Yeşil: dişler, pembe: implant, gökyüzü: protez, kahverengi: endodontik dolgu, kırmızı: diş çürükleri.(57)

Veri büyütme, eğitim veri setinin sınırlı olması durumunun üstesinden gelmek için kullanılan bir tekniktir. Eğitim görüntülerinin sayısını görüntü döndürme ve görüntü çevirme gibi teknikleri içeren çoklu dönüşümlerin çeşitli kombinasyonları kullanılarak yapay olarak artırma işlemidir.(38)



Şekil 14: Periapikal görüntülerde veri büyütme örneği.

a. orijinal görüntü, b, c. çevirme, d. rotasyon, e. yakınlaştırma. f. translasyon, g.kontrast ayarı, h. elastik deformasyon. Periapikal lezyon tespit modelinin performansını düşürebilecek olan d, e ve f'de apikal lezyonun çıkarılmıştır.(57)

Donanım ve yazılım: Matris işlemlerinin son derece hızlı işlenmesine izin veren yeni donanım teknolojisinin geliştirilmesiyle derin öğrenme mümkün olmuştur. (38) Grafik işlem birimleri (GPU), geleneksel merkezi işlem birimlerinin kullanılmasına kıyasla performanstaki hızlanma tipik olarak 10 ila 40 kat arasındadır ve on milyonlarca parametreden oluşan karmaşık modellerin haftalar veya aylar yerine birkaç gün içinde eğitilmesine olanak tanır.(16)

Donanım geliştirmeye paralel olarak, derin sinir ağlarını oluşturmak ve eğitmek için karmaşık yazılım araçları da oluşturulmuştur. Bu açık kaynaklı çerçeveler, sinir ağlarının programlanmasını kolaylaştırmıştır.(38) Derin öğrenme çerçevesi, üst düzey bir programlama arabirimi aracılığıyla derin sinir ağlarının tasarımını, eğitimini ve doğrulanmasını kolaylaştıran bir program koleksiyonudur. Çerçeveler genellikle belirli bir programlama dilinde yazılır. Programlama dili, bir bilgisayara belirli görevleri yerine getirme talimatı vermek için bir kelime bilgisi ve bir dizi gramer kuralı içerir. Popüler programlama dilleri arasında Python, Java, C, C++, JavaScript, R ve MATLAB bulunur.(50)

Sık kullanılan derin öğrenme çerçevelerinin bazıları şunlardır:

- Caffe: Berkeley Vision and Learning Center tarafından geliştirilmiş ve C, C++, Python ve MATLAB gibi arayüzleri destekler.
- Tensorflow: Google tarafından oluşturulmuş ve Python, C++ ve R gibi dilleri destekler.
- Torch: Ronan Collobert, Koray Kavukcuoğlu ve Clement Farabet tarafından geliştirilen ve sürdürülen; Facebook, Twitter ve Google tarafından kullanılan Lua tabanlı bir derin öğrenme çerçevesi olan bir pakettir.
- Keras: François Chollet tarafından geliştirilmiş ve TensorFlow veya Theano üzerinde çalışabildiği için üçüncü taraf paketi olarak belirlenmiştir.(38)

Bu kütüphaneler ayrıca araştırmacıların GPU'lar gibi mevcut bilgi işlem kaynaklarından verimli bir şekilde faydalanmalarını sağlamaktadır. Bu yazılım araçlarının çoğu ücretsiz ve açık kaynaklıdır. Herkes kod tabanlarını inceleyebilir ve bunlara katkıda bulunabilir. Akademik ve endüstriyel araştırma toplulukları, kodları, modelleri, verileri ve yayınları özgürce paylaşarak artan bir hızla makine öğrenimi sorunları üzerinde işbirliği yapabilmektedir.(16)

Sinir ağı mimarisi: ESA mimarisi sinir ağı katmanları yapısını tanımlar. ESA mimarilerinin çeşitli biçimleri olmasına rağmen, bunlar genellikle tekrarlanan bir dizi modeline dayanır. Farklı görevler için uygun mimariyi seçmek genel performansı iyileştirebilir. Araştırmacılar daha önce geliştirilmiş ESA modellerini kullanmayı seçebilir veya kendi mimarilerini oluşturabilirler. AlexNet, VGG, U-Net, ResNet sık kullanılan bazı sinir ağı mimarileridir.(38, 58)

Doğrulama: Makine öğreniminde ve özellikle derin öğrenmede, sistemin bağımsız bir veri kümesine genelleme yeteneğini değerlendirebilen bir tahmine dayalı model formüle etmek için bir doğrulama tekniği benimsenir. Holdout yöntemini ve k-katlama çapraz doğrulama yöntemini iki yaygın doğrulama yöntemidir.(38)


Herhangi bir makine öğrenimi modeli için, eğitim ve doğrulama optimizasyonu yapıldıktan sonra, eğitim ve doğrulama sürecinde model tarafından görülmeyen bağımsız bir test seti ile eğitilen modelin performansının doğrulanması çok önemlidir. Bir modelin popülasyona genellenebilir olarak kabul edilebilmesi için bağımsız testlerin kullanılması önemli bir adımdır.(38)

İleri Yayılım ve Geri Yayılım

İleri yayılım, model aracılığıyla girdi verilerinden tahmin edilen değeri hesaplamak için kullanılan bir işlemdir. Geri yayılım, maliyeti en aza indirmek için modelin her parametresini ayarlamak için kullanılan bir süreçtir (Şekil 15).(50)

2.5.1.Model eğitimi

İleri ve geri yayılım yoluyla parametre (çekirdek + ağırlık) optimizasyonu sürecidir. İleri yayılım, model aracılığıyla girdi verilerinden tahmin edilen değeri hesaplamak için kullanılan bir süreçtir. Geri yayılım, modelin her parametresini maliyeti en aza indirecek şekilde ayarlamak için kullanılan bir süreçtir. Modele eğitim örnekleri serisi sunulurken, maliyet fonksiyonu kullanılarak tahmin edilen değer ile gerçek (hedef sınıf veya regresyon değeri) arasındaki fark ölçülür. Gradyan iniş yöntemini kullanarak, tüm parametreler (tamamen bağlı katmandaki ağırlıklar ve evrişimli katmandaki çekirdekler) maliyeti en aza indirmek için biraz ayarlanır.(50)




Şekil 15: Sinir ağı modeli

Kayıp Fonksiyonu

Maliyet işlevi olarak da adlandırılan bir kayıp işlevi, ileriye doğru yayılım yoluyla ağıın çıktı tahminleri ile verilen temel doğruluk etiketleri arasındaki uyumluluğu ölçer. Bir tür kayıp fonksiyonu hiperparametrelerden biridir ve verilen görevlere göre belirlenmesi gerekir.(51)

Epoch, Batch ve Iteration

Genel olarak, tüm büyük veri kümesi bir kerede sinir ağına geçemez. Bu nedenle, veri kümesinin geçilebilmesi için bölünmesi gerekir. Bir epoch, model boyunca tüm eğitim verilerinin bir ileri ve bir geri geçişini ifade eder. Genellikle, bir modeli eğitmek için birkaç epoch tekrarlanır. Batch boyutu, bir ileri/geri geçişte sabit sayıda eğitim verisidir. Batch boyutu, veri kümesinin toplam boyutu, modeldeki ağırlık sayısı ve GPU'nun kullanılabilir belleği dikkate alınarak belirlenir. Batch boyutu genellikle 1 ile 128 arasında değişir. Boyut ne kadar yüksek olursa, o kadar fazla bellek alanına ihtiyaç duyulur. Yineleme sayısı, toplam geçiş sayısıdır (Şekil 16).(50)




Şekil 16: Epoch, batch ve iterasyon

Aşırı Uyum ve Yetersiz Uyum


Bir modelin parametreleri, temeldeki dağılımı yakalamadan girdi eğitim verilerine çok yakın uyduğunda ve böylece modelin diğer veri kümelerine genelleme yeteneğini azalttığından aşırı uyum oluşur. (40) Bu makine öğrenimindeki ana zorluklardan biridir, çünkü fazla uyum gösteren bir model, daha önce hiç görülmemiş verilere genelleştirilemez. Model, doğrulama setine kıyasla eğitim setinde iyi performans gösteriyorsa, model büyük olasılıkla eğitim verilerine fazla uyuyordur demektir. Model hem eğitim hem de doğrulama setlerinde düşük performans gösteriyorsa, model verilere yetersiz uyum sağlamıştır. Bir ağ ne kadar uzun süre eğitilirse, eğitim setinde o kadar iyi performans gösterir, bir noktada ağ eğitim verilerine çok iyi uyum sağlar ve genelleme yeteneğini kaybeder. Aşırı uyumu en aza indirmek için önerilen birkaç yöntem vardır: (51)

- Daha fazla eğitim verisi
- Veri büyütme
- Düzenleştirme (ağırlık azalması, bırakma)
- Batch normalleştirme
- Mimari karmaşıklığını azaltın (51)

Yetersiz uyum ise girdi verilerinin temel dağılımlarını yakalayamayan aşırı basit bir modelin sonucudur. Hem aşırı uyum hem de yetersiz uyum, görünmeyen veriler üzerinde zayıf tahminlere yol açar.(40)



Şekil 17: Aşırı uyumu tanımak için rutin bir kontrol, eğitim yinelemesi sırasında eğitim ve doğrulama setlerindeki kayıp (51)



Şekil 18: Verilerdeki uyum diyagramı

Uyum, verilerdeki varyansı açıklamak için çok basit olduğunda ve kalıbı yakalamadığında yetersiz uyum oluşur. Uygun bir uyum, kalıbı yakalar ancak verilere sığdırmak için çok esnek veya esnek değildir. Aşırı uyum, uyum gerçek olamayacak kadar iyi olduğunda ve verilerdeki gürültüye uyma olasılığı olduğunda meydana gelir. Eksenler, özellik vektörünün ilk iki ögesini yansıtmak için genel olarak özellik 1 ve özellik 2 olarak etiketlenir.(40)

K-Katlama apraz doęrulama

Modelin nihai performansı, bir test veri setindeki performansı ile belirlenir. Modelin ne kadar iyi performans gstereceęini test veri setinde test edilene kadar tahmin etmenin bir yolu yoktur. Ancak apraz doęrulama, fazla uyumu kontrol etmek ve modellerin verilen test veri kmesine nasıl genelleneceęi hakkında bir fikir edinmek iin eęitim ařamasında modellerin performansını tahmin etmek iin kullanılan bir tekniktir. K-katlı apraz doęrulamada, eęitim veri kmesi k eřit alt kmeye blnr. Bir veri alt kmesi doęrulama kmesi olarak tutulur ve dięerleri (k-1 alt kmeleri) bir apraz doęrulama eęitim kmesi olarak tutulur. Model daha sonra apraz doęrulama eęitim seti kullanılarak eęitilir ve modelin performansı doęrulama seti kullanılarak deęerlendirilir. Doęrulama seti deęiřtirilirken bu iřlem toplam k kez tekrarlanır.(50)

2.6.Tıbbi Grntlemede Derin ęrenme

Radyoloji, hastalıkları teřhis etmek ve tedavi etmek iin grntleme teknolojisini ve radyasyonu kullanan bir tıp bilimi dalıdır. Fizik, elektronik mhendislięi ve bilgisayar bilimlerindeki geliřmelerden byk lde yararlanmıřtır. Farklı algılama ve grntleme mantıęına dayalı olarak, tanısai radyoloji alanında son on yılda eřitli modaliteler geliřtirilmiřtir.(59)

Gnlk radyoloji pratięinde, tıbbi grntler radyologlar tarafından okunur ve yorumlanır. Genellikle radyologların bu grntleri kısa srede kapsamlı bir řekilde analiz etmesi ve deęerlendirmesi gerekir. Ancak modern tıp teknolojilerindeki geliřmelerle birlikte grntleme verilerinin miktarı hızla artması radyologların okuma ve yorumlama sresini de arttırmaktadır.(59) Yapay zeka tıbbi grntlerin analizini ve teřhisini otomatikleřtirmenin etkili bir yolunu sunup radyologların zerindeki yk potansiyel olarak azaltabilir.

Derin ęrenme teknikleri (ve genel olarak yapay zeka algoritmaları), radyoloji alanında kullanmak iin muazzam bir potansiyele sahiptir. Tıbbın dięer birok alanından farklı olarak, radyologlar tarafından retilen ıktıların (yani grntleme raporları) yanı sıra grntlemede kullanılan birincil verilerin

neredeyse tamamı dijitaldir ve bu verileri yapay zeka algoritmaları tarafından analiz edilebilir.(37)

ESA, tıbbi görüntü analizinde en yaygın kullanılan derin öğrenme modelidir.(16) Bu durumun en yaygın sebepleri aşağıdaki gibidir:

Birincisi, eğitilmesi gereken parametre sayısı açısından ESA daha verimlidir. Diğer sinir ağlarında, her katman bir sonraki katmandaki tüm nöronlara tam olarak bağlıdır. İki nöronun birbirine bağlı olması, iki nöron arasında eğitilecek bir parametre olduğunu gösterdiğinden dolayı normal sinir ağlarında eğitilecek parametre sayısı çok fazladır. Öte yandan, ESA'nın bir katmanındaki nöronlar, bir sonraki katmandaki tüm nöronlara değil, ESA'nın evrişimli katmanlarında aynı çekirdek aracılığıyla bir sonraki katmandaki nöronların sadece küçük bir bölgesine bağlanır. Başka bir deyişle, evrişim katmanlarında eğitilecek olan tek parametre, evrişim katmanlarındaki çekirdek olduğu için ESA'da parametre sayısı azaltılabilir. Örneğin, 256×256 giriş katmanı ve 256×256 çıkış katmanı olduğunda, tam bağlı sinir ağlarında toplam 42.9496.7296 ($[256 \times 256] \times [256 \times 256]$) parametre vardır. Öte yandan, ESA'da 3×3 çekirdek kullanılıyorsa, eğitilmesi gereken sadece 9 parametre vardır. (Burada kanal sayısının sadece 1 olduğunu varsayıyoruz, yani gri tonlamalı görüntü.). (50)


İkinci olarak, ilgili özellikler bir görüntüden öğrenilebilir. Bulanıklaştırma veya keskinleştirme gibi geleneksel görüntü işleme görevlerinde, işlevin çekirdekleri önceden tanımlanmış belirli filtreler olup ESA'da çekirdekler önceden tanımlanmamıştır. Ancak ham verilerden belirli bir görevi gerçekleştirmek için eğitilmiştir. Örneğin, akıllı telefon uygulamaları, orijinal bir fotoğrafı filtreler kullanarak bulanıklaştırmak veya keskinleştirmek için kullanılabilir. Bununla birlikte, ESA'da eğitim sonucunda belirlenen çekirdekler giriş görüntülerine uygulanmakta, ardından ESA'de farklı seviyelerde çeşitli öznetelik haritaları üretilmektedir.(50)

ESA, şimdiye kadar özellikle örüntü ve görüntü tanıma uygulamalarında görüntü analizinde diğer algoritmalarından daha iyi performans göstermiştir.(50)

Derin öğrenme modellerinin tıbbi görüntülere uygulandığı dört temel bilgisayarla görme görevi: sınıflandırma, nesne algılama, semantik segmentasyon ve örnek segmentasyondur.(60)

2.6.1.Görüntü sınıflandırma


Görüntü sınıflandırma, tüm görüntünün sınıfını veya etiketini tahmin etme görevidir ve ikili (iki sınıf) veya çok sınıflı (ikiden fazla) olabilir. Örneğin bir anormalliğin varlığını veya yokluğunu belirlemek, anormalliklerin iyi huylu veya kötü huylu olarak sınıflandırılması; kanserli lezyonların histopatolojik ve genomik özelliklerine göre sınıflandırılması vs.



Şekil 19: Görüntü sınıflandırma

2.6.2.Nesne algılama

Nesne tespiti, bir BT görüntüsünde karaciğer metastazlarının tespiti ve lokalizasyonu gibi, bir görüntü veya hacim üzerinde ilgili belirli bir varlığın bireysel örneklerinin tanımlanması ve lokalizasyonu anlamına gelir. Bir nesne algılama algoritması, tipik olarak, nesneyi çevreleyen dikdörtgen bir kutu (sınırlayıcı kutu) ile algılanan nesnelerin konumunu ve uzamsal kapsamını belirtir.



Şekil 20: Nesne algılama

2.6.3.Semantik segmentasyon


Semantik segmentasyon, bir görüntüdeki her pikseli belirli bir sınıfa atar. Örneğin, karaciğerdeki her piksel parankime, tümöre veya kan damarına atanabilir. Bu görevin çıktısı, her sınıf için bir pikselin o sınıfa aitse "açık" olduğu bir ikili (siyah beyaz) görüntü maskesi olacaktır.



Şekil 21: Semantik segmentasyon

2.6.4.Örnek segmentasyon

Örnek segmentasyonu, bir göğüs radyografisinde ayrı ayrı ayırt edilen akciğer nodülleri gibi aynı sınıftaki birden fazla nesnenin piksel düzeyinde tespiti ve tanımlanmasıdır. Semantik segmentasyonun aksine, örnek segmentasyon, aynı sınıfın farklı nesnelerini (örneklerini) ayırmak için bir nesne algılama adımı gerektirir.



Şekil 22: Örnek segmentasyon



Şekil 23: Bitewing radyografide sınıflandırma, tespit etme, segmentasyon

a. Görüntüdeki dikdörtgen kutuda diş çürüğü var (sınıflandırma). b. Kare kutuda diş çürükleri tespit edilir (tespit). c. Görüntü üzerinde bir diş çürüğü bölümlere ayrılmıştır (segmentasyon).(57)

2.7.Diş Hekimliğinde Yapay Zeka

Tıbbi görüntüleme hızla artan yapay zeka çalışmaları ile birlikte dental radyoloji alanında da çalışmalar artmaktadır. ESA yapılarını kullanan derin öğrenme sistemleri ile iki boyutlu görüntülerin yanı sıra üç boyutlu KIBT (Konik ışınli bilgisayarlı tomografi) görüntülerini de kullanan çalışmalar yapılmaktadır.

Ağız, diş ve çene radyolojisi alanında, diş çürüğü(2, 10), periodontal hastalık(61), dikey kök kırığı(62), periapikal patoloji(11) ve çene kemiği kistleri ve tümörlerinin tespiti için derin öğrenmenin kullanımını(63) gibi birçok çalışma yapılmıştır. Chang ve diğerleri derin öğrenmede hibrit yöntemi kullanarak ve derin öğrenme mimarisi ile geleneksel bilgisayar destekli tanı (CAD) yaklaşımını birleştirdi ve dental panoramik radyografilerde periodontitis evrelemesi için otomatik bir yöntem geliştirdiler.(12)

Ayrıca yapay zeka kullanılarak görüntü analizi, diş segmentasyonu veya lokalizasyonu, kemik kalitesi (osteoporoz) değerlendirmesi, el-bilek radyografileri kullanılarak kemik yaşı değerlendirmesi ve sefalometrik landmark lokalizasyonu gibi çeşitli çalışmalarda yapılmıştır.(64)

Tıbbi görüntü kalitesini iyileştirmeye yönelik yapay zeka çalışmaları yürütülmektedir ve bu çalışmaların dental görüntüleme alanında da uygulanması gerekmektedir. Çoğu tıbbi görüntü, görüntü alma ve aktarma sürecinde gürültüye

eğilimlidir. Özellikle, ESA ve GAN mimarileri, gürültü azaltma ve görüntü engellenmenin önüne geçmek için uygulanmıştır.(65)

Hasta veya organ hareketlerinin neden olduğu hareket artefaktları, tanı doğruluğunu etkileyebilmektedir. Bulanık görüntülerin kalitesini artırmak için ESA'ları kullanan çalışmalar yürütülmektedir.(66)

Görüntü gürültü giderme teknolojisinin önemli bir uygulaması, düşük dozlu BT (Bilgisayarlı Tomografi) için görüntü kalitesinin iyileştirilmesidir. Düşük doz BT kullanımı kaçınılmaz olarak gürültüyü arttırmaktadır. Son araştırmalarda düşük doz BT'ye derin öğrenme uygulandığında derin öğrenmeyi makine öğrenimi teknolojisiyle birleştiren gürültü giderme çalışmaları aktif olarak yürütülmektedir.(67)

Görüntülerdeki metal artefaktlarını azaltmak için de yapay zeka kullanılmıştır. Diş kuronları ve implantlar gibi yüksek atenüasyona sahip malzemeler şiddetli saçılmaya ve ışın sertleşmesine nedeniyle tanısız doğruluk azalmaktadır.(57)

2.8.Derin Öğrenmenin Sınırlamaları

Derin öğrenme, tüm veri analizi sorunları için en uygun makine öğrenimi tekniği değildir. Verilerin iyi yapılandırıldığı veya optimal özelliklerin iyi tanımlandığı problemler için, lojistik regresyon, destek vektör makineleri gibi diğer daha basit makine öğrenimi yöntemleri daha kolay uygulanır ve daha etkilidir. (68)

Bilgisayarlı görsel görevlerde baskın bir yöntem olan ESA'lar için bile önemli sınırlamalar vardır. En belirgin sınırlama, derin öğrenmenin aşırı derecede veriye aç ihtiyaç duymasıdır. Büyük bir ağ için sıfırdan öğrenme ağırlıkları, doğru sınıflandırma elde etmek için çok sayıda etiketli örnek gerektirir. (16) Tıbbi görüntüleri etiketleme radyologların alan bilgisi gerektirir ve yeterli tıbbi verilere açıklama eklemek çok zaman alıcı bir süreçtir. Bu sebeple sınırlı etiketli veri sorununu hafifletmek için mevcut etiketli verilerin ve geniş etiketsiz verilerin bir arada kullanılması için yarı denetimli öğrenme uygulanabilir.(46)

Klinik görüntüler için mahremiyet endişelerinin yanı sıra birden fazla uzmandan veya patoloji teşhisinden doğru yer-gerçek etiketler elde etmenin maliyeti ve zorlukları da diğer kısıtlamalardandır.(16)

Klinik uygulamadaki prosedürlerin neden olduğu verilerin kendisindeki (çözünürlük, kontrast, sinyal-gürültü) tutarsızlıktır ve tıbbi görüntülerin standartlaştırılmamış olarak elde edilmesi, tıbbi görüntü analizinde başka bir sınırlamalardır.(46)

Derin öğrenme modelleri, devasa karmaşıklıkları ve çok sayıda parametre içermeleri nedeniyle yoğun bellek ve hesaplama gereksinimlerine sahiptir.(51)

Derin öğrenme modelleri, karmaşık bir şekilde ilişkilendirilen çok sayıda parametre nedeniyle eğitim aşamasında aşırı uyum göstermesi yüksek olasılıklara sahiptir. Bu gibi durumlar, modelin test edilen veriler üzerinde iyi bir performans elde etme yeteneğini azaltmaktadır.(69)

Derin öğrenme tabanlı sistemin ticari gelişimi için klinik görüntüleme verilerinin kullanımına ilişkin yasal ve etik sorunlar olabilmektedir.(52)

2.9.Diş Çürüğü

Diş çürüğü, diş yüzeyini kaplayan biyofilmdeki metabolik olayların neden olduğu lokalize kimyasal çözünmenin sonuçları olarak tanımlanır. Bu yıkım mine, dentin ve sementi etkileyebilir.(70) Diş sert dokularının yıkımı bakterilerin karbonhidratları fermente etmesi sonucu oluşan laktik asitten kaynaklandığı için çürük enfeksiyöz bir hastalıktır.(71) Bu asit, lokal pH değerlerinin kritik bir değerin altına düşmesine neden olarak diş dokularının demineralizasyonuna neden olur. Diş çürüğünün ilerlemesi, durması veya tersine dönmesi demineralizasyon ve remineralizasyon arasındaki dengeye bağlıdır. Demineralizasyon ve remineralizasyon süreci çoğu insanda gün içinde sıklıkla gerçekleşir.(72)

Diş çürükleri, karmaşık biyofilm içindeki mikrobiyal değişikliklerle başlayan, tükürük akışı ve bileşiminden, florür maruziyetinden, diyet şekerlerinin tüketiminden ve koruyucu davranışlardan (diş fırçalama) etkilenen çok faktörlü bir hastalıktır.

Hastalık başlangıçta geri dönüşümlüdür ve herhangi bir aşamada, yeterli biyofilmin çıkarılması koşuluyla, bir miktar dentin veya mine yok edildiğinde (kavitasyon) bile durdurulabilir. (73)

Diş çürükleri daha uzun süre tedavi edilmezse, çürük lezyonunun yapısına bağlı olarak çeşitli komplikasyonlara yol açabilir. Diş çürüğü, pulpa inflamasyonuna yol açarak apikal periodontitis, periapikal apse, periapikal granülom, periapikal kist, selülit, osteomyelit gibi patolojilere sebep olabilir. (74)

Herhangi bir hastalığın tedavisine karar vermek için hastalığın ilerlemesi ve evrelemesi hakkında bilgi önemli bir rol oynar. Diş çürüğünün ilerlemesinde belirli bir aşamaya müdahale edip etmemeye karar verebilmek için diş hekiminin hastalığın seyrini bilmesi gerekir. (74)

Çürük tespiti için geleneksel muayene (görsel, sondlama ve radyografi), çürük tespit boyaları, geliştirilmiş görsel teknikler (fiber optik ve dijital fiber optik transilüminasyon yöntemleri (FOTI-DIFOTI), floresan teknikler, kamera ve floresan tekniklerin kombinasyonu, optik koherens tomografi, elektriksel iletkenlik ölçümleri, Ultrasonografi gibi yöntemler kullanılmaktadır. Görsel ve dokusal muayene en yaygın olarak kullanılan çürük teşhis yöntemidir.(75) Radyografik muayene çürük lezyonlarının değerlendirilmesinde tamamlayıcı bir rol oynar. Özellikle klinik olarak ulaşılması zor olan proksimal çürüklerin tespitinde radyolojik muayene gereklidir. (71)

Radyografi, klinik olarak erişilemeyen yüzeylerdeki çürük lezyonlarının tanısında yaygın olarak önerilen bir yardımcı yöntemdir.(76) Demineralizasyon, radyografik görüntüde radyolüsent bir bölge olarak görülür, çünkü dişin demineralize bölgesi, normal diş sert dokuları kadar çok foton absorbe etmez.(71)

Proksimal çürük lezyonları, yalnızca %30 ile %40 arasında demineralizasyon olduğunda radyografik olarak saptanabilir. Böylece lezyon normal mine ve dentinden ayırt edilebilir.(77)

Görüntü yalnızca mevcut demineralizasyon derecesini yansıttığından, tek başına bir radyografi, geçerli bir klinik muayene olmadan aktivitenin devam edip etmediğini belirleyemez. (78)

2.9.1.Çürük lezyonların tespiti

Lokalizasyonlarına göre çürük lezyonları dörde ayrılır.(78)

2.9.1.1.Oklüzal Yüzey (Pit ve Fissür) Çürükleri

Pit ve fissür çürükleri posterior dişlerde oklüzal, lingual, palatinal ve bukkal bölgede, anterior dişlerde ise kesici dişlerin palatinal yüzeyinde gözlenir. İnce mine yapısı ve plak retansiyonundan dolayı diğer bölgelere göre çürük oluşumu daha kolaydır.(78) Lezyon, tabanı mine-dentin birleşimine, tepesi diş yüzeyine bakan bir üçgen şeklinde olabilir ve erken evrede klinik olarak tebeşirimsi beyaz, sarı, kahverengi ve siyah renklemelerle kendini gösterebilir.(71)

Çürük pit ve fissürlerden başlar ve mine-dentin sınırını geçmediyse radyografda gözükmez. Mine-dentin sınırını geçen lezyonlar fissürün hemen altında geniş tabanlı radyolusent bir alan şeklinde gözlenir.(71, 78) Remineralizasyona bağlı olarak dişlerde kaviteasyon veya renklenme bulunmadan da oklüzal çürükler oluşabilir. Bu tip çürükler gizli çürükler olup klinik incelemede fissür tabanları sağlıklı görünür ancak mine altında ilerleyen bir çürük mevcuttur.(78)

2.9.1.2.Bukkal ve lingual yüzey çürükleri

Bukkal ve lingual yüzey çürükleri sıklıkla dişlerin mine pit ve fissürlerinden başlayan sınırları belirgin ve keskin, yuvarlak şekilde başlayıp çürük ilerledikçe elips veya yarım ay formunu alan lezyonlardır.(71, 78) Radyografide oklüzal çürüklerden ayırt etmek zor olmakla birlikte lezyonu çevreleyen çürüksüz mine varlığı hekime yardımcı olur. Kesin tanı klinik muayene ile sağlanır.(71)

2.9.1.3.Proksimal yüzey (arayüz) çürükleri

Proksimal çürükler dişlerin sıklıkla temas noktaları veya alanları ile serbest diş eti kenarı altında gözlenir. Lezyon mine prizmaları boyunca yayılan üçgen şekilli radyolusensi olarak görülebildiği gibi çentik, nokta, bant veya birkaç ince çizgi şeklinde de görülebilir. Lezyon mine dentin birleşimine ulaştığında genellikle tepesi pulpa odasına doğru ikinci bir üçgen tabanı oluşturacak şekilde yayılır.(71, 78)

Radyografik görüntüde servikal burnout, Mach band etkisi, hipoplastik pitler veya aşınma sonucu oluşmuş içbükey yüzeyler çürük lezyonunu taklit edebilir.(71)

2.9.1.4.Kök yüzey çürükleri

Periodontal problemler sonucu dentin ve sementi içeren çürüklerdir. Sement mineralizasyon yönünden kimyasal ve mekanik yıkıma mineden daha elverişlidir ve erozyon, atrizyon ve abrazyon gibi durumlarda hızla kayba uğrar.(78)

Kök yüzeyi çürüklerini tespit etmek için sadece radyolojik değerlendirme yeterli değildir. Anatomik yapıların süperpozisyonlarından dolayı veya servikal burnout fenomeni sonucu hatalı çürük teşhisleri konulabilir.(71, 78)

Etyolojisine göre diş çürükleri üçe ayrılır.(78)

2.9.2.1.Primer çürük

Herhangi bir restorasyon olmayan başlayan çürüklerdir.(78)

2.9.2.2.Rezidüel çürük

Rezidüel çürükler, primer çürüğün tamamen temizlenmeden restorasyon yapılması sonucu bırakılan çürüklerdir.(78) Çürüğün pulpaya çok yakın olduğu durumlarda indirek kuafaj yapılarak tersiyer dentin oluşumu sağlanır ve kalan çürük temizlenerek restorasyon yapılır.(71)

2.9.2.3.Sekonder (tekrarlayan, rekürrent) çürük

Restorasyonun sınırında yeni gelişen çürük lezyonuna denir. Kavitenin yetersiz preparasyonu, iyi genişletilmemesi, kenar adaptasyonunun zayıf olması veya kötü kenar şekillendirilmesi sonucu plak birikimi ile demineralizasyon başlar. Demineralize alanlar restorasyonun radyoopak görüntüsü üzerine süperpoze olabileceğinden radyografi ile birlikte klinik muayene de gereklidir.(78)

2.10.Diş Çürüğü Tespitinde Kullanılan Radyografik Görüntüleme Yöntemleri

8 Kasım 1895'te Wilhelm Conrad Röntgen, yanlışlıkla katot ışınlarının olası aralığının çok ötesine yansıtılan katot ışın üreticinden alınan bir görüntü keşfetti. Keşiften bir hafta sonra Röntgen, x-ışınları olarak adlandırdığı bilinmeyen radyasyon

nedeniyle oluşan bir fotoğraf plakasında karısının elinin resmini yaptığında tıbbi kullanımını keşfetti. Alyansını ve kemiklerini açıkça ortaya çıkardı. Bir cam görüntüleme plakasının bir kısmından ilk orijinal diş röntgenogramı, Ocak 1896'da Dr Otto Walkhoff tarafından kendi ağzında çekildi ve 25 dakika sürdü. O zamandan beri dental görüntüleme muazzam ilerleme gösterdi.(79)

Geleneksel film bazlı radyografî, karanlık oda varlığını ve bakımını, kimyasal banyo işlemlerini, sınırlı saklama koşullarını gerektirmektedir. Ayrıca kimyasal işleme bağlı hatalar da oluşabilmektedir. Tüm bu dezavantajlar, dijital radyografinin ortaya çıkmasıyla aşılmıştır. (79)

Diş hekimliğinde dijital radyografideki ilk sistem, 1987 yılında Fransa'da Trophy tarafından tanıtılan Radiovisiography (RVG, eski adıyla Trex-trophy Radiology Inc., Marietta, GA) idi.(80)

Dijital görüntüleme hastaya veya operatöre herhangi bir ek radyasyon maruziyeti olmadan üretilen görüntünün kontrast, densite, keskinleştirme ve görüntü yönü değiştirme gibi işlemlere izin verir. Ayrıca radyasyon dozu daha düşüktür. Bu devrim, hem görüntü elde etme süreçlerindeki teknolojik yeniliklerin hem de görüntü alma ve iletme için ağ bağlantılı bilgi işlem sistemlerinin geliştirilmesinin bir sonucu olarak gerçekleşmiştir.(79)

Ayrıca görüntünün hızlı oluşması, kolaylıkla saklanabilmesi ve iletilebilmesi dijital sistemlerin hızla yaygınlaşmasının en önemli nedenleri arasındadır.(81, 82)

Fiyatının pahalı olması, çözünürlüğünün geleneksel filmlerden düşük olması, damak derinliği az veya alveol kavsî dar olanlarda, rubber-dam kullanılan hastalarda sensörün yerleştirilmesinin zor olabilmesi konvansiyonel filmlere göre dezavantajlarıdır.(83)

Dijital sistemlerin kullanılması x ışınlarının madde ile etkileşimini veya projeksiyon geometrisinin radyografik görüntüsü üzerindeki etkisini değiştirmez. Dijital görüntülemede kullanılan başlıca görüntü reseptörleri solid state dedektörler ve fosfor plak teknolojisi olarak ikiye ayrılır. Solid state dedektörler de kendi içinde CCD (Charged Coupled Device), CMOS/APS (Complementary Metal Oxide Semiconductor/Active Pixel Sensor) ve Flat panel dedektörler olarak üçe ayrılır.(84)

2.10.1.Görüntü reseptörleri

2.10.1.1.Solid state dedektörler

Solid state dedektörler x ışınları tarafından üretilen yükü, katı yarı iletken materyaller içerisinde toplar ve görüntü ışınlanmadan hemen sonra elde edilir. Ancak sensör hacmi ve elektronik kablo intraoral dedektörler için dezavantajdır.(84)

2.10.1.1.1.CCD (Charged Coupled Device) sensörler

CCD sensörler gerçek zamanlı görüntüleme yapabilen, ışınlamadan hemen sonra görüntünün monitörde izlendiği kablolu sistemlerdir.(85)

CCD, dental dijital görüntülemelerde yaygın kullanılan içinde elektronik devre bulunan bir silikon çip içeren bir katı hal dedektörüdür. İletilen ışığı algılama ve onu elektronik bir mesaja çevirme işlevi görür. Silikon çip, x-radyasyonuna veya ışığa duyarlıdır. CCD'deki silikon çipi oluşturan elektronlar, piksel olarak bilinen bir dizi blok veya resim elemanına bölünmüş olarak görselleştirilebilir. Bir piksel, geleneksel radyografide kullanılan bir gümüş kristalin dijital eşdeğeridir. Piksel boyutu dijital alıcıya bağlı olarak değişir ve piksel boyutunun görüntü çözünürlüğü üzerinde etkisi vardır. (86) Her sensör 1,5 milyon ile 2,5 milyon pikselden oluşur ve piksel boyutları 15 ila 20 µm arasında değişir.(87)

Radyasyona maruz kaldığında, silikon atomları arasındaki kovalent bağlar koparak elektriksel şarj oluşur. Elektronlar, yük paketleri oluşturdukları cihazdaki en pozitif potansiyele doğru çekilir. Her paket bir piksele karşılık gelip matristeki tek tek piksellerden oluşan yük modeli, latent imajı temsil eder. Her sıradaki piksel yükü bir pikselden diğerine aktarılarak görüntü kaydedilir. Elektronik olarak sırasıyla analog sinyaller oluşur. Oluşan bu analog sinyaller analog-dijital dönüştürücü (ADC-Analog Digital Converter) aracılığı ile dijitalize edilerek ekranda görünür bir görüntüye dönüştürülür.(84, 88)

CCD sensörler kalın olduğu için ağız içi maniplasyonu zordur ve bu nedenle hasta toleransı azalmaktadır. Ayrıca sensörlere otoklav sterilizasyonu yapılamaması ve dezenfekte edilememesinden dolayı enfeksiyon kontrolü yapabilmek için hasta ağızına tek kullanımlık poşetler kullanılarak yerleştirilmelidir.(81)

2.10.1.1.2.CMOS/APS (Complementary metal oxide semiconductor/active pixel sensor)

Dedektör silikon bazlı yarı iletkenlerdir. Her piksel diğer pikselden izole olup transistörle doğrudan bağlı olmasıyla CCD'den ayrılır.(84, 87)

Elektron-delik çiftleri, absorbe edilen x-ışını enerjisi miktarıyla orantılı olarak piksel içinde üretilir. Bu yük, transistöre küçük bir voltaj olarak aktarılacak her transistördeki voltaj ayrı ayrı yöneltir. Görüntü alıcı tarafından okunur, dijital gri bir değer olarak saklanır ve görüntülenir. CMOS teknolojisi dijital kamera dedektörlerinin yapımında yaygın olarak kullanılır.(84)

CMOS sensörler CCD sensörlere göre daha küçük sistemlerdir. Bu sebeple daha az enerji harcarlar ve şarj kaçaklarına bağlı görüntüde bozulma oluşmaz. CCD sensörlere göre görüntü çözünürlüğü daha iyi ve daha dayanıklıdır; maliyeti ise düşüktür. İntraoral görüntüleme alanı, fosfor plaklardan küçük olup sefalometrik ve panoramik röntgenlerde kullanımı uygun değildir.(88)

2.10.1.1.3.Flat (düz, yassı) panel dedektörler

Dedektörler, 100 µm'den küçük piksel boyutlarına sahip büyük matris alanları sağlayabilir. Bu nedenle kafa dahil olmak üzere vücudun daha geniş alanlarının doğrudan dijital olarak görüntülenmesine olanak tanır.(84)

Flat panel dedektörler, direkt ve indirekt dönüştürme sistemleri olmak üzere ikiye ayrılır. İndirekt dedektörlerde gadolinyum oksisülfid veya sezyum iyodit içeren intensifying screen ile x ışını enerjisi görülebilir ışığa çevrilir. Bu cihazların performansı, yoğunlaştırıcı ekranın kalınlığına göre belirlenmekte olup daha kalın ekranlar daha verimlidir. Ancak ışık fotonlarının daha fazla yayılmasına izin vererek görüntünün net olmamasına neden olur.(84, 88)

Direkt dedektörler, silikona benzer özelliklere ve daha yüksek atom numarasına sahip bir foto iletken malzeme (selenyum) kullanır, bu da x ışınlarının daha verimli absorpsiyonuna izin verir.(84) Uygulanan bir elektrik alanının etkisi altında, selenyumun x-ışınına maruz kalması sırasında serbest kalan elektronlar,

alttaki ince film transistör (thin-film transistor (TFT)) detektör elemanına doğrudan bir hatta iletilir. (84)

İnce film transistör dizilimi, x ışınının etkilemesi sonucu meydana gelen elektriksel yük değişikliğinin saptanması ve bu değişimin elektronik olarak işlenmesini sağlayan sistemdir. Bu yapıda ışına duyarlı pikseller ve her bir pikselin kenarında elektronik okuma işlemini sağlayan transistörler mevcuttur. Işın duyarlı alanda oluşan yük değişimi her bir pikseldeki transistörlerle okunur, yükseltilir (amplifikasyon) ve dijital veriye çevrilir.(88)

Flat panel dedektörler, ekstraoral radyografilerde kullanılırlar. Pahalı olması nedeniyle de konik ışınlı bilgisayarlı tomografi gibi özel görüntüleme görevleriyle sınırlı olmaları muhtemeldir.(84)

2.10.1.2.Fosfor plaklar (Photostimulable phosphor plate-PSP)

Fosfor plaklar x ışınlarına duyarlı evropiyum (europium) ile aktif hale getirilen baryum florohalid kristallerini içeren, kablo ile bilgisayara bağlı olmayan ancak dijital işlemeyi gerçekleştirmek için ek tarayıcı ekipmanı gerektiren sensörlerdir.(84, 88) Bütün bileşikler yarı iletken özelliğe sahip kristal bir ortam içinde olup Europium, fosfor kristalinde elektron alışverişini sağlayarak görüntü oluşumunu sağlar.(82)

Fosfor plaklarda elektronların yoğun olarak konumlandığı Valans (Valence, değerlik) bandı, elektronların çok az bulunduğu kondüksiyon (conduction,iletken) bandı ve ikisinin arasında F merkezi olarak bilinen elektronların yakalanıp tutulduğu bir ara alan mevcuttur. F merkezinde tutulan elektronların enerjisi, Valans bandında olan elektronlardan yüksek, kondüksiyon bandında olan elektronlardan düşüktür.(82, 88)

X ışınları, yarı iletken özelliğindeki fosfor ekrana ulaştığında absorbe edilen enerjiyle evropiyumdan, Valans elektronları salınarak Eu^{+2} den Eu^{+3} değerlikli atoma dönüşür.(88) Bu elektronlar, F-merkezine göç eder ve orada yarı kararlı bir durumda tutulur. Yakalanan elektronların sayısı x-ışınına maruz kalma ile orantılıdır ve latent görüntüyü temsil eder. Latent görüntünün görünür hale geçmesi F merkezindeki elektronların (tutulmuş elektronların) eski durumlarına gönderilmesi ve bu sırada

oluşan görünür ışık fotonlarının veriye dönüştürülmesi temeline dayanır.(88) Yaklaşık 600 nm'lik kırmızı ışıkla uyarıldığında, baryum florohalojenür, yakalanmış elektronları iletim bandına bırakır. Bir elektron Eu^{+2} iyonuna geri döndüğünde, yeşil spektrumda 300 ile 500 nm arasında enerji açığa çıkar. (84)

Fiberoptikler, fosfor plaktan gelen ışığı bir foto çoğaltıcı tüpe iletir. Foto çoğaltıcı tüp, ışığı elektrik enerjisine dönüştürür. Foto çoğaltıcı tüpteki kırmızı bir filtre, uyarıcı lazer ışığını seçici olarak ayırır. Kalan yeşil ışık algılanarak değişik bir voltajlara dönüştürülür. Foto çoğaltıcı tüpten çıkan voltaj çıktılarındaki değişiklikler, latent imajdan uyarılan ışık yoğunluğundaki değişikliklere karşılık gelir. Voltaj sinyali, bir analogdan dijitale dönüştürücü tarafından ölçülür ve dijital bir görüntü olarak saklanır ve görüntülenir.(84)

Tasarımlar farklı olsa da farklı sistemler kısaca aynı prensiple çalışır:

- Radyografik işlem sırasında fosfor plak, hasta tarafından atenüasyona uğramayan x-ışını enerjisini absorbe eder ve depolar.
- Plak daha sonra okuyucuya yerleştirilir.
- Plak bir lazer ışını ile taranır ve depolanan x-ışını enerjisi floresan ışık olarak serbest bırakılır.
- Işık, bir foto çoğaltıcı tüp tarafından algılanır ve bir elektrik sinyaline (voltaj) dönüştürülür ve Bu analog sinyal dijitale çevrilir ve bilgisayara aktarılıp monitörde incelenir.
- Plak temizlenir (silinir) yeniden kullanıma hazır hale gelir.(87)

Hem intraoral hem de ekstraoral sistemlerde kullanılabilir. İntraoral plakların boyutu üreticiden üreticiye farklılık gösterir. Ancak genellikle boyut olarak periapikal, bitewing ve oklüzal radyografi için kullanılan konvansiyonel filme benzerdir.(87)

Işınlamadan sonra, plaklar en kısa sürede işlenmelidir, çünkü tutulan elektronlar zamanla kendiliğinden serbest kalır. Elektron kaybı oranı, ışınlamadan kısa bir süre sonra en fazla olup bu oran fosfor plak yapısına ve ortam sıcaklığına bağlı olarak değişir. Bazı fosfor plaklar 30 dakika sonra tutulan elektronların %23'ünü ve 1 saat sonra %30'unu kaybedebilmektedir. Yeterli miktarda ışınlanmış görüntülerde erken zamandaki yük kaybı yakalanan elektronların kaybı plak yüzeyi

boyunca uniform olduğundan, klinik olarak anlamlı görüntü bozulmasına neden olmaz. Yeterli düzeyde pozlanmış görüntüler 12-24 saat arasında saklanıp kabul edilebilir görüntü kalitesini koruyabilse de (84) çeşitli çalışmalar fosfor plakların çekimi takiben 10-15 dakika içinde taranması gerektiğini önermiştir.(88)

Fosfor plakların kablosuz ve esnek olmaları CCD sensörlere göre hasta için konforlu olmasını sağlar. Ayrıca CCD sensörlere göre ucuzdurlar. Ancak tekrar tekrar kullanımları sonucu görüntü kalitesinin bozulması, tarama aşamasının olması, plak üzerindeki oluşan çiziklerin neden olduğu görüntü artefaktları dezavantajlarıdır. (81) Fosfor plakların ömürleri 750-1000 kullanım arasındadır. Konvansiyonel filmlere göre daha pahalıdır.(88)

2.10.2.Çürük tespitinde kullanılan dijital görüntüleme yöntemleri

Çürük tespitinde intraoral ve ekstraoral görüntüleme yöntemlerinden faydalanılır. İntraoral radyografik değerlendirme, genel diş hekimi için görüntülenmenin bel kemiğidir ve periapikal radyografi, bitewing radyografi ve oklüzal radyografi olarak üçe ayrılır.(79) Çürük tespitinde periapikal radyografiler ve bitewing radyografilerden faydalanılır.(89) Oklüzal görüntüleme ise periapikal bir radyografide görüntülenemeyecek kadar büyük patolojilerin tespitine, çenelerdeki gömülü dişlerin, yabancı cisimlerin ve submandibular bez kanallarındaki taşların yerinin tespitine yardımcı olur.(79) Çürük tespitinde kullanılan panoramik radyografi ise ekstraoral bir görüntüleme yöntemidir.

2.10.2.1.İntraoral görüntüleme

2.10.2.1.1.Periapikal radyografi

Periapikal radyografilerde, çevreleyen kemik de dahil olmak üzere tüm diş görüntülenir.(89) Esas olarak pulpa ve kök kanal morfolojisinin değerlendirilmesi, interdental bölgede destekleyici alveolar kemik durumunu, periapikal patolojinin tespiti, kuron/kök kırıkları, endodontik tedavide çalışma uzunluğunun belirlenmesi, tedavi öncesi değerlendirilme ve tedavi sonrası iyileşmenin izlenmesi için kullanılır.(79) Periapikal görüntüleme için paralel teknik veya açıortay tekniği kullanılır.(89)

2.10.2.1.1.1.Paralel teknik

Paralel teknikte (aynı zamanda dik açı tekniği veya uzun kon tekniği olarak da adlandırılır) reseptörün dişlerin uzun eksenine paralel olarak desteklenmesi ve x ışınının dişlere ve reseptöre ya da filme dik açılarda yönlendirilmesi amaçlanır.(89)

Paralel teknikte hastanın baş pozisyonu ayarlanırken üst çeneden radyografi alınacaksa üst çene oklüzal düzleminin yere paralel olması (ala-tragus çizgisi yere paralel olmalı), alt çeneden radyografi alınacaksa alt çene oklüzal düzleminin yere paralel olması (dudak köşesi ile tragus arasındaki çizgi yere paralel olmalı) gerekmektedir. Sagittal düzlem ise yere dik olmalıdır.(90)

Filmin, fosfor plağın veya reseptörün ağız içinde dişe paralel bir şekilde sabit durması ve x ışının hizalamak için çeşitli tutucular kullanılır.

Bu teknikte uzama (elongasyon) ve kısalma (foreshortening) gibi geometrik bozulmalar en aza iner. Röntgen tüpü yatay ve dikey olarak daha kolay ve doğru açılabilir. Merkezi ışın alıcının merkezine konumlandırıldığı için cone-cut oluşmaz. Aynı diştten farklı zamanlarda aynı görüntüler alınabilir. Bu avantajlarının yanında anatomik varyasyonlardan dolayı (damak kubbesinin sığ olması) veya bulantı refleksi olan hastalarda uygulanması zordur. Film tutucuların otoklavda steril edilmesi ya da disposibl olması gerekliliği zaman ve maliyet açısından sorun oluşturmaktadır.(90)

2.10.2.1.1.2.Açıortay tekniği

Açıortay yönteminde merkezi ışın, dişin uzun eksenini ile film düzlemi arasındaki açının açıortayına dik olarak verilmelidir. Açıortay tekniği Cieszyński'nin izometri teoremine dayanır. Bu teoreme göre iki üçgen bir tam kenarı paylaştığında ve iki eşit açıyla sahip olduklarında eşittirler. Merkezi ışın açıortaya dik açıyla gönderildiği zaman, birer kenarını açıortayın oluşturduğu iki açısı eşit olan iki üçgen oluşacaktır. Bu üçgenlerden birisi dişin uzun eksenini ve açıortayın oluşturduğu, diğeri ise film veya reseptörün düzlemi ile açıortayın oluşturduğu üçgendir. Bu teoriye göre dişin gerçek boyu ile filmdeki görüntünün boyu birbirine eşit olmalıdır. (89, 90)

Üst çeneden radyografi alınacaksa üst çene oklüzal düzleminin (ala-tragus çizgisinin) yere paralel olması gerekmektedir. Alt çeneden radyografi alınacaksa baş

geriye alınması ve alt çene oklüzal düzleminin (dudak köşesi ile tragus arasındaki çizginin) yere paralel olması gerekir. Sagital düzlem ise yere dik olmalıdır.(89, 90) Maksilla ve mandibulada ilgili dişlerin açıortay tekniği ile periapikal radyografisi alınırken merkezi ışın açısı (tablo 2) doğru belirlenmelidir. (89)

Tablo 2: Açıortay tekniği ile periapikal radyografisi alınırken merkezi ışın açısı

İlgili bölge	Maksilla	Mandibula
Kesici dişler	+40°	-15°
Kanin dişleri	+45°	-20°
Premolar dişler	+30°	-10°
Molar dişler	+20°	-5°

Açıortay tekniğinde açıortayın hesaplanmasının zorluğundan dolayı yanlış konumlandırma nedeniyle ve film, fosfor plağın ağız içerisine uygulanması sırasında kırılması neticesinde görüntüde distorsiyonlar (görüntüde boyutların oranının değişmesi) sıklıkla oluşmaktadır. Ayrıca çok köklü bir dişin her bir kökünün uzunluğunu doğru bir şekilde tespit etmek için, her kök için farklı açılarda radyografi alınmalıdır. (89, 90)

2.10.2.1.2.Bitewing radyografi

Bitewing radyografi maksiller ve mandibular dişlerin kuronları ve bitişik alveolar kretlerini görüntülemek için kullanılır. (89)

İnterproksimal yüzeylerde tekrarlayan çürüklerin gözlemlenmesi ve saptanması klinik olarak zordur; bu çürük lezyonlar sıklıkla radyografik olarak tespit edilir. Bitewing radyografi bu lezyonların tespiti için en sık kullanılan radyografik tekniktir.(91)

Bitewing radyografi röntgen ışınının yatay açısı nedeniyle periapikal radyografilerde restorasyonların altındaki görünemeyebilen sekonder çürükleri de göstermektedir. Ayrıca periodontal durumu değerlendirmek için de yararlıdır. Çünkü alveolar kemik kretine iyi bir bakış açısı sağlar ve kemik yüksekliğindeki

değişiklikler komşu dişlerle karşılaştırılarak doğru bir şekilde değerlendirilebilir. Ek olarak, projeksiyon açısı doğrudan interproksimal boşluklardan geçtiği için özellikle interproksimal alanlarda diş taşını tespit etmek için kullanışlıdır.(89)

Bitewing radyografi alınırken baş pozisyonu oklüzal düzlem yere paralel, sagittal düzlem yere dik olacak şekilde ayarlanır. Filmin ışın alacak yüzeyi, dişlerin palatinal ve lingual yüzeylerine bakacak şekilde ağıza yerleştirilir. Hasta film üzerindeki kanatçığı ısırır. Kasların oklüzal yüzey üzerinde üst üste binmesini önlemek için röntgen tüpü dikey olarak +7 ila +10 derece açılı olmalıdır. Yatay açı ise dişlerin kontakt yüzeylerine paralel olacak şekilde verilmelidir. Yatay açı, merkezi ışın kontakt yüzeylerine paralel gelecek şekilde ayarlanmazsa dişlerin kontakt yüzeylerinin görüntüsü birbirinin üzerine süperpoze olur. (89, 90)

Her kadranda için bir premolar ve bir molar olmak üzere iki posterior bitewing radyografi önerilir. Ancak 12 yaş ve altındaki çocuklar için bir ısırma reseptörü (2 numaralı reseptör) genellikle yeterlidir. Premolar bitewing radyografi, kanin dişlerin distal yarısını ve premolarların kuronlarını içermelidir. Molar bitewing radyografi ise en distalde sürmüş moların (maksiller veya mandibular) 1 veya 2 mm ötesine yerleştirilir.(89)

2.10.2.2.Panoramik radyografi

Ekstraoral radyografik tekniklerinde hem x ışını kaynağı hem de görüntü reseptörü hasta ağzının dışındadır. Diş hekimliğinde kullanılan ekstraoral radyografi teknikleri; panoramik radyografiler, lateral sefalometrik radyografi, postero-anterior sefalometrik radyografi, Water'ın projeksiyonu, submentoverteks projeksiyonu ve reverse-towne projeksiyonunu içerir. Ekstraoral radyografiler, çenelerin ve kafatasının daha geniş alanlarını incelemeye, kranyofasiyal iskeletinin büyümesini ve gelişimini izlemeye, gömülü dişleri ve büyük patolojik lezyonları bulmaya ve temporomandibular eklemi değerlendirmeye yardımcı olur.(4)

Panoramik görüntüleme (pantomografi olarak da adlandırılır), hem maksiller hem de mandibular dental arkları ve bunların destekleyici yapılarını içeren yüz yapılarının tek bir görüntüsünü üretmek için kullanılan bir tekniktir.(4) Görüntü x-ışını kaynağının ve görüntü reseptörünün hasta etrafında döndürülmesiyle elde

edilir.(3) Panoramik radyografinin düşük radyasyon dozu, uygulama kolaylığı, daha az zaman gereksinimi ve daha fazla hasta konforu nedeniyle ekstraoral bir yöntem olarak popüleritesi artmıştır.(5)

Elde edilen panoramik radyografide görüntülenen yapıların net olarak görüldüğü kavisli bölgeye odak ark (focal trough) denir. Panoramik bir görüntüde görülen yapılar öncelikle odak ark içinde yer alan yapılardır. Görüntüler ortada en net şekilde görülür. Odak arkın dışındaki yapılar bulanıklaşır, büyür, küçülür veya bazen tanınmayacak kadar bozulur.(4)

Panoramik radyografi genellikle gerekli öngörüğü sağlayabilen veya diğer radyografilere duyulan ihtiyacın belirlenmesine yardımcı olarak kullanılabilen bir tekniktir. Yaygın kullanım amaçlarına örnekler arasında çene kırıkları, üçüncü molarların konumu, yaygın diş veya kemik hastalığı, bilinen veya şüphelenilen büyük lezyonlar, diş gelişimi ve sürmesi (özellikle karışık dişlenmelerde), kalmış kök parçaları temporomandibular eklem (TME) ağrısı ve gelişimsel anomaliler yer alır. Ağız içi işlemleri iyi tolere edemeyen hastalar için (trismus, bulantı refleksi, koopere olmayan hasta vb) kullanımı uygundur.(4)

Panoramik görüntüler diğer anatomik yapıların üst üste binmesi, artan görüntü bulanıklığı ve posterior proksimal temasların tutarsız açılması nedeniyle intraoral görüntüleme ile karşılaştırıldığında çoğunlukla daha düşük performansla çürük tespit potansiyeline sahiptir.(92) Ayrıca panoramik görüntüler yüksek çözünürlük sağlamamakta ve çürük tespiti başta olmak üzere bazı diş hastalıkları için ek olarak intraoral radyografi gerekmektedir.(93) Ancak teknolojik gelişmelerle birlikte, panoramik radyografi artık intraoral görüntülemeler ile karşılaştırılabilir hale gelmiştir.(94) Magnifikasyon ve distorsiyonlar nedeni ile görüntüde alveol kemiği yüksekliği ve kök boyu gibi ölçümler yeterli keskinlikte yapılamaz.(90)

Panoramik cihazlar çalışma prensiplerine göre dörde ayrılır;

- Tek Rotasyon Merkezli Cihazlar (Rotograph)
- İki Rotasyon Merkezli Cihazlar (Panorex)
- Üç Rotasyon Merkezli Cihazlar (Orthopantomograph)
- Çok Rotasyon Merkezli Cihazlar'dır.(4)



Şekil 24: Çalışmada kullanılan panoramik cihazı

Panoramik radyografileri Veraview IC5 HD (J Morita Mfg. Corp., Kyoto, Japan) panoramik cihazı ile 60-70 kVp ve 1-7.5mA aralığında erişkin dozunda elde edilmiştir. Yüksek oranda artefakt içeren ve diagnostik açıdan yetersiz olduğu düşünülen radyografiler çalışma dışı bırakılmıştır.

2.10.2.3.Konik ışınli bilgisayarlı tomografi (KIBT)


KIBT'nin yüksek çözünürlüğü, çeşitli kistlerin, tümörlerin, enfeksiyonların, gelişimsel anomalilerin ve maksillofasiyal yapıları içeren travmatik yaralanmaların tespitinde yardımcı olur. Özellikle çenelerdeki diş ve kemik hastalıkları ile temporamandibular eklemin değerlendirilmesinde ve dental implantların tedavi planlamasında yaygın olarak kullanılmaktadır.(79)

Amalgam restorasyonların yokluğunda, konik ışınli bilgisayarlı tomografinin proksimal çürüklerin tespitinde geleneksel iki boyutlu görüntülemeye göre daha duyarlı olduğu gösterilmiştir. Ancak mevcut restorasyonlar, çürükleri taklit edebilen ve gerçek çürük lezyonları maskeleyebilen önemli artefaktlara neden olabilir. Ayrıca, KIBT'den gelen radyasyon dozu, geleneksel radyografiden daha yüksektir ve ekipman daha pahalıdır. Bu nedenlerle KIBT'nin çürük tespiti için rutin olarak

kullanılması önerilmemektedir. Ancak dişler ve çeneler KIBT taraması yapılmışsa ve herhangi bir restorasyon mevcut değilse, görüntüler çürük lezyonları açısından incelenebilir(87).

3. MATERYAL METOD

Çalışmada panoramik radyografi görüntüleri kullanılarak diş çürüklerinin tespiti için oluşturulan derin öğrenme modelinin işlem adımlarını içeren akış diyagramı Şekil 25’de verilmektedir. İlerleyen kısımlarda bu adımlar detaylı bir şekilde açıklanmaktadır.



Şekil 25: Çalışmada uygulanan işlem adımlarını içeren akış diyagramı.

3.1. Veri Kümeleri


Bu çalışma Üniversitemiz Etik Kurul onayı (2020/05 karar no) ile yapılmıştır ve Helsinki Bildirgesi'nin etik standartlarına uygundur. Çalışma retrospektif veri tarama çalışması olarak planlanmıştır.

Çalışmada 2019 yılında Zonguldak Bülent Ecevit Üniversitesi Diş Hekimliği Fakültesine başvuran, herhangi bir sebep ile arşivde bulunan 101 hastanın panoramik radyografisi kullanılmıştır. Panoramik radyografiler Ağız, Diş ve Çene Radyolojisi alanında uzmanlığını almış iki hekim ve Ağız, Diş ve Çene Radyolojisi uzmanlık eğitimini sürdüren bir araştırma görevlisi tarafından oluşturulan ortak bir konseyde dişlerde “çürük var/yok” şeklinde seçilmiştir ve en az bir hekimin fikir ayrılığı yaşadığı hasta radyografileri çalışmaya dahil edilmemiştir.

Dahil etme kriterleri arasında hastaların 13-100 yaş aralığında bulunması (13 yaştan önce karışık dişlenme devam etmektedir), tüm çenede radyografide görülen en az bir adet diş görüldüğü radyografiler yer almaktadır. Çalışmadan çıkarma kriterleri ise panoramik radyografide optimum değerlendirmeye mâni olacak kadar artefakt bulunması, süt dişlerinin ağız ortamında bulunması, çene kemiklerinde gömülü bir diş varlığı, ağızdaki tüm dişlere herhangi bir dental işlem uygulanmış olması ve ciddi boyutlara ulaşmış maksillofasiyal patolojilerin yer almasıdır.

3.2. Ön İşleme ve Görüntü Büyütme

101 adet panoramik görüntüden etiketlenen sağlıklı ve çürük diş verileri model oluşturma aşamasında kullanılmıştır. 101 adet görüntüden toplamda 2660 adet sağlıklı ve çürük olarak etiketlenmiş diş görüntüsü ayrılmıştır. (Dolgu, kök kanal tedavisi, kuron-köprü protezi gibi herhangi bir işlem yapılmış dişler etiketlenmemiştir.) Bunlar hepsini kapsayacak şekilde tüm diş boyutları dikkate alınarak 400x250 piksel boyutunda jpg formatında kaydedilmiştir. Örnek görüntü için etiketlenen dişler ile birlikte aşağıdaki gibi çizdirme işlemi yapılmaktadır. (Şekil 26)




Şekil 26: Etiketli sağlıklı ve çürük dişler ayrı ayrı jpg formatında kaydedilmiştir.

Tablo 3: Örnek 24 nolu görüntü için etiketlenen sağlıklı dişler birbirinden ayrılarak jpg formatında kaydedilmiştir.

11	12	13	14	17	21	22

23	24	26	27	28	31	32

						
33	34	35	37	41	42	43

			
44	45	46	47

Tablo 4: Örnek 24 nolu görüntü için etiketlenen çürük dişler birbirinden ayrılarak jpg formatında kaydedilmiştir.

	
15	16

101 görüntüden sağlıklı ve çürük olmak üzere toplamda 2660 adet diş verisi ayıklanmıştır. Toplamda 2660 adet veriden 2324 sağlıklı (gerçek veri) ve 336 çürük (gerçek veri) diş ayrılmıştır. Eğitim aşamasına geçmeden önce sağlıklı dişlerden 176 ve çürük dişlerden 2164 adet sentetik veri elde edilmiştir. Sentetik veri üretilirken

saat yönünde ve tersi yönde olmak üzere -75, -60, -45, -30, -15, 15, 30, 45, 60, 75 derecelik döndürme işlemi uygulanmıştır.

Eğitim aşamasında, gerçek ve sentetik toplam 5000 veriden (2660 gerçek veri, 2340 sentetik veri) %80 eğitim, %20 test olacak şekilde, her sınıf için eşit sayıda örnek rastgele ayrılmıştır.

Model eğitiminden sonra, test aşaması için ayrılan 1000 adet dış verisi (500 sağlıklı, 500 çürük diş) kullanılarak model performansı ölçülmüştür.


3.3. Derin Evrişimsel Sinir Ağı Algoritmasının Mimarisi

Derin evrişimsel sinir ağı algoritması (Derin Öğrenme Algoritmaları), biyolojik sinir sistemlerinin bilgi işleme yöntemlerinden esinlenerek yapay sinir ağları olarak bilinen algoritmaları kullanmaktadır. Bu sayede, bilgisayarların her verinin neyi temsil ettiğini tanımlamasına ve modelleri öğrenmesine imkân tanımaktadır. Yapısal olarak YSA'lardan daha karmaşık olan derin öğrenme algoritmaları, insan beyninin işlevlerini taklit eden hesaplama sistemlerine dayanmaktadır.

3.4. ResNet50 Mimarisi

ResNet, Residual Network'ün kısaltmasıdır. Hedef sınıflandırma alanında yaygın olarak kullanılan klasik bilgisayarlı görü görevinin omurgalarından biridir. Klasik ResNet, ResNet50, ResNet101 ve benzerlerini içerir.(95)

Imagenet üzerinde eğitilmiş ResNet50 mimarisi 50 evrişimsel katman ve beş evrişimsel blok içerir. İlk blok, bir evrişim katmanı olan $\text{Konv}(7 \times 7)$ dahil olmak üzere yalnızca bir alt bloğa sahiptir. İkinci, üçüncü, dördüncü ve beşinci evrişim bloklarının her biri sırasıyla 3, 4, 6 ve 3 alt blok içerir. Alt blokların her birinde, $\text{Konv}(1 \times 1)$, $\text{Konv}(3 \times 3)$ ve $\text{Konv}(1 \times 1)$ olmak üzere 3 evrişim katmanı vardır. Ortalama havuz katmanı, daha küçük boyutlu bir özellik haritası elde etmek için kullanılır, dolayısıyla alt örnekleme, daha düşük boyutlu bir özellik haritasıyla sonuçlanır. Görüntülerin sınıflandırılması yani etiketlenmesi, ağın son bölümünde tam bağlantılı katmanlar aracılığıyla yapılır.(96)



Şekil 27: ResNet50 mimarisi (97)

ResNet50 mimarisinin temsil gücünü arttırmak için Gauss Bağlam Dönüştürücüsü (GCT) adı verilen kanal dikkat bloğu uygulanmıştır ve bu derin öğrenme modeli GCT-ResNet50-b0 adını almıştır.(98)

GCT-ResNet50-b0 deep learning yöntemi ile eğitim aşaması 20 epoch için tamamlanmıştır. Eğitim aşamasında 2000 adet sağlıklı, 2000 adet çürük diş toplamda 4000 adet veri kullanılmıştır.

3.5.Sınıflandırma Modellerinin Başarımının Ölçümü

Bir modelden tahmin edilen etiketler göz önüne alındığında, hassasiyeti hızlı bir şekilde hesaplamak ve hatırlamak için kullanışlı olan karışıklık matrisidir (Şekil 4). İkili sınıflandırma için bir karışıklık matrisi dört farklı sonucu gösterir: gerçek pozitif, yanlış pozitif, gerçek negatif ve yanlış negatif. Gerçek değerler sütunları, tahmin edilen değerler (etiketler) satırları oluşturur. Satır ve sütunların kesişimi dört sonuçtan birini gösterir. Örneğin, bir veri noktasının pozitif olduğunu, ancak aslında negatif olduğunu tahmin edersek, bu yanlış pozitifdir.

		Actual	
		Positive	Negative
Predicted	Positive	True Positive	False Positive
	Negative	False Negative	True Negative

Şekil 28: Karışıklık Matrisi

Karışıklık matrisinden geri çağırma ve hassasiyete geçmek, matristeki ilgili değerleri bulmayı ve eşitlik 1 ve 2'yi uygulamayı gerektirir.

$$recall = \frac{true\ positives}{true\ positives + false\ negatives} \quad 1$$

$$precision = \frac{true\ positives}{true\ positives + false\ positives} \quad 2$$

Bu iki kavram genel olarak birbiriyle ters ilişkilidir. Yani genelde, geri çağırma arttıkça kesinlik düşmektedir.

3.6.İstatistik Analiz

Tüm verilerin değerlendirilmesi için SPSS 22.0 Paket Veri Programı (SPSS 21.0 Software Package Program, Inc., Chicago, IL, ABD) kullanıldı.


ResNet50 ile derin öğrenme yönteminin, tespit ve tanısal performansı için tanısal doğruluk, duyarlılık (sensitivite), özgüllük (spesifite), pozitif prediktif değer (PPV), negatif prediktif değer (NPV), ROC (reciever operator characteristics) eğrisi ve eğri altındaki alan (AUC-area under curve) hesaplandı. Yapılan testlerde p değeri 0.05 olarak kabul edildi.

4.BULGULAR

Öğrenme modelinin 20 epoch sonucunda ortalama kayıp ve doğrulama kaybı Tablo 5 ve Şekil 29'da verilmiştir.


Tablo 5: Model eğitiminde her epoch için ortalama kayıp ve ortalama doğrulama kaybı değişimi

Epoch	Average Loss	Average Validation Loss
1	0,1425	0,1118
2	0,0825	0,0771
3	0,0726	0,0569
4	0,0689	0,0641
5	0,0674	0,0667
6	0,0533	0,0464
7	0,0527	0,0389
8	0,0468	0,0395
9	0,0492	0,0396
10	0,0450	0,0453
11	0,0439	0,0381
12	0,0401	0,0370
13	0,0420	0,0378
14	0,0405	0,0405
15	0,0401	0,0412
16	0,0412	0,0349
17	0,0411	0,0360
18	0,0400	0,0412
19	0,0419	0,0374
20	0,0408	0,0369




Şekil 29: Model eğitiminde her epoch için ortalama kayıp ve ortalama doğrulama kaybı değişimi

Model eğitiminden sonra, test aşaması için ayrılan 1000 adet dış verisi kullanılarak model performansı ölçülmektedir. Bunun için modelin her bir dış verisini sınıflandırma başarımına bakılmaktadır. 500 adet sağlıklı ve 500 adet çürük dış verisini, oluşturulan derin öğrenme modelinin %82 oranında sınıflandırdığı ölçülmektedir. Karışıklık matrisi(confusion matrix) (Şekil 30) incelendiğinde sağlıklı dişleri sınıflandırma oranı %70 (350 doğru,150 yanlış), çürük dişleri sınıflandırma oranı %94 (470 doğru, 30 yanlış), tüm test verisini sınıflandırma oranı %82 olarak gerçekleşmiştir.



Şekil 30: Karışıklık matrisinin oluşturulması

Derin öğrenme sisteminin PPV değeri %75.8, NPV değeri %92, sensitivitesi %94 ve spesifitesi %70 olarak bulunmuştur. AUC değeri ise %82 (Şekil 31) olarak bulunmuştur. Tablo 6’da elde edilen başarımlar ölçütleri verilmektedir.



Şekil 31: ROC eğrisi ve AUC

Tablo 6: ESA Modelinin Başarım Ölçütleri

Başarım Ölçütleri	Değerler
AUC	0.820
Ppv	75.8
Npv	92
Sensitivite	94
Spesifite	70
Doğruluk değeri	82

5.TARTIŞMA

Diş çürükleri klinik diş hekimliğinde en sık karşılaşılan durumlardan biridir ve insidansı oldukça yüksektir.(3) Çürüğün erken ve doğru tespiti ile tedavi edilmesi dişin fonksiyonunu uzun süre sürdürmesini sağlamaktadır. Proksimal diş yüzeylerine doğrudan ulaşmanın veya görmenin zorluğundan dolayı bu yüzeylerdeki çürükler genellikle radyografiler yardımıyla teşhis edilir.(99)

Bitewing radyografi, çürük tespiti için en yaygın kullanılan klinik teknik olmakla birlikte ekstraoral tekniklere kıyasla daha fazla hasta işbirliği ve tolerans gerektirir.(3) Bitewing ve periapikal radyografilerin projeksiyon geometrisi ve görüntü çözünürlüğü nedeniyle geleneksel panoramik görüntülere göre daha üstün olduğu gösterilmiş olsa da, panoramik radyografinin görüntü çözünürlüğünün teknolojik gelişmelerle arttığı ve diş çürüğü tanısı için intraoral radyografi ile karşılaştırılabilir hale geldiği öne sürülmüştür. (5, 100) Özellikle dijital panoramik görüntüleme de görüntü iyileştirme özellikleri, tanı değerlerini artırabilir veya tanı yorumlamasını kolaylaştırabilir.(101)

Abdinian ve arkadaşlarının çürük tespiti için yapmış olduğu çalışmada iyileştirilmiş interproksimal panoramik, intraoral bitewing ve ekstraoral bitewing radyografilerinin özgüllüğü ve duyarlılığı istatistiksel olarak benzer bulunmuştur.(3)

Yapay zekanın radyoloji görüntüleri üstüne uygulanabilirliğinin son yıllarda artması ile dental radyoloji alanında da çalışma yapılmasının önünü açmıştır. Özellikle dental radyografilerin artışı ve dijital ortamda depolanabilirliği derin öğrenme temelli çalışmalarda kullanılabilecek büyük bir veri potansiyeli oluşturmaktadır.

Çalışmamızda panoramik radyografi üzerinde derin öğrenme modelini kullanarak çürük tespitini değerlendirdik. Tanısal doğruluk değerini 0.82 olarak umut verici ve birkaç çalışmaya yakın değerde bulduk.(2, 9) Sensivite, spesifite, PPV ve NPV değerleri sırasıyla %94, %70, %75 ve %92'dir. Sensivite ve NPV değerleri yüksek bulunmuştur. Ancak yanlış çürük sayısının fazla olması spesifite ve PPV değerlerinin düşmesine neden olmuştur. Bunun sebebi ise çürük dişler için çok fazla sentetik veri üretilmesidir. (Sağlıklı ve çürük diş sınıfları için örnek sayılarının dengesiz olmasından dolayı, sentetik veriler bu açığı kapatmak için eğitim ve test aşamasında kullanılmıştır. Böylelikle sınıflar arasında örnek sayıları dengeli olması sağlanarak (sağlıklı diş %50, çürük diş %50), modelin veri sayısı çok olan sınıfı seçmesinin önüne geçilmektedir)

Yapay zeka temelli çürük tespitinin yapıldığı sınırlı sayıda çalışma mevcut olup, panoramik radyografi üzerinde tüm dişlerde (3. molar hariç) çürük tespitinin yapıldığı bir makale(102) bulunmuştur. Çalışmaların panoramik radyografiler üzerinde yapılmamasının nedenleri arasında çürük tespitinde bitewing ve periapikal radyografilerin daha etkin olması, derin öğrenme modeli oluştururken segmentasyonun daha zor olması gibi nedenler yer almaktadır.

Lian ve arkadaşları(102) diş hekimleri ve ayrı ayrı iki farklı derin öğrenme yöntemini kıyaslayarak panoramik radyografi üzerinde çürük tespiti yapmıştır. Diş hekimleri ve nnU-Net modeli kıyaslamasında doğruluk değerleri sırasıyla %95 ve %98 olarak bizim çalışmamız da dahil benzer çalışmalara göre oldukça yüksek bulunmuştur. Modelin sensitivite, spesifite ve NPV değerleri ise sırasıyla %82, %100 ve %98,5 olup yapmış olduğumuz çalışmadan farklı sonuçlar vermiştir. Yapılan ikinci model olan DenseNet121 ve diş hekimleri kıyaslamasında çürük lezyonları derinliğine göre D1, D2 ve D3 olarak sınıflandırılmış ve model buna göre eğitilmiştir. D3 lezyonu, pulpa tutulumu olan veya olmayan dentinin pulpaya yakın üçte birindeki radyolüsensiler olup en derin çürük lezyonu olarak etiketlenmiştir. D3

lezyonları için doğruluk, sensivite ve NPV değerleri sırasıyla %86, %91 ve %86 olarak bulunmuş ve çalışmamızın istatistik değerlerine D1 ve D2 lezyonlarına göre daha yakın bulunmuştur.

Vinayahalingam ve arkadaşları MobileNet V2 derin öğrenme algoritmasına dayalı panoramik röntgen üzerinde üçüncü molar dişlerin çürük lezyonlarını sınıflandırmak için yapmış olduğu çalışmada doğruluk değeri (0.87) çalışmamızdan yüksek bulunmuştur. Performans metrikleri 0.86'lık bir duyarlılık, 0.88'lik bir özgüllük ve 0.90'lık bir AUC'ye ulaşmıştır. Çalışmamızın duyarlılığı bu çalışmaya göre yüksek bulunmuştur(103)

Bayraktar ve arkadaşlarının(8) bitewing radyografı üzerinde YOLO tabanlı derin öğrenme modeli kullanarak interproksimal çürük tespiti yaptığı çalışmasında genel doğruluk değeri %94.59 olarak yüksek bir değerde bulunmuştur. Ayrıca sensivite, spesifite, PPV, NPV ve AUC değerleri sırasıyla %72.26, %98.2, %86.6, %95.6 ve %87.2'dir. Sonuçlar umut verici olup ESA modelleri ısıрма radyografilerinde çürük teşhisi için diş hekimlerine yardımcı olabilir. Veri seti çalışmamızda olduğu gibi rastgele olarak eğitim (%80) ve test-doğrulama (%20) gruplarına ayrılmıştır. Daha sonra, sadece test veri seti (verilerin %20'si) kullanılarak nihai model performansı hesaplanmıştır.

Cantu ve arkadaşları(9) U-Net derin öğrenme modelini kullanarak bitewing radyografileri üstünde çürük tespiti için diş hekimleri ve ESA modelini kıyasladığı çalışmada ESA'nın doğruluk değeri çalışmamıza benzer şekilde %80 bulunmuştur. Yedi diş hekiminin ortalama doğruluk değeri ise %71 olup sinir ağının diş hekimlerinden önemli ölçüde daha hassas ve NPV değerinin ise yüksek olduğu bulunmuştur. Sonuçların böyle olmasında diş hekimlerinin başlangıç çürüklerini işaretleme kararlarında (aşırı tespit ve tedaviden korkarken) daha ihtiyatlı davranırken, sinir ağının böyle bir davranış göstermemesi gösterilebilir. ESA modelinin sensivite, spesifitesi, NPV ve PPV değerleri sırasıyla %75, %83, %86 ve %70 olup çalışmamızın sadece PPV değeri daha yüksek bulunmuştur.

Lee ve arkadaşlarının(2) periapikal radyografilerde diş çürüklerinin tespiti ve teşhisi için derin CNN algoritmalarının etkinliğini değerlendirdiği çalışmada premolar, molar ve her ikisinin tanı doğruluk değerlerini, PPV, NPV, sensivite ve

spesifite deęerlerini karřılařtırmıřtır. Premolar diřler iin tanısal doęruluk deęeri %89.0, sensitivite, spesifite, PPV ve NPV deęerleri sırasıyla %84, %94, % 93.3 ve %85.5 idi. Molar diřlerinde tanısal doęruluk deęeri %88, sensitivite %92.3, spesifite %84, PPV %85.2 ve NPV %91.3'tür. Hem premolar hem de molarlarda sensitivite %81.0, spesifite %83, PPV %82.7 ve NPV %81.4 bulunmuřtur. Tanısal doęruluk deęeri yapmıř olduęumuz alıřmayla aynı (%82) bulunmuřtur.

Lee, Oh ve arkadaşlarının(104) bitewing radyografilerde ürük tespiti iin U-Net kullanarak geliřtirdikleri ESA modeli ile klinisyenlerin performansını deęerlendirmiřlerdir. Ü diř hekimi, ESA modelinin sonuçlarını referans veri olarak kullanarak ürük tespit ettięinde, klinisyenlerin genel teřhis performansı önemli ölçüde iyileřmiřtir. Derin öęrenme modelinin PPV deęeri %76.08 ve hassasiyeti ise %83.25 bulunmuřtur.

Bayrakdar ve arkadaşlarının(7) retrospektif yaptıęı alıřmada VGG-16 ve U-Net mimarisini kullanarak dental bitewing radyografilerinde otomatik ürük tespiti ve segmentasyon modelleri (CranioCatch, Eskiřehir, Türkiye) oluřturulmuřtur. ürük tespiti iin duyarlılık, kesinlik ve F-ölü deęerleri sırasıyla 0,84, 0,84 ve 0,84 idi. ürük segmentasyonuna duyarlılık, kesinlik ve F1-ölüm deęerleri sırasıyla 0,81, 0,86 ve 0,84 bulunmuřtur. alıřma sonucunda harici radyografik veri setinde 5 farklı deneyimli gözlemci ve yapay zeka modeli ile karřılařtırıldıęında, yapay zeka modelleri uzman yardımcılara üstünlük gösterdięi görölmüřtür.

Devito ve arkadaşlarının(105) yaptıęı alıřmada ise ekilmiş diřlerin proksimal yüzeylerinin radyografik görüntüsü, 25 arařtırmacı tarafından ürük varlıęı aısından deęerlendirildi. Daha sonra radyografların incelenmesi sinir aęını beslemek iin kullanıldı ve karřılık gelen diřler, optik mikroskop altında (altın standart) kesilerek deęerlendirildi. alıřmanın sonucunda AUC deęeri alıřmamızdan daha yüksek bir deęerde (0.884) bulunmuřtur.

Derin öęrenmede katman sayısının yüksek olması modelin doęruluęunu ve performansını artırır. Eklenen her katman farklı özelliklerin ortaya ıkmasını saęlar. Örneęin bir katmanda kenarlar öęrenilirken dięer katmanda köřeler öęrenilir. Ancak, geleneksel ESA'da katman derinlięi iin maksimum bir eřik vardır

ve katman sayısının çok fazla artırılması test performansının düşmesine (kaybolan gradyan problemine) neden olabilmektedir. Rezidüel ağlar (ResNets), kullandıkları farklı bağlantılarla ortaya çıkan bu sorunu çözmeyi amaçlamaktadır. Geleneksel ESA'lardan farklı olarak, ResNet mimarilerinde kısayol bağlantıları kullanılır. Kısayol bağlantıları ekstra parametreler içermez, hesaplama karmaşıklığına neden olmaz ve önceki katmanlardan alınan önemli bilgilerin sonraki katmanlara iletilmesini sağlar.(96)

ResNet50, çok sayıda örnekle nesne algılama ve sınıflandırma için en yaygın yapay sinir ağı mimarilerinden biridir ve ağıdaki artan katman sayısının neden olduğu bozulmayı iyi bir şekilde çözer. ImageNet veri setlerinde ResNet50'nin görüntü alanı sınıflandırmasında diğer ESA modellerinden daha iyi performans gösterdiği belirtilmiştir.(106)

Elpeltagy ve arkadaşlarının değiştirilmiş ResNet50 kullanılarak BT ve göğüs görüntülerinden Kovid-19'un otomatik tahmini için çeşitli derin öğrenme mimarilerinin doğruluk, spesifite ve sensivite değerlerini karşılaştırılmıştır. Çalışmada ResNet50 mimarisine üç yeni katman eklenerek elde edilen yeni bir model (ResNet53) ile ResNet50, ResNet101, GoogleNet, AlexNet, DenseNet201, VGG16, VGG19, ve InceptionV3 modellerine dayalı olarak derin özellik çıkarmanın performans sonuçlarını değerlendirilmiştir. ResNet50 ve ResNet53 diğer modellerin çoğundan daha iyi performans göstermiştir.(107)

Bu çalışmada hemen hemen aynı performans değerlerine sahip olan ResNet101 101, ResNet50 50 katman derinliğinde olup ResNet101, ResNet50'nin yaklaşık iki katı zaman tüketir. (107)

Raihan ve arkadaşlarının InceptionV3 ve ResNet50 derin öğrenme mimarisini kullanarak kovid-19 hastalarının sınıflandırdığı çalışmada değerlendirme metriklerinin sonuçları ResNet50 mimarisinin daha yüksek performansa sahip olduğunu göstermiştir. Ayrıca veri setleri kendi içlerinde 80:20 ve 90:10 olarak ayrı ayrı da değerlendirilmiştir. Doğrulama aşamasında doğruluk değeri ResNet50 için 90:10 orana sahip model için %96.66; 80:10 orana sahip model için %96.53 bulunmuştur. Kesinlik değeri ise 80:10 orana sahip modelde %98; 90:10'da ise %97'dir.(108)

Mukti ve arkadaşlarının ResNet50 ile transfer öğrenmeye dayalı bitki hastalıkları tespiti adlı çalışmasında çalışmamızda olduğu gibi veri seti %80 eğitim, %20 doğrulama seti olarak ikiye ayrılmıştır. Üzerinde oynama yapılan ResNet50 modeli ile VGG16, VGG19, AlexNet modelleri performans açısından karşılaştırılmıştır. Bu çalışmanın sonunda ResNet50'li modelin en yüksek doğruluğa ve en düşük kayba sahip olduğunu görülmüştür. ResNet50 modelinin epoch sayısı diğer modellere göre çok düşük olup eğitimde daha hızlı ve verimlidir.(97)

Çalışmanın geliştirilebilecek yönlerine bakıldığı zaman, sonuçların geçerliliği histolojik olarak değerlendirilmediğinden hekimlerin kararları ve olası hataları sonuçları etkilemektedir. Bunun yanında bu çalışmada çürük lezyonlarını Ağız, Diş ve Çene Radyolojisi alanında uzmanlığını almış iki hekim ve Ağız, Diş ve Çene Radyolojisi uzmanlık eğitimini sürdüren bir araştırma görevlisi tespit etti ve altın standart olarak kabul edildi. Veri setlerimiz birçok çalışmada(2, 8, 103) olduğu gibi %80 eğitim, %20 test verisi olarak ayrıldı. ESA ve diş hekimlerinin teşhis performansı karşılaştırılmadı.

Derin öğrenmeye dayalı çalışmalarda başarılı sonuçlar elde etmek için büyük miktarda eğitim verisine ihtiyaç duyulur. Fakat tıp alanında büyük ölçekli verilerin elde edilmesi, bazı etik zorluklarla birlikte zahmetli, zaman alıcı bir süreç olduğundan bu çalışmada eğitim verilerini artırmak için veri artırma yöntemi kullanılmıştır. Veriler, çeşitli görüntü işleme yöntemleri (döndürme, histogram eşitleme, ölçekleme, kırpma vb.) yardımıyla ham verilerden yeni veriler elde edilerek artırılabilir.(8)

Panoramik filmlerde diş yapıları ve kemik arasındaki gri seviyelerindeki hafif farklılık nedeniyle tatmin edici segmentasyon sonuçları elde etmek zordur. Radyografideki üst üste binen burun bölgesi, maksiller sinüs, dişleri çevreleyen kemik gibi yapıların piksel yoğunluğundaki karmaşık değişiklikler, üstesinden gelinmesi gereken bir engeldir.(102)

Çalışmamızda panoramik radyografi üzerinde çürük ve sağlıklı dişler etiketlenirken doğal olarak sağlıklı diş sayısı çürük diş sayısına oranla çok fazla bulunmuştur. Veri seti hazırlama aşamasında sağlıklı ve çürük diş sayısı eşitlenmesi çürük dişler üzerinde fazla miktarda sentetik veri elde edilmesine neden olmuştur.

6.SONUÇ

Çalışmamızda ResNet50 derin öğrenme modeli kullanarak panoramik radyografi üzerinde çürük tespiti yapmayı amaçladık ve %82 doğruluk değeri ile bu modelin umut verici ve uygulanabilir olduğunu gördük. Performansı arttırmak için daha fazla veri kümesi gerek olduğu ve derin öğrenme modelinin iyileştirilmesi gerektiği sonucuna vardık.

Yapay zeka, giderek daha akıllı, daha hızlı, daha hassas ve daha güvenilir hale gelmektedir. Bu sebeple radyologlar, yeni sınırları değerlendirmek, eksiklikleri ve zorlukları belirlemek için yapay zekanın gelişim hızına ayak uydurmalı, terminoloji ve kavramlara hakim olmalıdır.

Bu çalışmanın sınırlamaları dahilinde, şu sonuca varıyoruz:

- ESA'lar, panoramik radyografilerinde çürük lezyonlarının teşhisinde kullanılabilir.
- ESA modeli, yaptığımız çalışma sonucunda çürük lezyonlarının teşhisinde %82 doğruluk sağlayarak klinik pratiğinde diş hekimlerine yardımcı bir araç olarak kullanılabilmek için umut vaat etmektedir.

7.KAYNAKLAR

1. Featherstone JD. The science and practice of caries prevention. J Am Dent Assoc. 2000;131(7):887-99.
2. 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.
3. Abdinian M, Razavi SM, Faghihian R, Samety AA, Faghihian E. Accuracy of Digital Bitewing Radiography versus Different Views of Digital Panoramic Radiography for Detection of Proximal Caries. J Dent (Tehran). 2015;12(4):290-7.
4. Sanjay M. Mallya and Alan G. Lurie. Panoramic Imaging. İçinde; Oral Radiology Principles and Interpretation. White SC, Pharoah MJ, editors. 7. ed: Mosby Elsevier, St. Louis, Missouri; 2014. s. 166-84.
5. Akkaya N, Kansu O, Kansu H, Cagirankaya LB, Arslan U. Comparing the accuracy of panoramic and intraoral radiography in the diagnosis of proximal caries. Dentomaxillofac Radiol. 2006;35(3):170-4.
6. Murata M, Arijji Y, Ohashi Y, Kawai T, Fukuda M, Funakoshi T, et al. Deep-learning classification using convolutional neural network for evaluation of maxillary sinusitis on panoramic radiography. Oral radiol. 2019;35(3):301-7.
7. Bayrakdar IS, Orhan K, Akarsu S, Celik O, Atasoy S, Pekince A, et al. Deep-learning approach for caries detection and segmentation on dental bitewing radiographs. Oral Radiol. 2021:1-12.
8. Bayraktar Y, Ayan E. Diagnosis of interproximal caries lesions with deep convolutional neural network in digital bitewing radiographs. Clin Oral Investig. 2022;26(1):623-32.
9. Cantu AG, Gehrung S, Krois J, Chaurasia A, Rossi JG, Gaudin R, et al. Detecting caries lesions of different radiographic extension on bitewings using deep learning. J Dent. 2020;100:103425.
10. Casalegno F, Newton T, Daher R, Abdelaziz M, Lodi-Rizzini A, Schurmann F, et al. Caries Detection with Near-Infrared Transillumination Using Deep Learning. J Dent Res. 2019;98(11):1227-33.
11. Orhan K, Bayrakdar I, Ezhov M, Kravtsov A, Özyürek. Evaluation of artificial intelligence for detecting periapical pathosis on cone-beam computed tomography scans. Int Endod J. 2020;53(5):680-9.
12. Chang HJ, Lee SJ, Yong TH, Shin NY, Jang BG, Kim JE, et al. Deep Learning Hybrid Method to Automatically Diagnose Periodontal Bone Loss and Stage Periodontitis. Sci Rep. 2020;10(1):7531.
13. Jader G, Fontineli J, Ruiz M, Abdalla K, Pithon M, Oliveira L. Deep instance segmentation of teeth in panoramic X-ray images. 2018 31st SIBGRAPI Conference on Graphics, Patterns and Images (SIBGRAPI); 2018: IEEE.
14. Amasya H, Yildirim D, Aydogan T, Kemalolu N, Orhan K. Cervical vertebral maturation assessment on lateral cephalometric radiographs using artificial

intelligence: comparison of machine learning classifier models. *Dentomaxillofac Rad.* 2020;49(5):20190441.

15. 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. *Dentomaxillofac Rad.* 2019;48(1):20170344.

16. Chartrand G, Cheng PM, Vorontsov E, Drozdal M, Turcotte S, Pal CJ, et al. Deep Learning: A Primer for Radiologists. *Radiographics.* 2017;37(7):2113-31.

17. Group S-I, Community FR. Artificial intelligence and medical imaging 2018: French Radiology Community white paper. *Diagn Interv Imaging.* 2018;99(11):727-42.

18. McCarthy J, Minsky ML, Shannon CE. A proposal for the Dartmouth summer research project on artificial intelligence - August 31, 1955. *Ai Mag.* 2006;27(4):12-4.

19. Miller DD, Brown EW. Artificial Intelligence in Medical Practice: The Question to the Answer? *Am J Med.* 2018;131(2):129-33.

20. Rosenblatt F. The perceptron: a probabilistic model for information storage and organization in the brain. *Psychol Rev.* 1958;65(6):386.

21. Samuel AL. Some studies in machine learning using the game of checkers. *IBM J Res Dev.* 1959;3(3):210-29.

22. Lodwick GS, Keats TE, Dorst JP. The coding of roentgen images for computer analysis as applied to lung cancer. *Radiology.* 1963;81(2):185-200.

23. Crevier D. AI: the tumultuous history of the search for artificial intelligence: Basic Books, Newyork; 1993. p.432

24. De A, Sarda A, Gupta S, Das S. Use of artificial intelligence in dermatology. *Indian J Dermatol.* 2020;65(5):352.

25. Abonamah AA, Tariq MU, Shilbayeh S. On the Commoditization of Artificial Intelligence. *Front Psychol.* 2021;12:696346.

26. Sogani J, Allen Jr B, Dreyer K, McGinty G. Artificial intelligence in radiology: the ecosystem essential to improving patient care. *Clinical Imaging.* 2020;59(1):A3-A6.

27. Erickson BJ, Korfiatis P, Akkus Z, Kline TL. Machine Learning for Medical Imaging(1). *Radiographics.* 2017;37(2):505-15.

28. Shen C, Nguyen D, Zhou Z, Jiang SB, Dong B, Jia X. An introduction to deep learning in medical physics: advantages, potential, and challenges. *Phys Med Biol.* 2020;65(5):05TR1.

29. Han J, Pei J, Kamber M. Data mining: concepts and techniques: Elsevier, Morgan Kaufmann Publishers, Burlington; 2011. p. 83-85

30. Rashidi HH, Tran NK, Betts EV, Howell LP, Green RJ. Artificial intelligence and machine learning in pathology: the present landscape of supervised methods. *Acad Pathol.* 2019;6:2374289519873088.

31. Sidey-Gibbons JAM, Sidey-Gibbons CJ. Machine learning in medicine: a practical introduction. *BMC Med Res Methodol.* 2019;19(1):64.

32. Sarker IH. Machine learning: Algorithms, real-world applications and research directions. *SN Comput Sci.* 2021;2(3):1-21.
33. El Naqa I, Haider MA, Giger ML, Ten Haken RK. Artificial Intelligence: reshaping the practice of radiological sciences in the 21st century. *Br J Radiol.* 2020;93(1106):20190855.
34. Sarker IH, Kayes A, Badsha S, Alqahtani H, Watters P, Ng A. Cybersecurity data science: an overview from machine learning perspective. *Journal of Big data .*2020;7(1):1-29.
35. Mohammed M, Khan MB, Bashier EBM. Machine learning: algorithms and applications: Crc Press; 2016.
36. Montagnon E, Cerny M, Cadrin-Chênevert A, Hamilton V, Derennes T, Ilinca A, et al. Deep learning workflow in radiology: a primer. *Insights Imaging.* 2020;11(1):1-15.
37. Mazurowski MA, Buda M, Saha A, Bashir MR. Deep learning in radiology: An overview of the concepts and a survey of the state of the art with focus on MRI. *J Magn Reson Imaging.* 2019;49(4):939-54.
38. Soffer S, Ben-Cohen A, Shimon O, Amitai MM, Greenspan H, Klang E. Convolutional neural networks for radiologic images: a radiologist's guide. *Radiology.* 2019;290(3):590-606.
39. Jiang F, Jiang Y, Zhi H, Dong Y, Li H, Ma S, et al. Artificial intelligence in healthcare: past, present and future. *Stroke Vasc Neurol.* 2017;2(4):230-43.
40. Gupta A, Harrison PJ, Wieslander H, Pielawski N, Kartasalo K, Partel G, et al. Deep Learning in Image Cytometry: A Review. *Cytometry A.* 2019;95(4):366-80.
41. Lee C, Kim Y, Kim YS, Jang J. Automatic Disease Annotation From Radiology Reports Using Artificial Intelligence Implemented by a Recurrent Neural Network. *Am J Roentgenol.* 2019;212(4):734-40.
42. Rumelhart DE, Hinton GE, Williams RJ. Learning representations by back-propagating errors. *Nature.* 1986;323(6088):533-6.
43. Ker J, Wang L, Rao J, Lim T. Deep learning applications in medical image analysis. *Ieee Access.* 2017;6:9375-89.
44. Hinton GE, Salakhutdinov RR. Reducing the dimensionality of data with neural networks. *Science.* 2006;313(5786):504-7.
45. Kazuhiro K, Werner RA, Toriumi F, Javadi MS, Pomper MG, Solnes LB, et al. Generative Adversarial Networks for the Creation of Realistic Artificial Brain Magnetic Resonance Images. *Tomography.* 2018;4(4):159-63.
46. Puttagunta M, Ravi S. Medical image analysis based on deep learning approach. *Multimed Tools Appl.* 2021; 80.16:24365-24398.
47. McCulloch WS, Pitts W. A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics.* 1943;5(4):115-33.
48. LeCun Y, Boser B, Denker JS, Henderson D, Howard RE, Hubbard W, et al. Backpropagation Applied to Handwritten Zip Code Recognition. *Neural Comput.* 1989;1(4):541-51.

49. Goodfellow I, Bengio Y, Courville A. Deep learning: MIT press; 2016. p.165.
50. Do S, Song KD, Chung JW. Basics of Deep Learning: A Radiologist's Guide to Understanding Published Radiology Articles on Deep Learning. Korean J Radiol. 2020;21(1):33-41.
51. Yamashita R, Nishio M, Do RKG, Togashi K. Convolutional neural networks: an overview and application in radiology. Insights Imaging. 2018;9(4):611-29.
52. Lee JG, Jun S, Cho YW, Lee H, Kim GB, Seo JB, et al. Deep Learning in Medical Imaging: General Overview. Korean J Radiol. 2017;18(4):570-84.
53. Wagner MW, Namdar K, Biswas A, Monah S, Khalvati F, Ertl-Wagner BB. Radiomics, machine learning, and artificial intelligence—what the neuroradiologist needs to know. Neuroradiology. 2021;63(12):1957-67.
54. Alzubaidi L, Zhang J, Humaidi AJ, Al-Dujaili A, Duan Y, Al-Shamma O, et al. Review of deep learning: concepts, CNN architectures, challenges, applications, future directions. J Big Data. 2021;8(1):53.
55. Razavian N, Knoll F, Geras KJ. Artificial intelligence explained for Nonexperts. Semin Musculoskelet Radiol. 2020;24(1):3-11.
56. Lakhani P, Prater AB, Hutson RK, Andriole KP, Dreyer KJ, Morey J, et al. Machine Learning in Radiology: Applications Beyond Image Interpretation. J Am Coll Radiol. 2018;15(2):350-9.
57. Heo M-S, Kim J-E, Hwang J-J, Han S-S, Kim J-S, Yi W-J, et al. Artificial intelligence in oral and maxillofacial radiology: what is currently possible? Dentomaxillofac Radiol. 2021;50(3):20200375.
58. Krizhevsky A, Sutskever I, Hinton GE. Imagenet classification with deep convolutional neural networks. Advances in neural information processing systems. Communications of the ACM. 2012;25:1097-105.
59. Wang S, Summers RM. Machine learning and radiology. Med Image Anal. 2012;16(5):933-51.
60. Cheng PM, Montagnon E, Yamashita R, Pan I, Cadrin-Chenevert A, Perdigon Romero F, et al. Deep Learning: An Update for Radiologists. Radiographics. 2021;41(5):1427-45.
61. Kim J, Lee HS, Song IS, Jung KH. DeNTNet: Deep Neural Transfer Network for the detection of periodontal bone loss using panoramic dental radiographs. Sci Rep. 2019;9(1):1-9.
62. Fukuda M, Inamoto K, Shibata N, Arijii Y, Yanashita Y, Kutsuna S, et al. Evaluation of an artificial intelligence system for detecting vertical root fracture on panoramic radiography. Oral Radiol. 2020;36(4):337-43.
63. Kwon O, Yong TH, Kang SR, Kim JE, Huh KH, Heo MS, et al. Automatic diagnosis for cysts and tumors of both jaws on panoramic radiographs using a deep convolution neural network. Dentomaxillofac Rad. 2020;49(8):20200185.
64. Hwang JJ, Jung YH, Cho BH, Heo MS. An overview of deep learning in the field of dentistry. Imaging Sci Dent. 2019;49(1):1-7.

65. Zhang K, Zuo W, Chen Y, Meng D, Zhang L. Beyond a Gaussian Denoiser: Residual Learning of Deep CNN for Image Denoising. *IEEE Trans Image Process.* 2017;26(7):3142-55.
66. Park J, Hwang D, Kim KY, Kang SK, Kim YK, Lee JS, et al. Computed tomography super-resolution using deep convolutional neural network. *Physics in Medicine & Biology.* 2018;63(14):145011.
67. Chen H, Zhang Y, Kalra MK, Lin F, Chen Y, Liao P, et al. Low-Dose CT With a Residual Encoder-Decoder Convolutional Neural Network. *IEEE Trans Med Imaging.* 2017;36(12):2524-35.
68. Broder A, Domingos P, de Freitas N, Guyon I, Malik J, Neville J, editors. Is deep learning the new 42. plenary panel at the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining; 2016.
69. 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.
70. Fejerskov O, Nyvad B, Kidd E. Dental caries: the disease and its clinical management. 3 ed: John Wiley & Sons, Iowa; 2015. p. 7-13.
71. Ann Wenzel. Dental caries. İçinde; *Oral Radiology Principles and Interpretation.* White SC, Pharoah MJ, editors. 7 ed: Mosby elsevier, St. Louis, Missouri; 2014. s. 285-98.
72. Featherstone J. The continuum of dental caries—evidence for a dynamic disease process. *J Dent Res.* 2004;83(1_suppl):39-42.
73. Selwitz RH, Ismail AI, Pitts NB. Dental caries. *The Lancet.* 2007;369(9555):51-9.
74. Rathee M, Sapra A. Dental caries. *StatPearls [Internet].* Erişim tarihi 15.12.2021.
75. Özgür B, Ünverdi G, Çehreli Z. Diş Çürüğünün Tespitinde Geleneksel ve Güncel Yaklaşımlar. *Türkiye Klinikleri J Pediatr Dent.* 2018;4(1):1-9.
76. Wenzel A. Radiographic modalities for diagnosis of caries in a historical perspective: from film to machine-intelligence supported systems. *Dentomaxillofac Radiol.* 2021;50(5):20210010.
77. Whaites E, Drage N. Dental Caries and the Assessment of Restorations. İçinde; *Essentials of Dental Radiography and Radiology.* Whaites E, Drage N, editor. 6. ed: Elsevier, St. Louis, Missouri; 2021. s. 550-89.
78. Özcan İ, Göksel S, Ünsal G, Atapek MM. Diş çürüklerinde tanı ve radyolojik değerlendirme. İçinde; *Diş Hekimliğinde Radyolojinin Esasları.* Özcan İ, editor. İstanbul tıp kitapevi, İstanbul; 2017. s. 917-36.
79. Shah N, Bansal N, Logani A. Recent advances in imaging technologies in dentistry. *World J Radiol.* 2014;6(10):794-807.
80. Nair MK, Nair UP. Digital and advanced imaging in endodontics: a review. *J Endod.* 2007;33(1):1-6.
81. Direkt Sistemler C. İntraoral dijital görüntüleme sistemleri: Direkt sistemler, CCD, CMOS, düz panel dedektörler, indirekt sistemler, yarı direkt dijital

görüntüleme, fosfor plak taramaları. Türkiye Klinikleri J Oral Maxillofac Radiol-Special Topics. 2016;2(2):4-9.

82. Harorlı A. Ağız, Diş ve Çene Radyolojisi. 2. ed: Nobel tıp kitapçevleri, İstanbul; 2014. s. 191-205.

83. Yeler DY, Taşveren SK, Kaynar O. Diş hekimliğinde dijital görüntüleme sistemleri. Atatürk Üniv Diş Hek Fak Derg. 2020;30(1):138-147.

84. John B. Ludlow and André Mol. Digital imaging. İçinde; Oral Radiology Principles and Interpretation. White SC, Pharoah MJ, editor. 7. ed: Mosby elsevier, St. Louis, Missouri; 2014. s. 41-62.

85. Wakoh M, Kuroyanagi K. Digital imaging modalities for dental practice. Bull Tokyo Dent Coll. 2001;42(1):1-14.

86. Iannucci JM, Howerton LJ. Digital Imaging. İçinde; Dental radiography Principles and Techniques. Iannucci JM, Howerton LJ, editors. 5. ed: Elsevier, St. Louis, Missouri; 2017. s. 288-98.

87. Whaites E, Drage N. Image reseptors. İçinde; Essentials of Dental Radiography and Radiology. Whaites E, Drage N, editors. 6 ed: Elsevier, St. Louis, Missouri; 2021. s. 89-120.

88. Özcan İ, Yurdabakan Z. Dijital radyoloji. İçinde; Diş Hekimliğinde Radyolojinin Esasları. Özcan İ, editör. İstanbul tıp kitapçevi, İstanbul; 2017. s. 205-47.

89. White SC, Pharoah MJ. Intraoral Projections. İçinde; Oral Radiology Principles and Interpretation. White SC, Pharoah MJ, editor. 7. ed: Mosby Elsevier, St. Louis, Missouri; 2014. s. 91-130.

90. Şenel N, Özcan İ. Diş Hekimliğinde Kullanılan Radyografi Teknikleri. içinde; Hekimliğinde Radyolojinin Esasları. Özcan İ, editör: İstanbul tıp kitapçevi, İstanbul; 2016. s. 133-78.

91. Kasraei S, Shokri A, Poorolajal J, Khajeh S, Rahmani H. Comparison of Cone-Beam Computed Tomography and Intraoral Radiography in Detection of Recurrent Caries under Composite Restorations. Braz Dent J. 2017;28(1):85-91.

92. Gaalaas L, Tyndall D, Mol A, Everett ET, Bangdiwala A. Ex vivo evaluation of new 2D and 3D dental radiographic technology for detecting caries. Dentomaxillofac Radiol. 2016;45(3):20150281.

93. Jeon KJ, Han SS, Lee C, Choi YJ, Jung HI, Kim YH. Application of panoramic radiography with a multilayer imaging program for detecting proximal caries: a preliminary clinical study. Dentomaxillofac Radiol. 2020;49(8):20190467.

94. Farman AG. There are good reasons for selecting panoramic radiography to replace the intraoral full-mouth series. Oral Surg Oral Med O. 2002;94(6):653-4.

95. Luo Y, Zhang Y, Sun X, Dai H, Chen X. Intelligent Solutions in Chest Abnormality Detection Based on YOLOv5 and ResNet50. J Healthc Eng. 2021;2021:2267635.

96. Polat Ö, editor Detection of Pediatric Pneumonia from X-Ray Images using ResNet50 and GAL Networks. 2021 International Conference on INnovations in Intelligent SysTems and Applications (INISTA); 2021: IEEE.

97. Mukti IZ, Biswas D, editors. Transfer learning based plant diseases detection using ResNet50. 2019 4th International Conference on Electrical Information and Communication Technology (EICT); 2019: IEEE.
98. Ruan D, Wang D, Zheng Y, Zheng N, Zheng M, editors. Gaussian Context Transformer. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition; 2021.
99. Qu X, Li G, Zhang Z, Ma X. Detection accuracy of in vitro approximal caries by cone beam computed tomography images. *Eur J Radiol.* 2011;79(2):e24-e7.
100. Lundeen RC, McDavid WD, Barnwell GM. Proximal surface caries detection with direct-exposure and rare earth screen/film imaging. *Oral Surg Oral Med Oral Pathol.* 1988;66(6):734-45.
101. Akarslan ZZ, Akdevelioglu M, Gungor K, Erten H. A comparison of the diagnostic accuracy of bitewing, periapical, unfiltered and filtered digital panoramic images for approximal caries detection in posterior teeth. *Dentomaxillofac Radiol.* 2008;37(8):458-63.
102. Lian L, Zhu T, Zhu F, Zhu H. Deep Learning for Caries Detection and Classification. *Diagnostics (Basel).* 2021;11(9):1672.
103. Vinayahalingam S, Kempers S, Limon L, Deibel D, Maal T, Hanisch M, et al. Classification of caries in third molars on panoramic radiographs using deep learning. *Sci Rep.* 2021;11(1):1-7.
104. Lee S, Oh SI, Jo J, Kang S, Shin Y, Park JW. Deep learning for early dental caries detection in bitewing radiographs. *Sci Rep.* 2021;11(1):16807.
105. 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 Endod.* 2008;106(6):879-84.
106. He K, Zhang X, Ren S, Sun J. Deep residual learning for image recognition. Proceedings of the IEEE conference on computer vision and pattern recognition; 2016; 770-778.
107. Elpeltagy M, Sallam H. Automatic prediction of COVID- 19 from chest images using modified ResNet50. *Multimed Tools Appl.* 2021; 80(17):26451-26463.
108. Raihan M, Suryanegara M, editors. Classification of COVID-19 Patients Using Deep Learning Architecture of InceptionV3 and ResNet50. 2021 4th International Conference of Computer and Informatics Engineering (IC2IE); 2021: IEEE.

8. EKLER

EK 1. Etik Kurul Onayı



T.C.
ZONGULDAK BÜLENT ECEVİT ÜNİVERSİTESİ
Girişimsel Olmayan Klinik Araştırmalar
Etik Kurul Başkanlığı

TOPLANTI TARİHİ : 04/03/2020
TOPLANTI NO : 2020/05

KARARLAR :

- 9- Diş Hekimliği Fakültesi Ağız, Diş ve Çene Radyolojisi Anabilim Dalı Başkanlığı'nın "Panoramik Radyografide Diş Çürükleri Tespitinde Derin Öğrenme Sistemlerinin Değerlendirilmesi" konulu çalışmasının Etik Kurul İlkelerine uygun olduğuna,

Oy birliği ile karar verilmiştir.

A S ~~L I~~ G İ B İ D İ R

Prof. Dr. Günhur ÖZBAKİŞ DENGİZ
Girişimsel Olmayan Klinik Araştırmalar Etik Kurul Başkanı

ZONGULDAK BÜLENT ECEVİT ÜNİVERSİTESİ
GİRİŞİMSSEL OLMAYAN KLİNİK ARAŞTIRMALAR
ETİK KURULU KARAR FORMU

ETİK KURUL BİLGİLERİ	ETİK KURULUN ADI	Zonguldak Bülent Ecevit Üniversitesi Girişimsel Olmayan Klinik Araştırmalar Etik Kurulu
	AÇIK ADRESİ:	
	TELEFON	0
	FAKS	(0
	E-POSTA	c

PROJE YÜRÜTÜCÜSÜ / UNVANI/ ADI SOYADI	Dr. Öğr. Üyesi Gediz GEDUK
ARAŞTIRMANIN AÇIK ADI	Panoramik Radyografide Diş Çürükleri Tespitinde Derin Öğrenme Sistemlerinin Değerlendirilmesi

KARAR BİLGİLERİ	Karar No: 2020/05	Tarih: 04/03/2020
	Yukarıda bilgileri verilen çalışmanın yapılmasında etik ve bilimsel açıdan sakınca olmadığına oy birliği ile karar verilmiştir.	

Prof. Dr. Günnur ÖZBAKİŞ DENGİZ
Başkan

Doç. Dr. İ. Etem HİSKİN
Başkan Yrd.

Doç. Dr. Ayşe Semra DEMİR AKCA
Üye(Raporlu)

Doç. Dr. Ş. KODAK
Üye

Dr. Öğr. Üyesi Bilgehan AKKOZ
Üye

Dr. Öğr. Üyesi Yasin ÖZTÜRK
Üye

Dr. Öğr. Üyesi İnci TUKAN
Üye

Dr. Öğr. Üyesi Duygu ERDEM
Üye

Dr. Öğr. Üyesi Esra ACIMAN DEMİREL
Üye

Uzman Dr. Volkan Bilge YILMAZ
Üye

Öğr. Gör. İbrahim Kerem ERTEM
Üye




Uzman Ecz. Mehmet Kivanç ERDEM
Üye

Hilal GÜVEN
Üye

EK 2. İntihal Formu

Panoramik Radyografide Diş Çürükleri Tespitinde Derin Öğrenme Sistemlerinin Değerlendirilmesi			
ORJİNALLIK RAPORU			
%4 BENZERLİK ENDEKSİ	%3 İNTERNET KAYNAKLARI	%0 YAYINLAR	%2 ÖĞRENCİ ÖDEVLERİ
BİRİNCİ KAYNAKLAR			
1	www.mustafasecil.com İnternet Kaynağı	%1	
2	dergipark.org.tr İnternet Kaynağı	<%1	
3	Submitted to Istanbul Aydın University Öğrenci Ödevi	<%1	
4	Submitted to Batman University Öğrenci Ödevi	<%1	
5	acikerisim.aku.edu.tr İnternet Kaynağı	<%1	
6	ichi.pro İnternet Kaynağı	<%1	
7	9lib.net İnternet Kaynağı	<%1	
8	openaccess.hacettepe.edu.tr:8080 İnternet Kaynağı	<%1	
9	digitalreport.com.tr İnternet Kaynağı	<%1	

EK 3. İntihal Raporu Beyan Formu

	TÜRKİYE CUMHURİYETİ ZONGULDAK BÜLENT ECEVİT ÜNİVERSİTESİ DİŞ HEKİMLİĞİ FAKÜLTESİ İNTİHAL RAPORU BEYAN FORMU			
DİŞ HEKİMLİĞİ FAKÜLTESİ DEKANLIĞINA Ağız, Diş ve Çene Radyolojisi Anabilim Dalında yürütülen “Panoramik Radyografide Diş Çürükleri Tespitinde Derin Öğrenme Sistemlerinin Değerlendirilmesi” başlıklı tez için akademik intihal engelleme programında yapılan tarama sonucunda elde edilen benzerlik oranları aşağıdadır. Beyan edilen bilgilerin doğru olduğunu, aksi halde doğacak hukuki sorumlulukları kabul ve beyan ederiz. 19 /01/ 2022 <table style="width: 100%; margin-top: 20px;"><tr><td style="width: 50%; text-align: center;"> Hatice Biltekin Öğrenci Adı-Soyadı İmza </td><td style="width: 50%; text-align: center;"> Gediz GEDUK Danışman Adı-Soyadı İmza </td></tr></table> <u>BENZERLİK ORANLARI: %4</u> Ek: İntihal tespit programı çıktısı			Hatice Biltekin Öğrenci Adı-Soyadı İmza 	Gediz GEDUK Danışman Adı-Soyadı İmza 
Hatice Biltekin Öğrenci Adı-Soyadı İmza 	Gediz GEDUK Danışman Adı-Soyadı İmza 			
ZONGULDAK BEÜ Diş Hekimliği Fakültesi 67600 Kozlu / ZONGULDAK Tel : 0372 261 36 00 Fax : 0372 2613603 Web : http://dis.beun.edu.tr/ e-mail : dishekimligi@beun.edu.tr				
Form 15				

EK 4. Tez Yazım Değerlendirme Formu

	TÜRKİYE CUMHURİYETİ ZONGULDAK BÜLENT ECEVİT ÜNİVERSİTESİ DİŞ HEKİMLİĞİ FAKÜLTESİ TEZ YAZIM DEĞERLENDİRME FORMU	
DİŞ HEKİMLİĞİ FAKÜLTESİ DEKANLIĞINA		
Ağız, Diş ve Çene Radyolojisi Anabilim Dalında yürütülen “Panoramik Radyografide Diş Çürükleri Tespitinde Derin Öğrenme Sistemlerinin Değerlendirilmesi” başlıklı ve uzmanlık öğrencisi Hatice BİLTEKİN tarafından hazırlanan uzmanlık tezinde;		
☒ DİŞ KAPAK SAYFASI ☒ İÇ KAPAK SAYFASI ☒ TEZ KABUL VE ONAY SAYFASI ☒ ÖNSÖZ SAYFASI ☒ TÜRKÇE ÖZET ☒ İNGİLİZCE ÖZET (ABSTRACT) ☒ İÇİNDEKİLER ☒ SİMGELER ve KISALTMALAR ☒ ŞEKİL DİZİNİ (Gerekli ise) ☒ TABLO DİZİNİ (Gerekli ise) ☒ GİRİŞ ☒ GENEL BİLGİLER ☒ GEREÇ ve YÖNTEM ☒ BULGULAR ☒ TARTIŞMA ☒ SONUÇLAR ☒ KAYNAKLAR ☒ EKLER (Etik kurul onayı vb.) ☒ ÖZGEÇMİŞ ☒ İNTİHAL RAPORU ☒ FORMATLA İLGİLİ DİĞER HUSUSLAR (Alt bölümler, Latince isimler, Ondalık ayraçlar, Metin içerisindeki göndermeler ve kaynak göstermeler, Alıntılar, Dipnotlar, Simgeler ve kısaltmalar vb.)		
Tez yazım kılavuzunda belirtildiği gibi hazırlanmıştır.		
Yukarıda belirtilen hususlar tarafımdan kontrol edilmiştir.		
Danışmanın Adı-Soyadı: Dr Öğr Üyesi Gediz GEDUK		
Kontrol Eden	Tarih: 25.04.2022	İmza: 
Adı-Soyadı: Prof Dr Emre BODRUMLU	Tarih: 26.04.2022	İmza: 
ZONGULDAK BEÜ Diş Hekimliği Fakültesi 67600 Kozlu / ZONGULDAK Tel : 0372 261 36 00 Fax : 0372 261 36 03 Web : http://dis.beun.edu.tr/ e-mail : dishekimligi@beun.edu.tr		
Form 16		

9.ÖZGEÇMİŞ

Adı Soyadı: Hatice Biltekin

Doğum Yer: [REDACTED]

Doğum Tarihi: [REDACTED]

Bildiği Yabancı Diller: İngilizce

Eğitim Durumu: Lisans (2012-2017) İstanbul Üniversitesi Diş Hekimliği Fakültesi

Çalıştığı Kurum: Zonguldak Bülent Ecevit Üniversitesi, Diş Hekimliği Fakültesi

Fakültesi Ağız, Diş ve Çene Radyolojisi Anabilim Dalı

E-posta: [REDACTED]