



**OTOMATİK DİŞ DOLGU TESPİTİNDE DERİN ÖĞRENME
ALGORİTMALARININ PERFORMANSLARININ KARŞILAŞTIRILMASI**

Göktuğ BACANLI

YÜKSEK LİSANS

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANA BİLİM DALI

**GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

OCAK 2023

ETİK BEYAN

Gazi Üniversitesi Fen Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi,
- Tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu,
- Tez çalışmada yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
- Kullanılan verilerde herhangi bir değişiklik yapmadığımı,
- Bu tezde sunduğum çalışmanın özgün olduğunu,

bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

İmza

Göktuğ BACANLI

...../...../.....

OTOMATİK DİŞ DOLGU TESPİTİNDE DERİN ÖĞRENME ALGORİTMALARININ PERFORMANSLARININ KARŞILAŞTIRILMASI

(Yüksek Lisans Tezi)

Göktuğ BACANLI

GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Ocak 2023

ÖZET

Dış çürükleri günümüz dünyasında en çok görülen diş rahatsızlıklarındandır. Enfeksiyon nedeniyle meydana gelen ağrı ile kendini belli etmeden önce dental radyografiler sayesinde dış çürüklerinin tespiti yapılabilmektedir. Dış çürüğü tedavisinde farklı tedavi yöntemleri kullanılabilir ve bu yöntemlerden en yaygını dolgudur. Bu tezde, periapikal radyografiler üzerinde dış dolgularını derin öğrenme metotlarıyla otomatik olarak tespit eden hekimlere yardımcı bir karar destek sistemi sunulmuştur. Karar tespit sistemini oluşturmak için tek kademeli YOLOv3, SSD ve RetinaNet modelleri ve iki kademeli Faster R-CNN modeli kullanılmıştır. Özellik çıkarıcı olarak ResNet50, ResNet101, DarkNet-53 ve VGG16 evrimsel sinir ağları kullanılmıştır. Model performansları doğruluk, kesinlik, duyarlılık, mAP ve F1-skor performans metrikleri ile değerlendirilmiştir. Ayrıca bütün modellerin eğitim süreleri de değerlendirilmiştir. Tüm metrikler incelendiğinde, Faster R-CNN ResNet101 modelinden 0,92 mAP, 0,87 doğruluk, 0,9 kesinlik, 0,92 duyarlılık ve 0,93 F1-Skor performans metrikleri elde edilmiştir. Buna ek olarak, YOLOv3 modelinde ise 0,99 mAP, 0,8 doğruluk, 0,8 kesinlik, 1 duyarlılık ve 0,89 F1-Skor performans metrikleri elde edilmiştir. Bu metrik incelemelerinin sonucunda ise, bu iki modelin en iyi sonuçları verdiği gözlenmiştir. Fazla katmana sahip Faster R-CNN modelinin tek kademeli modellere göre eğitim süresinin daha uzun sürdüğü gözlemlenmiştir. Bu bulgular, diğer alanlarda uzmanlara yardımcı karar destek sistemleri oluşturulduğu gibi diş hekimliği alanında da diş hekimlerine yardımcı bu tür sistemler geliştirilebileceğini göstermektedir.

Bilim Kodu : 90507

Anahtar Kelimeler : Derin öğrenme, diş hekimliği, dolgu, tespit, sınıflandırma

Sayfa Adedi : 55

Danışman : Dr. Öğr. Üyesi Mahmut Emin ÇELİK

THE COMPARISON OF DEEP LEARNING ALGORITHMS' PERFORMANCES IN
DETECTION OF AUTOMATED DENTAL FILLING

(M. Sc. Thesis)

Göktuğ BACANLI

GAZİ UNIVERSITY
GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCES

January 2023

ABSTRACT

Tooth decay is one of the most common dental diseases worldwide. Dental caries can be detected by dental radiographs before they appear with pain caused by infection. Different treatment methods can be used in the treatment of dental caries, and the most common of these methods is filling. In this thesis study, a decision support system is presented to dentist that automatically detects dental fillings on periapical radiographs with deep learning methods. Single-stage YOLOv3, SSD and RetinaNet models and two-stage Faster R-CNN model were used to create the decision detection system. ResNet50, ResNet101, DarkNet-53 and VGG16 convolutional neural networks were used as feature extractors. Model performances were evaluated with accuracy, precision, recall, mAP and F1-score performance metrics. Plus, the training times of all models were also evaluated. When all metrics were analyzed, 0.92 mAP, 0.87 accuracy, 0.9 precision, 0.92 recall, and 0.93 F1-Score performance metrics were obtained from the Faster R-CNN ResNet101 model. In addition to this model, 0.99 mAP, 0.8 accuracy, 0.8 precision, 1 recall, and 0.89 F1-Score performance metrics were obtained in the YOLOv3 model. As a result of these metric examinations, it was observed that these two models indicated the best results. These findings show that such systems can be developed to assist dentists in the field of dentistry as well as creating decision support systems to assist experts in other fields.

Science Code : 90507

Key Words : Deep learning, dentistry, dental filling, detection, classification

Page Number : 55

Supervisor : Asst. Prof. Dr. Üyesi Mahmut Emin ÇELİK

TEŞEKKÜR

Tez çalışmam boyunca değerli bilgi ve birikimlerini benimle paylaşarak ve çalışmayı sahiplenerek yönlendiren Sayın Dr. Öğr. Üyesi Mahmut Emin ÇELİK'e, çalışmaya katkılarından dolayı Ankara Yıldırım Beyazıt Üniversitesi Diş Hekimliği Fakültesi Ağız Diş ve Çene Radyolojisi Ana Bilim Dalında görevli Dr. Öğr. Üyesi Berrin ÇELİK'e, bu süreçte hep yanımda olan desteklerini esirgemeyen annem Fatma BACANLI ve ablam Servet Seda DOĞAN'a teşekkür ederim.



İÇİNDEKİLER

	Sayfa
ÖZET	iv
ABSTRACT.....	v
TEŞEKKÜR.....	vi
İÇİNDEKİLER	vii
ÇİZELGELERİN LİSTESİ.....	ix
ŞEKİLLERİN LİSTESİ.....	x
RESİMLERİN LİSTESİ	xii
SİMGELER VE KISALTMALAR.....	xiii
1. GİRİŞ	1
2. LİTERATÜR ARAŞTIRMASI	5
3. VERİ SETİ	11
4. DERİN ÖĞRENME TABANLI TESPİT MODELLERİ	15
4.1. Özellik Çıkarıcılar	15
4.1.1. VGG16	15
4.1.2. ResNet	17
4.1.3. Darknet-53	20
4.2. Dedektörler	21
4.2.1. Tek aşamalı derin öğrenme tabanlı dedektörler	22
4.2.2. İki aşamalı derin öğrenme tabanlı dedektörler	27
5. DEĞERLENDİRME KRİTERLERİ	31
6. BULGULAR	37
7. TARTIŞMA	43
8. SONUÇ	47

Sayfa

KAYNAKLAR	49
ÖZGEÇMİŞ	55



ÇİZELGELERİN LİSTESİ

Çizelge	Sayfa
Çizelge 3.1. Dental görüntüleme yöntemlerinin radyasyon doz miktarı, avantaj ve dezavantajları	12
Çizelge 6.1. Dolgu tespiti görevinde derin öğrenme modellerinin performansları	37



ŞEKİLLERİN LİSTESİ

Şekil	Sayfa
Şekil 4.1. VGG mimarisi model yapısı	15
Şekil 4.2. VGG16 mimarisi	16
Şekil 4.3. Tek bir test ölçeğinde vgg mimarilerinin hata oranları	16
Şekil 4.4. Düz mimari yapısında 56 ve 20 katmanlı modellerin hata oranı grafikleri ...	17
Şekil 4.5. Artık kalıntı bağlantısı	17
Şekil 4.6. ResNet yapay sinir ağının tasarlanma aşamaları	18
Şekil 4.7. Düz mimari ile resnet modelinin katman sayılarına bağlı hata oranları	19
Şekil 4.8. ResNet34 ve ResNet50-101 modellerinin artık bağlantıları	20
Şekil 4.9. DarkNet-19 ve DarkNet-53 mimarileri	20
Şekil 4.10. ImageNet veri seti üzerinden özellik çıkarıcı sonuçlarının karşılaştırılması	21
Şekil 4.11. Tek aşamalı retinanet dedektörünün mimarisi	22
Şekil 4.12. Çapraz entropi yöntemi ile odak kaybı yönteminin kayıp değerlerinin karşılaştırması	23
Şekil 4.13. Nesne algılama modellerinin ortalama kesinlik değerleri	23
Şekil 4.14. Tek aşamalı SSD dedektörünün mimarisi	24
Şekil 4.15. SSD çerçevesi	24
Şekil 4.16. Birden çok çıktı katmanı kullanmanın etkisi	25
Şekil 4.17. PascalVOC veri seti ile test sonuçları	25
Şekil 4.18. YOLOv3 mimarisinin görsel grafiği	26
Şekil 4.19. YOLOv3 modelinin diğer modeller ile kıyaslama tablosu	27
Şekil 4.20. Faster R-CNN modelinin mimarisi	28
Şekil 4.21. Bölge önerisi ağı ve seçici arama yönteminin ortalama kesinlik değerleri .	29
Şekil 4.22. Bölge önerisi ağı ve seçici arama yönteminin zamansal değerleri	29

Şekil	Sayfa
Şekil 5.1. Makine öğrenmesi yaklaşımları	31
Şekil 5.2. Karışıklık matrisi	32
Şekil 5.3. Birleşimin kesişim değeri	33
Şekil 6.1. Faster R-CNN ResNet101 modelinin kesinlik-duyarlılık eğrisi	40
Şekil 6.2. YOLOv3 modelinin kesinlik-duyarlılık eğrisi	40



RESİMLERİN LİSTESİ

Resim	Sayfa
Resim 3.1. Periapikal radyografiler üzerinde dolgu tedavisi uygulanan diş örnekler ...	14
Resim 6.1. Dişte bulunan dolguların tespit ve sınıflandırma örnekleri (a) Tek bir dişte bulunan dolgu (b)Yan yana dört dişte bulunan dolgu (c) Yan yana iki diş ve ayrı tek bir dişte bulunan dolgu örneği	38



SİMGELER VE KISALTMALAR

Bu çalışmada kullanılmış simgeler ve kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur.

Simgeler

Açıklamalar

m

mili

Sv

Sievert

Kısaltmalar

Açıklamalar

AUC

Area under curve

CT

Computed Tomography

DCM

Digital imaging and communications in medicine

IOU

Intersection over union

KKDS

Klinik Karar Destek Sistemi

MATLAB

Matrix laboratory

MRI

Magnetic resonance imaging

NEMA

National electrical manufacturers association

PNG

Portable Network Graphics

R-CNN

Regional convolutional neural network

SSD

Single Shot Multibox Dedector

VGG

Visual Geometry Group

YOLO

You Only Look Once

1. GİRİŞ

Karar verme işlemi, karar vericinin değişik seçeneklerle karşı karşıya bulunduğu durumlarda, bunlar arasından kendi amaçlarına uygun, kendisince belirlenmiş ölçütlere en uygun olanı seçebilmesidir [1]. Karar vericilerin verdiği kararlar yararlı sonuçlara neden olabilirken ciddi sonuçlara yol açabilecek yanlış bir karar geri dönüşü olmayan durumlar doğurabilir. Karar verme işleminin başarısı elde edilen bilgilerin amaç doğrultusunda doğru bir şekilde analiz edilmesine bağlıdır. Karar destek sistemi ise uygulanacak sisteme muhakeme ve kararlılık gerektiren karar verme süreçlerinde yardımcı olan sistemlerdir, bu sistemlerin temeli 1960'lara kadar dayanmaktadır. Karar destek sistemleri toplanmış verileri analiz ederek karar verecek kişiye yararlı bilgiler üretir. Karar destek sistemleri en uygun yarı yapılandırılmış problemlere, yani bilgisayar ve analitik yardımların değerli olması için yeterli olduğu ancak insan yargısının hala gerekli olduğu problemlere yöneliktir [2]. Bu tür sistemlerin en önemli özelliklerinden biri kısıtlı zamanda önceden görülmesi zor olan durumları kullanan kişinin hızlı bir şekilde bilinçli bir karar almasını mümkün kılmasıdır. Karar destek sistemleri standart karar verme süreçlerini otomatikleştirerek alınacak kararın doğruluğunu arttırabilir.

Karar destek sistemleri pazarlama, güvenlik, tarım ve sağlık gibi birçok farklı alanda kullanılmaktadır. Tıpta kullanılan karar destek sistemleri ise literatürde klinik karar destek sistemleri olarak bilinmektedir. Bir klinik karar destek sistemi (KKDS) hedeflenen klinik bilgi, hasta bilgisi ve diğer sağlık bilgileri ile tıbbi kararları geliştirerek daha iyi sağlık hizmeti sunmayı amaçlar [3]. Klinik karar destek sistemleri ilerlemiş sağlık sonuçları, yanlış kararlardan kaçınma ve artan verimlilik sayesinde hem uzmanlara hem de hastalara önemli faydalar sağlamaktadır. Bilgisayar tabanlı klinik karar destek sistemlerin temeli 1970'lere kadar dayanmaktadır ancak o zamanlar sistem entegrasyonu zayıf, zaman kısıtlı ve akademik uğraşlar sınırlıydı [4]. Bu engellere ek olarak, o dönemde doktor özerkliği ve açıklanabilirliği olan bir sistem tavsiyesini kullanırken kimin hatalı olacağı konusunda ortaya çıkan etik ve yasal sorunlar vardı [5]. Teknolojinin ilerlemesiyle bu tür sistemlerin entegrasyonu hızlanmış ve akademik uğraşların sayısı artmıştır. Sağlık kuruluşları günümüzde bilişim sistemlerinden, yönetim hizmetleri, hastalıkların teşhis edilmesi, hekimlerin hastayla ilgili vereceği kararların desteklenmesi, hemşire ve hekimlerin yapacağı

işlerde rehberlik, sinyal yorumlama, laboratuvar hizmetleri ve hasta yönetimi gibi çok çeşitli alanlarda faydalanılmaktadır [6].

Hastalığın sınıflandırılmasında ve tespit edilmesinde yardımcı olan sistemler tanısal karar destek sistemi olarak anılmaktadır. Tanısal karar destek sistemleri hastayla ilgili verileri ve görüntüleri analiz ederek olası teşhislerin muhtemel sonuçlarını verir. Uzmanlar bu teşhis önerileni değerlendirir ve yeterli bulgu elde edilmiş ise hastalığın teşhis kararını veya gerekmesi durumunda tanı için daha fazla test isteme kararını verebilirler. Uzman verimli bir şekilde klinik karar destek sistemlerinin bilgilerinden faydalanırsa yanlış teşhislerin marjını önemli ölçüde azaltabilmektedir.

Yapay zeka akıllı davranışı karakterize eden yetileri anlamaya ve modellemeye çalışan temel bir bilimdir [7]. Yapay zekanın yıllar içinde gelişimi karar destek sistemlerinin gelişimini etkilemiş ve hızlandırmıştır. Yapay zeka bilimi genel olarak kural tabanlı bireysel çözümleri, öğrenmeye dayalı genel çözümlere dönüştürmüştür [8]. Uzmanlaşmış kişi uzmanlaştığı alana yani dar problem sınıflarına odaklandığından dolayı yapay zekanın en büyük ilerleme kaydettiği alanlardan biri yüksek eğitilmiş bir uzmanın akıl yürütmesini taklit etmektir [9]. Zaman içerisindeki gelişim bu tür sistemlerden beklentileri arttırmıştır. Bu alandaki çalışmalar insanların zekasını taklit etmekten ziyade veri kümelerini kullanarak kendi kendine öğrenip verilen görevleri yerine getiren sistemlere yönelmiştir. Makine öğrenimi bilgisayarın belirli bir görevi gerçekleştirmek için bir sorunu nasıl çözeceklerini veri setinden yararlanarak öğrenen yapay zekanın bir alt kümesidir [10]. Bu tür sistemler daha fazla veri seti kullanılarak gelişirler [11]. Makine öğreniminin önde gelen yöntemlerinden biri derin öğrenmedir. Derin öğrenme yapay sinir ağı adı verilen insan beyninin yapısal ve işlevsel özelliklerinden ilham alan algoritmalarla oluşur [12]. Derin öğrenme, yapay zeka ile ilgilenen araştırmacılarının en önemli problemlerin çözümünde büyük ilerlemeler kaydetmiştir [13]. Derin öğrenme metotları veri setinden elde edilen değerlerden kademeli olarak kendini geliştiren geri yayılım algoritmaları sayesinde yüksek boyutlu ve karmaşık yapıları görüntü işleme gibi birçok görevde oldukça değerli performans sergilemektedir.

Diş hekimliği alanında başarılı bir tedavi planlaması için öncelikle hastalığa doğru teşhisin konulması gerekmektedir. Uzmanlar hastalık teşhisi için ağız dışı, ağız içi ve radyolojik muayene yöntemlerini kullanırlar. Diş hekimleri teşhis ve tespit amaçlı sıklıkla farklı ilgi alanlarını görselleştiren çeşitli radyografi türlerini kullanırlar [14]. Karar destek

sistemlerinin yıllar içerisindeki gelişimi diş hekimliği alanını da etkilemiş, teşhis ve tespit amaçlı derin öğrenme uygulamaları üzerine çalışılmıştır. Derin öğrenme algoritmalarının tıp alanındaki tanınabilirliği, insan uzmanlığı seviyelerine yaklaşmakta ve bilgisayar destekli tanının rolünü ikinci görüş aracından daha işbirlikçi bir yapıya dönmesine yol açmaktadır [14]. Diş hekimliğinde derin öğrenmenin kullanımı ortodonti, periodontoloji, endodonti, dental radyoloji ve adli tıp dahil olmak üzere birçok alanda sınıflandırma, segmentasyon ve tespit görevlerinde umut verici sonuçlar göstermiştir [15]. Diş hekimliğindeki derin öğrenme çalışmaları birçok patolojiyi tespit etmede umut verici olduğu bilinmektedir [16]. Bu tür çalışmaların doğruluğu günlük kullanımda daha fazla değerlendirilmesi için geliştirilmeye devam etmektedir.

Bu çalışmada periapikal radyografiler üzerinden diş çürüğü tedavisi görmüş dolguların otomatik olarak tespiti için diş hekimine yardımcı karar destek sistemi üzerine çalışılmıştır. Bu sistem sayesinde diş hekimlerinin maliyet ve zamanın etkili kullanılmasının sağlanması ve insan yorumu ihtiyacını azaltıp tıbbi hataların sayısının azaltılması amaçlanmıştır. Çalışmada iki aşamalı Faster R-CNN ve tek aşamalı SSD, RetinaNet, YOLOv3 dedektörleri DarkNet-53, VGG16, ResNet50 ve ResNet101 özellik çıkarıcılarıyla kullanılmıştır. Kullanılan her bir model için ortalama kesinlik, doğruluk, kesinlik, duyarlılık ve F1-Skor performans değerlendirme metrikleri elde edilmiş, ayrıca modellerin çalışma hızları açısından incelemek amacıyla eğitim süreleri irdelenmiştir. Faster R-CNN modeli hem ResNet50 hem de ResNet101 özellik çıkarıcılarıyla kullanılmış ve performans metrikleri elde edilmiştir. Bu sayede özellik çıkarıcılarının katman sayısı artışının performansı ve eğitim süresini nasıl etkilediği konusunda çıkarımda bulunulmuştur. Bu değerlendirmelerden en iyi iki sonuç veren Faster R-CNN ResNet101 ve YOLOv3 modellerinin kesinlik-duyarlılık grafikleri üzerinden modelin çalışması hakkında bazı önemli ipucu veren eğri altında kalan alan (AUC) değerlerinin değişimi kıyaslanmış ve modellerin hangi durumda hata yaptığı yorumlanmıştır.

2. LİTERATÜR ARAŞTIRMASI

Yapay zeka uygulamaları, modern insan yaşamının tüm alanlarında yaygınlaşan bir gerçeklik haline gelmektedir. Yapay zeka, tıbbi karar verme sürecinde de uygulanmış ve bu yapay zeka sistemleri, uzman olmayan kişilerin uzman düzeyinde bilgi edinmesine yardımcı olabilir hale gelmiştir [18]. Sağlık alanında karar alma aşamasında uzman sayılarındaki eksiklik, uzmanların sezgisel olarak karar verirken hata yapabilmesi, yorgunluğa veya dikkatsizliğe bağlı olarak gözden kaçırılacak bulgular gibi birçok zorluk mevcuttur. Bu yüzden akademik alanda karar verme aşamasında uzmanlara destek verecek hızlı, doğru ve otomatik sistemler üzerinde çalışmalar yapılmış ve yoğun bir şekilde yapılmaya devam etmektedir. Tezin bu kısmında sağlık alanında uzmanlara destek verebilecek sistemler ile ilgili makale ve çalışmalardan bahsedilmiştir.

Mario W.L. Moreira ve arkadaşları sağlık alanında akıllı karar destek sistemlerinin son durumlarının derinlemesine bir incelemesini sunmuşlardır. Literatürde çalışılan en umut verici 16 adet çalışmayı uygulama alanı, yayın yılı, kullanılan yaklaşım metodu, çalışmalardaki temel amaç ve o alanda yapılabilecek gelecek çalışmalara göre analiz etmiş ve özetlemişlerdir. Kronolojik olarak bu araştırmanın amacı incelenen alanların açık konularını, niteliklerini ve karşılaşılan birincil zorluklarını belirleme ve bu alanlara genel bir tartışma sunmaktır. Bu araştırmalarının sonucunda akıllı karar destek sistemlerinin mevcut yaklaşımları önemli ölçüde iyileştirebileceğini uzmanlardan elde edilen bilgilerin destek sistemlerinden elde edilen bilgilerle desteklenebileceğini vurgulamışlardır [19].

Riccardo Miotto ve arkadaşları sağlık alanında derin öğrenme uygulamalarının önemli gördükleri 32 adet çalışmayı incelenmişlerdir. Bu çalışmalarda kullanılan veri tipleri, uygulama alanı, kullanılan modeller, uygulamalarda karşılaşılan zorluklar araştırılarak literatür araştırması yapılmıştır. Karmaşık, yüksek boyutlu ve heterojen biyomedikal verilerde yapay sinir ağı modelleriyle derin öğrenme modelleri kıyaslanmış ve biyomedikal verilerde katmanlı denetimsiz ön eğitim sayesinde derin öğrenme metotlarının yapay sinir ağı metotlarına göre daha iyi tahminler sunduğu sonucuna varılmıştır. Ayrıca derin öğrenme uygulamalarının tıp alanında umut verici sonuçları olmasına rağmen veri boyutu, veri kalitesi, geçicilik, etki alanı karmaşıklığı ve yorumlanabilirlik gibi zorlukları olduğu vurgulanmıştır [20].

Anandhavalli Muniasamy ve arkadaşları klinik karar destek sistemlerinde derin öğrenme uygulamaları çerçevesinde derin öğrenme metotlarının kısıtları, bu metotların birbirlerine göre avantajları, derin öğrenme araçları ve bu araçların özelliklerine genel bir bakış açısı sunmuşlardır. Bu çalışmada makale arama motoru olan PubMed’de anahtar kelimeler kullanılarak sağlık alanında derin öğrenme uygulamaları aranmış ve genel bilgiler elde edilmiştir. Araştırılan makalelerin 80’ine yakın MRI, 60’ına yakın CT görüntüleme cihazları kullanılmıştır. Kronolojik olarak bakıldığında sağlık alanında derin öğrenme uygulamaları 2013 yılında 300 civarında makale yayınlanmış, 2017 yılına geldiğimizde ise 1500’e yakın bir makale yayınlandığı vurgulanmıştır. Derin öğrenme metotları olan evrimsel sinir ağları, tekrarlayan sinir ağları, derin inanç ağları ve derin sinir ağları avantajları ve kısıtları sunulmuştur. Ayrıca Tensorflow, MXNet, Keras ve ConvNet gibi derin öğrenme araçlarının özelliklerinden bahsedilmiştir. Tüm bu araştırmalar sonucunda sağlık alanında ilerleyen yıllarda derin öğrenme uygulamalarının kullanımının hızlı bir şekilde artacağı vurgulanmıştır [21].

Diş hekimliği alanında sağlık alanının diğer alt alanlarında olduğu gibi uzmanların birçok dental görüntü üzerinden tekrarlanan değerlendirmeler yapması gerekmektedir. Bilgisayar destekli teşhis sistemleri klinisyenlere karar vermede yardımcı olabilir hale gelmiştir [22]. Derin öğrenme tabanlı destek sistemleri böyle değerlendirme süreçlerinde verilerin hızlı işlenmesi ile anında analiz yeteneği, daha etkin kararlar gibi yararlı katkılar sunmaktadır. Literatür araştırmasının bu kısmından sonra derin öğrenme uygulamalarının diş hekimliği alanında uygulama alanlarına yönelik çalışmalardan bahsedilmiştir.

Jae-Joon Hwang ve arkadaşları diş hekimliği alanında oral radyoloji alanında uygulanan derin öğrenme ile ilgili makaleleri gözden geçirmiştir. Gözden geçirdiği makalelerde yazar ve yazar yılı gibi değişkenlere ek olarak kullanılan derin öğrenme mimarisi, eğitim veri seti boyutu, değerlendirme sonuçları, kullanılan görüntüleme yöntemleri ve yapılan uygulamaların avantaj ve dezavantajlarını içeren çok yararlı bilgiler sunmuşlardır. Yaptıkları araştırmalarda 2018’e kadar dental görüntülerden nesne tespiti görevinde derin öğrenme ve yapay sinir ağı kullanılan uygulamaların bir araştırma makalesi haline getirmişlerdir. Sonuç olarak 209 makale elde edilmiş olup bazı filtreler kullanılarak en son 25 hakemli makale elde edilmiştir. Bu makaleler için yukarıda belirtilen bilgiler sunulmuştur. Bu makalelerde genel olarak tek bir derin öğrenme yöntemi ve tek bir özellik çıkarıcı kullanılmıştır. Bu

makalelerin çoğu dişlerle ilgilidir ancak diş eti, periodontiyum, diş arkı, osteoporoz ve anatomik işaretler gibi diğer konular da derin öğrenme kullanılarak çalışılmıştır [23].

Mircea Paul Muresan ve arkadaşları tıbbi personellerin teşhise ilişkin doğru kararlar alması için otomatik diş ve diş problemi sınıflandırması yapılması için yeni bir yaklaşım önermişlerdir. Veri seti olarak ellerinde 2000 radyografi görüntüsü olmasına rağmen 1000 radyografi seçilip bu görüntülerde etiketleme ve eğitme işlemi yapılmıştır. Kendi önerdikleri yaklaşım ile sınırlayıcı kutu üretici olarak YOLO9000, sınıflandırıcı olarak ERFNet kullanan metodun performans metriklerini ve ortalama çalışma sürelerini karşılaştırmışlardır. Kıyaslama yapılacak metod ile 0,68 doğruluk, 0,98 kesinlik, 0,68 duyarlılık ve 0,89 f1 skor elde etmişlerdir. Kendi önerdikleri metod ile 0,89 doğruluk, 0,98 kesinlik, 0,91 duyarlılık ve 0,93 f1 skor sonuç elde edilmiş olup kıyasladıkları metoda göre daha iyi sonuç alındığı vurgulanmıştır. Zamansal açıdan değerlendirildiğinde ise kıyaslanan metod ile ortalama çalışma süresi 300 saniyeyken kıyasladıkları metod ile 60 saniye gibi kısa bir ortalama çalışma süresi elde etmişlerdir [24].

Jae-Hong Lee ve arkadaşları periapikal radyografiler üzerinden diş çürüklerinin tespiti ve teşhisi için CNN modeli kullanmışlardır. Veri seti olarak toplam 3000 adet periapikal görüntü kullanılmıştır. Bu görüntülerin 2400 adet periapikal radyografi görüntüsü eğitim ve doğrulama amaçlı, kalan 600 adet görüntü ise test amaçlı kullanılmıştır. Ön işleme ve öğrenim modeli olarak önceden eğitilmiş GoogleNet Inception v3 CNN ağı kullanılmıştır. Bu çalışmanın değerlendirilmesi için performans metriği olarak doğruluk, duyarlılık, özgüllük pozitif öngörü değeri, negatif öngörü değeri ROC eğrisi ve eğri altında kalan AUC değeri kullanılmıştır. Değerlendirmeler azı diş, küçük azı diş ve hem azı diş hem de küçük azı dişlerde olan çürükler olmak üzere üç ayrı kategoriye ayrılarak değerlendirilmiştir. Doğruluk değeri küçük azı diş, azı diş ve her iki bulgunun olduğu örnekler olmak üzere sırasıyla 0,89, 0,88 ve 0,82 olarak hesaplanmıştır. AUC değeri sırasıyla 0,917, 0,890 ve 0,845 olarak hesaplanmıştır ve bu sonuçlara bağlı olarak en iyi sonuçları küçük azı dişinde bulunan çürüklerde aldığı vurgulanmıştır. Tüm değerler değerlendirildiğinde ise evrimsel sinir ağı modelinin diş çürüğü teşhisinde potansiyel olarak etkili ve verimli bir şekilde kullanılabileceği sonucuna varmışlardır [25].

Xuan Zhang ve arkadaşları kameralar ile çekilmiş oral görüntülerden diş çürüklerini tespit etmek için ConvNet'e dayalı bir derin öğrenme modeli geliştirmiş ve bu modeli doğruluk,

hassasiyet ve AUC değerlerine göre değerlendirmişlerdir. Veri seti olarak 625 gönüllüden alınan 3932 fotoğraf kullanılmıştır. Sonuç olarak bu model ile 0,85 AUC değeri, görüntü bazında 0,81 hassasiyet ve kutu bazında 0,64 hassasiyet değerleri elde edilmiştir. Bu sonuçlar değerlendirildiğinde dental görüntüleme cihazlarından elde edilen görüntülerin maliyet düşünülürse tüketici kameralarından çekilmiş bu oral fotoğraflardan çürük tespiti uygulamasının umut verici olduğu sonucuna varmışlardır [26].

Stefano Corbella ve arkadaşları diş hekimliğinin çeşitli alanlarında özellikle yüksek doğruluk iddiasında bulunan 28 çalışmayı incelemiştir. Bu makaleleri incelerken bu uygulamaları ileriye dönük insanlara fikir verme amacıyla incelediği her makale için potansiyel metodolojik zayıflıklarını yani karşılaştıkları sınırlamaları eleştirel bir bakış açısıyla değerlendirmişlerdir. Sonuç olarak inceledikleri makalelerde genel anlamda görüntü sayısındaki azlığa dikkat çekerek klinik uygulamalarda tanısal destek araçları olarak evrimsel sinir ağlarının kullanılması için zamanla kademeli olarak daha fazla bilimsel kanıt gerektiğini vurgulamışlardır [27].

Michael G. Endres ve arkadaşları enfeksiyon, granülom, kist ve tümör gibi tanıları 24 oral cerrah ile derin öğrenme algoritması tabanlı bir nesne tespiti uygulamasını karşılaştırmışlardır. Bu çalışmada 2902 adet anonim panoramik radyografi kullanılmıştır. Bu çalışmada oral diş cerrahlarının ortalama pozitif prediktif değeri 0,69 yani diş hekimlerinin yüzde 31 olarak vakaları yanlış tespit edebildiği, derin öğrenme tabanlı uygulamanın 0,6 hassasiyet ve 0,58 F1 skor değerleri ile derin öğrenme tabanlı uygulamanın 24 oral cerrahın 14'ünden daha iyi performans sergilediği sonucuna varmışlardır [28]. Bu çalışma bize bu tarz derin öğrenme uygulamalarının oral diş cerrahlarına destek sistemlerinin başarılı olma potansiline sahip olduğunu göstermektedir.

Zheng ve arkadaşları derin çürük ve pulpitis tespiti yapmayı amaçlamışlardır. Veri seti olarak çalışmalarında 844 periapikal görüntü kullanmışlardır. Derin öğrenme modeli ve özellik çıkarıcı olarak ResNet18, VGG19, evrimsel sinir ağları ve InceptionV3 modelleri kullanmışlardır. Sonuç olarak çok modlu yaklaşımın 0,82 doğruluk, 0,81 kesinlik ve 0,85 spesifite metriği ile ResNet18'den daha iyi bir sonuç verdiği belirtilmiştir [29].

Ragda Abdalla-Aslan ve arkadaşları panoramik radyografiler üzerinde çeşitli restorasyonları otomatik olarak tespit etmeyi ve sınıflandırmayı amaçlamışlardır. Veri seti olarak 83

panoramik radyografide toplam 738 dental restorasyon örneği kullanılmıştır. Sınıflandırma görevinin gerçek restorasyon kategorileri arasında ayırım yapmada genel doğruluğu 0,93 olarak elde etmişlerdir [30].

Diş hekimliği alanında diş çürüğü tedavisinde kullanılan yöntemlerden biri dolgudur. Dolgu tedavisinin yaygın olarak kullanılmasından dolayı diş dolgularının tespiti için birçok derin öğrenme çalışması yapılmış ve yapılmaya devam etmektedir. Literatür araştırmasının bu kısmından sonra bu tezde de çalışılan derin öğrenme uygulamalarının diş hekimliği alanında dolgu teşhisi ve tespiti uygulamalarına yönelik çalışmalardan bahsedilmiştir.

Atıf Emre Yüksel ve arkadaşları panoramik radyografiler üzerinden periapikal lezyon tedavisi, diş dolguları, kök kanal tedavisi, cerrahi ve geleneksel çekim tedavileri olmak üzere beş farklı diş tedavisini ve diş bölütleme görevini otomatik olarak uygulayan derin öğrenme uygulaması üzerine çalışmışlardır. Veri seti olarak 1005 adet anonim panoramik radyografiler kullanılmıştır. Bu görüntülerde 247 adet periapikal lezyon, 3051 adet diş dolgusu, 610 adet diş kanal tedavisi, 865 adet cerrahi ve 195 adet geleneksel çekim tedavileri bulunmaktadır. Bu çalışmada bölütleme görevinde ortalama kesinlik değeri 0,89 olurken tedavilerin tespiti görevinde 0,59 olarak bulmuşlardır [31].

Faruk Öztekin ve arkadaşları panoramik görüntüler üzerinden panoramik görüntü üzerinden amalgam ve kompozit dolguların otomatik olarak algılanması ve segmentasyonu için derin öğrenme uygulaması üzerine çalışmışlardır. Veri seti olarak 250 adet anonimleştirilmiş panoramik görüntü kullanmışlardır. Çalışmalarında U-Net modelinde Resnet50 ve ResNet101 özellik çıkarıcıları kullanılmış ve en iyi sonucu ResNet50 özellik çıkarıcısından elde etmişlerdir. ResNet50 modelinin kullanıldığı modelden segmentasyon görevinde birleşimin kesişimi değerini sırasıyla eğitim verisetinde 0,948 ve doğrulama verilerinde ise 0,794 olarak elde etmişlerdir [32].

Başaran ve arkadaşları panoramik radyografilerde tanisal bir çizelge yapmayı amaçlamışlardır. Veri seti olarak 1084 adet panoramik radyografi kullanmışlardır. Derin öğrenme modeli olarak Faster R-CNN modeli InceptionV2 mimarisi ile kullanmışlardır. Radyografiler üzerinden 10 farklı dental vakanın tespiti amaçlanmış ve dolgu tespiti için 0,86 kesinlik ve 0,87 duyarlılık elde etmişlerdir [33].

Bouchahma ve arkadaşları diş röntgeni görüntüleri üzerinden diş çürümesini otomatik olarak tespit etmek için bir derin öğrenme yöntemi önermişlerdir. Diş çürükleri için florür, dolgu ve kanal olmak üzere üç tedavi yöntemi önerisi bulunmayı amaçlamaktadır. Veri seti olarak 200 anonim röntgen görüntüsü kullanılmıştır. Modelin genel doğruluğu 0,87 olurken, dolgu tespiti için 0,77 oranında daha düşük sınıflandırma oranı elde etmişlerdir [34].

Anıl Gürses ve arkadaşı panoramik görüntüler üzerinden kanal tedavisi, dolgu tedavisi, implant ve diş teli tespiti görevlerinde GoogleNet, DenseNet ve ResNet modellerinin performanslarını kıyaslamışlardır. Veri seti olarak 507 adet implant, 544 adet kanal tedavisi, 521 adet dolgu tedavisi ve 515 adet diş teli örneği içeren toplam 3013 adet diş örneği kullanmışlardır. Bu görüntülerin 2113 adetini eğitim amaçlı 900 adetini test amaçlı kullanmışlardır. Tüm tespit görevlerinde GoogleNet modelinden 0,89, DenseNet modelinden 0,94 ve ResNet modelinden 0,93 başarı değeri elde etmişlerdir. Dolgu tedavisi tespiti görevinde DenseNet modelinden 0,93 kesinlik ve 0,92 duyarlılık, GoogleNet modelinden 0,93 kesinlik ve 0,67 duyarlılık, ResNet modelinden 0,89 kesinlik ve 0,86 duyarlılık değeri elde edilmiştir [35]. Tüm sonuçlara bakılarak DenseNet modelinin diğer modellere göre daha iyi sonuç verdiği görülmektedir.

3. VERİ SETİ

Diş hekimliği alanında tanı ve tedavi amaçlı çeşitli radyolojik görüntüleme yöntemleri kullanılmaktadır. Bu yöntemler ağız içi ve ağız dışı radyolojik görüntüleme teknikleri olarak ikiye ayrılmaktadır. Yaygın olarak kullanılan ağız içi görüntüleme yöntemleri bite-wing radyografi, periapikal radyografi ve oklüzal radyografi olmak üzere üç çeşitten oluşmaktadır. Bite-wing yöntemi genellikle ağız içerisinde direkt olarak görülmeyen yan yana iki diş arasında oluşan diş çürüklerinin tespiti için kullanılmaktadır. Bu yöntemde diş kökleri görünmemektedir. Periapikal radyografiler diş köklerinin de içeren bir filmde en fazla 2 ile 4 adet arasında diş görüntülenebilmektedir. Oklüzal radyografi yatay olarak dişlerin, çene kemiğinin veya kanalların incelenmesinde kullanılan yöntemdir. Bu yöntemde sadece üst veya alt çeneye ait görüntü elde edilebilmektedir.

Ağız dışı görüntüleme yöntemleri ise panoramik radyografiler, dental tomografi, sefalometrik projeksiyonlar ve sialografi görüntüleme olmak üzere dört çeşitten oluşmaktadır. Dental tomografi ayrıntılı bir şekilde görüntülenmek istenen bölgenin biçimde incelenmesini sağlayan görüntüleme yöntemidir. Bu görüntüleme yönteminde diğer yöntemlerin detaylı olarak görüntüleyemediği kemik ve yumuşak doku incelemesi yapılabilmektedir. Bu görüntüleme yönteminde birçok kesitte ışınlama yapıldığından diğer yöntemlere göre daha yüksek radyasyon dozu alınmaktadır. Sefalometrik görüntüleme kemik ve yumuşak dokunun farklı pozisyonların tek bir filmde görüntülenmesidir. Bu yöntem genellikle ortodonti ve çene tedavilerinde kullanılmaktadır. Düşük maliyet ve radyasyon avantajları olmasına rağmen elde edilen kesit anatomik yapının görüntülenmesi açısından sınırlıdır. Sialografi görüntüleme yöntemi ise diğer yöntemlerden farklı olarak tükürük bezlerinin ayrıntılı bir şekilde incelenmesine olanak sağlayan yöntemdir.

Çizelge 3.1. Dental görüntüleme yöntemlerinin radyasyon doz miktarı, avantaj ve dezavantajları [36-39]

Görüntüleme Yöntemi	Radyasyon Dozu (mSv)	Avantaj	Dezavantaj
Bite-wing radyografi	0,0004	Yan yana iki diş arasında çürüme tespiti kolay yapılabilmesi	Diş köklerinin görünmüyor olması
Periapikal radyografi	0,001-0,006	Diş köklerinin ayrıntılı incelenmesi	Sınırlı bölgenin görüntülenmesi
Oklüzal radyografi	0,002-0,007	Maksilla(üst çene kemiği) ve mandibula (altçene kemiği) patolojilerinin ayrıntılı incelenmesi	Genellikle çene kemiği tanılarında kullanılması
Dental tomografi	0,2-0,5	Üç boyutlu görüntüleme	Yüksek maliyet ve radyasyon dozu
Panoramik radyografi	0,07	Geniş alanlı tarama	Düşük çözünürlüklü görüntü
Sefalometrik görüntüleme	0,04- 0,05	Düşük radyasyon ve maliyet	Yaygın olarak kullanılmaması ve kesit anatomik yapının sınırlı olması
Sialografi görüntüleme	-	Tükürük bezlerinin ayrıntılı incelenmesi	Sınırlı bölgenin görüntülenmesi

Panoramik radyografi diş, diş etrafındaki kemik doku ve çene kemiğinin ayrıntılı bir şekilde incelenmesini sağlayan yöntemdir. Bu yöntemin kullanılmasının nedenleri tüm diş, yumuşak ve kemik dokularının tek bir filmde görüntülenebilmesi, geniş bir alanda görüntüleme yapılmasına rağmen çok düşük radyasyon dozunun olması, ağız dışı görüntüleme tekniği olduğundan ağzını açamayan hastalarda pozisyon kolaylığı sağlaması ve bu yöntemin diğer yöntemlere göre daha yaygın kullanması ve düşük maliyetli olması olarak sıralanabilir. Panoramik radyografide geniş bir alanda tarama yapılmasına rağmen yaklaşık olarak 0,03 mSv radyasyon dozu uygulanmaktadır. Nagihan Koç ve arkadaşı panoramik radyografi endikasyonları ve görüntülemeye izlenen anatomik yapılar üzerinde çalışma yapmışlardır. Panoramik radyografinin diğer görüntüleme yöntemlerine göre yüz kemiklerini, dental arkları, dişleri ve komşu anatomik yapıları kapsamlı bir şekilde göstermesi, hızlı ve kullanışlı bir teknik olması ,diğer ağız içi görüntüleme yöntemlerine göre daha kolay uygulanması, daha düşük radyasyon dozu gibi avantajları olmasına rağmen diğer ağız içi yöntemlerine göre daha düşük çözünürlükte görüntüler ve görüntülerdeki detay bilgilerin

kısıtlı olması nedeniyle anatomik yapıların değerlendirilmesinin zor olduğu sonucuna varmışlardır [40].

Esin Bozdemir ve arkadaşı panoramik radyografiler üzerinde diş çürüğü, lezyon ve kök rezorpsiyonu gibi patolojilerin tanılarındaki doğruluğu periapikal ve bite-wing radyografi yöntemleriyle kıyaslamışlardır. Bu çalışmada veri seti olarak 241 hastadan alınmış panoramik radyografi, aynı hastalardan alınmış 195 periapikal radyografi ve 46 bite-wing radyografi görüntüsü kullanılmıştır. Ayrıca panoramik görüntülerden en çok tespit edilen tanıların %57,7 ile periapikal lezyon ve %20,3 ile çürük tanısı olduğundan bahsedilmiştir. Bu diş patolojilerinin tanılarında kullanılan panoramik ve periapikal radyografi görüntüleme yöntemleri kıyaslandığında 241 hastanın 122'sinde yani %50,6'sında yanlış tanı yapıldığı, diş patolojilerinin panoramik radyografide görünmesine rağmen periapikal radyografide görünmediği sonucuna varmışlardır [41]. Bu çalışma panoramik görüntülerin düşük çözünürlükte olmasının nesne tespiti görevlerini olumsuz etkilediği sonucu çıkarılabilir. Bütün görüntüleme yöntemlerinin avantajları ve dezavantajları değerlendirildiğinde bu çalışmada periapikal radyografi görüntüleri kullanılmıştır.

Bu çalışmada veri seti olarak 2018 ile 2020 yılları arasında anonim yani kişisel bilgiler içermeyen 18 yaşından büyük 138 periapikal radyografi görüntüsü kullanılmıştır. Bu görüntülerde hareket, artefaktların ve pozisyon kaynaklı tam kök gelişiminin tamamlanmadığı periapikal görüntüler dahil edilmemiştir. Görüntüler NEMA tarafından bilgisayarlı tomografi, ultrason ve emar görüntülerinin görüntülenmesi için geliştirilmiş bir standart olan DCM formatındadır. DCM formatında olan periapikal radyografi görüntüleri MATLAB programlama dili ile PNG formatına çevrilmiştir. Veri seti insanlardan elde edilen veriler ile tıbbi araştırmaların etik standartlarını belirleyen Dünya Tıp Birliği tarafından yayınlanan Helsinki bildirgesi gözetilerek hazırlanmıştır. Bu veri seti Ankara Yıldırım Beyazıt Üniversitesi Etik Değerlendirme Kurulu tarafından onaylanmıştır, onay numarası 2021-69'dur.



Resim 3.1. Periapikal radyografiler üzerinde dolgu tedavisi uygulanan diř örnekler

4. DERİN ÖĞRENME TABANLI TESPİT MODELLERİ

4.1. Özellik Çıkarıcılar


4.1.1. VGG16

Karen Simonyan ve Andrew Zisserman tarafından 2014 yılında ismini aldığı Oxford Üniversitesinde Görsel Geometri Grubu (Visual Geometry Group) tarafından tanıtılmış evrişimsel sinir ağı tabanlı yapay sinir ağı modelidir. 2014 yılında düzenlenen ILSVRC yarışmasında 1000 farklı kategoride 1000 resim bulunan veri seti ile %7,3 hata oranıyla nesne tespiti ve sınıflandırma görevlerinde sırasıyla birinci ve ikinci model olmuştur. Evrişimsel sinir ağlarında bir giriş, bir çıkış ve mimariye göre değişen sayıda gizli katman bulunur. Simonyan ve Zisserman diğer evrişimsel sinir ağlarından yola çıkarak zamanında kullanılan diğer tekniklere göre çok küçük (3x3) boyutunda evrişim filtreli bir mimari kullanarak derinliği arttırmışlardır. Şekil 4.1’de VGG mimarilerinin model yapıları gösterilmektedir. Bu çalışmada C harfi ile gösterilen VGG16 modeli kullanılmıştır.

ConvNet Configuration					
A	A-LRN	B	C	D	E
11 weight layers	11 weight layers	13 weight layers	16 weight layers	16 weight layers	19 weight layers
input (224 × 224 RGB image)					
conv3-64	conv3-64 LRN	conv3-64 conv3-64	conv3-64 conv3-64	conv3-64 conv3-64	conv3-64 conv3-64
maxpool					
conv3-128	conv3-128	conv3-128 conv3-128	conv3-128 conv3-128	conv3-128 conv3-128	conv3-128 conv3-128
maxpool					
conv3-256 conv3-256	conv3-256 conv3-256	conv3-256 conv3-256	conv3-256 conv3-256 conv1-256	conv3-256 conv3-256 conv3-256	conv3-256 conv3-256 conv3-256 conv3-256
maxpool					
conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512 conv1-512	conv3-512 conv3-512 conv3-512	conv3-512 conv3-512 conv3-512 conv3-512
maxpool					
conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512 conv1-512	conv3-512 conv3-512 conv3-512	conv3-512 conv3-512 conv3-512 conv3-512
maxpool					
FC-4096					
FC-4096					
FC-1000					
soft-max					

Şekil 4.1. VGG mimarisi model yapısı [42]

VGG16 mimarisindeki 16 sayılı ağırlığı olan 16 öğrenilebilir parametre katmanını ifade etmektedir. Şekil 4.2’de görülebileceği üzere VGG16 mimarisinde 13 konvolüsyonel katman, 5 en büyük havuzlama katmanı ve 3 yoğunluk katmanı olmak üzere toplam 21 katman bulunmaktadır.



Şekil 4.2. VGG16 mimarisi [43]


Karen Simonyan ve Andrew Zisserman Şekil 4.1’de gösterilen model yapılarını tek bir test ölçeğinde VGG mimarilerini kıyaslayacak test yapmışlardır ve Şekil 4.3’deki sonuçlar elde edilmiştir. Katman sayısı arttıkça hata oranlarının azaldığı gözlemlenmektedir.

ConvNet config. (Table 1)	smallest image side		top-1 val. error (%)	top-5 val. error (%)
	train (S')	test (Q)		
A	256	256	29.6	10.4
A-LRN	256	256	29.7	10.5
B	256	256	28.7	9.9
C	256	256	28.1	9.4
	384	384	28.1	9.3
	[256;512]	384	27.3	8.8
D	256	256	27.0	8.8
	384	384	26.8	8.7
	[256;512]	384	25.6	8.1
E	256	256	27.3	9.0
	384	384	26.9	8.7
	[256;512]	384	25.5	8.0

Şekil 4.3. Tek bir test ölçeğinde vgg mimarilerinin hata oranları [42]


4.1.2. ResNet

Kaiming He, Xinangyu Zhang, Shaoing Ren ve Jian Sun tarafından 2015 yılında tanıtılan, ILSVRC yarışmasında %3,57 gibi düşük bir hata oranıyla sınıflandırma görevinde birinci olan ve genellikle daha derin evrimsel sinir ağlarda özellik çıkarıcı olarak kullanılan bir yapay sinir ağıdır. Günümüzde derin öğrenme mimarileri karmaşık problemleri çözme amacıyla çok sayıda katman ekleyerek daha derin bir yapıya dönüştürülmektedir. Kaiming He ve arkadaşları katman sayısı arttıkça hata yüzdelere etkisini görmek amacıyla CIFAR-10 veri setinde Şekil 4.6'da gösterilen düz mimari yapısında 56 ve 20 katmandan oluşan modelleri kıyaslamışlardır. Katman sayısı artırıldığında hata oranının azalması beklenmesine rağmen katman sayısı yüksek olan modelin optimize edilememesinden dolayı Şekil 4.4'de görülebileceği gibi katman sayısı yüksek modelin hata oranının daha yüksek olduğunu gözlemlemişlerdir.




Şekil 4.4. Düz mimari yapısında 56 ve 20 katmanlı modellerin hata oranı grafikleri [44]

ResNet mimarisinin diğer mimarilere göre en büyük farkı Şekil 4.5'de görüleceği gibi iki aktivasyon fonksiyonu olan RELU ile doğrusal katman arasında artık bağlantısı olmasıdır. Bu bağlantı sayesinde bazı katmanları es geçerek öğrenme işleminin daha hızlı ve optimizasyon sorunun önüne geçilmesi amaçlanmıştır.



Şekil 4.5. Artık kalıntı bağlantısı[44]

ResNet yapay sinir ağı modeli VGG19 modeli temel alınarak tasarlanmıştır. Şekil 4.6’da görülebileceği gibi önce VGG19 modelinden 34 katmanlı daha az filtre kullanılarak düz bir mimari tasarlanmış sonrasında bu tasarlanmış düz mimari yapısına artık bağlantılar yapılmıştır.




Şekil 4.6. ResNet yapay sinir ağının tasarlanma aşamaları [44]

COCO nesne tespiti veri setinde Faster R-CNN modelinde özellik çıkarıcı olarak VGG16 ve ResNet101 sinir ağı modelleri kıyaslanmış ve ResNet101 modeli VGG16 modeline göre %28 daha iyi sonuç verdiği gözlemlenmiştir [44].


Kaiming He, Xinangyu Zhang, Shaoing Ren ve Jian Sun 1000 sınıftan oluşan ImageNet veri setinde artık bağlantıların yararlı bir sonuç verip vermediğini görmek amaçlı Şekil 4.6'da ortada görülen düz mimari ile artık bağlantı çekildikten sonraki ResNet mimarisinin sonuçlarını kıyaslamışlardır. Düz ağda 18 ve 34 katmanlı modellerde sırasıyla 27,94 ve 28,54 hata oranına sahipken, ResNet modelinde 18 ve 34 katmanlı modellerde sırasıyla 27,88 ve 25,03 hata oranlarına ulaşmışlardır [44]. Bu sonuçlardan görülebileceği gibi artık bağlantılı mimari 34 katmanlı modelde %3,51 oranında iyileşme sağlamıştır.

Düz mimari yapısında katman sayısı arttığında hata oranlarının yükseldiğini gözlemlemiştik. Şekil 4.7'nin sol tarafındaki grafikte düz mimari yapısında katman sayısı arttığında hata oranının arttığını görebiliyoruz ancak artık bağlantı yapısı sayesinde Şekil 4.7'nin sağ tarafındaki grafikte katman sayısı arttığında hata oranının düştüğünü yani artık bağlantı yapısının optimizasyon probleminin önüne geçtiği sonucuna varılır.



Şekil 4.7. Düz mimari ile resnet modelinin katman sayılarına bağlı hata oranları [44]

ResNet34 modelinden ResNet50 modeline geçiş aşamasında ise ResNet34 modelindeki 2 katman arasındaki artık bağlantı 3 katmanlı artık bağlantı ile değiştirilerek elde edilir. Bu artık bağlantı yapısı Şekil 4.8'de gösterilmektedir, sol tarafta ResNet34 modeli için sağ tarafta ise ResNet50 modeli için artık bağlantı yapıları gösterilmiştir. ResNet101 modeli ise daha çok 3 katmanlı artık bağlantı kullanılarak elde edilebilir.



Şekil 4.8. ResNet34 ve ResNet50-101 modellerinin artık bağlantıları [44]

4.1.3. Darknet-53

Joseph Redmon ve Ali Farhadi tarafından 2018 yılında YOLOv2’de özellik çıkarıcı olarak kullanılan DarkNet-19 modeli temel alınarak YOLOv3’de özellik çıkarıcı olarak kullanılmak üzere tasarlanmış yapay sinir ağıdır. DarkNet-53 modelinde 3x3 ve 1x1 boyutunda evrimsel katman kullanılmaktadır. Şekil 4.9’da görülebileceği üzere DarkNet-53 modeli DarkNet-19’a göre daha derin 53 adet konvolüsyonel katman içerecek şekilde tasarlanmıştır.

Type	Filters	Size/Stride	output		Type	Filters	Size/Stride	output
Convolutional	32	3 X 3	224 x 224		Convolutional	32	3 x 3	256 x 256
Maxpool		2 x 2/2	112 x 112		Convolutional	64	3 x 3/2	128 x 128
Convolutional	64	3 X 3	112 x 112		Convolutional	32	1 x 1	
Maxpool		2 x 2/2	56 x 56	1x	Convolutional	64	3 x 3	
Convolutional	128	3 X 3	56 x 56		Residual			128 x 128
Convolutional	64	1 X 1	56 x 56		Convolutional	128	3 x 3/2	64 x 64
Convolutional	128	3 X 3	56 x 56		Convolutional	64	1 x 1	
Maxpool		2 x 2/2	28 x 28	2x	Convolutional	128	3 x 3	
Convolutional	256	3 X 3	28 x 28		Residual			64 x 64
Convolutional	128	1 X 1	28 x 28		Convolutional	256	3 x 3/2	32 x 32
Convolutional	256	3 X 3	28 x 28		Convolutional	128	1 x 1	
Maxpool		2 x 2/2	14 x 14	8x	Convolutional	256	3 x 3	
Convolutional	512	3 X 3	14 x 14		Residual			32 x 32
Convolutional	256	1 X 1	14 x 14		Convolutional	512	3 x 3/2	16 x 16
Convolutional	512	3 X 3	14 x 14		Convolutional	256	1 x 1	
Convolutional	256	1 X 1	14 x 14		Convolutional	512	3 x 3	
Convolutional	512	3 X 3	14 x 14	8x	Residual			16 x 16
Maxpool		2 x 2/2	7 x 7		Convolutional	1024	3 x 3/2	8 x 8
Convolutional	1024	3 X 3	7 x 7		Convolutional	512	1 x 1	
Convolutional	512	1 X 1	7 x 7	4x	Convolutional	1024	3 x 3	
Convolutional	1024	3 X 3	7 x 7		Residual			8 x 8
Convolutional	512	1 X 1	7 x 7		Avgpool		Global	
Convolutional	1024	3 X 3	7 x 7		Connected		1000	
Convolutional	512	1 X 1	7 x 7		Softmax			
Convolutional	1024	3 X 3	7 x 7					
Convolutional	1000	1 X 1	7 x 7					
Avgpool		Global	1000					
Softmax								

(a) Darknet-19

(b) Darknet-53

Şekil 4.9. DarkNet-19 ve DarkNet-53 mimarileri [45]

Joseph Redmon ve Ali Farhadi ImageNet veri seti üzerinden DarkNet-19, ResNet101, ResNet152 ve DarkNet-53 modellerini kıyaslama amacıyla test yapmışlardır. Şekil 4.10'da görülebileceği üzere DarkNet-19 modeline göre çok daha güçlü, ResNet101 ve ResNet152 modellerine göre daha verimli olduğu sonucuna varmışlardır. Şekil 4.10'da DarkNet-53 modelinin ResNet modellerine göre daha yüksek saniyede görüntü sayısı verdiği görülmektedir. Bu sonuç DarkNet-53 modelinin ResNet modellerinin çok daha fazla katman olması sebebiyle ResNet152 modeline göre 2 kat, ResNet101 modeline göre 1,5 kat hızlı olduğunu göstermektedir.

Backbone	Top-1	Top-5	Bn Ops	BFLOP/s	FPS
Darknet-19 [15]	74.1	91.8	7.29	1246	171
ResNet-101[5]	77.1	93.7	19.7	1039	53
ResNet-152 [5]	77.6	93.8	29.4	1090	37
Darknet-53	77.2	93.8	18.7	1457	78

Şekil 4.10. ImageNet veri seti üzerinden özellik çıkarıcı sonuçlarının karşılaştırılması [45]


4.2. Dedektörler

Nesne tespiti görevi için derin öğrenme yöntemlerini kullanan güncel yaklaşımlar iki kategoriye ayrılabilir. Kategorilerden biri R-CNN, Fast R-CNN, Faster R-CNN ve Mask R-CNN gibi mimarileri temsil eden iki aşamalı modellerdir. Bu tür mimariler iki katmandan oluşur, ilk katman bölge önerilerinin yani sınırlayıcı kutuların oluşturulması, ikinci katman her bölge önerisi için nesne sınıflandırması ve buna ek olarak sınırlayıcı kutu regresyonu yapılan katmandır. Bu yöntemler genelde daha yüksek doğrulağa sahip olmasına rağmen daha yavaş modellerdir. Diğer kategori SSD, YOLO ve RetinaNet gibi mimarileri temsil eden tek aşamalı modellerdir. Bu tür mimariler tek bir hat üzerinden sınırlayıcı kutuları ve nesne tespiti görevlerini doğrudan yapan mimarilerdir. Tek aşamalı mimariler bölge önerileri sunan yapıyı kullanmadığından dolayı daha hızlı ancak algılaması zor nesneler için tespit oranları iki aşamalı mimariler kadar yüksek değildir. Her nesne tespiti görevi için tek doğru bir model yoktur, modelin algılama doğruluğu ve algılama hızı nesne tespiti görevi için hangi mimarinin en doğru sonuç verdiğini önemli ölçüde etkilemektedir.

4.2.1. Tek aşamalı derin öğrenme tabanlı dedektörler

RetinaNet

Facebook yapay zeka araştırma ekibinde bulunan Tsung-Yi Lin, Priya Goyal, Ross Girshick, Kaiming He ve Piotr Dollar tarafından 2017 yılında tasarlanmış tek aşamalı dedektördür. Şekil 4.11’de görülebileceği üzere tek aşamalı RetinaNet mimarisi özellik çıkarıcı olarak ileri beslemeli ResNet mimarisini kullanır. RetinaNet dedektörü algılama hızı önemli olduğu uygulamalarda doğruluk oranını artırma amaçlı diğer modellerden farklı olarak iki önemli yenilik getirmiştir.




Şekil 4.11. Tek aşamalı retinanet dedektörünün mimarisi [46]

Bu yeniliklerden biri RetinaNet dedektörünün omurga ağı olan Nesne Tespiti için Özellik Piramit ağıdır. Özellik Piramit Ağı ile standart evrişimsel bir ağı yukarıdan aşağıya ve yanal bağlantılar ile zenginleştirilerek tek bir çözünürlüklü giriş görüntüsünden zengin, çok ölçekli bir özellik piramiti oluşturmayı amaçlamışlardır.

İkinci önemli yenilik ise odak kaybı yöntemidir. Bu yöntem çapraz entropi kaybı temel alınarak tek aşamalı nesne algılama modellerinin sınıf dengesizliği sorunun önüne geçmek amacıyla tanıtılmıştır. Tek aşamalı modeller bağlantı kutularının yoğun örneklenmesinden dolayı ön plan-arka plan sınıf dengesizliği problemi ile karşı karşıyadır. RetinaNet mimarisinde her piramit katmanında çok sayıda bağlantı kutu önerisi olabilir. Bu önerilerin büyük çoğunluğu arka plan sınıfı olurken sadece az sayıda bağlantı kutusu gerçek nesnelere aittir. Bu dengesizlik küçük kayıp değerleri ile sonuçlansa da çok sayıda olmasından dolayı tüm modeli manipüle edebilir. Odak kaybı tam bu problemin önüne geçme amaçlı arka plan sınıflarının kayıp katkısını azaltmayı amaçlamıştır.

Tsung-Yi Lin, Priya Goyal, Ross Girshick Kaiming He ve Piotr Dollar odak kaybı yönteminin çapraz entropiye göre kayıp değerlerini kıyaslamışlardır. Şekil 4.12’de görülen kayıp grafiğinde odak kaybı yönteminin göreceli kaybı azalttığı sonucuna varmışlardır.



Şekil 4.12. Çapraz entropi yöntemi ile odak kaybı yönteminin kayıp değerlerinin karşılaştırması [46]


RetinaNet tek aşamalı mimarisi ile yaygın olarak kullanılan diğer tek aşamalı YOLOv2, SSD513, DSSD513 ve iki aşamalı Faster R-CNN modellerini kıyaslamak amacıyla COCO veri seti kullanılarak testler gerçekleştirilmiş ve her bir mimari için ortalama kesinlik değeri hesaplanmıştır. Getirdiği özellik piramit ağı ve odak kaybı yöntemi ile diğer modellere göre nesne algılama görevinde Şekil 4.13’de görülebileceği üzere RetinaNet modelinin diğer modellere göre daha iyi sonuç verdiği gözlemlenmiştir.

	backbone	AP	AP ₅₀	AP ₇₅	AP _S	AP _M	AP _L
<i>Two-stage methods</i>							
Faster R-CNN+++ [16]	ResNet-101-C4	34.9	55.7	37.4	15.6	38.7	50.9
Faster R-CNN w FPN [20]	ResNet-101-FPN	36.2	59.1	39.0	18.2	39.0	48.2
Faster R-CNN by G-RMI [17]	Inception-ResNet-v2 [34]	34.7	55.5	36.7	13.5	38.1	52.0
Faster R-CNN w TDM [32]	Inception-ResNet-v2-TDM	36.8	57.7	39.2	16.2	39.8	52.1
<i>One-stage methods</i>							
YOLOv2 [27]	DarkNet-19 [27]	21.6	44.0	19.2	5.0	22.4	35.5
SSD513 [22, 9]	ResNet-101-SSD	31.2	50.4	33.3	10.2	34.5	49.8
DSSD513 [9]	ResNet-101-DSSD	33.2	53.3	35.2	13.0	35.4	51.1
RetinaNet (ours)	ResNet-101-FPN	39.1	59.1	42.3	21.8	42.7	50.2
RetinaNet (ours)	ResNeXt-101-FPN	40.8	61.1	44.1	24.1	44.2	51.2

Şekil 4.13. Nesne algılama modellerinin ortalama kesinlik değerleri [46]


SSD

Wei Liu ve arkadaşları tarafından 2016 yılında nesne takibi görevi için yayınlamış tek aşamalı derin öğrenme modelidir. Wei Liu çalışmasında özellik çıkarıcı olarak VGG16 kullanmış olsa da diğer özellik çıkarıcılar ile çalışabileceğini belirtmiştir. Şekil 4.14’de görülebileceği üzere temel mimarinin sonuna farklı ölçek ve en boy oranlarındaki varsayılan kutulara olan uzaklıkları ve bunların ilişkili güvenilirliklerini tahmin eden birkaç özellik katmanı eklenmiştir.



Şekil 4.14. Tek aşamalı SSD dedektörünün mimarisi [47]

SSD eğitim sırasında her nesne için yalnızca bir girdi görüntüsüne ve temel doğruluk kutularına ihtiyaç duyar. Farklı ölçeklere sahip Şekil 4.15 (b)’de 8x8 ve (c)’de 4x4 boyutlarında gösterilen birkaç özellik haritasında her konumdaki farklı en boy oranlarına sahip küçük bir dizi varsayılan kutuyu değerlendirir. Her varsayılan kutu için tüm nesne kategorileri hem şekil boyutları hem de güvenilirlik değeri hesaplanır.



Şekil 4.15. SSD çerçevesi [47]

SSD'nin diğer modellere göre getirdiği en farklı yenilik farklı çözünürlüklerde çoklu çıktı katmanlarının olmasıdır. Bu katmanların sağladığı katkıyı görme amaçlı Liu ve arkadaşları kademeli olarak katmanları kaldırmış ve sonuçları kıyaslamışlardır, sonuçlar Şekil 4.16'da verilmiştir. Katman sayısı düştükçe doğruluk değerinin 74.3'den 62.4'e kadar düştüğü dolayısıyla çoklu çıktı katmanının yararlı bir yöntem olduğu sonucuna varılmıştır.

Prediction source layers from:						mAP		# Boxes
conv4_3	conv7	conv8_2	conv9_2	conv10_2	conv11_2	use boundary boxes?		
						Yes	No	
✓	✓	✓	✓	✓	✓	74.3	63.4	8732
✓	✓	✓	✓	✓		74.6	63.1	8764
✓	✓	✓	✓			73.8	68.4	8942
✓	✓	✓				70.7	69.2	9864
✓	✓					64.2	64.4	9025
	✓					62.4	64.0	8664

Şekil 4.16. Birden çok çıktı katmanı kullanmanın etkisi [47]

Wei Lui ve arkadaşları SSD dedektörünün diğer iki aşamalı ve tek aşamalı dedektörler ile kıyaslamak amacıyla her dedektörün PascalVOC veri seti ile test edilmiş ve her biri için ortalama kesinlik değeri hesaplanmıştır. Bu test sonuçları Şekil 4.17'de verilmiştir, en iyi ortalama hassasiyet değerinin PascalVOC 2007, PascalVOC2012 ve COCO veri seti ile eğitilmiş SSD512 mimarisi olduğu gözlemlenebilmektedir.

Method	data	mAP	aero	bike	bird	boat	bottle	bus	car	cat	chair	cow	table	dog	horse	mbike	person	plant	sheep	sofa	train	tv
Fast[6]	07++12	68.4	82.3	78.4	70.8	52.3	38.7	77.8	71.6	89.3	44.2	73.0	55.0	87.5	80.5	80.8	72.0	35.1	68.3	65.7	80.4	64.2
Faster[2]	07++12	70.4	84.9	79.8	74.3	53.9	49.8	77.5	75.9	88.5	45.6	77.1	55.3	86.9	81.7	80.9	79.6	40.1	72.6	60.9	81.2	61.5
Faster[2]	07++12+COCO	75.9	87.4	83.6	76.8	62.9	59.6	81.9	82.0	91.3	54.9	82.6	59.0	89.0	85.5	84.7	84.1	52.2	78.9	65.5	85.4	70.2
YOLO[5]	07++12	57.9	77.0	67.2	57.7	38.3	22.7	68.3	55.9	81.4	36.2	60.8	48.5	77.2	72.3	71.3	63.5	28.9	52.2	54.8	73.9	50.8
SSD300	07++12	72.4	85.6	80.1	70.5	57.6	46.2	79.4	76.1	89.2	53.0	77.0	60.8	87.0	83.1	82.3	79.4	45.9	75.9	69.5	81.9	67.5
SSD300	07++12+COCO	77.5	90.2	83.3	76.3	63.0	53.6	83.8	82.8	92.0	59.7	82.7	63.5	89.3	87.6	85.9	84.3	52.6	82.5	74.1	88.4	74.2
SSD512	07++12	74.9	87.4	82.3	75.8	59.0	52.6	81.7	81.5	90.0	55.4	79.0	59.8	88.4	84.3	84.7	83.3	50.2	78.0	66.3	86.3	72.0
SSD512	07++12+COCO	80.0	90.7	86.8	80.5	67.8	60.8	86.3	85.5	93.5	63.2	85.7	64.4	90.9	89.0	88.9	86.8	57.2	85.1	72.8	88.4	75.9

Şekil 4.17. PascalVOC veri seti ile test sonuçları [47]


YOLOv3

Joseph Redmon ve Ali Farhadi tarafından 2018 yılında YOLOv2 modelini iyileştirmek amacıyla sınırlayıcı kutuların farklı boyutları için hesaplama özelliği eklenerek tasarlanmış tek aşamalı derin öğrenme modelidir. YOLO modeli diğer modellere göre hızlı olduğu için gerçek zamanlı nesne tespiti görevlerinde daha başarılıdır [48]. Bu hızın ana faktörü resim

tek bir seferde doğrudan olarak yapay sinir ağına girip resim içersindeki nesnelerin sınıfının ve sınırlayıcı kutusunun belirleniyor olmasıdır.

YOLO modelinin temel çalışma prensibinde öncelikle resim $S \times S$ boyutunda ızgaralara bölünür. Her ızgara içerisinde nesne varlığından, nesnenin orta noktasının kendi içinde olup olmadığından, nesnenin en boy değerlerinden ve nesnenin sınıfından sorumludur. Tespit edilen her nesne için sınırlayıcı kutu ile nesnenin alanının örtüşme oranı IOU değeri hesaplanır ve tek bir nesne için IOU değeri en yüksek olan kutu haricindeki diğer tüm öneriler yok sayılır ve bir nesne için sadece bir tane öneri sunmuş olur.

YOLOv3 modeli orijinal olarak özellik çıkarıcı olarak Imagenet üzerinde eğitilmiş 53 katmanlı ağı sahip Darknet53 kullanır. Her biri toplu normalleştirme katmanı ve sızıntı Relu aktivasyon katmanı tarafından takip edilen 53 evrişimsel katman içerir. YOLO modelinde yalnızca evrişimsel katmanlar kullanıldığı için tamamen evrişimsel bir ağ olarak nitelendirilir. YOLOv3 modelinde algılama, ağda üç farklı yerde üç farklı boyuttaki özellik haritaları üzerinde 1×1 algılama çekirdeği uygulanarak yapılır. Şekil 4.18'de YOLOv3 modelinin mimarisi gösterilmektedir. YOLO v3 modeli her bir etiket için sınıflandırma kaybını hesaplamak için ikili çapraz entropi kullanırken, nesne güveni ve sınıf tahminleri lojistik regresyon yoluyla tahmin edilir.



Şekil 4.18. YOLOv3 mimarisinin görsel grafiği [49]

Joseph Redmon ve Ali Farhadi COCO veri setinini kullanarak diğer tek ve iki aşamalı dedektörler ile YOLOv3 modelini kıyaslamak amacıyla testler yapmışlar ve Şekil 4.19'dan görülebileceği üzere her model için ortalama kesinlik değerlerini hesaplamışlardır. YOLOv3 modeli SSD modelinden 3 kat hızlı olmasına rağmen ortalama kesinlik değerinin daha iyi sonuç verdiği görülmektedir. Önceki YOLO versiyonlarında kesişen dikdörtgen alanı büyüdükçe yani büyük nesnelerde daha iyi sonuç vermesine rağmen YOLOv3 versiyonunda bu durumun tersine döndüğü yani küçük nesnelerde daha iyi sonuç verdiği sonucuna varılmıştır. Genel olarak model değerlendirildiğinde ise yeni çok ölçekli tahminler sayesinde model hızları göz önüne alındığında nispeten diğer modellere göre oldukça iyi ortalama kesinlik değeri elde edilmiştir.

	backbone	AP	AP ₅₀	AP ₇₅	AP _S	AP _M	AP _L
<i>Two-stage methods</i>							
Faster R-CNN+++ [5]	ResNet-101-C4	34.9	55.7	37.4	15.6	38.7	50.9
Faster R-CNN w FPN [8]	ResNet-101-FPN	36.2	59.1	39.0	18.2	39.0	48.2
Faster R-CNN by G-RMI [6]	Inception-ResNet-v2 [21]	34.7	55.5	36.7	13.5	38.1	52.0
Faster R-CNN w TDM [20]	Inception-ResNet-v2-TDM	36.8	57.7	39.2	16.2	39.8	52.1
<i>One-stage methods</i>							
YOLOv2 [15]	DarkNet-19 [15]	21.6	44.0	19.2	5.0	22.4	35.5
SSD513 [11, 3]	ResNet-101-SSD	31.2	50.4	33.3	10.2	34.5	49.8
DSSD513 [3]	ResNet-101-DSSD	33.2	53.3	35.2	13.0	35.4	51.1
RetinaNet [9]	ResNet-101-FPN	39.1	59.1	42.3	21.8	42.7	50.2
RetinaNet [9]	ResNeXt-101-FPN	40.8	61.1	44.1	24.1	44.2	51.2
YOLOv3 608 × 608	Darknet-53	33.0	57.9	34.4	18.3	35.4	41.9


Şekil 4.19. YOLOv3 modelinin diğer modeller ile kıyaslama tablosu [49]

4.2.2. İki aşamalı derin öğrenme tabanlı dedektörler

Faster R-CNN

Shaoqing Ren, Kaiming He, Ross Girshick ve Jian Sun tarafından 2016 yılında Fast R-CNN mimarisine ek olarak yeni bir bölge önerisi yöntemi getirilerek tasarlanmış iki aşamalı derin öğrenme modelidir, Faster R-CNN mimarisi Şekil 4.20'de gösterilmektedir. İlk aşama herhangi bir boyuttaki görüntüyü alıp nesne skoruna göre dikdörtgen önerisinde bulunan evrimsel sinir ağı olan bölge öneri ağıdır. Fast R-CNN'de ilk aşamada bölge önerisi için seçici arama yöntemi kullanılmaktadır. Bu yöntemde küçük bölgeler belirlenir ve küçük bölgeler birleştirilerek daha büyük yeni bölgeler belirlenir. Bu işlemler sonunda yaklaşık olarak 2000 adet farklı bölge oluşturulup her bir adet bölge için 2000 adet evrimsel sinir

ağı kullanılarak bölgelerin özellikleri çıkarılır. Bu modelde her bölge için 2000 adet evrişimsel sinir ağı kullanılması eğitim sürecinde çok fazla süre harcanmasına neden olmaktadır. Bu nedenle Faster R-CNN mimarisinde zaman açısından daha iyi sonuç veren bölge önerisi ağı kullanılmıştır. Bölge önerisi ağında bölge önerisi yapılması için tek bir adet evrişimsel sinir ağı kullanıldığından Fast R-CNN'e göre daha kullanışlıdır. İkinci aşamada ise bölge önerisi ağı tarafından üretilen öneriler bir sınıflandırıcı ile nesnenin sınıfı, bir regressor ile de sınırlandırıcı kutusu tahmin edilerek işlem sonlandırılır.



Şekil 4.20. Faster R-CNN modelinin mimarisi [50]

Shaoqing Ren ve arkadaşları yeni bölge önerisi ağını seçici arama yöntemiyle hem zamansal açıdan hem de doğruluk açısından kıyasalamak amacıyla testlerini yapmış, Şekil 4.21'deki sonuçları elde etmişlerdir. Şekil 4.21'de COCO, VOC 2007 ve VOC 2012 veri setleri üzerinden yapılan testlerin sonuçları gösterilmektedir. Bu sonuçlardan yeni önerilen bölge önerisi yönteminin seçici arama yöntemine göre daha iyi ortalama kesinlik değeri verdiği sonucuna varılmıştır.

method	# proposals	data	mAP (%)
SS	2000	12	65.7
SS	2000	07++12	68.4
RPN+VGG, shared [†]	300	12	67.0
RPN+VGG, shared [‡]	300	07++12	70.4
RPN+VGG, shared [§]	300	COCO+07++12	75.9

Şekil 4.21. Bölge önerisi ağı ve seçici arama yönteminin ortalama kesinlik değerleri [50]

Zaman için değerlendirildiğinde ise Şekil 4.22’de görülebileceği üzere yeni bölge önerisi ağının yaklaşık olarak 10 kat daha hızlı olduğu sonucuna varılmıştır.


model	system	conv	proposal	region-wise	total	rate
VGG	SS + Fast R-CNN	146	1510	174	1830	0.5 fps
VGG	RPN + Fast R-CNN	141	10	47	198	5 fps

Şekil 4.22. Bölge önerisi ağı ve seçici arama yönteminin zamansal değerleri [50]




5. DEĞERLENDİRME KRİTERLERİ

Makine öğrenimi önceki elde edilmiş verilerden öğrenerek insan zekasını taklit etmek için tasarlanmış bir hesaplama algoritmaları dalıdır. Bu algoritmalar günümüzde birçok görev için kullanılmaktadır. Bu algoritmaların denetimli ve denetimsiz olmak üzere temel olarak iki farklı öğrenme yaklaşımı vardır. Bu yaklaşım arasındaki temel fark denetimli öğrenmede etiketli veriler kullanılırken, denetimsiz öğrenmede etiketsiz verilerin kullanılmasıdır. Denetimli öğrenme yaklaşımı ise tahmin edilen değişkenin kategorik veya sürekli olmasına bağlı olarak sınıflandırma ve regresyon modelleri olmak üzere ikiye ayrılmaktadır. Bu çalışmada uygulanan nesne tespiti görevinde etiketli veriler ve tahmin edilen bağımlı değişkenin kategorik olması sebebiyle sınıflandırma görevine girmektedir.



Şekil 5.1. Makine öğrenmesi yaklaşımları

Değerlendirme kriterleri tahmin edilen bağımlı değişkenin türünün farklı olması sebebiyle regresyon ve sınıflandırma modellerinde farklılık göstermektedir. Bu çalışmada sınıflandırma modelleri için yaygın olarak kullanılan doğruluk, kesinlik, duyarlılık ve F1-Skor değerlendirme kriterleri kullanılmıştır. Bu kriterleri hesaplamak için her hücresi bir değerlendirme faktörünü temsil eden Şekil 5.2’de gösterilen karışıklık matrisi kullanılmaktadır. Gerçek pozitif hücresi tahmin edilen değişkenin doğru sınıflandırıldığı örnekleri, yanlış pozitif hücresi yanlış olarak sınıflandırdığı halde o sınıfa ait olmadığı örnekleri, yanlış negatif hücresi o sınıfa ait olmasına rağmen sınıfa ait değil diye sınıflandırdığı örnekleri ve gerçek negatif hücresi o sınıfa ait olmayan örnekleri doğru olarak sınıfa ait değil olarak sınıflandıran örnekleri temsil etmektedir.



Şekil 5.2. Karışıklık matrisi

Doğruluk değeri doğru olarak tahmin edilen gerçek pozitif ve gerçek negatif örneklerinin toplam tahmin örneklerine bölünmesi ile elde edilir. Doğruluk değeri modelin genel anlamda tüm sınıflarda nasıl performans gösterdiğini açıklayan bir performans metriğidir.

$$\text{Doğruluk} = \frac{GP+GN}{GP+YP+GN+YN} \quad (5.1)$$

Kesinlik değeri model tarafından sınıflandırılmasının doğru yapıldığı, gerçek pozitif örnek sayısının tüm pozitif olarak sınıflandırıldığı gerçek pozitif ve yanlış pozitif örnek sayısına bölünmesi ile elde edilir. Dolayısıyla kesinlik değeri modelin sınıfa ait dediği örneklerin ne kadar doğru olarak sınıflandırıldığını gösteren performans metriğidir.

$$\text{Kesinlik} = \frac{GP}{GP+YP} \quad (5.2)$$


Duyarlılık değeri model tarafından sınıflandırılmasının doğru yapıldığı, gerçek pozitif örnek sayısının tüm o sınıfa ait olması gereken örneklerin gerçek pozitif ve yanlış negatif sayısına bölünmesi ile elde edilir. Dolayısıyla duyarlılık değeri modelin o sınıfa ait olan örneklerin ne kadar doğru olarak sınıfa ait olduğunu gösteren performans metriğidir.

$$Duyarlılık = \frac{GP}{GP+YN} \quad (5.3)$$

F1-Skor değeri model tarafından elde edilen kesinlik ve duyarlılık değerlerinin harmonik ortalaması alınarak elde edilir. Harmonik ortalama kullanılmasının sebebi uç durumların performans metriğine etkisinin azaltılmasıdır. Dolayısıyla eşit olarak dağılmayan veri setlerinde yanlış değerlendirme yapılmasının önüne geçilmesi amaçlanmıştır.

$$F_1 = 2 * \frac{Kesinlik * Duyarlilik}{Kesinlik + Duyarlilik} \quad (5.4)$$

Nesne algılama görevinde nesne sınıflandırma görevine ek olarak giriş görüntüleri üzerinden sınırlayıcı kutu koordinatları tahmin edilir. Giriş verileri üzerinde sınırlayıcı kutunun ideal olarak bulunması gereken yere kesin referans değeri denir. Modelin tahmin ettiği alan ile kesin referans değerinin kesişim alanının bu iki alanın birleşimine bölümü Birleşimin Kesişimi (Intersection over Union-IOU) değerini verir. Birleşimin kesişimi değeri nesne algılama görevinde nesne konumunun doğruluğunu ölçmeye yarayan başarı ölçütüdür.



Şekil 5.3. Birleşimin kesişim değeri

Kesinlik ve duyarlılık değerlerinin yüksek olması modelin pozitif olarak sınıflandırmada başarılı olduğunu gösteren metrikleridir ancak bu metrikler genel olarak birbiriyle ters oranlıdır. Bir model yüksek duyarlılık, düşük kesinlik değerlerine sahipse model pozitif örneklerin çoğunu doğru sınıflandırır ancak çok fazla yanlış pozitif örneğe sahiptir. Diğer bir model yüksek kesinlik, düşük duyarlılık değerlerine sahipse model pozitif olarak

sınıflandırdığında yüksek ihtimal ile pozitifdir ancak çok fazla pozitif olmasına rağmen sınıflandırmadığı örnek bulunmaktadır. Aradaki bu ters orantıyı yorumlamak amacıyla kesinlik-duyarlılık eğrilerinden yararlanılmaktadır.

Ortalama kesinlik değeri kesinlik-duyarlılık eğrisinin altında kalan alan olarak tanımlanmaktadır. Pozitif sayılması için birleşimin keşimi değerinin en düşük olduğu değeri eşik değeri olarak tanımlanmaktadır. Eşik değeri genellikle 0,5 olarak belirlenmektedir.

$$\text{Ortalama Kesinlik@eşik değeri} = \int_0^1 p(r)dr \quad (5.5)$$

Orantılı ortalama kesinlik değeri ise isminden de anlaşılacağı üzere tüm sınıflar için ortalama kesinlik değerinin ortalamasının alınması ile elde edilir. Ortalama kesinlik değerini elde etmek için her sınıf için ortalama kesinlik değeri ayrı ayrı ölçülmelidir.

$$\text{Orantılı Ortalama Kesinlik@eşik değeri} = \frac{1}{n} \sum_{i=1}^n \text{Ortalama Kesinlik}_i \quad (5.6)$$

Algılama performansı COCO performans metrikleri ile değerlendirilir [51]. COCO performans metriklerinden birisi ROC eğrisi altında kalan alan (Area Under Curve - AUC) değeridir. ROC eğrisi farklı sınıflandırma eşiklerinde diğer adı duyarlılık olan gerçek pozitif oran ve yanlış pozitif oran grafiğinden elde edilmektedir. Eşik değerini düşürmek hem yanlış pozitif örnekleri hem de gerçek pozitif örnekleri artırır.

$$\text{Gerçek Pozitif Oran} = \frac{GP}{GP+YN} \quad (5.7)$$

$$\text{Yanlış Pozitif Oran} = \frac{YP}{YP+GN} \quad (5.8)$$

AUC değeri olası tüm sınıflandırma eşiklerinde toplu bir performans ölçüsü sağlar. Bu çalışmanın sonuçlar kısmında verilmiş kesinlik-duyarlılık grafiğinde bazı önemli durumları değerlendirmek için AUC değerleri kullanılmıştır. Kullanılan bu AUC değerleri aşağıda verilmiştir;

- C75 olarak adlandırılan değer birleşimin keşimi (IoU) değerinin 0,75'e eşit olduğundaki AUC değerini,

- C50 olarak adlandırılan değer birleşimin kesişimi (IuO) değerinin 0,50'e eşit olduğundaki AUC değerini,
 - Loc olarak adlandırılan değer nesne konumu hataları göz ardı edildiği durumda AUC değerini,
 - SİM olarak adlandırılan değer süper kategori sınıf karışıklıkları kaldırıldığı durumda AUC değerini,
 - Oth olarak adlandırılan değer tüm sınıf karışıklıkları ortadan kaldırıldığında AUC değerini,
 - BG olarak adlandırılan değer tüm arka plan ve sınıf karışıklıkları ortadan kaldırıldığında AUC değerini, FN olarak adlandırılan değer kalan tüm hatalar kaldırıldığı durumda AUC değerini,
- ifade etmektedir.



6. BULGULAR

Dolgu tespiti görevinde Faster R-CNN dedektöründe ResNet50 ve ResNet101 özellik çıkarıcıları, RetinaNet dedektöründe ResNet50 özellik çıkarıcısı, SSD dedektöründe VGG16 özellik çıkarıcısı, YOLOv3 dedektöründe DarkNet53 özellik çıkarıcısı kullanılmıştır. Oluşturulan her model teker teker eğitilmiş ve performans metrikleri elde edilmiştir, her bir model için sırasıyla mAP@50, doğruluk, kesinlik, duyarlılık, F1-Skor ve eğitim süreleri Çizelge 6.1’de verilmiştir.

Çizelge 6.1. Dolgu tespiti görevinde derin öğrenme modellerinin performansları

Model	Backbone	mAP@0,5	D	K	Dy	F1-Skor	Eğitim Süresi (dk)
Faster RCNN	ResNet50	0,85	0,78	0,86	0,89	0,87	42dk
Faster RCNN	ResNet101	0,92	0,87	0,9	0,96	0,93	53dk
RetinaNet	ResNet50	0,8	0,67	0,88	0,74	0,8	36dk
SSD	VGG16	0,9	0,54	0,9	0,57	0,7	25dk
YOLOv3	DarkNet53	0,99	0,8	0,8	1	0,89	24dk


Dolgu tespiti görevleri performans açısından değerlendirildiğinde sırasıyla özellik çıkarıcısı ResNet101 olan iki aşamalı Faster R-CNN modeli 0,92 mAP ve YOLOv3 modeli 0,99 mAP değeri ile en iyi sonucu vermiştir. Modeller doğruluk değeri açısından değerlendirildiğinde özellik çıkarıcısı ResNet101 olan Faster R-CNN modeli 0,87 değeri ile YOLOv3 ile elden edilen 0,8 değerine göre daha iyi sonuç verdiği görülmektedir. Kesinlik değerine göre değerlendirildiğinde yine özellik çıkarıcısı ResNet101 olan Faster R-CNN modeli 0,9 değeri ile en iyi sonucu verdiği görülmektedir. Kesinlik ve duyarlılık değerlerinin harmonik ortalaması ile elde edilen F1-Skor değeri değerlendirildiğinde 0,93 değeri ile en iyi sonucun özellik çıkarıcısı ResNet101 olan Faster R-CNN modelinin verdiği görülmektedir. Özellik çıkarıcısı ResNet50 olan RetinaNet modelinin 0,8 mAP değeri ile en kötü sonucu verdiği görülmektedir. SSD modeli için mAP değeri 0,9 olmasına rağmen 0,54 doğruluk değeri, 0,57 duyarlılık değeri ve 0,7 F1-Skor değeri ile diğer modellere göre kötü sonuç verdiği görülmektedir. Modeller hızları açısından değerlendirildiğinde beklendiği üzere en hızlı

sonucun YOLOv3 modeli olduđu ,en yavaş modelin ise iki aşamalı olmasından dolayı Faster R-CNN modeline ait olduđu görölmektedir.

Faster R-CNN modelinin ResNet50 ve ResNet101 özellik çıkarıcılarıyla kullanılan modellerin performans olarak kıyaslandığında daha çok katmana sahip ResNet101 özellik çıkarıcısının ResNet50'ye göre daha iyi sonuç verdiği gözlemlenmektedir. Beklendiğı gibi daha fazla katmana sahip olmasından dolayı ResNet101'in ResNet50 modeline göre daha yavaş olduđu görölmektedir.




Resim 6.1. Dişte bulunan dolguların tespit ve sınıflandırma örnekleri (a) Tek bir dişte bulunan dolgu (b)Yan yana dört dişte bulunan dolgu (c) Yan yana iki diş ve ayrı tek bir dişte bulunan dolgu örneğı




Resim 6.1. (devam) Dişte bulunan dolguların tespit ve sınıflandırma örnekleri (a) Tek bir dişte bulunan dolgu (b) Yan yana dört dişte bulunan dolgu (c) Yan yana iki diş ve ayrı tek bir dişte bulunan dolgu örneği

Tüm performans metrikleri değerlendirildiğinde en iyi performansı YOLOv3 ve özellik çıkarıcısı ResNet101 olan Faster R-CNN modelleri vermektedir. Bu modellerin nerelerde daha iyi, nerelerde daha kötü sonuç verdiği ayrıntılı bir şekilde incelemek amacıyla kesinlik-duyarlılık eğrileri elde edilmiştir. Şekil 6.1’de Faster R-CNN ve Şekil 6.2’de YOLOv3 modellerinin kesinlik-duyarlılık eğrileri sunulmuştur.



Şekil 6.1. Faster R-CNN ResNet101 modelinin kesinlik-duyarlılık eğrisi



Şekil 6.2. YOLOv3 modelinin kesinlik-duyarlılık eğrisi

Birleşiminin kesişimi değeri 0,5'e eşitken AUC değerleri sırasıyla C50 ile gösterildiği üzere özellik çıkarıcısı ResNet101 olan Faster R-CNN modeli 0,885, YOLOv3 modelinde ise 0,852 olarak elde edilmiştir. Birleşiminin kesişimi değerini 0,75 olduğu durumda ise AUC değerleri sırasıyla C75'den görülebileceği üzere Faster R-CNN modeli 0,689, YOLOv3 modelinde 0,218 değerlerine düşmüştür. Nesne konumu hataları göz ardı edildiğinde Loc ile

gösterildiği üzere AUC değerinin Faster R-CNN modelinde 0,885 ile sabit kaldığı, YOLOv3 modelinde 0,921'e çıktığı görülmektedir. Sınıf hataları göz ardı edildiğinde Sim ve Oth ile gösterildiği üzere Faster R-CNN ve YOLOv3 modellerinin AUC değerleri sabit kalmıştır. Arka plan hataları göz ardı edildiği durumda BG ile gösterildiği üzere Faster R-CNN modelinin AUC değeri 0,891'e, YOLOv3 modelinin AUC değeri ise 0,96 değerine çıkmıştır. Tüm bu sonuçlar değerlendirildiğinde birleşimin kesişim değerini 0,5'den 0,75'e çıkarıldığında Faster R-CNN modelinin daha iyi sonuç verdiği, YOLOv3 modelinde nesne konumu hatası yapıldığı ancak Faster R-CNN modelinin nesne konumu hatası yapmadığı ve her iki modelinde belirli bir oranda arka plan hatası yaptığı anlaşılmaktadır.





7. TARTIŞMA

Derin öğrenmeye dayalı uygulamalar, özellikle son birkaç yılda diş hekimliğinin radyoloji araştırmalarında önemli ölçüde artmıştır ve çeşitli amaçlar için dikkate değer bir potansiyel göstermişlerdir [52]. Bu uygulamalar diş tespiti, numaralandırma, anatomik yapılar, lezyonlar, işaretler, kök morfolojisi ve kemik kaybı gibi durumları içerek sınıflandırma, tespit ve segmentasyon görevlerine dayalıdır [53]. Bu çalışmaların aksine diş dolguların tespiti ile ilgili önceki çalışmaların, incelenen diş koşulları ve keşfedilen derin öğrenme mimarilerinin sayısı açısından sınırlı olduğu görülmüştür. Bu çalışmada 4 farklı model ve 4 farklı özellik çıkarıcıların performansları geniş bir çerçevede değerlendirilmiştir. Kullanılan tek ve iki aşamalı dedektörlerin performansı da bu aşamada irdelenmiştir.

Bu çalışmada dolgu tespiti görevinde özellik çıkarıcıları ResNet50 ve ResNet101 olan Faster R-CNN, özellik çıkarıcısı ResNet50 olan RetinaNet, özellik çıkarıcısı VGG16 olan SSD ve özellik çıkarıcısı DarkNet53 olan YOLOv3 modellerinin performansları kıyaslanmıştır. Bu sonuçlar sayesinde tek aşamalı ve iki aşamalı modellerin hem sınıflandırma hem de eğitim süresi açısından performansları irdelenmiştir. Katman sayısındaki artışın eğitim süresini arttırdığı gözlemlenmiştir. Birleşimin kesişimi değeri arttırıldığında katman sayısı fazla olan ResNet101 modelinin ResNet50 modeline göre daha iyi sonuç verdiği sonucuna varılmıştır. Diş hekimliği alanında dolgu tespit görevleri ile ilgili yapılan diğer çalışmalar ayrıntılı bir şekilde incelenmiş ve sunulan bulgulara göre daha iyi performans metrikleri elde edilmiştir.

Atıf Emre Yüksel ve arkadaşları panoramik radyografiler üzerinden dolgu ve diğer diş tedavilerini otomatik olarak tespit eden DENTECT adında bir derin öğrenme uygulaması üzerinde çalışmışlardır. Eğitim ve testler için toplanan 3051 adet diş dolgusu örneği kullanmışlardır. Tedavi tespiti görevinde 0,59 ortalama kesinlik değeri elde etmişlerdir [31].

Başaran ve arkadaşları Faster R-CNN Inceptionv2 mimarisi kullanarak dolgu tedavisini otomatik olarak tespit eden derin öğrenme uygulaması üzerine çalışmışlardır. Eğitim ve test amaçlı 1084 adet panoramik radyografi kullanmışlardır. Dolgu tedavisi tespiti görevi için 0,86 kesinlik ve 0,87 duyarlılık değerleri elde etmişlerdir [33].

Anıl Gürses ve arkadaşı dolgu tedavisinin panoramik görüntüler üzerinden otomatik tespiti görevi için GoogleNet, DenseNet ve ResNet modellerinin performanslarını kıyaslamışlardır. Veri seti olarak 521 adet dolgu tedavisi içeren panoramik görüntü kullanmışlardır. Dolgu tedavisinin tespitinde DenseNet 0,93 kesinlik ve 0,92 duyarlılık değerleriyle diğer modellere göre daha iyi sonuç vermiştir. GoogleNet ve ResNet modellerinden ise sırasıyla 0,93 kesinlik, 0,67 duyarlılık ve 0,89 kesinlik, 0,86 duyarlılık değerleri elde edilmiştir [35].

Bouchahma ve arkadaşları periapikal radyografiler üzerinden gereken diş tedavilerini otomatik olarak tespit eden derin öğrenme modeli önermişlerdir. Veri seti olarak 60 adet dolgu tedavisi içeren toplamda 200 periapikal görüntü kullanmışlardır. Önerdikleri modelin tüm tedaviler için genel doğruluk oranı 0,87 olmasına rağmen dolgu tedavisi tespitinde 0,77 doğruluk değeri elde etmişlerdir [34].

Ragda Abdalla-Aslan ve arkadaşları panoramik radyografiler üzerinden çeşitli diş restorasyonlarını otomatik olarak algılayan ve sınıflandıran yapay zekaya dayalı bilgisayarlı görme algoritması önermişlerdir. Veri seti olarak 83 panoramik radyografi üzerinde 738 diş restorasyonu örneği kullanılmışlardır. Önerdikleri modelin amalgam dolgu tespiti için 1, kompozit dolgu tespiti için 0,83 duyarlılık değeri elde etmişlerdir [30].

Önceki çalışmalar ile kıyaslandığında, dolgu tespiti görevinde diğer çalışmaların aksine panoramik radyografi görüntüsü değil periapikal görüntüler kullanılmıştır. Esin Bozdemir ve arkadaşları diş patolojilerin tespitinde panoramik radyografilerde yapılan teşhislerin periapikal görüntülerde gözükmediği ve yanlış tanı yapıldığı sonucuna varmışlardır [41]. Dolayısıyla bu çalışmanın diğer çalışmalara göre daha iyi performans metriği elde edilmesinin nedenlerinden biri periapikal görüntüler kullanılmasıdır. Ayrıca bu çalışmada diğer çalışmalardan daha kapsamlı performans değerlendirilmesi yapılmıştır. Oluşturulan her bir model için doğruluk, kesinlik, duyarlılık, F1-Skor ve iyi sonuç veren modellerin kesinlik-duyarlılık eğrisi ve AUC değerleri hesaplanmıştır.

Bu çalışmada bazı sınırlandırmalar mevcuttur. Kullanılan modeller oldukça başarılı bir performans göstermesine rağmen kullanılan periapikal radyografi sayısı artırılabilir. Veri seti adetinin artırılması performansı önemli derecede arttırılacağı bilinmektedir [54]. Veri sayısının arttırılması için veri çoğaltma yöntemleri kullanılabilir. Çalışmadaki bir diğer kısıt eğitim ve test aşamaları için veri setinin tek bir cihazdan elde edilen görüntülerin

kullanılmasıdır. Farklı cihazlardan alınan görüntüler ile uygulama yapılmak istendiği durumda görüntülerin kalitesi ve özellikleri çeşitlilik göstereceği için modelin nasıl sonuç vereceği belirsizdir.





8. SONUÇ

Dünyada tıp ve diş hekimliğinin radyoloji alanında sınıflandırma, teşhis ve tespit görevlerinde kullanılmak üzere derin öğrenme uygulamalarına ilgi gün geçtikçe artmaktadır. Son yıllarda derin öğrenme uygulamaları diş radyografisinde çeşitli amaçlar için dikkate değer bir performans sergilemiştir. Bu çalışmada periapikal radyografi görüntüleri üzerinden iki aşamalı Faster R-CNN ve tek aşamalı SSD, RetinaNet, YOLOv3 modelleri DarkNet53, ResNet50, ResNet101 ve VGG16 özellik çıkarıcıları kullanılarak diş dolgu tedavisi tespiti görevinde sergiledikleri performanslar kıyaslanmıştır.

Çalışma diş radyografilerinde çeşitli amaçlar için hâlihazırda yapılmış derin öğrenme uygulamaları ile ilgili literatür incelemeleri ile başlamaktadır. Ardından çalışmada kullanılan veri setiyle ilgili bilgileri ve çalışmada kullanılan dedektörlerin, özellik çıkarıcıların, performans metriklerinin teorik bilgileri anlatılmıştır. Son kısımda ise testler sonrası elde edilen bulguların verilmesi ve çalışmanın literatürde dolgu tespiti görevinde yapılmış çalışmalar ile karşılaştırılması ile son bulmuştur.

Bu çalışmanın sonucunda periapikal radyografler üzerinden diş dolgu tedavilerinin tespiti görevinde Faster R-CNN ve YOLOv3 modellerinin oldukça başarılı performans sergiledikleri gösterilmiştir. Bulgulardan çalışmanın sınırları giderildikten sonra derin öğrenme uygulamalarının diş kliniklerinde diş hekimlerine karar verme sürecinde özellikle ilk teşhiste destek olabileceği kanısına varılmıştır. Güvenilir ve sağlam bir teşhis ve tedavi aracı olarak kullanılan derin öğrenme uygulamaları ileride diş hekimlerine daha verimli tedavi planlaması konusunda yardımcı olma konusunda çok önemli bir potansiyele sahip olduğu sonucuna varılmıştır.



KAYNAKLAR

1. Tekin, M. (1996). *Üretim yönetimi*. (2. Baskı). Konya: Arı Ofset Matbaacılık, 20.
2. Bonczek, R. H., Holsapple, C. W., and Whinston, A. B. (2014). *Foundations of decision support systems*. New York: Academic Press, 312-314.
3. Osherooff, J. A., Teich, J. M., Levick, D., Saldana, L., Velasco, F. T., Sittig, D. F., Jenders, and R. A. (2012). *Improving outcomes with clinical decision support: an implementer's guide*. New York: Himss Publishing, 348.
4. Dias, D., and Paulo Silva Cunha, J. (2018). Wearable health devices—vital sign monitoring, systems and technologies. *Sensors*, 18(8), 2414.
5. Middleton, B., Sittig, D. F., and Wright, A. (2016). Clinical decision support: a 25 year retrospective and a 25 year vision. *Yearbook of Medical Informatics*, 25(S 01), 103-116.
6. Özata, M., ve Aslan, Ş. (2004). Klinik karar destek sistemleri ve örnek uygulamalar. *Kocatepe Tıp Dergisi*, 5(1), 11-17.
7. Holmes, J., Sacchi, L., and Bellazzi, R. (2004). Artificial intelligence in medicine. *The Annals of The Royal College of Surgeons of England Home*, 86, 334-8.
8. Kooi, T., Litjens, G., Van Ginneken, B., Gubern-Mérida, A., Sánchez, C. I., Mann, R., and Karssemeijer, N. (2017). Large scale deep learning for computer aided detection of mammographic lesions. *Medical Image Analysis*, 35, 303-312.
9. Kahn Jr, C. E. (1994). Artificial intelligence in radiology: decision support systems. *Radiographics*, 14(4), 849-861.
10. Bishop, C. M., and Nasrabadi, N. M. (2006). *Pattern Recognition and Machine Learning*. New York: springer, 738.
11. Wang, S., and Summers, R. M. (2012). Machine learning and radiology. *Medical Image Analysis*, 16(5), 933-951.
12. Skansi, S. (2018). *Introduction to Deep Learning: from Logical Calculus to Artificial Intelligence*. Springer, Croatia, 54.
13. LeCun, Y., Bengio, Y., and Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436-444.
14. Zadrożny, Ł., Regulski, P., Brus-Sawczuk, K., Czajkowska, M., Parkanyi, L., Ganz, S., and Mijiritsky, E. (2022). Artificial Intelligence Application in Assessment of Panoramic Radiographs. *Diagnostics*, 12(1), 224.
15. Burt, J. R., Torosdagli, N., Khosravan, N., RaviPrakash, H., Mortazi, A., Tissavirasingham, F., and Bagci, U. (2018). Deep learning beyond cats and dogs: recent advances in diagnosing breast cancer with deep neural networks. *The British Journal of Radiology*, 91(1089), 20170545.

16. Schwendicke, F., Golla, T., Dreher, M., and Krois, J. (2019). Convolutional neural networks for dental image diagnostics: A scoping review. *Journal of Dentistry*, 91, 103226. *Oral Surgery, Oral Medicine, Oral Pathology and Oral Radiology*, 128(4), 424-430.
17. Arij, Y., Yanashita, Y., Kutsuna, S., Muramatsu, C., Fukuda, M., Kise, Y., and Arij, E. (2019). Automatic detection and classification of radiolucent lesions in the mandible on panoramic radiographs using a deep learning object detection technique. *Oral Surgery, Oral Medicine, Oral Pathology and Oral Radiology*, 128(4), 424-430.
18. Park, W. J., and Park, J. B. (2018). History and application of artificial neural networks in dentistry. *European Journal of Dentistry*, 12(04), 594-601.
19. Moreira, M. W., Rodrigues, J. J., Korotaev, V., Al-Muhtadi, J., and Kumar, N. (2019). A comprehensive review on smart decision support systems for health care. *IEEE Systems Journal*, 13(3), 3536-3545.
20. Miotto, R., Wang, F., Wang, S., Jiang, X., and Dudley, J. T. (2018). Deep learning for healthcare: review, opportunities and challenges. *Briefings in Bioinformatics*, 19(6), 1236-1246.
21. Muniasamy, A., Tabassam, S., Hussain, M. A., Sultana, H., Muniasamy, V., and Bhatnagar, R. (2019, March). *Deep learning for predictive analytics in healthcare*. In International Conference on Advanced Machine Learning Technologies and Applications, Las Vegas, 32-42.
22. Kuwada, C., Arij, Y., Fukuda, M., Kise, Y., Fujita, H., Katsumata, A., and Arij, E. (2020). Deep learning systems for detecting and classifying the presence of impacted supernumerary teeth in the maxillary incisor region on panoramic radiographs. *Oral Surgery, Oral Medicine, Oral Pathology and Oral Radiology*, 130(4), 464-469.
23. Hwang, J. J., Jung, Y. H., Cho, B. H., and Heo, M. S. (2019). An overview of deep learning in the field of dentistry. *Imaging Science in Dentistry*, 49(1), 1-7.
24. Muresan, M. P., Barbura, A. R., and Nedevschi, S. (2020, September). *Teeth detection and dental problem classification in panoramic X-ray images using deep learning and image processing techniques*. In 2020 IEEE 16th International Conference on Intelligent Computer Communication and Processing (ICCP), Romania, 457-463.
25. Lee, J. H., Kim, D. H., Jeong, S. N., and Choi, S. H. (2018). Detection and diagnosis of dental caries using a deep learning-based convolutional neural network algorithm. *Journal of Dentistry*, 77, 106-111.
26. Zhang, X., Liang, Y., Li, W., Liu, C., Gu, D., Sun, W., and Miao, L. (2022). Development and evaluation of deep learning for screening dental caries from oral photographs. *Oral Diseases*, 28(1), 173-181.

27. Corbella, S., Srinivas, S., and Cabitza, F. (2021). Applications of deep learning in dentistry. *Oral Surgery, Oral Medicine, Oral Pathology and Oral Radiology*, 132(2), 225-238.
28. Endres, M. G., Hillen, F., Salloumis, M., Sedaghat, A. R., Niehues, S. M., Quatela, O., and Gaudin, R. A. (2020). Development of a deep learning algorithm for periapical disease detection in dental radiographs. *Diagnostics*, 10(6), 430.
29. Zheng, L., Wang, H., Mei, L., Chen, Q., Zhang, Y., and Zhang, H. (2021). Artificial intelligence in digital cariology: a new tool for the diagnosis of deep caries and pulpitis using convolutional neural networks. *Annals of Translational Medicine*, 9(9), 335.
30. Abdalla-Aslan, R., Yeshua, T., Kabla, D., Leichter, I., and Nadler, C. (2020). An artificial intelligence system using machine-learning for automatic detection and classification of dental restorations in panoramic radiography. *Oral Surgery, Oral Medicine, Oral Pathology and Oral Radiology*, 130(5), 593-602.
31. Yüksel, A. E., Gültekin, S., Simsar, E., Özdemir, Ş. D., Gündoğar, M., Tokgöz, S. B., and Hamamcı, İ. E. (2021). Dental enumeration and multiple treatment detection on panoramic X-rays using deep learning. *Scientific Reports*, 11(1), 1-10.
32. Oztekin, F., Katar, O., Sadak, F., Aydogan, M., Yildirim, T. T., Plawiak, P., and Karabatak, M. (2022). Automatic semantic segmentation for dental restorations in panoramic radiography images using U-Net model. *International Journal of Imaging Systems and Technology*, 32(6), 1990-2001.
33. Başaran, M., Çelik, Ö., Bayrakdar, I. S., Bilgir, E., Orhan, K., Odabaş, A., and Jagtap, R. (2022). Diagnostic charting of panoramic radiography using deep-learning artificial intelligence system. *Oral Radiology*, 38(3), 363-369.
34. Bouchahma, M., Hammouda, S. B., Kouki, S., Alshemali, M., and Samara, K. (2019, November). *An automatic dental decay treatment prediction using a deep convolutional neural network on X-ray images*. In 2019 IEEE/ACS 16th International Conference on Computer Systems and Applications (AICCSA), Abu Dhabi, 1-4.
35. Gurses, A., & Oktay, A. B. (2020, November). *Tooth Restoration and Dental Work Detection on Panoramic Dental Images via CNN*. In 2020 Medical Technologies Congress, Antalya, 1-4.
36. Abbott, P. (2000). Are dental; radiographs safe?. *Australian Dental Journal*, 45(3), 208-213.
37. Abdelkarim, A. (2019). Cone-beam computed tomography in orthodontics. *Dentistry Journal*, 7(3), 89.
38. Estrela, C., Bueno, M. R., Leles, C. R., Azevedo, B., and Azevedo, J. R. (2008). Accuracy of cone beam computed tomography and panoramic and periapical radiography for detection of apical periodontitis. *Journal of Endodontics*, 34(3), 273-279.

39. Lomas, D. J., Carroll, N. R., Johnson, G., Antoun, N. M., and Freer, C. E. (1996). MR sialography. Work in progress. *Radiology*, 200(1), 129-133.
40. Nagihan, K. O. Ç., ve Özbek, Ş. Panoramik Radyografi. *ADO Klinik Bilimler Dergisi*, 10(2), 75-76.
41. Bozdemir, E. ve Yarbaşı, Ö. (2019). Tanıda sadece panoramik radyografi ne kadar güvenli? . *Selcuk Dental Journal* , *ODMFR 2019 Kongre Kitapçığı Özel Sayısı* , 100-103.
42. Simonyan, K., and Zisserman, A. (2014). *Very deep convolutional networks for large-scale image recognition*. International Conference on Learning Representations, San Diego, 49-63.
43. Pravitasari, A. A., Iriawan, N., Almuhayar, M., Azmi, T., Irhamah, I., Fithriasari, K., and Ferriastuti, W. (2020). UNet-VGG16 with transfer learning for MRI-based brain tumor segmentation. *TELKOMNIKA (Telecommunication Computing Electronics and Control)*, 18(3), 1310-1318.
44. He, K., Zhang, X., Ren, S., and Sun, J. (2016). *Deep residual learning for image recognition*. In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, Las Vegas, 770-778.
45. Wu, W., Guo, L., Gao, H., You, Z., Liu, Y., and Chen, Z. (2022). YOLO-SLAM: A semantic SLAM system towards dynamic environment with geometric constraint. *Neural Computing and Applications*, 34(8), 6011-6026.
46. Lin, T. Y., Goyal, P., Girshick, R., He, K., and Dollár, P. (2017). *Focal loss for dense object detection*. In Proceedings of the IEEE International Conference on Computer Vision, Venice, 2980-2988.
47. Liu, W., Anguelov, D., Erhan, D., Szegedy, C., Reed, S., Fu, C. Y., and Berg, A. C. (2016, October). *Ssd: Single shot multibox detector*. In European Conference on Computer Vision, Amsterdam, 21-37.
48. Redmon, J., and Farhadi, A. (2018). Yolov3: An incremental improvement. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 15, 1125-1131.
49. Dorrer, M. G., and Tolmacheva, A. E. (2020, November). Comparison of the YOLOv3 and Mask R-CNN architectures' efficiency in the smart refrigeration's computer vision. In *Journal of Physics: Conference Series*, 1679, 042022.
50. Ren, S., He, K., Girshick, R., and Sun, J. (2015). Faster r-cnn: Towards real-time object detection with region proposal networks. *Advances in Neural Information Processing Systems*, 28.
51. Lin, T. Y., Maire, M., Belongie, S., Hays, J., Perona, P., Ramanan, D., and Zitnick, C. L. (2014, September). *Microsoft coco: Common objects in context*. In European Conference on Computer vision, Zurich, 740-755.

52. Prados-Privado, M., Villalón, J. G., Martínez-Martínez, C. H., and Ivorra, C. (2020). Dental images recognition technology and applications: a literature review. *Applied Sciences*, 10(8), 2856.
53. Hung, K., Montalvao, C., Tanaka, R., Kawai, T., and Bornstein, M. M. (2020). The use and performance of artificial intelligence applications in dental and maxillofacial radiology: A systematic review. *Dentomaxillofacial Radiology*, 49(1), 20190107.
54. Khanagar, S. B., Al-Ehaideb, A., Maganur, P. C., Vishwanathaiah, S., Patil, S., Baeshen, H. A., and Bhandi, S. (2021). Developments, application, and performance of artificial intelligence in dentistry—A systematic review. *Journal of Dental sciences*, 16(1), 508-522.





Gazili olmak ayrıcalıktır