

**YOLOV7 ALGORİTMASI İLE DİŞ RÖNTGENLERİNDE
LEZYON VE ÇÜRÜK TESPİTİ**

SAFİYE ERSAN

ŞUBAT 2024

DİYARBAKIR

DİCLE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**YOLOV7 ALGORİTMASI İLE DİŞ RÖNTGENLERİNDE
LEZYON VE ÇÜRÜK TESPİTİ**

SAFİYE ERSAN

DİCLE ÜNİVERSİTESİ LİSANSÜSTÜ EĞİTİM-ÖĞRETİM VE SINAV
YÖNETMELİĞİNİN BİR PARÇASI OLARAK
BİYOMEDİKAL MÜHENDİSLİĞİ ANA BİLİM DALINDA
YÜKSEK LİSANS TEZİ
OLARAK HAZIRLANMIŞTIR

ŞUBAT 2024

DIYARBAKIR

YOLOV7 ALGORİTMASI İLE DİŞ LEZYONLARINDA LEZYON VE ÇÜRÜK TESPİTİ

Safiye ERSAN tarafından Dicle Üniversitesi Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliği'nin bir parçası olarak hazırlanan bu çalışma, aşağıda bilgileri yazılı jüri üyeleri tarafından değerlendirilerek **Biyomedikal Mühendisliği Ana Bilim Dalı**'nda **Yüksek Lisans Tezi** olarak kabul edilmiştir.

Prof. Dr. Neslihan DALKILIÇ
Müdür, **Fen Bilimleri Enstitüsü**

Doç. Dr. Cafer BUDAK
Danışman, **Elektrik Elektronik Mühendisliği Bölümü,**
Dicle Üniversitesi

Sınav Jürisi:

Prof. Dr. Abdullah TOPRAK (*)
Elektrik Elektronik Mühendisliği Bölümü,
Dicle Üniversitesi

Doç. Dr. Cafer BUDAK (**)
Elektrik Elektronik Mühendisliği Bölümü,
Dicle Üniversitesi

Doç. Dr. Muzaffer ATEŞ
Elektronik ve Otomasyon Bölümü,
Van Yüzüncü Yıl Üniversitesi

ONAY

Savunma Tarihi: 26 / 01 / 2024

(*) Jüri Başkanı.

(**) Tez Danışmanı.



Babama, Anneme...

Dicle Üniversitesi Fen Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak hazırlanan bu tez çalışmasında yer alan tüm bilgilerin akademik kurallara ve etik ilkelere uygun olarak elde edildiğini ve sunulduğunu beyan ederim. Ayrıca, bahse konu bu kural ve ilkelerin gerektirdiği üzere, bu çalışmada özgün olmayan tüm bilimsel içerikleri kurallara uygun biçimde alıntılıyıp kaynak gösterdiğimi beyan ederim. Beyanımınla çelişen herhangi bir delil bulunduğu takdirde tüm sorumluluğu üstleneceğimi kabul ederim.

Ad, Soyad: Safiye ERSAN

İmza:

TEŞEKKÜR

Öncelikle danışmanım Doç. Dr. Cafer BUDAK'a çalışmanın daha fikir aşamasından, örnekleme, deney setlerini oluşturma, analizlerin yorumlanması ve tez taslağındaki düzeltmeler konularına kadar gösterdikleri destek ve sabırdan dolayı teşekkür ederim. Jüri üyelerime bu tezin daha nitelikli bir hale gelmesi için yaptıkları eleştiri ve önerileri için teşekkür ederim.

Tezin her aşamasındaki yardımları ve yol göstericiliğı için, analizlerin yorumlanması ve çizim aşamalarında sundukları destek için Öğr. Gör. Veysel GİDER'e teşekkür ederim.

En önemlisi, beni araştırma hevesiyle coşturdukları ve kendime bazı zamanlar inanmasam da bana inandıkları için annem Sevim ERSAN'a, babam Muhlis ERSAN'a, kardeşlerime ve arkadaşım Tuba SOLMAZ'a teşekkür ederim.

Yardımları ve destekleriyle yanımda olan değerli müdürüm Hüseyin AKCAN'a ve çalışma arkadaşlarıma da teşekkür ederim.

İÇİNDEKİLER

TEŞEKKÜR	v
İÇİNDEKİLER	vi
ŞEKİLLER LİSTESİ	viii
TABLolar LİSTESİ	x
SİMGELER VE KISALTMALAR LİSTESİ	xi
ÖZET	xiii
ABSTRACT	xiv
1. GİRİŞ	1
1.1 Literatür Taraması	3
1.2 Yapay Zeka	6
1.3 Makine Öğrenmesi	6
1.4 Derin Öğrenme	7
1.4.1 Yapay sinir ağları	7
1.4.2 Evrişimsel sinir ağları	9
1.5 Nesne Tanıma	11
1.6 Derin Öğrenme Tabanlı Nesne Tanıma Yaklaşımları	14
1.6.1 R-CNN mimarisi	15
1.6.2 Fast R-CNN mimarisi	16
1.6.3 Faster R-CNN mimarisi	17
1.6.4 Yolo algoritması	18
1.6.5 Önerilen yöntem(Yolov7 algoritması)	21
2. MATERYAL VE YÖNTEM	25
2.1 Veri Seti	25
2.2 Verinin Etiketlenmesi	26
2.3 YOLOv7 Modeli ile Eğitimin Gerçekleştirilmesi	29
2.4 Performans Metrikleri	30

3. ARAŞTIRMA BULGULARI.....	35
4. TARTIŞMA VE SONUÇ.....	42
KAYNAKLAR.....	43
ÖZGEÇMİŞ.....	50



ŞEKİLLER LİSTESİ

Şekil 1.1 Sağlıklı diş ve enfekte diş gösterimi	2
Şekil 1.2 Yapay zeka ve alt dalları	6
Şekil 1.3 Klasik programlama ve makine öğrenmesi karşılaştırılması.....	7
Şekil 1.4 Biyolojik sinir hücresi yapısı	8
Şekil 1.5 Yapay sinir ağının matematiksel modeli	8
Şekil 1.6 Yapay sinir ağı modeli	9
Şekil 1.7 Klasik bir CNN mimarisi.....	11
Şekil 1.8 Sınıflandırma	12
Şekil 1.9 Lokalizasyon.....	12
Şekil 1.10 Nesne tanıma.....	13
Şekil 1.11 Sınıflandırma, lokalizasyon ve nesne tanıma karşılaştırılması	13
Şekil 1.12 Nesne tanıma yaklaşımları.....	14
Şekil 1.13 Tek aşamalı ve çift aşamalı nesne dedektörleri	15
Şekil 1.14 R-CNN mimarisi	16
Şekil 1.15 Fast R-CNN mimarisi.....	17
Şekil 1.16 Faster R-CNN mimarisi.....	18
Şekil 1.17 Yolo'da nesne dedektörlerinin mimarisi	19
Şekil 1.18 Yolo versiyonlarının zaman çizelgesi	19
Şekil 1.19 Sınırlayıcı kutu.....	20
Şekil 1.20 Yolov7 mimarisi.....	23
Şekil 2.1 Diş röntgen görüntüleri	25
Şekil 2.2 (a) Periapikal diş röntgeni (b) panoramik diş röntgeni.....	26
Şekil 2.3 Nesne tanıma işlemlerinin akış diyagramı.....	26
Şekil 2.4 Labellmg programı ile etiketlenen veri görüntüsü.....	27
Şekil 2.5 YOLO etiket dosyasının içeriği	28
Şekil 2.6 Etiketlenmiş diş röntgen görüntüleri	28
Şekil 2.7 Roboflowda veri artırma yöntemleri uygulanan diş röntgen görüntüleri	29
Şekil 2.8 Karışıklık Matrisi	31
Şekil 2.9 IoU formülü	32
Şekil 2.10 IoU örneği.....	32
Şekil 3.1 YOLOv7 modelinin test verisi üzerindeki tespit sonuçları	35

Şekil 3.2 YOLOv7 modelinin test verisi üzerindeki tespit sonuçları	36
Şekil 3.3 YOLOv7 modelinin kesinlik eğrisi	36
Şekil 3.4 YOLOv7 modelinin duyarlılık eğrisi	37
Şekil 3.5 YOLOv7 modelinin kesinlik-duyarlılık eğrisi.....	37
Şekil 3.6 Performans grafikleri.....	38
Şekil 3.7 Yolov7 modelinin eğitim kayıp grafiği	39
Şekil 3.8 Yolov7 modelinin eğitim kayıp grafiği	39
Şekil 3.9 Yolov7 modelinin eğitim kayıp grafiği	39



TABLÖLAR LİSTESİ

Tablo 2.1 YOLOv7 modeli ile elde edilen performans metrik sonuçlarının karşılaştırılması.....	34
---	----



SİMGELER VE KISALTMALAR LİSTESİ

Simge	Açıklama
b_x	Orta Nokta
b_y	Orta Nokta
b_w	Genişlik
b_h	Yükseklik
p_c	Güven Skoru
C	Bağıl Sınıf Olasılığı

Kısaltma

Açıklama

YOLO	You Only Look Once
CNN	Convolutional Neural Network
RCNN	Regional Convolutional Neural Network
SSD	Single Shot Dedection
TP	True Positive
FP	False Positive
FN	False Negative
TN	True Negative
AP	Average Precision
mAP	Mean Average Precision
IoU	Intersection over Union
E-ELAN	Extended Efficient Layer Aggregation Networks
MPCA	Multiscale Principal Component Analysis
COCO	Coomon Objects in Context
RBN	Region Based Network
API	Application Programming Network
FPS	Frames Per Second
SVM	Support Vector Machine
CAD	Computer Aided Design

ÖZET

YOLOV7 ALGORİTMASI İLE DİŞ RÖNTGENLERİNDE LEZYON VE ÇÜRÜK TESPİTİ

ERSAN, Safiye

Yüksek Lisans, Biyomedikal Mühendisliği Bölümü

Danışman: Doç. Dr. Cafer BUDAK

Şubat 2024, 65 sayfa

Sağlık sektörü, derin öğrenme algoritmalarının kullanımı sayesinde teşhislerin daha tutarlı hale getirilmesi ve başarılı sonuçların elde edilmesi konusunda büyük ilerlemeler kaydetmektedir. Diş sağlığı açısından, diş iltihapları zaman içinde dişlerde çürüklere neden olmaktadır. Diş bakımına özen gösterilmediğinde, zamanla kişinin ağzında bakteriler oluşur. Bu bakteriler gıdalarla birleşerek diş minesine zarar verir ve diş çürükleri meydana gelir. Diş çürükleri yaşamımızı olumsuz yönde etkileyen önemli bir sağlık problemi olarak karşımıza çıkmaktadır. Yakın zamana kadar iltihaplı dişler, diğer bölgelere zarar vermesini önlemek amacıyla hemen çekilirdi. Günümüzde görüntüleme yöntemlerinin gelişmesiyle birlikte diş kayıplarını engellemek için çeşitli tedavi yöntemleri uygulanıp, başarı oranı artmıştır. Çürüklerin ve lezyonların teşhisi genellikle diş röntgen görüntüleri çekilerek yapılır. Ancak bu tür teşhisler, uzman kişiler tarafından gerçekleştirildiğinde dahi farklılık gösterebilmektedir. Bu nedenle, derin öğrenme temelli yaklaşımlardan yararlanma ihtiyacı doğmaktadır. Bu çalışmada, diş röntgenlerinde YOLOv7 tabanlı bir derin öğrenme algoritması kullanılarak lezyon ve çürüklerin otomatik olarak tespiti amaçlanmıştır. Uzman bir diş hekimi tarafından işaretlenmiş 400 adet panoramik diş röntgen görüntüsü kullanılmıştır. Bu işaretleme, lezyon ve çürük bölgelerinin hassas bir şekilde tanımlanmasını sağlamıştır. Daha sonra, bu görüntüler Roboflow platformunda YOLOv7 formatına dönüştürülmüş ve modelin eğitimi için kullanılmıştır. YOLOv7 algoritması, bu veriler üzerinde eğitilmiş ve diş röntgenlerindeki lezyonları ve çürükleri yüksek bir doğrulukla tanıma yeteneği sergilemiştir. Modelin performansı kesinlik, hatırlama, mAP gibi performans metrikleri kullanılarak değerlendirilmiş ve %38 ortalama kesinlik (mAP) değeri elde edilmiştir. Elde edilen sonuçlar, sağlık kurumları arasında teşhis tutarlılığını artırabilir, kişisel yorumlama hatalarını en aza indirebilir ve tedavi planlarını daha etkili hale getirebilir.

Anahtar Kelimeler: Nesne tanıma, YOLOv7, Diş lezyonu tespiti, Derin öğrenme

ABSTRACT

LESION AND CARIES DEDECTION IN DENTAL X-RAYS WITH YOLOV7 ALGORITHM

ERSAN, Safiye

Master of Science in Department of Biomedical Engineering

Supervisor: Doç. Dr. Cafer BUDAK

February 2024, 65 pages


The healthcare sector has made significant advancements in achieving more consistent diagnoses and successful outcomes through the utilization of deep learning algorithms. In the context of oral health, dental inflammations over time can lead to the development of cavities in teeth. When care is not taken for dental care, bacteria form in the person's mouth over time. This bacteria combine with food to damage tooth enamel and tooth decay occurs. Tooth decay is an important health problem that negatively affects our lives. Until recently inflamed teeth are immediately removed to prevent damage to other areas. Nowadays, with the development of imaging methods, various treatments have been used to prevent tooth lose and the success rate has increased. The diagnosis of these cavities and lesions are usually diagnosed by taking dental X-ray images. However, even when performed by expert professionals, such diagnoses may exhibit variations. Hence, there arises a need for leveraging deep learning-based approaches. This study aims to automatically detect lesions and cavities in dental X-ray images using a YOLOv7-based deep learning algorithm. Four hundred panoramic dental X-ray images, meticulously annotated by an expert dentist, were employed for this purpose. This annotation ensured precise delineation of lesion and cavity regions. Subsequently, these images were transformed into YOLOv7 format using the Roboflow platform and utilized for model training. The YOLOv7 algorithm was trained on this dataset and demonstrated a high level of accuracy in identifying lesions and cavities in dental X-ray images. The performance of the model was evaluated using performance metrics such as precision, recall and mAP resulting in an average precison(mAP) of 38%. The obtained results have the potential to enhance diagnostic consistency among healthcare institutions, minimize personal interpretation errors and optimize treatment plans.

Keywords: Object dedection, YOLOv7, Dental lesion dedection, Deep learning

1. GİRİŞ

Diş hekimliği, ağız içi hastalıkların teşhisi ve tedavisiyle ilgilenen hızla gelişen bir sağlık dalıdır. Ağız hastalıkları, dünya genelinde her yaştan kesimi etkileyen ve en sık görülen hastalıklar arasında yer alır. Bu kapsamda diş çürükleri, en sık görülen ağırlı diş hastalıklarından biridir (Datta vd., 2019). Ağız hastalıklarından en yaygın olanı kronik enfeksiyöz olan diş çürükleridir. Diş çürüğü, plaktaki mikroorganizmaların neden olduğu dişlerin sert dokularını etkileyen bir hastalık olarak tanımlanmaktadır. Amerika Birleşik Devletleri'nde (ABD) diş çürüğü prevalansı, 2-11 yaş grubu çocuklarda %41, 6-19 yaş grubu çocuk ve ergenlerde %42 ve 20 yaş üstü yetişkinlerde yaklaşık %90 arasındadır (Lee vd., 2018). Çin'de ise yetişkinlerde bu oran 35-44 yaş grubunda %89, 55-64 yaş grubunda ise %95,6 olduğu bildirilmiştir (Ding vd., 2021). Ayrıca dünya çapında yaklaşık 3,5 milyar insanın ağız hastalığından mustarip olduğu ve bu hastalıkları tedavi etmenin doğrudan maliyetinin 298 milyar dolar olduğunu bildiren hastalık yükü araştırmaları mevcuttur. Bu araştırmalar diş çürüklerinin büyük bir sosyal ve ekonomik yüke neden olduğunu da göstermektedir (Zhu vd., 2022).

Diş çürüklerine sıklıkla “defect” adı verilirken, “lezyon” ise vücutta çeşitli hastalıkların neden olduğu doku ve organ değişikliklerini ifade eder. Bu çürükler bakterilerin neden olduğu diş enfeksiyonlarının sonucunda ortaya çıkar (Majanga ve Viri, 2022). Çürük sinirlere ulaştığında, kök ucunda lezyon oluşmaya başlar. Tedavi edilmediği zaman çürüğün boyutu artar ve enfeksiyon dentin tabakasında yayılır. Enfeksiyon pulpa bölgesine ulaştığında da acı verici hale gelir. Daha sonra diş hekiminin görüşüne göre dolgu yapılır ya da diş çekilir. Bazı durumlarda ağrı rahatsızlık, şekil bozukluğu ve hatta ölüm gibi ciddi sorunlara yol açabilir. Bu sebeple, bu çürüklerin kötüleşmesini ve diş kayıplarını engellemek için erken teşhis ve tedavi kritik öneme sahiptir. Bu nedenle, diş hekimleri için röntgen görüntüleri incelenirken çürüklerin doğru olarak tespit edilmesi önem arz etmektedir.



Şekil 1.1 Sağlıklı diş ve enfekte diş gösterimi

Diş çürüğünün teşhisi, ilgili doktorların öznelliğine bağlı olarak görsel muayene ile tespit edilir. Gizli çürüklerin tespitinin zor olduğu düşünüldüğünde yanlış tanı oranı çok yüksektir. Ayrıca erken tanı her hastalıkta olduğu gibi ağız hastalıklarında da çok önemlidir. Ağızdan alınan panoramik radyografiler (X-ışınları) çürük gibi diş hastalıklarının teşhisinde çok kritik bir rol oynamaktadır (Zhu vd., 2022). Teşhis aracı olarak yaygın olmalarına rağmen diş çürüklerini radyografilerle teşhis etmek zor olabilir. Diş röntgen görüntüleri düşük kontrastları nedeniyle lezyonların tespitini zorlaştırır. Aynı radyografiyi inceleyen gözlemciler çürük lezyonlarının görülüp görülmediği konusunda çok büyük farklılıklara sahip olabilirler. Bu radyografin kalitesi, doktorun onu nasıl gördüğü ve bir muayeneyi tamamlama süresi gibi faktörlerden etkilenebilir (Al-Ghamdi vd., 2022). Aynı zamanda diş hekimlerinin hızlı bir şekilde çok sayıda hastanın röntgenlerini incelemesi gerekmektedir. Tüm bu zorluklar otomatik tespit yöntemine duyulan ihtiyacı artırmıştır (Türkoğlu ve Hanbay, 2018). Tüm bu etkenler, ağız boşluğundaki lezyonların özelliklerini belirleme potansiyeline sahip olabileceği düşüncesi, araştırmacıları yapay zekâ destekli diş teşhisine yöneltmiştir. Diş görüntülerinde diş tanıma ve sınıflandırma hastalık teşhisi için bir ön koşul olduğu için araştırmacıların çoğu çalışmalarında apikal kesit görüntüleri için görüntü işleme ve segmentasyonuna dayalı görüntü işleme ve segmentasyon algoritmaları uygulamıştır (Ding vd., 2022).

Yapay zekanın hızla gelişen teknolojileri, derin öğrenme algoritmalarının çeşitli uygulama alanlarında büyük başarılarla imza atmaktadır. Bu başarılardan biri de derin öğrenme algoritmalarının video ve görüntü analizi ile gözle görülemeyen nesneleri tespit etme yeteneğidir.

Panoramik radyograflerde lezyonların bilgisayar destekli teşhisine (CAD) yönelik teknikler ilerlemiştir. CAD, doktorların hızlı karar vermelerine yardımcı olan bilgisayar tabanlı sistemdir. CAD sisteminin temel amacı, işinde profesyonel bir insanın bulamadığı anormal işaretleri en erken zamanda tespit etmektir. Bu sebeple derin öğrenmeyi CAD alanına uygulama konusunda güçlü ilgileri beraberinde getiriyor. Derin öğrenmenin birçok makine öğrenimi görevindeki başarısı, çeşitli CAD türlerinin araştırma ve geliştirmesine olan ilgiyi artırıyor. Son zamanlarda görüntü sınıflandırma (Lin vd., 2021; Mahbod vd., 2020) nesne algılama (Talukdar vd., 2018; Wong vd., 2019) gibi çeşitli görevleri gerçekleştirdikleri, birçok tıbbi görüntüleme alanında derin öğrenme modelleri olan evrişimli sinir ağları (CNN) geliştirildi. Bununla birlikte tıbbi görüntüleme alanlarında nesne tespiti yöntemleri hızla ilerlemesine rağmen panoramik radyograflarda nesne tespiti hala zor olabilir (Cao vd., 2019; Dubost vd., 2020). Nesne tanıma, bilgisayarla görmenin önemli bir alanıdır ve bilimsel araştırma, endüstriyel üretimde, yüz algılama (Aralikatti vd., 2020; Brownlee, 2019) metin algılama (Wang vd., 2021; Zhang vd., 2020), yaya algılama (Gao vd., 2020), video algılama (Jiao vd., 2021; Zhu vd., 2020), araç algılama (Dai, 2019; Wang vd., 2019) ve tıbbi görüntü algılama (Liu vd., 2019; Yang ve Yu, 2021) gibi uygulamaları mevcuttur (Xiao vd., 2020). Bu bağlamda sağlık sektörünün bir parçası olan diş hekimliği alanında da derin öğrenme tabanlı nesne tanıma yöntemleri kullanılmaktadır. Bu çalışmada derin öğrenme tabanlı nesne tanıma yöntemlerinden YOLOv7 algoritması ile eğitim gerçekleştirilmiştir. Bu çalışmanın amacı nesne tanıma algoritmaları kullanılarak, diş hekimlerinin çürük ve lezyonları daha doğru bir şekilde tespit etmelerine yardımcı olmaktır. Böylece hem hekimlerin hem de hastaların yaşam kalitesi artar hem de yanlış teşhislerden kaynaklanan hatalar da önlenmiş olur.

1.1 Literatür Taraması

Günümüzde yapay zekâ birçok alanda kullanılmaktadır. Örneğin akıllı asistanlar ve sohbet robotları müşterilerin sorunlarına çözüm bulmak için yapay zekadan yararlanır. Öneri motorları da kullanıcıların izleme alışkanlıklarını dikkate alarak televizyon programları için otomatik önerilerde bulunabilmektedir.

Ben Ali ve arkadaşları dijital diş röntgenlerinde çürük tespiti ile ilgili bir yazılımı kullanmıştır (Wang ve Summers, 2012; Foster vd., 2014). Valizadeh ve ekibi, dijital radyografi görüntülerinde mine ve dentin seviyesindeki çürükleri tespit eden bir yazılım geliştirmiştir (Valizadeh vd., 2015). Srivastava ve ekibi, bitewing radyografi görüntülerinde diş çürüklerini tespit eden bir Bilgisayar Destekli Tanı sistemini göstermiştir (Ali vd., 2016).

Lee ve arkadaşları ise periodontal olarak riskli dişlerin tespitini gösteren bir çalışma yapmışlardır (Srivastava vd., 2017). Lee ve arkadaşları tarafından yapılan bir çalışmada periapikal radyografilerde diş çürüklerini tespit etmek amacıyla derin öğrenme tabanlı konvolüsyonel sinir ağı (CNN) mimarisi ile oldukça iyi bir performans sağlanmıştır (Lee vd., 2018).

Diş hekimliğinde lezyon ve çürük tespiti için derin öğrenme teknikleri geliştirilmiş ve literatürde yayınlanmıştır (Çelik vd., 2019). Derin öğrenme algoritmaları kullanılarak en başarılı yöntem bulunmaya çalışılmıştır. Tuzoff ve arkadaşları tarafından yapılan bir çalışmada CNN tabanlı bir sistemin otomatik diş çizelgeleme amacıyla eğitilebileceği gösterilmiştir (Tuzoff vd., 2019). Hung ve arkadaşları tarafından yapılan çalışmada yaşlı nüfusunda kök çürüklerinin erken teşhisi ve tedavisinde makine öğrenme algoritmalarının iyi performans gösterdiği bulunmuştur (Hung vd., 2019). Ekert ve arkadaşları tarafından yapılan çalışmada sınırlı sayıda görüntü verisi kullanılarak eğitilen orta derece bir CNN ile panoramik radyografilerdeki apikal lezyonlar tespit edilmiştir (Ekert vd., 2019). Murata ve arkadaşları tarafından yapılan çalışmada panoramik radyografilerde maksiller sinüzit için teşhis performansı derin öğrenme ile oldukça yüksek bulunmuştur (Murata vd., 2019).

Patil ve arkadaşları, diş çürüklerini tespit etmek amacıyla kullandıkları algoritmanın analizini uyarlanabilir sinir ağı aracılığıyla yaptılar. Uygulamada görüntü ön işleme, özellik çıkarma ve sınıflandırma ile diş çürükleri belirlenmiştir. MPCA-ADA modeli sınıflandırma için kullanılmıştır. Görüntü ön işleme ile görüntünün piksel yoğunluğu açısından iyileştirilmesi sağlanarak otsu eşikleme ve aktif konturlar ile ilgilenilen bölge elde edilmiştir. Özellik çıkarma için Çok Ölçekli Temel Bileşen Analizi

(MPCA) kullanılıp, sınıflandırma için ileri beslemeli ağı girdi olarak kullanılan ağırlıkla çarpılmıştır. Seçilen özellikler arasındaki mesafeyi maksimum seviyeye çıkarmak için doğrusal olmayan programlama optimizasyonu kullanılıp bu şekilde sınıflandırma performansında artış sağlanmıştır. Bu uygulamada üç test vakası yürütülmüştür. Yazarlar MPCA-ADA'nın her test vakası için diğer algoritmalarından %20 daha doğru olduğunu göstermişlerdir (Patil vd., 2019).

Ağız ve diş sağlığında, hastalıkların erken teşhisi önem arz etmektedir. Bu yüzden erken diş çürüğü tespitleri, tanı raporlama, gömülü yirmi yaş dişlerin çene içindeki yerlerinin anatomik zorluk oluşturup oluşturmayacağı yapay zekâ ile daha kolay tespit edilebilmesi özellikle kök kanalının belirlenmesinde kullanılmaktadır (Khanagar vd., 2021).

Thanh ve arkadaşları; diş çürüklerini tespit etmek için, Faster R-CNN, YOLO v3 SSD ve RetinaNet olmak üzere dört tane derin öğrenme modelini kullanıp, mobil tabanlı bir teşhis uygulaması sunmuşlardır. Eğitimde toplam 1902 görüntü kullanılmıştır. Bu görüntüler dişlerin durumunu gösteren; merkezi görünüm, sol yan görünüm ve sağ yan görünüm olmak üzere üç sınıfa ayrılmıştır. Faster R-CNN ve YOLOv3 ile en iyi performans elde edilmiştir (Thanh vd., 2022).

Kühnisch ve arkadaşları, ağız içi görüntülerdeki çürükleri tespit etmek amacıyla konvolüsyonel sinir ağı kullanmıştır. Kaliteden dolayı görüntülerin birçoğu filtrelenmiştir. CNN ile toplamda 2417 görüntü üzerinde eğitim gerçekleştirilmiştir. Model görüntü büyütme ve transfer öğrenme gibi önceden belirlenmiş ve birçok özellikten oluşan bir sistem ile eğitilmiştir. Görüntü artırımı ile modelde sürekli olarak çok sayıda görüntü elde edilmiştir. Önceden belirlenmiş ağırlıklarla birlikte MobileNetV2 adlı sinir ağı kullanılarak eğitim hızlandırılmıştır. CNN ile görüntülerin %100'ü dikkate alındıktan sonra %92,5'lik bir doğruluk sağlanmıştır (Kühnisch vd., 2022).

Diş röntgen görüntülerinin analizi için derin öğrenme tekniklerinin kullanılması, diş hekimlerinin daha doğru teşhisler koymalarına yardımcı olabilir. Bu çalışma, diş röntgenlerinde lezyon ve çürüklerin otomatik olarak tespiti için YOLOv7

algoritmasını kullanarak bu amaca yönelik bir adımı temsil etmektedir. Bu çalışmanın amacı YOLOv7 algoritmaları kullanılarak diş hekimlerinin çürük ve lezyonları daha doğru bir şekilde tespit etmelerine yardımcı olmaktır. Böylece hem hekimlerin hem de hastaların yaşam kalitesi artar hem de yanlış teşhislerden kaynaklanan hatalar da önlenmiş olur.

1.2 Yapay Zekâ


Yapay zeka insana özgü görme, konuşma, anlama gibi davranışları makinelerin yapabilme yeteneğidir. Bilgisayarlar karmaşık matematiksel hesaplamaları çok kısa bir sürede yapabilirken; insanlara özgü konuşma, anlama, düşünme becerilerine sahip değildir. Yapay zeka makinelere düşünme becerisi kazandırma çalışmalarıdır (Murat, 2021). Şekil 1.2’de yapay zeka ve alt dalları hiyerarşik biçimde gösterilmiştir.



Şekil 1.2 Yapay zeka ve alt dalları

1.3 Makine Öğrenmesi

Yapay zekanın tanıma ve öğrenme yeteneklerini geliştiren uygulamalara makine öğrenmesi denir. Bilgisayarın en iyi tahminde bulunabilmesi için en uygun algoritmayı oluşturmasını hedefler. Bu algoritma eğitim sırasında karşılaştığı örneklerden öğrenip elde ettiği bilgiyi yeni durumlara uyarlayabilir. İşte makine öğrenme, bu algoritmaların geliştirilip bilgisayara öğrenme işinin kazandırılmasıdır. Klasik programlamada kurallar ve veriler makineye verilip cevaplar istenir. Makine öğrenmesinde ise veriler ve cevaplar makineye verilip kurallar makineden istenir. Yani makinenin bir kural çıkarması istenir (Murat, 2021). Şekil 1.3’de klasik programlama ve makine öğrenmesi arasındaki fark gösterilmiştir.



Şekil 1.3 Klasik programlama ve makine öğrenmesi karşılaştırılması

1.4 Derin Öğrenme


Yapay zeka ile çok zor matematiksel ifadelerin çözülmesi sağlanabilir. Ama insanlar tarafından kolay bir şekilde yapılan konuşma, ses tanıma, nesne tanıma gibi davranışları bilgisayarların yapması mümkün değildir. Bilgisayarların kavramlar hiyerarşisi mantığına göre, örüntü kurma yoluyla karmaşık kavramlar daha basit kavramlardan yola çıkarak oluşturulabilir. Derin öğrenme bu kavramların birbiri üzerine eklenerek birden çok katmandan oluşan bir yapıdır (Goodfellow vd., 2018).

1.4.1 Yapay sinir ağları

Yapay sinir ağları, insan sinir sisteminin taklit edilmesi sonucunda ortaya çıkmıştır (Murat, 2021). Yapay sinir ağları biyolojik sinir sisteminin modellenmesi hedefinden esinlenmiştir.


İnsan beyninin nasıl çalıştığı kesinlik derecesinde bilinmemektedir. Bilgisayarlar çok zor matematiksel hesaplamaları yapmalarına rağmen insan beyninin çok kolay bir şekilde yapabildiği (konuşma, görme, duyma) davranışları hala yapamamaktadır. Bununla birlikte biyolojik beyin tecrübe ile öğrenme, bilgiyi kendi kendine yorumlama, hatta eksik bilgilerden sonuçlar çıkarma yeteneğine sahiptir. İşte yapay sinir ağları bu özellikleri bünyesinde bulunduracak şekilde geliştirilmektedir (Türkoğlu, 1996). İlk olarak nörofizyolog McCulloch, matematikçi Pitts 1943 yılında beyindeki nöronların nasıl çalıştığı ile ilgili basit bir sinir ağı oluşturarak siniri

matematiksel olarak modellemiştir (Cantemir, 2019). Şekil 1.4'te biyolojik sinir hücresinin yapısı gösterilmiştir.




Şekil 1.4 Biyolojik sinir hücresi yapısı

Nöronlar dentrit, gövde, akson ve çekirdekten oluşur. Nöronlar dentritleri aracılığıyla aldıkları sinyalleri aksone iletir. Akson kolları bir sonraki nöronun dentritine sinapsları aracılığıyla bağlanır. Şekil 1.5'te yapay sinir ağının matematiksel modeli gösterilmiştir. Şekil 1.6'da yapay sinir ağı modeli gösterilmiştir.



Şekil 1.5 Yapay sinir ağının matematiksel modeli (Calp, 2019)



Şekil 1.6 Yapay sinir ağı modeli

Nöron girişlerden aldığı sinyallerin her birini o sinyallere ait ağırlıkla çarpıp toplamını alır. Daha sonra bu toplam değere bias değeri eklenerek nöronun değeri bulunur. Bir nöronun çıkışının aktif olup olmayacağını aktivasyon fonksiyonu belirler. Aktivasyon fonksiyonu değer üzerinde non-lineer bir dönüşüm gerçekleştirir (Keskintaş 2021). Şekil 1.6’da insan beyninden esinlenerek yapay zekâ çalışmalarında kullanılan yapay sinir ağı gösterilmiştir. (Murat, 2021). Yapay sinir ağı çalışmaları öğrenme ve tanıma alanında yoğunlaşmıştır.

1.4.2 Evrişimsel sinir ağları

Evrişimsel sinir ağları görüntülerden belirli özellikleri tanıma, sınıflandırma ve analiz etmede yaygın olarak kullanılan derin sinir ağları sınıfıdır. CNN yüksek doğruluğa sahip olmasından dolayı görüntü tanımda kullanışlıdır. (Heaton vd., 2018). CNN temelinde matematiksel bir işlem olan evrişim işlemini barındırır (Çağlayan, 2018). Evrişim özel bir lineer işlem türüdür. Matematikte iki fonksiyon arasındaki evrişim (1.1) numaralı denklemde; $f, g : R^d \rightarrow R$ için, şöyle tanımlanır (Zhang vd., 2020).

$$(f * g)(x) = \int f(z)g(x - z)dz \quad (1.1)$$


Yani, bir işlev “çevrilmiş” ve x ile kaydırılmış olduğunda f ve g arasındaki örtüşme ölçülür. Ayrık nesnelere sahip olduğunda, integral bir toplama dönüşür. Örneğin Z üzerinde çalışan indisi olan kare toplanabilir sonsuz boyutlu vektörler kümesinden vektörler için (1.2) numaralı denklemdeki tanımı elde ederiz.

$$(f * g)(i) = \sum_a f(a)g(i - a) \quad (1.2)$$

İki boyutlu nesneler için sırasıyla f için (a,b) ve g için $(i-a, j-b)$ indislerine karşılık gelen toplam (1.3) numaralı denklemde gösterilmektedir.

$$(f * g)(i, j) = \sum_a \sum_b f(a, b)g(i - a, j - b) \quad (1.3)$$

CNN biyolojik sinir sisteminden esinlenerek oluşturulmuş bir yapay sinir ağı türüdür. Algoritmasının temeli hayvanların görme merkezinden esinlenerek meydana gelmiştir. Burada matematiksel konvolüsyon işlemi hayvanlarda bir nöronun kendi uyarı alanından uyarılara verdiği yanıt olarak değerlendirilebilir (Fukushima, 1980; Hubel ve Wiesel, 1968; Lecun vd., 1998). Bir veya daha fazla konvolüsyonel katman, alt örnekleme (subsampling) katman ve standart çok katmanlı bir sinir ağı gibi bir veya daha fazla tam bağlı katman CNN’i oluşturur (Lecun vd., 2015). CNN’yi oluşturan evrimsel katmanlar, havuz katmanı ve tam bağlı katmanlar olmak üzere üç tür katmanı vardır. Bu katmanlar bir araya geldiğinde CNN mimarisi oluşmuş olacaktır. Klasik bir CNN yapısı Şekil 1.7’de gösterilmiştir. CNN nesnelerin özelliklerine göre sınıflandırılmasını ve görüntü içerisinde bulunduğu konumun tespit edilmesini sağlar. Bu ağlar görüntü işleme ve sınıflandırmada başarılıdır.



Şekil 1.7 Klasik bir CNN mimarisi

CNN tabanlı mimarilere sahip çok katmanlı ağ yapıları, derin öğrenme algoritmalarının incelenmesinde dikkat çeken bir özelliktir. Bu mimariler, farklı bilimsel çalışmalarda çeşitli uygulamalara yönelik olarak kullanılmıştır (Onuk vd., 2023; Karadağ vd., 2021). CNN algoritmaları yüz tanıma, nesne algılama ve görüntü sınıflandırma gibi farklı alanlarda kullanılmıştır (Burgaz, 2020). CNN modeli başarısından dolayı nesne tanıma problemlerinde tercih edilen bir ağ modelidir (Wang vd., 2022). Nesne tanıma amacıyla kullanılan CNN'den istenen; görüntü içerisindeki nesneleri sınıflandırıp bu nesnelerin görüntü içerisinde bulunduğu konumu tespit etmesidir.

1.5 Nesne Tanıma

Görüntü işleme ve bilgisayarlı görme alanında, öne çıkan bir görev nesne tanımadır. Nesne tanıma, verilerin farklı özelliklerine göre nesnenin en uygun özelliklere sahip sınıfa yerleştirme işlemidir. Aslında yaptığı işlem itibarıyla nesnenin sınıflandırılmasıdır. Bireyler herhangi bir nesneyi kolayca tanıyabilmekte iken makinelerin bunu yapması mümkün değildir. Tanıma görevinin algoritmik açıklamaları ile makinelere uygulanması karmaşıktır. Bu sebeple verimliliği yüksek karmaşık olmayan nesne tespit yöntemlerinin uygulanması gereklidir (Khurana ve Awasthi, 2013).

Hayatımızın her alanında parmak izi ve insan yüzü tanıma gibi alanlarda nesne tanıma uygulamaları gelişmiştir. Bununla birlikte nesne tanımda görüntü işlemenin payı oldukça fazladır. Nesne tanıma tıbbi teşhis, biyomedikal sinyallerin analizi,

insan yüzü ve parmak izi tanıma, ses tanıma gibi uygulamalarda kullanılır (Türkoğlu, 1996).

- **Sınıflandırma**


Görüntü sınıflandırma, Şekil 1.8’de gösterildiği gibi verilen bir görüntünün içerdiği bir nesneyi önceden belirlenmiş sınıflardan birine kategorize etme işlemidir. Algoritma her nesne için en olası sınıfı önerir (O’Mahony vd., 2019).



Şekil 1.8 Sınıflandırma

- **Lokalizasyon**


Sınıflandırma yapılırken sadece görüntünün hangi sınıfa ait olduğu tahmin edilir. Nesnenin görüntü içerisindeki konumu hakkında bir yorum yapılmaz. Şekil 1.9’da lokalizasyon işleminde ise nesnenin etrafına sınırlayıcı kutu çizilip konumu hakkında yorum yapılır.




Şekil 1.9 Lokalizasyon

Sınıflandırma işlemi bütün görüntü üzerinde uygulanır. Bu yüzden bir görüntüde birden çok nesne ve sınıf olduğu zaman ilgili görüntü tek bir çıkış etiketiyle

sınıflandırılmaz. Nesne tanıma ile görüntüde yer alan nesnelerin tek tek sınıfı ve içinde bulundukları konumu bulunabilir. Şekil 1.10'da gösterildiği gibi görüntüde bulunan nesnelerin her birinin sınıf olasılık değeri ile birlikte sınırlayıcı kutuları ayrı ayrı tespit edilmiştir. Şekil 1.11'de sınıflandırma, lokalizasyon ve nesne tanıma olayları karşılaştırılmıştır.



Şekil 1.10 Nesne tanıma




Şekil 1.11 Sınıflandırma, lokalizasyon ve nesne tanıma karşılaştırılması

Nesne tanıma, geleneksel yöntemler ve derin öğrenme yöntemleri olmak üzere iki sınıfa ayrılır. Nesne tanımada derin öğrenme yöntemlerinde başarı oranı daha yüksektir (Tao vd., 2017).

1.6 Derin Öğrenme Tabanlı Nesne Tanıma Yaklaşımları

Derin Öğrenme, yapay sinir ağları olarak bilinen algoritmaları kullanan bir sistemdir. Genellikle görüntü sınıflandırma, nesne tanıma, video analizi gibi alanlarda uygulanmaktadır. Derin öğrenme nesne tanıma ve sınıflandırmada etkilidir. Sınıflandırmada görüntüdeki nesnenin sınıfı tahmin edilir. Nesne tanımda ise bir görüntüdeki nesne bulunur ve bulunan nesnenin sınıfı ve konumu tespit edilmiş olur (Sharma ve Mir, 2020).


Şekil 1.12’de gösterildiği gibi nesne tanıma tek aşamalı ve çift aşamalı nesne tespit algoritmaları olmak üzere iki sınıfa ayrılmaktadır (Biçgi, 2022). Tek adımlı nesne tanıma algoritmaları SSD ve YOLO modellerini kullanarak özellikleri yalnızca bir kez yakalayarak hedefleri tanımlar. Çift aşamalı nesne tespit algoritmalarında ise RCNN, Fast RCNN, Faster RCNN Mask RCNN modelleri kullanılarak öncelikle bölge seçimi yapılır daha sonra nesne tespit edilir (Li vd., 2023).



Şekil 1.12 Nesne tanıma yaklaşımları

Son yıllarda nesne tanıma ile derin öğrenmeye dayalı teknikler geliştirildi. Nesne tanımda kullanılan birçok algoritma ve teknoloji vardır. YOLO (You Only Look Ones) algoritmaları, CNN (Convolutional Neural Networks) tabanlı tek adımlı hedef tespit modelidir.

Şekil 1.13'te gösterildiği gibi YOLO'da nesne tanıma problemi bir regresyon problemine dönüştürülerek Faster R-CNN algoritması gibi çift aşamalı hedef tespit modellerinden ayrılmaktadır. YOLO algoritmaları hız ve doğruluk açısından daha iyi performans gösterdiklerinden dolayı daha çok tercih edilmektedir (Kıvrak ve Gurbuz, 2022).




Şekil 1.13 Tek aşamalı ve çift aşamalı nesne dedektörleri

1.6.1 R-CNN mimarisi

Bölge tabanlı CNN (R-CNN), algılamayı sınıflandırma ve yerleştirme problemine dönüştürmek için CNN'lerle birlikte bir bölge önerisi modülü kullanır. Giriş görüntüsü ilk olarak bölge önerisi modülünden geçirilir. Bu modül seçici arama kullanarak bir nesneyi bulma olasılığı daha yüksek olan görüntünün parçalarını bulur. Daha sonra bu adaylar çarpıtılır ve 4096 boyutlu bir özellik vektörü çıkaran CNN ağı ile yayılır. Özellik vektörleri de destek vektör makinelerinden (SVM) geçirilir. R-CNN karmaşık çok aşamalı eğitim sürecine sahiptir. İlk aşama, CNN'yi büyük bir sınıflandırma veri kümesiyle önceden eğitmektir. Şekil 1.14'te R-CNN mimarisi gösterilmiştir.


R-CNN nesne tanımada yeni bir dalga yarattı ancak yavaştı (yaklaşık 47 sn). Bu nedenle küçük bir veri seti üzerindeki bir eğitim günlerce sürebilir.



Şekil 1.14 R-CNN mimarisi

1.6.2 Fast R-CNN mimarisi

Fast R-CNN, birden fazla sistemi ayrı ayrı eğitmek yerine uçtan uca eğitilebilir tek bir sistem haline getirdi. Ağ girdi olarak bir görüntüyü ve nesne önerilerini alır. Daha sonra özellik haritalarını oluşturmak için bir dizi evrişim katmanından geçirilir ve nesne önerileriyle eşlenir. Fast R-CNN, R-CNN’de hızdaki bir gelişme olarak tanıtılırken, doğrulukteki artış tamamlayıcı nitelikteydi. Eğitim sürecini basitleştirdi, piramidal havuzlamayı kaldırdı ve yeni bir kayıp fonksiyonu sundu. Şekil 1.15’te Fast R-CNN mimarisi gösterilmektedir.




Şekil 1.15 Fast R-CNN mimarisi

1.6.3 Faster R-CNN mimarisi

Faster R-CNN, gerçek zamanlı nesne algılamaya biraz daha yaklaşmış olsa dahi bölge önerisi oluşturma hala bir büyüklük sırasına göre daha yavaştı. Giriş görüntüsü, bir dizi özellik eşlemesi elde etmek için önce CNN'den geçirilir. Bunlar sınırlayıcı kutular ve sınıflandırmalarını üreten bölge teklif modülü (RBN)'ne iletilir. Seçilen öneriler daha sonra ROI havuzu katmanındaki önceki CNN katmanında elde edilen özellik haritalarına geri eşlenir ve sonuçta tamamen bağlı katmana beslenir. Sonuç daha sonra sınıflandırıcıya ve sınırlayıcı kutu regresyoncusuna gönderilir. Daha hızlı R-CNN, bölge teklifi modülü olarak RBN'ye sahip hızlı R-CNN'dir. Faster R-CNN mimarisi Şekil 1.16'da gösterilmektedir.


Faster R-CNN'nin eğitimi çok farklı görevleri yerine getiren iki model arasında paylaşılan katmanların varlığı nedeniyle daha karışıktır. Daha hızlı R-CNN, önceki algılamalara göre doğruluğunu artırdı ve çıkarım süresini büyüklük sırasına göre azalttı.



Şekil 1.16 Faster R-CNN mimarisi


1.6.4 YOLO algoritması

Nesne tanıma otonom araçlar, robotik ve video gözetimi gibi alanlarda kullanılmaktadır. Nesne tanıma algoritmaları arasında YOLO, görüntülerdeki nesnelerin hızlı ve güvenilir şekilde tanımlanmasını sağlayarak, hız ve doğruluk açısından ön plana çıkmıştır. YOLO’da nesne dedektörlerinin mimarisi Şekil 1.17’de gösterildiği gibi omurga, boyun ve kafa olarak tanımlanmıştır. Omurga giriş özelliklerinden faydalı bilgilerin çıkarılmasından sorumludur. Boyun omurgayı başa bağlayan bir ara bileşendir. Kafa kısmı ise nesne dedektörünün son kısmıdır. Kafa kısmı ise omurga ve boyun tarafından sağlanan özelliklerden faydalanan görüntü içerisindeki nesneyi tahmin etmekten sorumludur.



Şekil 1.17 YOLO'da nesne dedektörlerinin mimarisi

Joseph Redmon ve diğerleri (2016) tarafından ilk defa kullanılan YOLO algoritması, "You Only Look Once" yani Türkçe olarak "Sadece Bir Kez Bak" ifadesinin kısaltmasıdır (Redmon vd., 2016). Şekil 1.18'de gösterildiği gibi YOLO ailesi başlangıçtan bu yana performansı artırmak için her biri önceki sürümlerin üzerine inşa edildi. Zamanla birçok yinelemeyle gelişti.




Şekil 1.18 Yolo versiyonlarının zaman çizelgesi

Görüntüyü bölen YOLO algoritması, ardından bu bölgelerdeki nesnelerin konumlarını belirlemek için sınırlayıcı kutular çizer. Bu kutulara "bounding box" adı verilir ve her bölgedeki nesnenin var olma olasılığını değerlendiren bir kriter olan "Güven Skoru" bulunmaktadır.

YOLO algoritmasının temel mantığını kavramak için, neyin tahmin edildiğinin anlaşılması büyük bir öneme sahiptir. Nesne tanıma sürecinde hedef, nesnenin sınıfını ve konumunu belirleyen sınırlayıcı kutuların doğru bir şekilde tahmin edilmesidir. Her bir sınırlayıcı kutunun parametreleri şu şekildedir:

- Orta Nokta (b_x, b_y)
- Genişlik (b_w)
- Yükseklik (b_h)
- Güven skoru (p_c)
- Bağlı sınıf olasılığı (c)



Şekil 1.19 Sınırlayıcı kutu

Şekil 1.19’da sınırlayıcı kutunun parametreleri gösterilmiştir. Ancak, sınırlayıcı kutuda bulunma olasılığı olarak tahmin ettiğimiz gerçek sayı p_c 'yi kullanıyoruz. p_c nesnenin tahmini ile gerçek nesne arasındaki eşleşme yüzdesini ifade eder. Bağlı sınıf olasılığı (c), eğitimdeki sınıf sayısı kadar tahmin değerini gösterir.

YOLO, görüntüde potansiyel nesneleri aramaz; bunun yerine, genellikle $N \times N$ ızgaralara bölünmüş hücrelerde görüntüyü işler. Sınırlayıcı kutu y koordinatlarını tahmin etme sorumluluğu her bir hücreye aittir. Sınırlayıcı kutu merkezi koordinatları bir hücrenin içinde olduğunda, bir nesne o hücrenin içinde düşünülecektir. Merkez koordinatları hücre bazında tespit edilirken, yükseklik ve genişlik değerleri görüntünün genel ölçülerine göre belirlenir (Altay ve Yılmaz, 2023).

YOLO, girdi görüntüsünü bir kez evrişimli sinir ağından geçirir ve nesneleri tespit ettiğinde görüntü üzerine "bounding box" çizer. YOLO algoritması, girdi görüntüsünü 5×5 , 9×9 , 17×17 gibi ızgaralara böler. Her ızgara, kendi içinde nesne olup olmadığını değerlendirir; eğer nesne varsa, merkez noktasının kendi alanında

olup olmadığını kontrol eder. Eğer nesnenin merkezi noktasında ise, ızgara o nesnenin sınıfını, yüksekliğini ve genişliğini bulur ve etrafına sınırlayıcı kutular çizer.

Sınırlayıcı kutuların içinde bulunan nesnelerin öncelikle nesne olup olmadığı ardından bu nesnenin hangi sınıf etiketine sahip olduğu kontrol edilir. Birden fazla ızgara nesnenin kendi içerisinde olduğunu düşünebilir. Bu durumda gereksiz sınırlayıcı kutular oluşur. Bütün sınırlayıcı kutuların güven skoru vardır. Sınırlayıcı kutulardan güven değeri en yüksek olanı “Maksimum Olmayanı Bastırma” (Non Max Suppression) algoritması sayesinde çizilmiş olur. “Maksimum Olmayanı Bastırma” algoritması ile gereksiz kutuların ortaya çıkması engellenir. YOLO her sınırlayıcı kutunun içinde güven skoru hesaplayarak nesne tanıma işlemini gerçekleştirir (Yılmaz vd., 2023). Redmon ve arkadaşları (Redmon vd., 2016), nesne tanıma problemini bir regresyon problemine indirgemıştır. Buna ek olarak, tek bir sinir ağının kullanılması, görüntünün evrişimsel sinir ağından geçirilerek maliyeti daha düşük bir şekilde sonuca ulaşılabileceğini göstermiştir. Bu tek sinir ağı, çevreleyici kutuları ve sınıf olasılıklarını tüm görüntüyü değerlendirerek doğrudan tahmin etmektedir (Biçgi ve Karaca, 2022).

YOLO algoritmasında, giriş görüntüsü, konvolüsyon ve özellik çıkarma katmanı aracılığıyla işlenir. Böylece görüntü içindeki nesneler tanımlanır. YOLO algoritması, tek bir geçişte görüntü verileri üzerinde birden çok nesneyi tespit etmeyi amaçlar, bu da algoritmanın hızlı çalışmasını sağlar. YOLO, diğer nesne tanıma algoritmalarına göre daha doğru sonuçlar elde edip aynı zamanda hızlı çalıştığı için özellikle gerçek zamanlı uygulamalarda tercih edilen bir seçenektir (Kılıç ve Nabıyev, 2023). YOLO tıp alanında kanser tespiti (Al-Masni vd., 2018; Nie vd., 2019), deri segmentasyonu (Unver ve Ayan, 2019), ilaç tanımlama (Tan vd., 2021) için kullanılmıştır. Bu da gelişmiş teşhis doğruluğu ve daha verimli tedavi süreçlerine yol açar.


1.6.5 Önerilen yöntem (Yolov7 algoritması)

YOLOv7 (Wang vd., 2022) YOLOv4 ve YOLOR’un aynı yazarları tarafından Temmuz 2022’de ArXiv’de yayınlanmıştır. Bilinen tüm nesne dedektörlerini 5 FPS

ile 160 FPS aralığında hız ve doğruluk açısından geride bıraktı. YOLOv7 önceden eğitilmiş algoritmalar olmadan, yalnızca MS COCO veri kümesi kullanılarak eğitilmiştir.

YOLOv7, güçlü ve hızlı bir ağ mimarisine sahiptir, bu da etkili özellik bütünleştirme, daha doğru nesne tanıma ve geliştirilmiş etiketleme yetenekleri anlamına gelir. Bu özellikleri sayesinde, diğer derin öğrenme modellerinden daha az bilgi işleme gücü ve donanım gereksinimi gerektirir ve küçük veri kümeleriyle önceden eğitilmiş ağırlıklara ihtiyaç duymadan hızlı bir şekilde eğitilebilir (Wang vd., 2022). Geleneksel nesne tanıma algoritmaları, genellikle görüntüyü bölgelere ayırarak nesne içeren bölgeleri seçerek ve her bölgeyi ayrı ayrı sınıflandırarak işlem yükünü artırır. YOLOv7 ise görüntüyü tek bir seferde evrimsel sinir ağından geçirir ve grup normalizasyonu uygular. Bu, çerçeve işleme hızını 5 FPS'den 160 FPS'e kadar değişen bir hızda artırır (Hu vd., 2022). FPS, bir saniyede işlenen görüntü sayısını belirtmek için kullanılır.

YOLOv7 yapısı, E-ELAN hesaplama bloğundan meydana gelir. E-ELAN mimarisi, çerçevenin daha etkili bir şekilde öğrenmesini sağlar. Bellek erişim maliyeti, G/Ç kanal oranı, element bazlı işlem, aktivasyonlar ve gradyan yolunu analiz ederek tasarlanan faktörler, hız ve doğruluğu etkiler (Özcan ve Bakır, 2023). Şekil 1.20'de YOLOv7 mimarisinin gösterildiği bir görselleştirme bulunmaktadır.



Şekil 1.20 Yolov7 mimarisi (Terven ve Cordova-Esparza, 2023; Wang vd., 2023)

Genişletirilmiş verimli katman birleştirme ağı (E-ELAN) (Wang vd., 2022); en kısa ve en uzun gradyan yolunu kontrol ederek derin bir modelin daha verimli bir şekilde öğrenmesini ve yakınsamasını sağlayan bir stratejidir. YOLOv7’de sınırsız yığılmış hesaplama blokları kullanılmıştır. E-ELAN orijinal gradyan yolunu yok etmeden ağıın öğrenmesini geliştirmek için kardinaliteyi karıştırıp birleştirerek farklı grupların özelliklerini birleştirir.

Birleştirme tabanlı modeller için model ölçeklendirme; bazı model niteliklerini ayarlayarak farklı boyutlarda modeller oluşturur. YOLOv7 mimarisi derinlik ölçekleme gibi standart ölçme tekniklerinin bir geçiş katmanının giriş kanalı ile çıkış kanalı arasında bir oran değişikliğine neden olduğu birleştirme tabanlı bir mimaridir. Bu da modelin donanım kullanımında bir azalmaya yol açar. YOLOv7 modelinin

optimum yapısını korumak için bloğun derinliğinin ve genişliğinin aynı faktörle ölçeklendirildiği birleştirme tabanlı modelleri ölçeklendirmek için yeni bir strateji önerilmiştir.

YOLOv7, YOLO algoritmasının geliştirilmiş bir sürümüdür. Bu çalışmada derin öğrenme tabanlı nesne tanıma yöntemlerinden YOLOv7 algoritması ile eğitim gerçekleştirilmiştir. Doğruluk ve hız kriterleri açısından daha iyi performans sağladığı için diş röntgenlerinde lezyon ve defect tanıma işlemi için YOLOv7 algoritması kullanılmıştır.


Bu çalışmanın amacı YOLOv7 algoritmaları kullanılarak diş hekimlerinin çürük ve lezyonları teşhis etmelerine yardımcı olmaktır. Bu şekilde hem hekimlerin hem de hastaların yaşam kalitesi artar hem de yanlış teşhislerden kaynaklanan hatalar da önlenmiş olur.

2. MATERYAL VE YÖNTEM

Bu uygulamada Roboflow platformunda, Google Colaboratory ortamında YOLOv7 algoritması kullanılarak diş röntgenlerinde lezyon ve defect tanıma işlemi gerçekleştirilmiştir.


2.1 Veri Seti

Veri setinin çeşitliliği ve büyüklüğü nesne tanımda önemli bir unsurdur. Aynı zamanda diş röntgen görüntülerinin farklı ortamlarda çekilmesi de modelin eğitimini olumlu yönde etkilemektedir. Bu unsurlara yeterince dikkat edilmediğinde, modelin eğitim sürecinde aşırı öğrenme (overfitting) meydana gelebilir. Aşırı öğrenme, modelin eğitim verilerini ezberleyerek genelleme yeteneğini kaybettiği bir durumu ifade eder. Model eğitim verilerinde keskin bir sonuç verirken, test verilerinde aynı doğrulukta sonuç verememektedir. Aynı zamanda underfitting (yetersiz öğrenme) ise modelin eğitim verilerine uymadığından verilerdeki genel eğilimi kaçırmaması durumudur. Yetersiz öğrenme sorunu olan modellerde hem eğitim hem de test veri setindeki hata oranı yüksektir (Yılmaz, 2023). Ayrıca eğitim süresi düşünüldüğünde, görüntülerin boyutlarının küçültülmesi önem arz etmektedir. Bunlar dikkate alınıp Şekil 2.1’de “.jpeg” formatına dönüştürülen 400 adet panoramik diş röntgen görüntüsünden birkaç röntgen görüntüsü yer almaktadır. Bu çalışmada Roboflow platformundan alınan panoramik diş röntgenleri kullanılmıştır.



Şekil 2.1 Diş röntgen görüntüleri


Periapikal röntgen ile ağızda yerel bir bölgede birkaç diş üzerinde yoğunlaşırken panoramik röntgenlerde çoğunlukla tüm dişler üzerinde yoğunlaşılır (Oktay, 2018). Şekil 2.2’de panoramik ve periapikal diş röntgen görüntüleri yer almaktadır.



Şekil 2.2 (a) Periapikal diş röntgeni (b) panoramik diş röntgeni

2.2 Verilerin Etiketlenmesi

Bu çalışmada diş röntgenlerinde lezyon ve çürük tespit etmek amacıyla uygulanan işlemler Şekil 2.3’te sırasıyla gösterilmiştir.



Şekil 2.3 Nesne tanıma işlemlerinin akış diyagramı

Eğitimi gerçekleştirmek amacıyla 400 adet panoramik diş röntgenlerini etiketleme işlemi için “lezyon” ve “defect” şeklinde iki sınıf belirlenmiştir. Diş çürükleri “defect” şeklinde adlandırılmıştır. Daha sonra diş röntgen görüntülerinde uzman bir diş hekimi tarafından etiketleme işleminin yapılabilmesi amacıyla Labellmg

programı kullanılmıştır. Labellmg, görüntü etiketlemek amacıyla kullanılan bir programdır (Lin, 2018). Bu program ile herhangi bir görüntüde bulunan nesneler etiketlenebilir. Şekil 2.4'te Labellmg programı ile etiketlenen bir veri görüntüsü yer almaktadır.



Şekil 2.4 Labellmg programı ile etiketlenen veri görüntüsü

Öncelikle “Open Dir” ile görüntülerin bulunduğu klasör seçilmiştir. Daha sonra uzman bir hekim tarafından “Create Rectbox” ile diş röntgenlerinde çürük ve lezyon olan kısımlar dikdörtgen içine alınmıştır. Bu seçim yapılırken, isimlendirme aşamasında Türkçe karakter kullanılmaması gerekir. Bu yüzden bu çalışmada çürük “defect” şeklinde isimlendirilip; lezyon ve defect şeklinde iki sınıf belirlenmiştir. Daha sonra “Save” ile kaydedilip etiketleme işlemi yapılmıştır. Bu şekilde uzman bir diş hekimi tarafından tüm diş röntgenlerindeki lezyon ve defect’ler tek tek işaretlenmiştir.

Görüntü etiketleme, belirli bölgeleri veya nesneleri tanımlamak amacıyla görüntüdeki özel bölgelerin işaretlenmesi işlemidir. Bu süreçte, her nesnenin çevresine bir sınırlayıcı kutu çizilir ve her kutuya bir sınıf etiketi atanır. Etiketlenen nesnelerin verileri genellikle bir ".txt" dosyasında saklanır. Bu dosyada nesnenin sınıf kodu, merkez noktasının x ve y koordinatları ile yükseklik ve genişlik bilgileri bulunur. Şekil 2.5'te örnek bir etiket dosyası gösterilmektedir.

1	1	0.5398475	0.7328125	0.061875	0.10625
2	1	0.6421875	0.74453125	0.03125	0.034375
3	1	0.2359375	0.63359375	0.03125	0.053125
4	1	0.65703125	0.3703125	0.03125	0.0640625

Yükseklik

Genişlik


Y Değeri

X Değeri

Nesne Sınıfı

Şekil 2.5 YOLO etiket dosyasının içeriği


Burada ilk satır incelendiğinde, baştaki 1 sayısı nesnenin sınıfını, 0.0671875 ile 0.10625 değerleri nesnenin genişlik ve yükseklik bilgilerini, 0.5398475 nesnenin x koordinatını, 0.7328125 nesnenin y koordinatını göstermektedir. Sınıf sayısı dışındaki diğer sayılar “0” ve “1” arasındaki değerleri içerir. Şekil 2.6’da Labellmg ile etiketlenen diş röntgen görüntüleri yer almaktadır.



Şekil 2.6 Etiketlenmiş diş röntgen görüntüleri

2.3 Yolov7 Modeli ile Eğitimin Gerçekleştirilmesi

Roboflow uygulaması veri seti oluşturmak ve yönetmek amacıyla nesne tanımda kullanılır. Roboflow ortamında dış röntgen görüntülerine veri artırma tekniklerinden döndürme, griskala, parlaklık yöntemleri uygulanarak 400 adet olan görüntü sayısı 960 adete çoğaltılmıştır. Şekil 2.7’de Roboflow ortamında veri artırma teknikleri uygulanan dış röntgen görüntüleri yer almaktadır.



Şekil 2.7 Roboflowda veri artırma yöntemleri uygulanan dış röntgen görüntüleri

Veri artırma (data augmentation) yöntemi, bazı geometrik dönüşümlerle (döndürme, çevirme, kırpma gibi) orijinal görüntülerin değiştirilmiş versiyonlarının oluşturulup türetilme işlemidir. Eğitim için kullanılan veri setinin çeşitliliğini artırmak ve modelin doğruluğunu geliştirmek için veri artırma işlemi uygulanmaktadır. Roboflow ortamında bu görüntülerin %10’u test, %20’si doğrulama, %70’i eğitim olmak üzere üç sınıfa ayrılmıştır. Modelin gelecekteki performansını tahmin etmek için test veri seti kullanılırken, eğitim aşamasındaki modelin performansını değerlendirmek için de doğrulama veri seti kullanılır. Daha sonra görüntüler YOLOv7 formatına dönüştürülmüştür. Bu şekilde Roboflow ile “.xml” uzantılı dosyalardan YOLO formatına uygun “.txt” uzantılı dosyalar elde edilmiştir. Eğitimde kullanılan gerekli dosyalar ve komutlar YOLOv7 resmi github adresinden elde edilmiştir. Ücretsiz GPU sağlaması sayesinde eğitim işlemi için Google Colaboratory

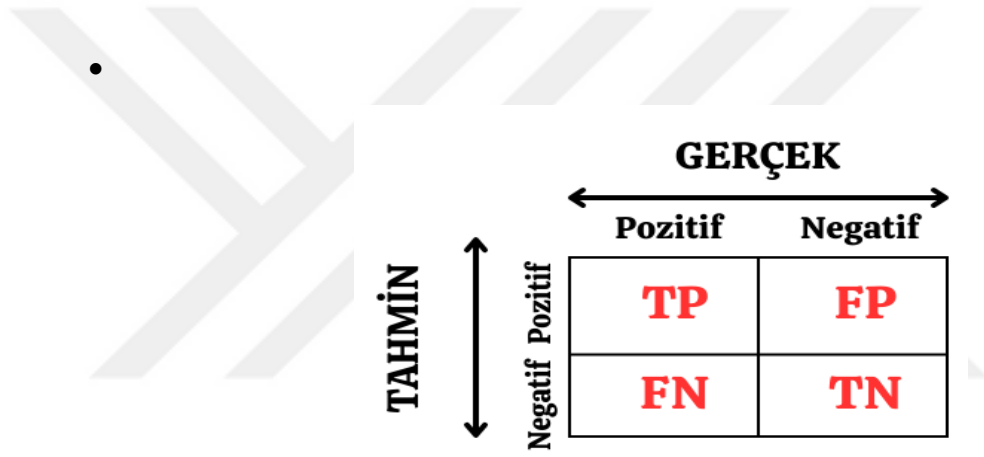
ortamından faydalanılmıştır. Google Colaboratory genellikle “Google Colab” ya da kısaca “Colab” şeklinde adlandırılmaktadır. Colab, NVIDIA Tesla T4 GPU kartını sunmaktadır. Bu sayede eğitim için gerekli olan yüksek boyutlu bellek ve güçlü bir işlemci sağlanmış olmaktadır. Etiketlenen veriler YOLOv7 algoritması kullanılarak Google Colaboratory ortamında Python programlama dili ile eğitilmiştir. Çalışma zamanı oluşturuldu ve Drive'da bulunan zip dosyası, sanal makineye transfer edildi. YOLOv7 modelinin parametreleri güncellenip eğitim yapılmıştır. Google Colab ortamında YOLOv7 modeli ile gerçekleştirilen çalışmada eğitim parametreleri; girdi görüntü boyutu 416x416, yığın boyutu (batch size) 32, devir (epochs) 250 olarak belirlenmiştir. Yığın boyutu her iterasyonda (yineleme başına) evrimsel ağa girilen görüntü sayısıdır. Epoch sayısı doğruluğun en yüksek olduğu yerde idealdir. Bu parametrelerle eğitim 3 saat 22 dakika sürmüştür. Eğitim sonucunda YOLOv7 algoritması kullanılarak dış röntgen görüntüleri üzerinde lezyon ve çürük tanıma işlemi gerçekleştirilmiştir.

2.4 Performans Metrikleri

Nesne tanıma uygulamasının performansını ölçmek için birçok ölçüm kriteri vardır. YOLOv7 algoritması ile başarımlar parametreleri hesaplanır. Duyarlılık/Geri Çağırma (recall), kesinlik (precision), ortalama kesinlik (Average Precision; AP), ortalama kesinlik değerlerinin ortalaması (mean Average Precision; mAP), kesiştirilmiş bölge (Intersection over Union; IoU) en çok kullanılan ölçüm kriterlerindendir (Cengil ve Çınar, 2020). Bu parametreleri hesaplamak için Karışıklık matrisinin terimleri kullanılır. Karışıklık matrisi (Hata matrisi) Şekil 2.8’de gösterilmiştir.

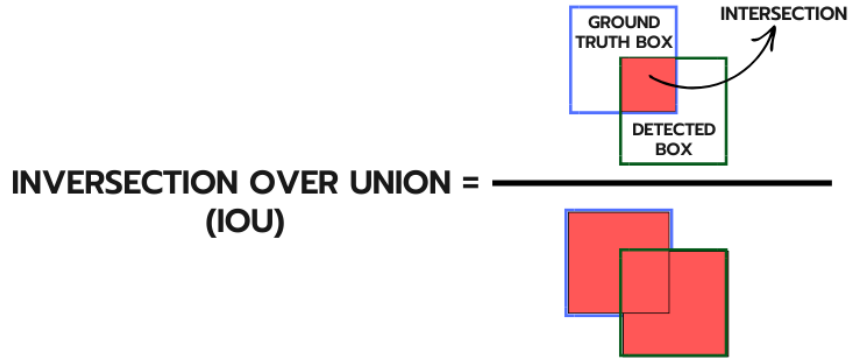
- Doğru Pozitif (True Positive/TP): Modelin, gerçekte var olan bir nesneyi başarılı bir şekilde tespit ettiği durumu ifade eder. Yani, modelin doğru bir isabetle bir nesneyi bulmasıdır.
- Yanlış Pozitif (False Positive/FP): Modelin, gerçekte bulunmayan bir nesneyi yanlış bir şekilde var olarak tahmin ettiği durumdur. Yani, modelin hatalı bir şekilde bir nesne varmış gibi algılamasıdır.

- Yanlış Negatif (False Negative/FN): Modelin, gerçekte var olan bir nesneyi yanlış bir şekilde yok olarak tahmin ettiği durumdur. Yani, modelin bir nesneyi kaçırması veya tespit etmekte başarısız olmasıdır.
- Doğru Negatif (True Negatif/TN): Modelin, gerçekte bulunmayan bir nesneyi başarılı bir şekilde yok olarak tahmin ettiği durumu belirtir. Yani, modelin arka plan gibi nesnesiz alanları doğru bir şekilde tanımlamasıdır (Biçgi ve Karaca, 2022). Bu, sınıflandırılacak nesnelerin dışındaki arka planı temsil eder ve performans değerlendirmelerinde genellikle kullanılmaz (Inkaya, 2021).



Şekil 2.8 Karışıklık matrisi


Intersection Over Union: İki sınırlayıcı kutunun birbirine ne kadar örtüştüğünün ölçüsüdür. Sinir ağının tahmin edilmesi istenen kutu (ground truth) ile tahmin ettiği sınırlayıcı kutunun (detected box) karşılaştırılması için kullanılır. Intersection over Union (IoU), Şekil 2.9’da gösterildiği gibi sınırlayıcı kutuların kesişimlerinin birleşimlerine oranıdır.



Şekil 2.9 IoU Formülü

IoU, 0 ile 1 arasında değer alır. Bu değer ne kadar yüksekse o kadar iyi tahmin yapılmış olur (Keskintaş, 2021). 0,5 olarak ayarlanmış olan kesiştirilmiş bölge değeri, bu değer in üstünde yapılan tahminleri doğru kabul etmektedir (Başaran ve Cagıl, 2021).

Örneğin Şekil 2.10’da siyah kutu gerçek sınırlayıcı kutu olursa; siyah kutu ile kesişimlerinin birleşimine oranı en yüksek olan, en yüksek IoU oranına sahip olan mavi kutudur.



Şekil 2.10 IoU örneği

Kesinlik: Kesinlik değeri, doğru olarak sınıflandırılan pozitif değerlerin sayısının, pozitif olarak sınıflandırılan toplam değer sayısına oranı olarak hesaplanmaktadır. Pozitif tahminlerin doğruluk oranını gösteren bir metriktir (Cengil ve Çınar, 2021). Kesinlik değeri (2.1) numaralı denklemdeki gibi hesaplanır.

Duyarlılık: Bu parametre, pozitif olarak doğru şekilde sınıflandırılan değişken sayısının toplam gerçek pozitiflere oranını ifade etmektedir. Gerçek pozitif oranıdır.

Kesin referans değerlerinin doğru bir şekilde algılanma olasılığını ölçer (Cengil ve Çınar, 2020). Duyarlılık değeri (2.2) numaralı denklemdeki gibi hesaplanır.

AP (Average Precision): Her sınıf için duyarlılık-değer kesinliği eğrisindeki değişik duyarlılık değerlerine bağlı olarak elde edilen kesinlik değerlerinin ortalaması, bu metriği temsil eder. Yani, her sınıfın performansını değerlendirirken kesinlik ve duyarlılık arasındaki ilişkiyi ölçer. AP değeri, sınıfın nesnelerini doğru bir şekilde tespit etme yeteneğini belirleyen bir ölçüdür ve bu değer, kesinlik-duyarlılık eğrisinin ortalama performansını özetler (Biçgi ve Karaca, 2022). AP, bir sınıfın spesifik performansını ölçen bir sayısal değerdir.

mAP (Mean Average Precision): Bu metrik, bütün sınıfların AP değerlerinin ortalamasını temsil eder. Yani, her sınıfın performansının ortalaması alınarak genel bir değer elde edilir. mAP, bir nesne tanıma modelinin farklı sınıflar üzerindeki ortalama başarısını ölçer. Bu değer, genel model performansını değerlendirirken tüm sınıfları kapsayan bir ölçüdür. Her bir sınıfın kesinlik-duyarlılık eğrisinin altında kalan alan mAP değeri olarak ifade edilir (Cengil ve Çınar, 2021). mAP değeri (2.3) numaralı denklemdeki gibi hesaplanır.

$$Kesinlik = \frac{TP}{(TP+FP)} \quad (2.1)$$

$$Duyarlılık = \frac{TP}{TP+FN} \quad (2.2)$$

$$mAP = \sum_{i=1}^N AP_i \quad (2.3)$$

Burada;

“TP” true positive; “FP” false positive; “AP” ortalama kesinlik;” mAP” ortalama kesinlik değerinin ortalaması olarak adlandırılır.

Tablo 2.1 YOLOv7 modeli ile elde edilen performans metrik sonuçlarının karşılaştırılması

YOLOv7 Modeli	Lezyon	Çürük	Toplam
Precision	0.39	0.45	0.42
Recall	0.42	0.40	0.41
mAP	0.37	0.39	0.38


Eğitim sonucunda YOLOv7 modeli ile elde edilen performans metrik sonuçları Tablo 2.1’de gösterilmiştir. Precision, Recall ve mAP değerleri sırasıyla 0.42, 0.41, 0,38 olarak elde edilmiştir.

3. ARAŞTIRMA BULGULARI

Diş Röntgen görüntüleri üzerinde nesne tanıma ile birçok uygulamalar mevcuttur. Bu çalışmada YOLOv7 algoritması kullanılarak panoramik diş röntgenlerinden elde edilen görüntüler üzerinde nesne tanıma ile lezyon ve çürük yerleri tespit edilmiştir. Eğitim sürecinde Roboflow ortamında 400 adet diş röntgen görüntüsü veri artırma yöntemleri uygulanarak 960 adete çoğaltılıp eğitim yapılmıştır. Roboflow aracılığıyla eğitim görüntüleri dışında test ve doğrulama görüntüleri oluşturulup görüntüler YOLOv7 formatına dönüştürülmüştür. Google Colab ortamında YOLOv7 algoritması kullanılarak eğitim gerçekleştirilmiştir. Eğitim sonucunda Şekil 3.1 ve Şekil 3.2’de YOLOv7 modelinin test verisi üzerindeki tespit sonuçları yer almaktadır.




Şekil 3.1 YOLOv7 modelinin test verisi üzerindeki tespit sonuçları




Şekil 3.2 YOLOv7 modelinin test verisi üzerindeki tespit sonuçları

Şekil 3.3'te Precision, Şekil 3.4'te Recall eğrileri yer almaktadır. Precision ve Recall değeri 0 ile 1 arasında yer alır. Precision ve Recall değerlerinin bire doğru yükselmesi modelin performansında artış sağlayacaktır. Recall aynı zamanda doğruluk oranı olarak adlandırılır.




Şekil 3.3 YOLOv7 modelinin kesinlik eğrisi




Şekil 3.4 YOLOv7 modelinin duyarlılık eğrisi

Şekil 3.5’de Precision-Recall eğrisi yer almaktadır. Bu eğride lezyon için 0.37, çürük için 0.39 olmak üzere toplamda mAP değeri 0,38 olarak ifade edilmiştir. Burada mAP (0,5), AP hesaplanırken güven eşğinin (Intersection over Union, IoU) 0,5 değerinden büyük olması demektir. Eğer $IoU \geq 0.5$ ise tahmin doğrudur.



Şekil 3.5 YOLOv7 modelinin kesinlik-duyarlılık eğrisi


YOLOv7 eğitilen modelinin performans grafikleri de Şekil 3.6’da gösterilmiştir. Sonuç eğitim kaybının olduğunu göstermektedir. Aşağıdaki sol üç grafik eğitim kayıp fonksiyonlarını göstermektedir. Sol alt köşedeki üç grafik de doğrulama kayıp fonksiyonunu temsil etmektedir. Bu grafiklerde eğitim kaybının zamanla azaldığı görülmektedir. Grafikler incelendiğinde mAP metrik değeri grafiği bire doğru yükseliş göstermektedir. Bu da aşırı tespit gerçekleştiğinde daha büyük modellerin daha sık elde edileceğini göstermektedir. Aynı zamanda Precision ve Recall grafiklerinde de modelin doğruluğunda artış meydana gelmiştir. Eğitim sonucunda mAP değeri %38 oranında tespit edilmiş, %42 precision, %41 recall değeri elde edilmiştir. Precision, Recall ve mAP değerleri modelimizin iyi performans gösterip göstermediği hakkında bilgi verir.



Şekil 3.6 Performans grafikleri


Tensorboard verilerin görselleştirilmesinde kullanılan kayıp ve doğruluk metriklerinin görselleştirildiği, model grafiğinin gösterildiği bir araçtır. Eğitim sonucunda tensorboard ortamındaki eğitim kayıp (loss) grafikleri Şekil 3.7, Şekil 3.8 Şekil 3.9’da yer almaktadır. Tahmini değeri gerçek değer arasındaki farkı gösteren metrik “Loss” şeklinde adlandırılır. Şekillerde de gösterildiği gibi eğitim sırasında loss değerinin zamanla sıfıra yaklaşması beklenir.

train/cls_loss
tag: train/cls_loss




Şekil 3.7 YOLOv7 modelinin eğitim kayıp grafiği

train/box_loss
tag: train/box_loss



Şekil 3.8 YOLOv7 modelinin eğitim kayıp grafiği

train/obj_loss
tag: train/obj_loss



Şekil 3.9 YOLOv7 modelinin eğitim kayıp grafiği

Sınıflandırma kaybı, her bir sınıf için sınıf olasılıklarını hesaplar. Sınıflandırma kaybı (3.1) numaralı denklemde gösterilmektedir (Aktaş vd., 2020)

$$\sum_{i=0}^{S^2} = 1_i^{obj} \sum_{c \in sınıflar} (P_i(C) - \hat{p}_i(C))^2 \quad (3.1)$$

Burada;

“ 1_i^{obj} ” hücrede nesne olması durumunda 1, olmaması durumunda 0 şeklinde adlandırılır. “ $\hat{p}_i(C)$ ” ise c sınıfının i hücresinde bulunma olasılığıdır.

Konum kaybı, sınırlayıcı kutunun konumu, boyutu ile ilgili kayıp değerini hesaplamak için kullanılır. Nesneyi tanımlayan kutu için kullanılmaktadır. Yerini belirleme kaybı (3.2) numaralı denklemde gösterilmektedir (Aktaş vd., 2020).

$$\lambda_{coord} \sum_{i=0}^{S^2} \sum_{j=0}^B 1_{ij}^{obj} [(x_i - \hat{x}_i)^2 + (y_i - \hat{y}_i)^2] \\ + \lambda_{coord} \sum_{i=0}^{S^2} \sum_{j=0}^B 1_{ij}^{obj} \left[(\sqrt{w_i} - \sqrt{\hat{w}_i})^2 + (\sqrt{h_i} - \sqrt{\hat{h}_i})^2 \right] \quad (3.2)$$

Burada;

“ 1_{ij}^{obj} ” i. hücredeki j. sınırlayıcı kutu nesne tanımadan sorumlu ise 1 değilse 0 şeklinde adlandırılır; “ λ_{coord} ” ise sınırlayıcı kutu koordinatlarında meydana gelen kayıpların miktarını artıran değerdir.

Nesne algılandığı aşamada tespit edilen kutunun güven değeri güven kaybı ile belirlenir. Güven kaybı (3.3) ve (3.4) numaralı denklemde yer almaktadır (Aktaş vd., 2020).

$$\sum_{i=0}^{S^2} \sum_{j=0}^B 1_{ij}^{obj} (C_i - \hat{C}_i)^2 \quad (3.3)$$

Burada;

“ $\hat{C}_i$ ” i hücresinde bulunan j . kutunun güven değeridir; “ 1_{ij}^{obj} ” ise i . hücrede bulunan j . sınırlayıcı kutu nesne tanımadan sorumlu ise 1 değilse 0 şeklinde adlandırılır.

Eğer kutuda nesne algılanmazsa güven kaybı (3.4) numaralı denklemde gösterilmektedir.

$$\lambda_{noobj} \sum_{i=0}^{S^2} \sum_{j=0}^B 1_{ij}^{noobj} (C_i - \hat{C}_i)^2 \quad (3.4)$$

Burada;

“ $\hat{C}_i$ ” i hücresinde bulunan j . kutunun güven değeridir; “ 1_{ij}^{noobj} ,” “ 1_{ij}^{obj} ,” değerinin tümleyenidir; “ λ_{noobj} ” ise kaybı azaltmak amacıyla arka plan algılandığında kullanılan değerdir.

Sınıflandırma kaybı, kutu kaybı ve nesne kayıp değerlerinin toplamı son kayıp değeri olarak ifade edilir. Toplam kayıp (3.5) numaralı denklemde gösterilmektedir (Aktaş vd., 2020).

$$\begin{aligned} & \lambda_{coord} \sum_{i=0}^{S^2} \sum_{j=0}^B 1_{ij}^{obj} [(x_i - \hat{x}_i)^2 + (y_i - \hat{y}_i)^2] \\ & + \lambda_{coord} \sum_{i=0}^{S^2} \sum_{j=0}^B 1_{ij}^{obj} [(\sqrt{w_i} - \sqrt{\hat{w}_i})^2 + (\sqrt{h_i} - \sqrt{\hat{h}_i})^2] \\ & + \sum_{i=0}^{S^2} \sum_{j=0}^B 1_{ij}^{obj} (C_i - \hat{C}_i)^2 \\ & + \lambda_{noobj} \sum_{i=0}^{S^2} \sum_{j=0}^B 1_{ij}^{noobj} (C_i - \hat{C}_i)^2 \\ & + \sum_{i=0}^{S^2} 1_i^{obj} \sum_{c \in sınıflar} (P_i(C) - \hat{p}_i(C))^2 \quad (3.5) \end{aligned}$$

4. TARTIŞMA VE SONUÇ

Yapay zekâ, günümüzde sağlık sektöründe benzersiz donanım ve ileri seviye modellerin entegrasyonu sayesinde etkin bir şekilde kullanılmaktadır. Son zamanlarda birçok çalışmada tıbbi ve dental görüntülerin yorumlanmasında yapay zekanın kullanımı ve doğruluğu araştırılmaktadır. Diş hekimliğinde çürük tespiti, diş numaralandırma üzerine çalışmalar yapılmıştır. Bu çalışmada nesne tanıma ile YOLOv7 algoritması kullanılarak diş röntgen görüntülerinden lezyon ve çürük tespiti yapılmıştır. Ancak diş röntgenlerinde daha iyi lezyon ve defect tanıma işlemi için başarı oranının artması önem arz etmektedir. Yolov7 modelinin başarı ve hızını iyileştirmek için, daha fazla veri veya geliştirilmiş nesne tanıma algoritmaları kullanılabilir. Modelin performansı daha büyük veri seti ile geliştirilebilir. Röntgen görüntülerinin sayısı artırılıp eğitim yapılırsa daha iyi sonuçlar alınabilir. Böylece veri setindeki görüntü sayısının çoğaltılmasıyla derin öğrenme modellerinin de performansını artıracakları düşünülmektedir. YOLO'nun farklı donanım özelliklerine göre uyarlanmasıyla, YOLO daha fazla sektör ve kullanıcı için erişilebilir ve etkili hale getirilebilir. Sonuç olarak derin öğrenme yöntemlerinin kullanımı en başta sağlık olmak üzere birçok alanda yaşamımızı kolaylaştıracaktır. Bu şekilde erken teşhis ile diş kayıplarına engel olunup, diş hekimlerine yardımcı olunması amaçlanmıştır. Aynı zamanda diş hekimliği öğrencileri, genç diş hekimleri, pratisyen hekimler ve uzmanlar için özellikle yararlı olabileceğini varsayabiliriz. Sağlık çalışanlarının yükünü azaltmak için bu çalışmaların artması önemlidir. Sağlık kuruluşları arasındaki teşhis ve tedavilerdeki farklılıklar en aza indirgenecektir. Bu sayede insan sağlığı açısından hatalar azaltılıp, daha iyi sonuçlar elde edilecektir. Böylece hekimlerin de sağlık problemlerini kolaylıkla çözmesi sağlanmaktadır. Gelecekte yapılacak çalışmalarda daha özgün ve geniş veri setleriyle birlikte daha farklı derin öğrenme modelleri kullanılarak farklı çalışmalar yapılabilir. Bu çalışmanın amacı, medikal görüntüler üzerinde nesne tanıma alanında yeni ve özgün çalışmalara ilham kaynağı olmaktır.

KAYNAKLAR

- Aktaş, A., Demir, Ö., & Doğan, B. (2020). Derin öğrenme yöntemleri ile dokunsal parke yüzeyi tespiti. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 35(3), 1685-1700.
- Ali, R. B., Ejballi, R., & Zaied, M. (2016, August). Detection and classification of dental caries in x-ray images using deep neural networks. In International conference on software engineering advances (ICSEA) (p. 236).
- Al-Masni, M. A., Al-Antari, M. A., Park, J. M., Gi, G., Kim, T. Y., Rivera, P., ... & Kim, T. S. (2018). Simultaneous detection and classification of breast masses in digital mammograms via a deep learning YOLO-based CAD system. *Computer methods and programs in biomedicine*, 157, 85-94.
- AL-Ghamdi, A. S., Ragab, M., AlGhamdi, S. A., Asseri, A. H., Mansour, R. F., & Koundal, D. (2022). Detection of dental diseases through X-ray images using neural search architecture network. *Computational Intelligence and Neuroscience*, 2022.
- Altay, A., & Yılmaz, S. (2023). YOLO Algoritması Kullanılarak T Hücrelerinin Sınıflandırılması. *İleri Mühendislik Çalışmaları ve Teknolojileri Dergisi*, 3(2), 66-81.
- Aralikatti, A., Appalla, J., Kushal, S., Naveen, G. S., Lokesh, S., & Jayasri, B. S. (2020, December). Real-time object detection and face recognition system to assist the visually impaired. In *Journal of Physics: Conference Series* (Vol. 1706, No. 1, p. 012149). IOP Publishing.
- Başaran, G., & Cagıl, G. (2021). Koruyucu Gözlük Kullanımının Görüntü İşleme Yöntemiyle Tespit Edilmesi. *El-Cezeri*, 9(1), 86-95.
- Biçgi, M., & Karaca, İ. (2022). Nesne Tespit Algoritması (YOLOv4) Kullanarak Patates Böceğinin (*Leptinotarsa decemlineata*)(Say) Patates Bitkisi Üzerinde Tespiti ve Populasyon İzleme Olanakları. *Türk Bilim ve Mühendislik Dergisi*, 4(2), 123-129.
- Biçgi, M. (2022). Nesne Tespit Algoritması (YOLOv4) Kullanarak Patates Böceğinin (*Leptinotarsa decemlineata*)(Say) Patates Bitkisi Üzerinde Tespiti ve Populasyon İzleme Olanakları. (Yüksek Lisans Tezi). Isparta Uygulamalı Bilimler Üniversitesi Lisansüstü Eğitim Enstitüsü: Isparta.
- Brownlee, J. (2019). *Deep learning for computer vision: image classification, object detection, and face recognition in python*. Machine Learning Mastery.
- Burgaz, M. (2020). Derin öğrenme algoritmaları kullanarak insansız hava araçları ile silah tespiti. (Yüksek Lisans Tezi). Batman Üniversitesi Fen Bilimleri Enstitüsü: Batman.
- Calp, M. H. (2019). İşletmeler için personel yemek talep miktarının yapay sinir ağları kullanılarak tahmin edilmesi. *Politeknik dergisi*, 22(3), 675-686.

- Cantemir Z, 2019. Derin Öğrenme Yöntemleriyle Medikal Görüntü Sınıflandırma. (Yüksek Lisans Tezi). Gazi Üniversitesi Fen Bilimleri Enstitüsü: Ankara.
- Cao, Z., Yang, Z., Liu, X., Zhang, Y., Wu, S., Lin, R. S., ... & Ma, J. (2019, June). Deep learning based lesion detection for mammograms. In *2019 IEEE International Conference on Healthcare Informatics (ICHI)* (pp. 1-3). IEEE.
- Cengil, E., & Çınar, A. (2020). Göğüs Verileri Metrikleri Üzerinden Kanser Sınıflandırılması. *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, 11(2), 513-519.
- Cengil, E., & Çınar, A. (2021). Poisonous mushroom detection using YOLOV5. *Turkish Journal of Science and Technology*, 16(1), 119-127.
- Çağlayan, A. (2018). Derin Öğrenme Tekniklerini Kullanarak RGB-D Nesne Tanıma.(Doktora Tezi). Hacettepe Üniversitesi Fen Bilimleri Enstitüsü: Ankara.
- Çelik Ö, Odabaş, A. L. P. E. R., Bayrakdar, İ. Ş., Bilgir, E. L. İ. F., and Akkoca, F. (2019). Derin öğrenme yöntemi ile panoramik radyografiden diş eksikliklerinin tespiti: Biryapay zeka pilot çalışması. *Selcuk Dental Journal*, 6(4), 168-172.
- Dai, X. (2019). HybridNet: A fast vehicle detection system for autonomous driving. *Signal Processing: Image Communication*, 70, 79-88.
- Datta, S., Chaki, N., & Modak, B. (2019). A novel technique to detect caries lesion using isophote concepts. *IRBM*, 40(3), 174-182.
- Ding, B., Zhang, Z., Liang, Y., Wang, W., Hao, S., Meng, Z., ... & Lv, Y. (2021). Detection of dental caries in oral photographs taken by mobile phones based on the YOLOv3 algorithm. *Annals of Translational Medicine*, 9(21).
- Dubost, F., Adams, H., Yilmaz, P., Bortsova, G., van Tulder, G., Ikram, M. A., ... & de Bruijne, M. (2020). Weakly supervised object detection with 2D and 3D regression neural networks. *Medical image analysis*, 65, 101767.
- Ekert, T., Krois, J., Meinhold, L., Elhennawy, K., Emara, R., Golla, T., & Schwendicke, F. (2019). Deep learning for the radiographic detection of apical lesions. *Journal of endodontics*, 45(7), 917-922.
- Foster, K. R., Koprowski, R., & Skufca, J. D. (2014). Machine learning, medical diagnosis, and biomedical engineering research-commentary. *Biomedical engineering online*, 13, 1-9.
- Fukushima, K. (1980). Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position. *Biological cybernetics*, 36(4), 193-202.
- Gao, F., Wang, C., & Li, C. (2020). A combined object detection method with application to pedestrian detection. *IEEE Access*, 8, 194457-194465.
- Heaton, J. (2018). Ian Goodfellow, Yoshua Bengio, and Aaron Courville: Deep learning: The MIT Press, 2016, 800 pp, ISBN: 0262035618. *Genetic programming and evolvable machines*, 19(1-2), 305-307.

- Hubel, D. H., & Wiesel, T. N. (1968). Receptive fields and functional architecture of monkey striate cortex. *The Journal of physiology*, 195(1), 215-243.
- Hu, B., Zhu, M., Chen, L., Huang, L., Chen, P., & He, M. (2022, November). Tree species identification method based on improved YOLOv7. In 2022 IEEE 8th International Conference on Cloud Computing and Intelligent Systems (CCIS) (pp. 622-627). IEEE.
- Hung, M., Voss, M. W., Rosales, M. N., Li, W., Su, W., Xu, J., ... & Licari, F. W. (2019). Application of machine learning for diagnostic prediction of root caries. *Gerodontology*, 36(4), 395-404.
- Goodfellow, I., Bengio, Y., Courville, A. (2018). Derin Öğrenme, %1 içinde Derin Öğrenme (pp. 1-1). Ankara: Buzdağı Yayınevi.
- İnkaya, M. F. (2021). Derin öğrenme algoritmaları kullanarak güvenli çocuk oyun alanlarında karşılaştırmalı tehlikeli nesne tespiti yapılması. (Yüksek Lisans Tezi). Bursa Teknik Üniversitesi Fen Bilimleri Enstitüsü: Bursa.
- Jiao, L., Zhang, R., Liu, F., Yang, S., Hou, B., Li, L., & Tang, X. (2021). New generation deep learning for video object detection: A survey. *IEEE Transactions on Neural Networks and Learning Systems*, 33(8), 3195-3215.
- Karadağ, B., Ali, A. R. I., & Karadağ, M. (2021). Derin öğrenme modellerinin sinirsel stil aktarımı performanslarının karşılaştırılması. *Politeknik Dergisi*, 24(4), 1611-1622.
- Keskintaş, G. (2021). İnsansız Hava Aracı ile Gerçek Zamanlı Nesne Tanıma. (Yüksek Lisans Tezi). Bitlis Üniversitesi Lisansüstü Eğitim Enstitüsü: Bitlis.
- Kılıç, M., & Nabiye, V. (2023, February). Maskeli ve Maskesiz Yüzlerin Gerçek Zamanlı Tespiti. In International Conference on Frontiers in Academic Research (Vol. 1, pp. 581-585).
- Kıvrak, O., & Gürbüz, M. Z. (2022). Performance Comparison of YOLOv3, YOLOv4 and YOLOv5 Algorithms: A Case Study for Poultry Recognition. *Avrupa Bilim ve Teknoloji Dergisi*, (38), 392-397.
- Khurana, K., & Awasthi, R. (2013). Techniques for object recognition in images and multi-object detection. *International journal of advanced research in Computer Engineering & Technology (IJARCET)*, 2(4), 1383-1388.
- Khanagar, S. B., Al-Ehaideb, A., Maganur, P. C., Vishwanathaiah, S., Patil, S., Baeshen, H. A., ... & Bhandi, S. (2021). Developments, application, and performance of artificial intelligence in dentistry—A systematic review. *Journal of dental sciences*, 16(1), 508-522.
- Kühnisch, J., Meyer, O., Hesenius, M., Hickel, R., & Gruhn, V. (2022). Caries detection on intraoral images using artificial intelligence. *Journal of dental research*, 101(2), 158-165.
- LeCun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278-2324.

- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *nature*, 521(7553), 436-444.
- Lee, J. H., Kim, D. H., Jeong, S. N., & 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.
- Li, Y., Xue, J., Zhang, M., Yin, J., Liu, Y., Qiao, X., ... & Li, Z. (2023). YOLOv5-ASFF: A Multistage Strawberry Detection Algorithm Based on Improved YOLOv5. *Agronomy*, 13(7), 1901.
- Lin, Q., Cao, C., Li, T., Man, Z., Cao, Y., & Wang, H. (2021). dSPIC: a deep SPECT image classification network for automated multi-disease, multi-lesion diagnosis. *BMC Medical Imaging*, 21(1), 1-16.
- Liu, Y., Ma, Z., Liu, X., Ma, S., & Ren, K. (2019). Privacy-preserving object detection for medical images with faster R-CNN. *IEEE Transactions on Information Forensics and Security*, 17, 69-84.
- Lin, T. (2018). LabelImg. Retrieved 10.04.2021 from <https://tzutalin.github.io/labelImg>.
- Mahbod, A., Tschandl, P., Langs, G., Ecker, R., & Ellinger, I. (2020). The effects of skin lesion segmentation on the performance of dermatoscopic image classification. *Computer Methods and Programs in Biomedicine*, 197, 105725.
- Majanga, V., & Viriri, S. (2022). A survey of dental caries segmentation and detection techniques. *The Scientific World Journal*, 2022.
- Murat, S. (2021). *İnsansız hava aracı görüntülerinden derin öğrenme yöntemleriyle nesne tanıma* (Yüksek Lisans Tezi). Maltepe Üniversitesi Lisansüstü Eğitim Enstitüsü: İstanbul.
- Murata, M., Arij, Y., Ohashi, Y., Kawai, T., Fukuda, M., Funakoshi, T., ... & Arij, E. (2019). Deep-learning classification using convolutional neural network for evaluation of maxillary sinusitis on panoramic radiography. *Oral radiology*, 35, 301-307.
- Nie, Y., Sommella, P., O'Nils, M., Liguori, C., & Lundgren, J. (2019, November). Automatic detection of melanoma with yolo deep convolutional neural networks. In *2019 E-Health and Bioengineering Conference (EHB)* (pp. 1-4). IEEE.
- Oktay, A. B. (2018). Human identification with dental panoramic radiographic images. *IET Biometrics*, 7(4), 349-355.
- Onuk, K., Ali, A. R. I., Özdemir, M. F., & Hanbay, D. (2023). Deep feature selection for facial emotion recognition based on BPSO and SVM. *Politeknik Dergisi*, 26(1), 131-142.
- O'Mahony, N., Campbell, S., Carvalho, A., Harapanahalli, S., Hernandez, G. V., Krpalkova, L., ... & Walsh, J. (2020). Deep learning vs. traditional computer vision. In *Advances in Computer Vision: Proceedings of the 2019 Computer*

Vision Conference (CVC), Volume 1 1 (pp. 128-144). Springer International Publishing.

- Özcan, B., & Bakır, H. (2023, June). Yapay Zeka Destekli Beyin Görüntüleri Üzerinde Tümör Tespiti. In *International Conference on Pioneer and Innovative Studies* (Vol. 1, pp. 297-306).
- Patil, S., Kulkarni, V., & Bhise, A. (2019). Algorithmic analysis for dental caries detection using an adaptive neural network architecture. *Heliyon*, 5(5).
- Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). You only look once: Unified, real-time object detection. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 779-788).
- Sharma, V., & Mir, R. N. (2020). A comprehensive and systematic look up into deep learning based object detection techniques: A review. *Computer Science Review*, 38, 100301.
- Srivastava, M. M., Kumar, P., Pradhan, L., & Varadarajan, S. (2017). Detection of tooth caries in bitewing radiographs using deep learning. *arXiv preprint arXiv:1711.07312*.
- Talukdar, J., Gupta, S., Rajpura, P. S., & Hegde, R. S. (2018, February). Transfer learning for object detection using state-of-the-art deep neural networks. In *2018 5th international conference on signal processing and integrated networks (SPIN)* (pp. 78-83). IEEE.
- Tan, L., Huangfu, T., Wu, L., & Chen, W. (2021). Comparison of RetinaNet, SSD, and YOLO v3 for real-time pill identification. *BMC medical informatics and decision making*, 21, 1-11.
- Tao, J., Wang, H., Zhang, X., Li, X., & Yang, H. (2017, October). An object detection system based on YOLO in traffic scene. In *2017 6th International Conference on Computer Science and Network Technology (ICCSNT)* (pp. 315-319). IEEE.
- Terven, J., & Cordova-Esparza, D. (2023). A comprehensive review of YOLO: From YOLOv1 to YOLOv8 and beyond. *arXiv preprint arXiv:2304.00501*.
- Thanh, M. T. G., Van Toan, N., Ngoc, V. T. N., Tra, N. T., Giap, C. N., & Nguyen, D. M. (2022). Deep learning application in dental caries detection using intraoral photos taken by smartphones. *Applied Sciences*, 12(11), 5504.
- Tuzoff, D. V., Tuzova, L. N., Bornstein, M. M., Krasnov, A. S., Kharchenko, M. A., Nikolenko, S. I., ... & Bednenko, G. B. (2019). Tooth detection and numbering in panoramic radiographs using convolutional neural networks. *Dentomaxillofacial Radiology*, 48(4), 20180051.
- Türkoğlu, M., & Hanbay, D. (2018, September). Apricot disease identification based on attributes obtained from deep learning algorithms. In *2018 International Conference on Artificial Intelligence and Data Processing (IDAP)* (pp. 1-4). IEEE.

- Türkoğlu, İ. (1996). Yapay sinir ağları ile nesne tanıma. (Yüksek Lisans Tezi). Fırat Üniversitesi Fen Bilimleri Enstitüsü: Elazığ.
- Ünver, H. M., & Ayan, E. (2019). Skin lesion segmentation in dermoscopic images with combination of YOLO and grabcut algorithm. *Diagnostics*, 9(3), 72.
- Valizadeh S, Goodini M, Ehsani S, Mohseni H, Azimi F, Bakhshandeh H. (2015). Designing of a computer software for detection of approximal caries in posterior teeth. *Iranian Journal of Radiology*, 12(4).
- Yang, R., & Yu, Y. (2021). Artificial convolutional neural network in object detection and semantic segmentation for medical imaging analysis. *Frontiers in oncology*, 11, 638182.
- Yılmaz, R., Yaman, O., ve Karaköse, M. (2023). Kuantum Devrelerinde Kapı ve Giriş Tespiti için YOLO Tabanlı Bir Yöntem. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 35(2), 527-540.
- Yılmaz, S. (2023). Beyin Tümörü Tanıları İçin YOLOv7 Algoritması Tabanlı Karar Destek Sistemi Tasarımı. *Kocaeli Üniversitesi Fen Bilimleri Dergisi*, 6(1), 47-56.
- Zhang, F., Luan, J., Xu, Z., & Chen, W. (2020). DetReco: object-text detection and recognition based on deep neural network. *Mathematical Problems in Engineering*, 2020, 1-15.
- Zhang, A., Lipton, Z. C., Li, M., Smola, A. J. (n.d.). Dive Into Deep Learning. Birleşik Krallık: Cambridge University Press.
- Zhu, H., Cao, Z., Lian, L., Ye, G., Gao, H., & Wu, J. (2022). CariesNet: a deep learning approach for segmentation of multi-stage caries lesion from oral panoramic X-ray image. *Neural Computing and Applications*, 1-9
- Zhu, H., Wei, H., Li, B., Yuan, X., & Kehtarnavaz, N. (2020). A review of video object detection: Datasets, metrics and methods. *Applied Sciences*, 10(21), 7834.
- Wang S, Summers RM. (2012). Machine learning and radiology. *Medical image analysis*, 16(5):933-51.
- Wang, H., Yu, Y., Cai, Y., Chen, X., Chen, L., & Liu, Q. (2019). A comparative study of state-of-the-art deep learning algorithms for vehicle detection. *IEEE Intelligent Transportation Systems Magazine*, 11(2), 82-95.
- Wang, H., Pan, C., Guo, X., Ji, C., & Deng, K. (2021). From object detection to text detection and recognition: A brief evolution history of optical character recognition. *Wiley Interdisciplinary Reviews: Computational Statistics*, 13(5), e1547.

- Wang, Y., Wang, H., & Xin, Z. (2022). Efficient detection model of steel strip surface defects based on YOLO-V7. *IEEE Access*, 10, 133936-133944.
- Wang, C. Y., Liao, H. Y. M., & Yeh, I. H. (2022). Designing network design strategies through gradient path analysis. *arXiv preprint arXiv:2211.04800*.
- Wang C.-Y.; Bochkovskiy A.; Liao H.-Y.M., 2022. YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors. *arXiv preprint arXiv:2207.02696*.
- Wang, C. Y., Bochkovskiy, A., & Liao, H. Y. M. (2023). YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition* (pp. 7464-7475).
- Wong, A., Famuori, M., Shafiee, M. J., Li, F., Chwyl, B., & Chung, J. (2019, December). YOLO nano: A highly compact you only look once convolutional neural network for object detection. In *2019 Fifth Workshop on Energy Efficient Machine Learning and Cognitive Computing-NeurIPS Edition (EMC2-NIPS)* (pp. 22-25). IEEE.
- Xiao, Y., Tian, Z., Yu, J., Zhang, Y., Liu, S., Du, S., & Lan, X. (2020). A review of object detection based on deep learning. *Multimedia Tools and Applications*, 79(33), 23729-23791.

ÖZGEÇMİŞ

Kişisel Bilgiler

Soyad, Ad

ERSAN, Safiye

Web sayfası

(Research Gate, Academia, vs.)

Eğitim Bilgileri

Derece	Kurum	Mezuniyet Yılı
Yüksek Lisans		
Lisans	Erciyes Üniversitesi	2014
Lise	Anadolu Lisesi	2008

İş Deneyimi

Dönem (Yıl)	Şirket, Kurum	Görev
2016-2016	Artuklu İlçe Milli Eğitim Müdürlüğü	İngilizce Öğretmeni
2017-halen	Artuklu İlçe Nüfus Müdürlüğü	Memur

Yabancı Dil

İngilizce, Arapça

Yayınlar

1.Safiye ERSAN-Cafer BUDAK/ Nesne Tanıma ile Dış Röntgenlerinde Lezyon ve Çürük Tespiti: YOLOv7 Algoritması / Dicle Üniversitesi 1.Uluslararası Fen Bilimleri Lisansüstü Araştırmalar Sempozyumu /2023/ Diyarbakır-Türkiye

Özel İlgiler

Kitap okumak

DİCLE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
TEZ BENZERLİK BİLDİRİMİ FORMU

Öğrencinin Adı, Soyadı	Safiye ERSAN
Öğrenci No	20824006
Ana Bilim Dalı	Biyomedikal Mühendisliği
Program Türü	Proje ☐ Yüksek Lisans ☒ Doktora ☐
Tez Danışmanı (Ünvanı, Adı, Soyadı)	Doç. Dr. Cafer BUDAK
(Varsa) II. Tez Danışmanı (Ünvanı, Adı, Soyadı)	
Tez Başlığı	YOLOv7 Algoritması ile Diş Röntgenlerinde Lezyon ve Çürük Tespiti
RAPOR BİLGİLERİ	
Raporlama Aşaması	Tez Savunma Sınavı Sonrası
Sayfa Sayısı	65
Raporlama Tarihi	09/02/2024
Benzerlik Oranı (%)	13

Yukarıda bilgileri verilen tez çalışmamın toplam 65 sayfalık kısmına ilişkin, 09/02/2024 tarihinde şahsım/tez danışmanım tarafından *TURNITIN* isimli intihal tespit programından aşağıda belirtilen filtrelemeler uygulanarak alınmış olan intihal raporuna göre, tezimin benzerlik oranı % 13 olarak tespit edilmiştir.

Uygulanan filtrelemeler:

- ☐Başlangıç Bölümleri (Kabul ve Onay sayfası, Teşekkür sayfası, Özet/Abstract) hariç
☒Kaynaklar hariç
☐Alıntılar hariç/dâhil
☐Diğer (Açıklayınız)

Tezimin benzerlik oranı, Dicle Üniversitesi Fen Bilimleri Enstitüsü İntihal Raporu Uygulama Esaslarında belirtilen üst sınır benzerlik oranını aşmamaktadır. Benzerlik oranım üst sınır benzerlik oranının altında olsa dahi aksinin tespit edilmesi durumunda her türlü yasal sorumluluğu kabul ettiğimi ve hukuki sonuçlarına razı olduğumu bildirir, gereğini arz ederim.

Öğrencinin Adı, Soyadı: Safiye ERSAN

Tarih: 09/02/2024

İmza:

Danışman Adı, Soyadı: Doç. Dr. Cafer BUDAK

İmza:

Tarih:

Ana Bilim Dalı Başkanı Adı, Soyadı: Doç. Dr. Cafer BUDAK

İmza:

Tarih: