

Diş Görüntüleri Üzerinde Görüntü İşleme ve Derin Öğrenme Yöntemleri Kullanılarak Çürük Seviyesinin Sınıflandırılması

Ümran ÜNSAL¹ (Orcid ID: 0000-0002-4608-5690)

Kemal ADEM^{2*} (Orcid ID: 0000-0002-3752-7354)

¹Aksaray Üniversitesi, İktisadi ve İdari Bilimler Fakültesi, Sosyal Bilimler Enstitüsü Yönetim Bilişim Sistemleri Anabilim Dalı, Aksaray, Türkiye

²Sivas Bilim ve Teknoloji Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Bilgisayar Mühendisliği Bölümü, Sivas, Türkiye

*Sorumlu yazar (Corresponding author): kemaladem@sivas.edu.tr

Geliş Tarihi (Received): 20.12.2023

Kabul Tarihi (Accepted): 30.12.2023

Özet

Ağız bakımına yeterli özen gösterilmediğinde diş minesini zarar görür ve diş çürümeleri gerçekleşir. Bu çalışmada röntgen görüntüleri üzerinde diş çürüklerinin hızlı bir şekilde tespit edilerek hastaların diş kayıplarının minimuma indirilmesi amaçlanmaktadır. Diş görüntüleri ile derin öğrenme modelleri kullanılarak uygulanan tedavi yöntemleri dolgu, kanal, köprü sınıflarına ayrılmıştır. Ayrıca diş görüntülerine ön işlem olarak luv-v kanalı ve adaptif histogram eşitleme işlemi uygulanarak derin öğrenme modellerinin performanslarının artırılması amaçlanmıştır. 553 tane diş röntgeninden oluşan veri seti üzerinde yapılan segmentasyon işlemlerinin ardından, derin öğrenme modellerinden Faster R-CNN ve YOLOv5 modelleri ile deneysel çalışmalar gerçekleştirilmiştir. Yapılan deneysel çalışmalar sonucunda; Faster R-CNN %86,7 doğruluk değerine ulaşılırken, YOLOv5 modelinde ise %92,7 oranında doğruluk oranına ulaşılmıştır.

Keywords: Kanal, dolgu, köprü, derin öğrenme, görüntü işleme

Classification of Caries Aries Level Using Image Processing and Deep Learning Methods on Dental Images

Abstract

When adequate care is not given to oral care, tooth enamel is damaged and tooth decay occurs. In this study, it is aimed to quickly detect dental caries on x-ray images and to minimize the tooth loss of the patients. Treatment methods applied using dental images and deep learning models are divided into filling, canal and bridge classes. In addition, it is aimed to increase the performance of deep learning models by applying the luv-v channel and adaptive histogram equalization process as a preprocessing to tooth images. After segmentation processes on the

data set consisting of 553 dental x-rays, experimental studies were carried out with Faster R-CNN and Yolov5 models, which are deep learning models. As a result of the experimental studies; while Faster R-CNN reached %86.7 accuracy, Yolov5 model achieved %92.7 accuracy.

Keywords: Canal, filling, bridge, deep learning, image processing

GİRİŞ

Dişler, ağız boşluğunda yer alan sindirime yardımcı olan kemiklerdir. Vücut sağlığının korunmasında, hastalıkların tedavisinde yeterli ve dengeli beslenme büyük önem taşımaktadır. Yeterli ve dengeli beslenme sağlıklı dişlerle mümkündür. Bu sebeple ağızda olan diş çürükleri ve eksik dişler kişinin yeterince yiyecek almasını engeller. Bu durum ise hastalıklara karşı vücut direncinin düşmesine sebep olmaktadır. Ağız ve diş sağlığı dikkat ve özen gerektiren bir konudur. Gerekli özen gösterilmediği takdirde bakteriyel oluşumlara neden olmaktadır. Ağızda oluşan bakteriyel oluşumlar da diş çürüklerine sebebiyet vermektedir. Bu nedenle, ağız ve diş hastalıklarının önlenmesi için ağız bakımı düzenli bir şekilde yapılmalıdır. Düzenli ağız bakımı yapılmaz ise dişlerde oluşan bakteri plakları diş minesine zarar vererek diş çürüklerine sebep olmaktadır. Bu durum yaşam kalitesini olumsuz etkiler ve ağız ile ilgili farklı hastalıklara da neden olabilmektedir.

Son zamanlarda diş hekimlerinin kullanmış olduğu dijital görüntüleme sisteminde ilerlemeler olmuştur. Diş hekimlerinin dijital görüntülemeye çürük tespiti için kullandığı röntgenlerden bir tanesi panoramik röntgenlerdir. Panoramik röntgen, çene ve dişlerdeki birçok hastalıkların tek filmde görülmesini sağlayan röntgenlerdir. Diş hekimlerinin röntgenlerde dişin yerini tespit edebilmesi için değişik numaralandırma teknikleri kullanılmaktadır. Diş hekimleri yazarken veya konuşurken belirli bir diş hakkında bahsetmek için birkaç farklı diş numaralandırma sistemi kullanılır. Bunlar Dünya Sağlık Örgütü (ISO) Sistemi, Palmer Numaralandırma Yöntemi, Üniuersal Numaralandırma Sistemleridir. Türkiye'deki uzmanlar tarafından bu yöntemlerden Dünya Sağlık Örgütü 2019 (ISO) Sistemi kullanılmaktadır. ISO Sistemi, diş numaralandırmasında ilk rakamın dişin çeyreğini, ikinci rakamın ise yüzün orta yarısından itibaren kaçınıcı diş olduğunu temsil ettiği iki rakamlı bir sistemdir. Kalıcı dişlerde üst sağ dişler "1," üst sol dişler "2," alt sol dişler "3," alt sağ dişler "4" rakamıyla başlar. Örneğin, kalıcı sağ maksiller orta kesici diş "11" olarak ifade edilir ve sayı olarak "bir, bir" şeklinde okunur. Bu sistem, diş numaralandırmasını standart hale getirerek, belirli bir dişten bahsedilirken karışıklığı önler (Wikipedia, 2023).



Şekil 1. Dünya Sağlık Örgütü sistemi numaralandırılması

Diş Çürükleri

Her yaşta bireyi etkileyen diş çürükleri, diş minesinin ve dişlerin dış sert yüzeyinin tahrip olmasından kaynaklanmaktadır. Dişler üzerinde bakteriden plak oluşur ve şeker içerikli besinlerin tüketilmesiyle birlikte bu bakteriler diş minesine saldırı düzenler. Bunun sonucunda diş yüzeyi zamanla parçalanır ve dişlerde boşluklar, çürükler oluşmaktadır. Diş dokusu ve plak sıvısı arasındaki dengenin bozulmasıyla birlikte ileriki aşamada dişin inorganik bileşenlerinin demineralizasyonunu ve organik yapısının enzimatik olarak bozulmasının eşlik ettiği süreçtir (Aktaş ve ark., 2020). Diş kökleri, diş yüzeyine göre daha hassastır. Bu sebeple dişler çürümeye daha yatkındır. Çürük olan dişler sıcak ve soğuğa karşı duyarlıdır. Daha ileriki dönemlerde endodontik (kanal) tedavisi veya diş kaybına yol açacak şiddetli ağrılı pulpa apsesine sebep olabilmektedir (Zero, 1993). Çürük dişlerin tedavi edilmesi amacıyla farklı yöntemler kullanılmaktadır. Bunlar diş dolgusu, kanal tedavisi, köprü ve implant tedavileri olarak örneklendirilebilir. Dolgu tedavisi çürük dişlere ve kırılmış dişlere uygulanmaktadır. Dolgu tedavisi ile deforme olan diş eski görünümünü yeniden kazanır.




Şekil 2. Dolgu diş röntgeni

Kanal tedavisi, dişin enfekte olması sonucunda çürümüş dişlere uygulanan tedavi yöntemidir. Tedavi sırasında dişin içerisinde bulunan diş siniri çıkartılır ve dişin içi temizlenir. Temizlenen kısımda boşluk oluşur. Bu boşluğun yeniden doldurulması işlemi ile kanal tedavisi tamamlanmış olur. Son yıllarda geliştirilmiş olan Lazer/ Sweep tekniği ile çürüyen dişin içindeki sinirler çıkartılıp kanal tedavisinin başarı oranını artırılmıştır.



Şekil 3. Kanal diş röntgeni

Çürüyen dişin çekilmesi sonucunda, bu boşluğu kapatmak amacıyla restoratif diş tedavisi uygulanmaktadır. Protez dişleri sağlıklı dişlere sabitleyerek köprü tedavisi yapılmış olmaktadır. Köprü tedavisinde ilk olarak diş etine lokal anestezi uygulandıktan sonra kronları barındıracak dişler yeniden şekillenir. Kronların köprüyü tutması amacıyla güvenli olarak sabitlenir. Köprü tedavisi ile diş hassasiyeti ortadan kaldırılır ve bozuk dişlerin düzeltilmesi de sağlanmaktadır.



Şekil 4. Köprü diş röntgeni

Son yıllarda yapılan çalışmalar incelendiğinde birçok hastalığın (insanlarda böbrek, diyabet, parkinson gibi hastalıkların; bitkilerde ise şekil bozukluklarına, solmalara, çürümelere sebep olan

çeşitli hastalıkların) erken tespit edilmesi ve doğru sınıflandırılması için çeşitli derin öğrenme ve makine öğrenmesi yöntemlerinin kullanıldığı görülmektedir (Orhan ve ark., 2012; Cömert ve ark., 2017; Adem, 2018; Kılıçarslan, 2023; Yılmaz ve ark., 2023a). Bunun yanısıra davranış analizi, fiyat tahmini, ürün sınıflandırması, saldırı tespiti gibi farklı alanlarda da multidisipliner bir şekilde gerçekleştirilen birçok çalışma mevcuttur (Adem, 2017; Kılıçarslan, 2022; Yılmaz ve Akcayol, 2022; Yılmaz, 2023; Yılmaz ve ark., 2023b). Bu çalışmada da diş çürüğünün tespiti için Lee ve ark. (2018), yaptığı araştırmalarda derin öğrenme modellerinden Google LeNet, Inceptionv3 ve CNN ağları kullanılmıştır. Bu görüntülerin %80'i eğitim, %20'lik kısmı ise test veri kümesi olarak iki kısma ayrılmıştır ve derin öğrenme modellerine göre en başarılı olan CNN olmuştur ve bu yöntemde %95 oranında başarı sağlanmıştır (Lee ve ark., 2018). Suryani ve ark. (2020), yaptıkları makalede ise diş röntgeni görüntülerinde nesne algılaması için derin öğrenme yöntemleri kullanmıştır. Diş problemlerinin teşhisinde ve vaka tespitine göre doğru tedavi yöntemine karar vermek için radyolojik röntgenlere önem verilmektedir. Bu röntgenler sayesinde diş hekimlerinin yanlış tanı konmasının önüne geçilebilir. Bunun için diş restorasyonu için derin öğrenme yöntemlerinden R-CNN kullanılarak nesne tespit işlemi gerçekleştirilmiş ve bir model geliştirilmiştir. Bu model sayesinde panoramik röntgenlerdeki nesnelerin otomatik olarak algılanarak zamandan tasarruf edilmesi beklenmektedir. Panoramik diş görüntülerinde nesne algılama sonuçları ise 0,91 ile 0,96 arasında güven değerini gösterir (Suryani ve ark., 2020). Çelik ve ark. yaptıkları çalışmada ise diş eksikliklerinin tespiti için derin öğrenme yöntemlerini kullanmıştır. Bu veriler 153 panoramik röntgenden oluşmakta olup Google Net, Inception v3, CNN ağı ile eğitilmiştir. Eğitimde kullanılan görüntülerdeki başarı oranının %94,7 olduğu tespit edilmiştir (Çelik ve ark., 2019). Gurses ve Oktay (2020), yaptıkları çalışmada ise diş restorasyonlarının sınıflandırılması için GoogleNet, DenseNet ve ResNet kullanmışlardır. Buradaki implant, kanal tedavileri, dolgular ve diş telleri sınıflarına ayrılmıştır. 3013 tane panoramik diş röntgeninde çalışılmıştır. %94 olarak DenseNet sonucuna ulaşılmıştır (Gurses ve Oktay, 2020). Osmanoglu ve ark. (2019), çalışmasında ise Matrix Laboratory (Matlab) programı ile görüntü işleminin sağlık alanında kullanılmasını değerlendirilmektedir. Son yıllarda gelişen teknolojiyle birlikte tıp alanında görüntü işleme teknikleri de yaygın olarak kullanılmaktadır. Bu yöntemler de uzmanlara zaman, maliyet, teşhis konusunda yarar sağlamaktadır. Bu çalışmada Eskişehir Osmangazi Üniversitesi Tıp Fakültesi Göz Hastalıkları Anabilim Dalına başvuran Orbita MR endikasyonu olan hastaların verileri alınmıştır. MR görüntüleri Codonics Clarity Viewer programı, Matlab ve Lenster cihazı kullanılarak Ön Kamera Derinliği (ÖKD), Lens Kalınlığı (LK) ve Aksiyel Uzunluk (AU) hesaplamaları yapılarak karşılaştırmalar yapılmıştır. Ölçüm sonucunda ise Matlab programının ölçüm ile uyum gösterdiği sonucuna ulaşılmıştır

(Osmanoglu ve ark., 2019). Bu çalışmada kullanılan veri seti Aksaray ilinde özel muayenehanelerden alınarak veri seti oluşturulmuştur. Röntgen görüntüleri üzerinde diş çürükleri tespit edilerek derin öğrenme modelleri kullanılarak uygulanan tedavi yöntemleri dolgu, kanal, köprü sınıflarına ayrılmıştır. Derin öğrenme modellerinden Faster R-CNN ve YOLOv5 modelleri ile deneysel çalışmalar karşılaştırılarak performans sonuçları karşılaştırılmıştır. Makalenin geri kalanında, ikinci bölümde çalışmada kullanılan panoramik görüntü veri kümesi ve kullanılan yöntemler verilmiştir. Üçüncü bölümde, deneysel değerlendirme sonuçları ve tartışma verilmiştir. Son bölümde, sonuçlar ve gelecekte yapılacak çalışma sunulmuştur.

MATERIAL AND METHODS

Panoramik Diş Röntgenleri Veri Seti

Bu çalışmada Aksaray ili içerisinde bulunan 553 hastanın röntgeni (panoramik) diş verileri alınmıştır. Görüntü temininde kişinin özel hayatı ihlal edilmemiştir. Daha sonra uzman yardımı ile bu röntgenlerin sınıflandırılması yapılmıştır. 154 hastaya dolgu tedavisi, 163 hastaya kanal tedavisi ve 116 hastaya ise köprü tedavisi uygulanmıştır. Ayrıca 120 tane ise sağlıklı panoramik diş röntgeni bulunmaktadır. Veri setimizde yer alan görüntülerden örnekler Şekil 5'te yer almaktadır.

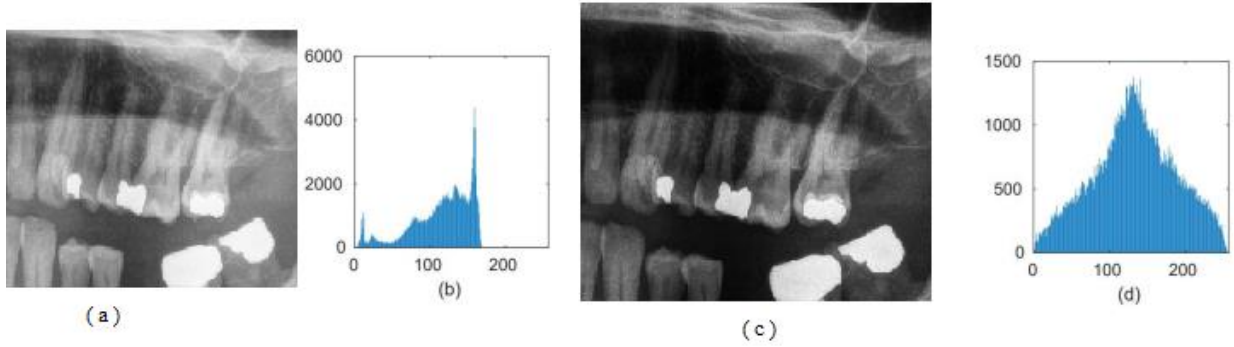


Şekil 5. Veri setinde bulunan örnek görüntüler

Diş Röntgenlerine Uygulanan Ön İşlemler

Diş röntgeni veri seti düzenlenirken bozulma, belirsizlik ve gölgeler değerlendirmeye alınmamıştır. Veri setinde yer alan diş röntgenleri üzerinde ilgili bölüm ile görüntü kırılma işlemi gerçekleştirilmiştir. Bu işlem ile sınıflandırma modelinin röntgenlerde bulunan ayırıcı özelliklerini zorlaştıran görüntülerin atılması amaçlanmıştır. Ayrıca diş görüntülerine ön işlem

olarak luv-v kanalı ve adaptif histogram eşitleme işlemi uygulanarak derin öğrenme modellerinin performanslarının artırılması amaçlanmıştır.



Şekil 6. Dolgu röntgenine adaptif histogram uygulanmış görüntü


Şekil 6’da sırasıyla a ve b’de histogram uygulanmamış dolgu röntgeni ve bu görüntünün histogram grafiği, c ve d’de ise aynı resme histogram uygulanmış dolgu röntgeni ve onun histogram grafiği paylaşılmıştır. Grafikler incelendiğinde kontrast dağılımında histogram eşitleme yapılmış röntgenin yoğunluk düzeylerinin eşit bir şekilde dağılımı gösterdiği görülmektedir. Bu çalışmada kullanılan adaptif histogram eşitleme işlemi için Matlab programı kullanılmıştır.

Veri Etiketleme

Nesneyi tanımlamak için hazırladığımız veriler danışmanlı öğrenme yöntemi ile yapay sinir ağında kullanılması için etiketlenmesi gerekmektedir. Verileri etiketlemek için kullanılan bazı etiketleme programları bulunmaktadır. Bunlar Labellmg, Make Sense, Label Tool ve Image Labeler gibi programlardır. Diş röntgenlerini etiketlemek için image labeler programı kullanılmıştır. Etiketlenen veriler ile oluşan g-Truth dosyası eğitim aşamasında kullanılmaktadır. Bu aşamada 3 farklı sınıfta eğitim işlemi gerçekleştirilmiştir. Bu sınıflar; dolgu, kanal ve köprüdür. Şekil 7’de Image Labeler veri etiketleme aracı gösterilmiştir.

Şekil 7’de görüldüğü gibi, diş röntgen görüntüleri Image Labeler yardımıyla dolgu, kanal ve köprü olmak üzere etiketlenmiştir. Burada görüntüler üzerinde seçilen kısımlar nesne, sınırlayıcı kutu (bounding box) ile çevrelenir. Daha sonra bulunan nesne üzerinde N x N olarak ızgaralara bölünmektedir: Nesnenin merkez noktasına karar veren ızgara ise bu nesnenin yüksekliğini, genişliğini ve hangi sınıfta bulunduğunu belirlemektedir. Sınırlayıcı kutular belirlenerek güven puanı her ızgara için hesaplanır, bulunan bu güven puanına göre analiz işlemi gerçekleştirilmektedir. Güven puanı ise 0 ve 1 arasındadır (0: Nesne yok, 1: Nesne


kesinlikle var). Bütün sınırlayıcı kutuların güven puanı bulunmaktadır. Eğer bir nesnede birden fazla bu kutulardan var ise güven skoru en yüksek olan ekrana çizdirilmektedir.



Şekil 7. Image Labeler veri etiketleme

Transfer Öğrenmesi

Transfer öğrenmesi için bir problem belirlenmesi gerekir. Bu problem için derin öğrenme modelleri kullanılarak öğrenme aktarımı yapılmaktadır. Modeli sıfırdan eğitmek yerine transfer öğrenmeyi kullanarak verilere ince ayar yapmak daha hızlı ve kolay öğrenmeyi sağlar. İlk olarak, kaynak veriden hangi bilginin aktarılması gerektiğinin belirlenmesi gerekir. Daha sonra aktarılacak bilginin hangi aşamada aktarılması gerektiği belirlenmektedir. Son olarak bilginin aktarılmasında hangi derin öğrenme yöntemleri kullanılmalı bunun belirlenmesi gerekmektedir.

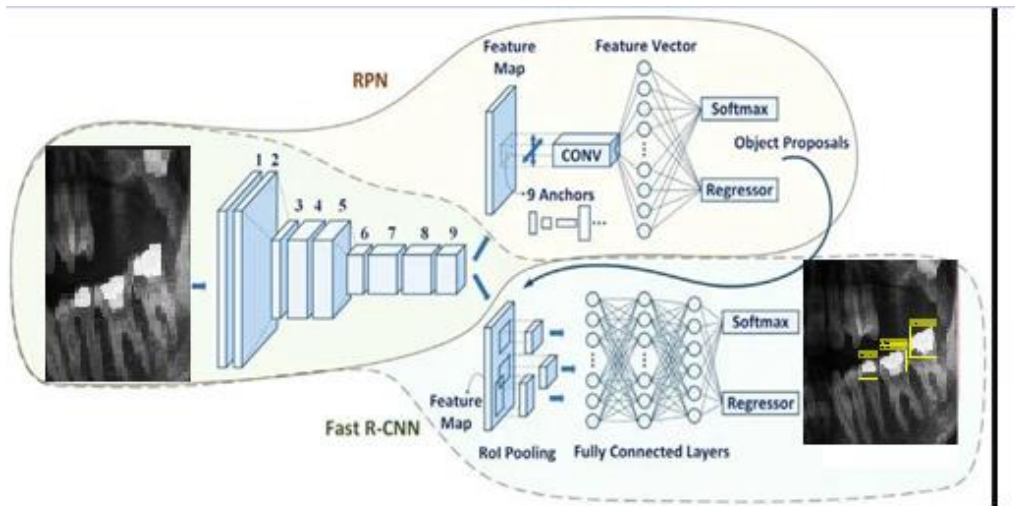


Şekil 8. Transfer öğrenme mimarisi

Şekil 8’de gösterildiği gibi, transfer öğrenme mimarisi ile daha önce eğitilmiş olan derin öğrenme modelinin ağırlıklarının, farklı veri setleri üzerinde uygulanması amaçlanmaktadır. Bunu yaparken zaman ve donanım tasarrufu elde edilmektedir. Transfer öğrenmesi ile yüksek başarı elde edilmesi sağlanmaktadır. Etiketlediğimiz veriler kullanılarak transfer öğrenmesi yöntemi kapsamında Faster RCNN ve YOLOv5 modelleri ile nesneyi tespit etmek amaçlanmıştır.

Faster R-CNN


Faster R-CNN modelinde bölgeleri oluştururken RPN (Region Proposal Network) algoritması kullanılmaktadır. RPN bölge önermeye yarayan evrişimsel sinir ağıdır. Bu nedenle girdi olarak herhangi bir görüntüyü alarak, obje skoruna göre nesnelere ait dikdörtgen teklifi ortaya çıkarmaktadır.



Şekil 9. Faster R-CNN mimarisi

YOLOv5

YOLO evrişimsel sinir ağıları kullanılarak nesne tespiti yapılabilen algoritmadır. Son yıllarda YOLO (You Only Look Once) algoritması sıklıkla kullanılmaktadır. Tek aşamalı nesne tanımda bu algoritma uygulanmaktadır. YOLO diğer nesne tanıma algoritmalarına göre daha hızlı tahmin yapabilmektedir.



Şekil 10. YOLOv5 Algoritması

YOLOv5, Glenn Jocher tarafından kapsamlı bir araştırma sonucunda yayınlanmıştır ve regresyona dayalı bir algoritmadır. Bu model baş, boyun ve omurga kısımlarından oluşmaktadır. YOLOv4, darknet kütüphanesi üzerine geliştirilmiştir. YOLOv5 modeli ise pytorch kütüphanesi üzerine üretilmiştir. Pytorch ekosisteminde dağıtım desteği daha kolaydır. YOLOv5 en yeni özelliklerinden bir tanesi mobil cihazlara dağıtım sağlamasıdır. Şekil 10'da gösterildiği gibi, YOLOv5 modeli için oluşturulan ağırlık dosyaları diğer YOLO modellerine göre oldukça küçük boyuttadır. Bu sebeple gömülü cihazlara daha kolay uygulanabilmektedir.

Değerlendirme Kriterleri

Çalışmada kullanılan veri kümesindeki veriler dış röntgenlerinde bulunan dolgu, köprü, kanal sınıfları şeklinde üç farklı sınıf ile ifade edilmektedir. Çalışmada modellerin eğitimi için öğrenme oranı 0.01 ve epoch değeri 1000 alınarak deneysel değerlendirmeler gerçekleştirilmiştir. Bunlar “Doğruluk (Accuracy), Hassasiyet (Precision), Özgüllük (Specificity), Geri Çağırma (Recall) ve Hata Oranı (Error Rate) metriklerine göre karşılaştırılmıştır.

$$\text{Doğruluk} = \frac{TP+TN}{TP+TN+FP+FN} \quad (1)$$

$$\text{Hassasiyet} = \frac{TP}{TP+FP} \quad (2)$$

$$\text{Özgüllük} = \frac{TN}{TN+FP} \times 100 \quad (3)$$

$$\text{Geri Çağırma} = \frac{TP}{TP+FN} \quad (4)$$

$$\text{Hata Oranı} = 1 - \text{Doğruluk} \quad (5)$$

BULGULAR VE TARTIŞMA

Bu çalışmada diş röntgenlerinde uygulanan dolgu, kanal ve köprü tedavilerini tespit etmek amacıyla Matlab R20221b programı kullanılarak derin öğrenme yöntemlerinden Faster R-CNN ve YOLOv5 modelleri kullanılmış ve performansları paylaşılmıştır. Bu çalışmada 553 adet diş röntgeninden oluşan veri seti kullanılmaktadır. Bu veri setinde; 154 dolgu, 116 köprü, 163 tane kanal tedavisi ve 120 sağlıklı diş röntgeni bulunmaktadır. Çalışmadaki röntgenlerin %70'i eğitim ve %30'u ise test için ayrılmıştır. 3 farklı sınıfta yer alan veri setinde giriş etiketleri Tablo 1'de belirtilmiştir.

Tablo 1. Sınıf düzeylerinde giriş etiketleri

<u>Sınıf Adı</u>	<u>Etiket Adı</u>
Dolgu	D
Kanal	KA
Köprü	KO

Tablo 1'de görüldüğü gibi dolgu, kanal ve köprü olarak sınıflarımızı etiketledik. Bu sınıfları etiketlerken eğer verimiz dolgu ise etiket adını D, kanal ise KA, köprü ise KO olarak uygulanmıştır. Etiketleme işlemi uygulanırken Türkçe karakter kullanmamaya özen gösterilmiştir.

Dolgu İçin Gerçekleştirilen Deneysel Çalışmalar

Diş röntgen görüntüleri üzerinde öznelik çıkarım işlemi öncesinde, görüntüleri ayırt etmek için RGB olan görüntülere Luv renk uzayı dönüşümü uygulanmıştır. Daha sonra diş görüntüleri v kanalına çekilerek bu görüntülere adaptif histogram eşitleme işlemi uygulanmıştır. Derin öğrenme modellerinin doğru şekilde nesne tespitini gerçekleştirebilmesi için bazı hiperparametreler (başlangıç öğrenme oranı, resmin boyutları, batch boyutu ve epoch) kullanılmaktadır. Dolgu eğitimi için Faster R-CNN ve YOLOv5 modeli ile eğitimler gerçekleştirilirken Tablo 2'de kullanılan parametre değerleri kullanılmıştır.

Tablo 2. Dolgu için Faster R-CNN ve YOLOv5 modelinde kullanılan parametreler

Parametreler	Değerler
Initial Learn Rate (Öğrenme Oranı)	0.01
Verbose	True
Mini Batch Size (Yığın Boyutu)	16
Max Epochs (Tekrar Sayısı)	1000
Verbose Frequency	10

Belirlenen hiperparametreler ile dolgu bölgelerinin tespiti için Faster R-CNN ve YOLOv5 modellerinin dış röntgenlerine uygulanması sonucu elde edilen karşılık matrisi Tablo 3 ve Tablo 4'te gösterilmektedir.

Tablo 3. Faster R-CNN ile dolgu görüntülerinde karşılık matrisi

GERÇEK		Tahmin Edilen	
		Dolgu	Sağlıklı
	Dolgu	39	8
	Sağlıklı	3	33

Tablo 3 incelendiğinde, Faster R-CNN ile gerçekleştirilen dolgu sınıflandırması için; toplam test verisinde 47 adet dolgu bulunan dış röntgeninden 39'u doğru olarak tespit edilirken, 8'i ise sağlıklı olarak yanlış sınıflandırılmıştır. Sağlıklı dış röntgeni olarak ise 36 test görüntüsü bulunmaktadır. Bu test görüntülerinden 33'ü doğru bir şekilde sağlıklı olarak tespit edilirken 3'ü ise dolgu sınıfında yanlış teşhis edilmiştir.

Tablo 4. YOLOv5 modeli ile dolgu görüntülerinde karşılık matrisi


GERÇEK		Tahmin Edilen	
		Dolgu	Sağlıklı
	Dolgu	42	5
	Sağlıklı	1	35

Tablo 4 incelendiğinde, YOLOv5 ile gerçekleştirilen dolgu sınıflandırması için; toplam test verisinde 47 adet dolgu bulunan dış röntgeninden 42'si doğru olarak tespit edilirken, 5'i ise sağlıklı olarak yanlış sınıflandırılmıştır. Sağlıklı dış röntgeni olarak ise 36 test görüntüsü bulunmaktadır. Bu test görüntülerinden 35'i doğru bir şekilde sağlıklı olarak tespit edilirken 1'i ise dolgu sınıfında yanlış teşhis edilmiştir. Tablo 5'te ise Faster R-CNN ve Yolov5 derin öğrenme modellerin uygulanması sonucu oluşan duyarlılık, özgüllük, doğruluk ve eğitim sürelerine yer almaktadır.

Tablo 5. Dolgu için Faster R-CNN ve YOLO modeli ölçüm parametre sonuçları

Modeller	Duyarlılık	Özgüllük	Doğruluk	Eğitim Süresi
Faster R-CNN	%82.9	%91.6	%86.7	2 Saat
YOLOv5	%89.3	%97.2	%92.7	1.5 Saat

Tablo 5’te görüldüğü gibi, Faster R-CNN modelinde doğruluk oranı %86.7, duyarlılık oranı %82,9 ve özgüllük oranı %91.6’dır. Yolov5 modelinde ise doğruluk oranı %92.7, duyarlılık oranı %89.3 ve özgüllük oranı ise %97.2’dir. Burada özellikle her iki modelde de özgüllük değerinin duyarlılık değerine göre daha yüksek çıkmasının nedeni sağlıklı diş röntgeni görüntülerinin daha doğru bir şekilde sınıflandırılmasından kaynaklanmaktadır. Ayrıca Yolov5 modelinin doğru sınıflandırma performansının yanında daha kısa sürede eğitim işleminin tamamlanması da oldukça önemlidir. Başarılı olan Yolov5 derin öğrenme modelinin diş röntgenlerine uygulanması sonucu elde edilen görüntüler Şekil 11’de gösterilmektedir.

**Şekil 11.** Yolov5 modelinin uygulanması sonucu oluşan örnek görüntüler

Şekil 11’de görüldüğü gibi, YOLOv5 derin öğrenme modeli ile dolgu bölgelerinin doğru bir şekilde tespit edildiği görülmektedir. Burada tespit edilen bölgenin üzerindeki belirtilen skor değerlerinin 1’e yakın olması ilgili modelin o bölgeyi ne kadar doğru olasılıkla dolgu sınıfına ait olduğunu göstermektedir. Çalışmamızda YOLOv5 derin öğrenme modeli ile tüm test görüntülerinde ilgili dolgu bölgelerinin en az %80 olasılık ile dolgu olarak sınıflandırıldığı tespit edilmiştir.

Kanal için Gerçekleştirilen Deneysel Çalışmalar

Kanal verileri için yapılan deneysel çalışmalarda 163 adet röntgen kullanılmıştır. Bu görüntülerin 114 tanesi eğitim, 49 tanesi ise test görüntüsüne ayrılmıştır. Diş röntgen görüntüleri üzerinde öznetelik çıkarım işlemi öncesinde, görüntüleri ayırt etmek için RGB olan görüntülere Luv renk uzayı dönüşümü uygulanmıştır. Daha sonra diş görüntüleri v kanalına

çekilerek bu görüntülere adaptif histogram eşitleme işlemi uygulanmıştır. Burada amaç dış röntgenleri üzerinde kanal bölgelerinin belirgin hale getirilmesidir. Derin öğrenme modellerinin doğru bir şekilde nesne tespiti gerçekleştirebilmesi için bazı hiperparametreler (başlangıç öğrenme oranı, resmin boyutları, batch boyutu ve epoch) değerleri kullanılmaktadır. Kanal eğitimi için Faster R-CNN, YOLOv5 modeli ile eğitimler gerçekleştirilirken Tablo 6’da modellerde kullanılan parametre değerleri gösterilmektedir.

Tablo 6. Kanal için Faster R-CNN ve YOLOv5 modelinde kullanılan parametre değerleri

Parametreler	Değerler
Initial Learn Rate (Öğrenme Oranı)	0.01
Verbose	True
Mini Batch Size (Yığın Boyutu)	16
Max Epochs (Tekrar Sayısı)	1000
Verbose Frequency	10

Tablo 6’da görüldüğü gibi, bu değerler deneysel çalışmalar sonucu incelendiğinde epoch sayısının 1000, yığın boyutunun 16 ve başlangıç öğrenme oranının 0.01 değerleri ile daha başarılı sonuçlara ulaşıldığı tespit edilmektedir. Belirlenen hiper parametreler ile kanal bölgelerinin tespiti için Faster R-CNN ve YOLOv5 modellerinin dış röntgenlerine uygulanması sonucu elde edilen karşıtlık matrisi Tablo 7 ve Tablo 8’de gösterildiği gibidir.

Tablo 7. Faster R-CNN ile kanal görüntülerinde karşıtlık matrisi

GERÇEK		Tahmin Edilen	
		Kanal	Sağlıklı
	Kanal	41	8
	Sağlıklı	4	32

Tablo 7 incelendiğinde, Faster R-CNN ile gerçekleştirilen kanal sınıflandırması için; toplam test verisinde 49 adet kanal bulunan dış röntgenlerinden 41’i doğru olarak tespit edilirken, 8’i ise sağlıklı olarak yanlış sınıflandırılmıştır. Sağlıklı dış röntgeni olarak ise 36 test görüntüsü bulunmaktadır. Bu test görüntülerinden 32’si doğru bir şekilde sağlıklı olarak tespit edilirken 4’ü ise kanal sınıfında yanlış teşhis edilmiştir.

Tablo 8. YOLOv5 ile kanal görüntülerinde karşıtlık matrisi


GERÇEK		Tahmin Edilen	
		Kanal	Sağlıklı
	Kanal	43	6
Sağlıklı	1	35	

Tablo 8 incelendiğinde, YOLOv5 ile gerçekleştirilen kanal sınıflandırması için; toplam test verisinde 49 adet kanal bulunan diş röntgeninden 43'ü doğru olarak tespit edilirken, 6'sı ise sağlıklı olarak yanlış sınıflandırılmıştır. Sağlıklı diş röntgeni olarak ise 36 test görüntüsü bulunmaktadır. Bu test görüntülerinden 35'i doğru bir şekilde sağlıklı olarak tespit edilirken 1'i ise kanal sınıfında yanlış teşhis edilmiştir. Tablo 9'da Faster R-CNN ve YOLOv5 derin öğrenme modellerin uygulanması sonucu oluşan duyarlılık, özgüllük, doğruluk ve eğitim süreleri verilmektedir.

Tablo 9. Kanal için Faster R-CNN ve YOLO modeli ölçüm parametreler

Modeller	Duyarlılık	Özgüllük	Doğruluk	Eğitim Süresi
Faster R-CNN	%83.6	%88.8	%85.8	2 Saat
YOLOv5	%87.7	%97.2	%91.7	1.5 Saat

Tablo 9'da görüldüğü gibi, Faster R-CNN modelinde doğruluk oranı %85.8, duyarlılık oranı %83.6 ve özgüllük oranı ise %88.8'dır. YOLOv5 modelinde ise doğruluk oranı %91.7, duyarlılık oranı %87.7 ve özgüllük oranı ise %97.2 dir. YOLOv5 modelinin doğru sınıflandırma performansının yanında daha kısa sürede eğitim işlemini tamamlamıştır. Başarılı olan YOLOv5 derin öğrenme modelinin diş röntgenlerine uygulanması sonucu elde edilen görüntüler Şekil 12'de gösterilmektedir.

**Şekil 12.** Yolov5 modelinin uygulanması sonucu oluşan örnek görüntüler

Şekil 12’de görüldüğü gibi, YOLOv5 derin öğrenme modeli ile kanal bölgelerinin doğru bir şekilde tespit edildiği görülmektedir. Burada tespit edilen bölgenin üzerindeki belirtilen skor değerlerinin 1’e yakın olması ilgili modelin o bölgeyi ne kadar doğru olasılıkla kanal sınıfına ait olduğunu göstermektedir. Çalışmamızda YOLOv5 derin öğrenme modeli ile tüm test görüntülerinde ilgili dolgu bölgelerinin en az %70 olasılık ile kanal olarak sınıflandırıldığı tespit edilmiştir.

Köprü için Gerçekleştirilen Deneysel Çalışmalar

Köprü verisi üzerinde yapılan deneysel çalışmalarda 116 adet röntgen kullanılmıştır. Bu görüntülerin 81 tanesi eğitim, 35 tanesi ise test görüntüsüne ayrılmıştır. Diş röntgen görüntülerine adaptif histogram eşitleme işlemi uygulanmıştır. Burada amaç diş röntgenleri üzerinde köprü bölgelerinin belirgin hale getirilmesidir. Derin öğrenme modellerinin doğru şekilde nesne tespitini gerçekleştirebilmesi için bazı hiperparametreler (başlangıç öğrenme oranı, resmin boyutları, batch boyutu ve epoch) değerleri kullanılmaktadır. Köprü eğitimi için Faster R-CNN ve YOLOv5 modeli ile eğitimler gerçekleştirilirken Tablo 10’da modellerde kullanılan parametre değerleri gösterilmektedir.

Tablo 10. Köprü için Faster R-CNN ve YOLOv5 modelinde kullanılan parametre değerleri

Parametreler	Değerler
Initial Learn Rate (Öğrenme Oranı)	0.01
Verbose	True
Mini Batch Size (Yığın Boyutu)	16
Max Epochs (Tekrar Sayısı)	1000
Verbose Frequency	10

Tablo 10’da görüldüğü gibi, bu değerler deneysel çalışmalar sonucu incelendiğinde epoch sayısının 1000, yığın boyutunun 16 ve başlangıç öğrenme oranının 0.01 değerleri ile daha başarılı sonuçlara ulaşıldığı tespit edilmiştir. Belirlenen hiper parametreler ile kanal bölgelerinin tespiti için Faster R-CNN ve YOLOv5 modelinin diş röntgenlerine uygulanması sonucu elde edilen karşıtlık matrisi Tablo 11 ve Tablo 12’de yer almaktadır.

Tablo 11. Köprü görüntülerinde Faster R-CNN ile oluşturulan karşıtlık matrisi

GERÇEK		Tahmin Edilen	
		Köprü	Sağlıklı
	Köprü	29	6
Sağlıklı	6	30	

Tablo 11 incelendiğinde, Faster R-CNN ile gerçekleştirilen köprü sınıflandırması için; toplam test verisinde 35 adet köprü bulunan dış röntgeninden 29'u doğru olarak tespit edilirken, 6'sı ise sağlıklı olarak yanlış sınıflandırılmıştır. Sağlıklı dış röntgeni olarak ise 36 test görüntüsü bulunmaktadır. Bu test görüntülerinden 30'u doğru bir şekilde sağlıklı olarak tespit edilirken 6'sı köprü sınıfında yanlış teşhis edilmiştir.

Tablo 12. Köprü görüntülerinde YOLOv5 ile oluşturulan karşıtlık matrisi

GERÇEK		Tahmin Edilen	
		Köprü	Sağlıklı
	Köprü	31	4
Sağlıklı	4	32	


Tablo 12 incelendiğinde, YOLOv5 ile gerçekleştirilen köprü sınıflandırması için; toplam test verisinde 35 adet köprü bulunan dış röntgeninden 31'i doğru olarak tespit edilirken, 4'ü ise sağlıklı olarak yanlış sınıflandırılmıştır. Sağlıklı dış röntgeni olarak ise 36 test görüntüsü bulunmaktadır. Bu test görüntülerinden 32'si doğru bir şekilde sağlıklı olarak tespit edilirken 4'ü ise köprü sınıfında yanlış teşhis edilmiştir. Tablo 13'te Faster R-CNN ve YOLOv5 derin öğrenme modellerin uygulanması sonucu oluşan duyarlılık, özgüllük, doğruluk ve eğitim süreleri yer almaktadır.

Tablo 13. Köprü için Faster R-CNN ve YOLOv5 modeli ölçüm parametre sonuçları

Modeller	Duyarlılık	Özgüllük	Doğruluk	Eğitim Süresi
Faster R-CNN	%82.8	%83.3	%83	2 Saat
YOLOv5	%88.5	%88.8	%88.7	1.5 Saat

Tablo 13'te görüldüğü gibi, Faster R-CNN modelinde doğruluk oranı %83, duyarlılık oranı %82,8 ve özgüllük oranı ise %83.3'tür. YOLOv5 modelinde ise doğruluk oranı %88.7, duyarlılık oranı %88.5 ve özgüllük oranı ise %88.8'dir. Burada özellikle her iki modelde özgüllük değerinin duyarlılık değerine göre daha yüksek çıkmasının nedeni sağlıklı dış röntgeni görüntülerinin daha doğru bir şekilde sınıflandırılmasından kaynaklanmaktadır. Ayrıca

YOLOv5 modelinin doğru sınıflandırma performansının yanında daha kısa sürede eğitim işleminin tamamlanması da oldukça önemlidir. Başarılı olan YOLOv5 derin öğrenme modelinin diş röntgenlerine uygulanması sonucu elde edilen görüntüler Şekil 13’de gösterilmektedir.

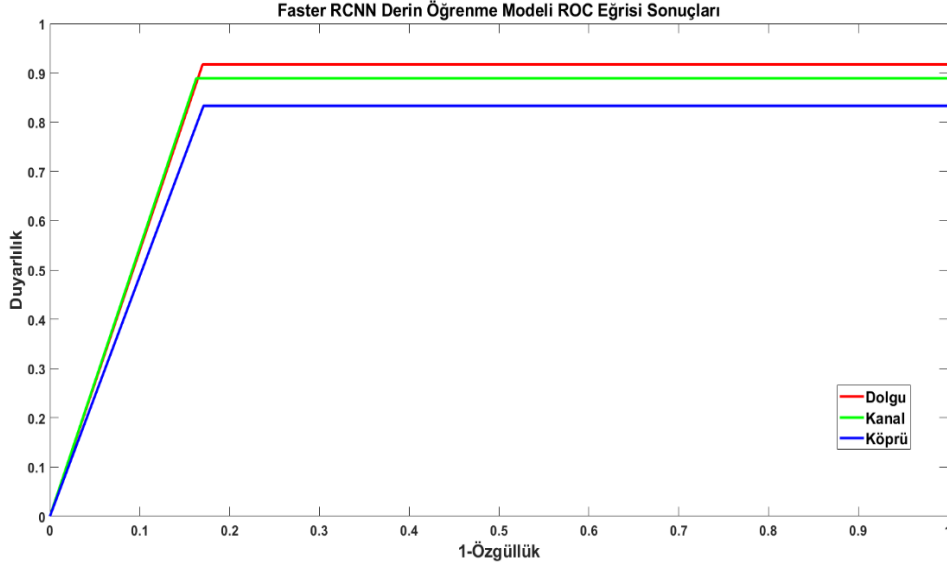


Şekil 13. Köprü dedektörü sonucu oluşan örnek görüntüler

Şekil 13’de görüldüğü gibi, YOLOv5 derin öğrenme modeli ile köprü bölgelerinin doğru bir şekilde tespit edildiği görülmektedir. Burada tespit edilen bölgenin üzerindeki belirtilen skor değerlerinin 1’e yakın olması ilgili modelin o bölgeyi ne kadar doğru olasılıkla köprü sınıfına ait olduğunu göstermektedir. Çalışmamızda YOLOv5 derin öğrenme modeli ile tüm test görüntülerinde ilgili köprü bölgelerinin en az %90 olasılık ile köprü olarak sınıflandırıldığı tespit edilmiştir. Yanlış olarak tespit edilen veya tespit edilemeyen köprü bölgeleri incelendiğinde diş röntgenlerinin standartlara uygun bir şekilde çekilmemesi ve hastanın sabit durmaması gibi nedenlerden kaynaklandığı düşünülmektedir.

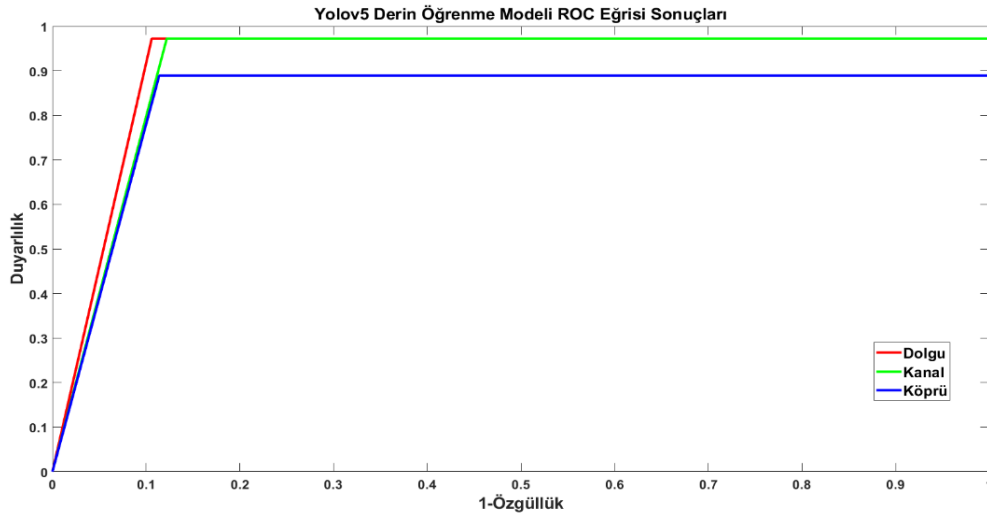
Faster R-CNN ve YOLOv5 Modelleriyle Oluşturulan ROC Eğrisi

ROC (Receiver Operating Characteristic) eğrileri sınıflandırma performansının değerlendirilmesinde uygulanan analitik yöntemlerden biridir. Bu eğriler incelendiğinde x ekseninde Özgüllük yer alırken y ekseninde Duyarlılık yer almaktadır. ROC eğrileri değişkenler için karşıtlık matrisinde bulunan doğru pozitif, doğru negatif, yanlış pozitif, yanlış negatif hakkında tahmin yapılmasını sağlamaktadır. Test için yapılan en iyi kesim noktasının saptanmasında, doğru ve yanlış kararların hesaplanmasında kullanılır. Bunun yanı sıra farklı testlerin doğru sınıflandırma başarılarının karşılaştırılmasını sağlar.



Şekil 14. Faster R-CNN modeliyle oluşturulan ROC eğrisi grafiği

Şekil 14'te yer alan ROC eğrilerinde görüldüğü gibi, Faster R-CNN modeli ile yapılan değerlendirmelerde dolgu, kanal ve köprü verileri bulunmaktadır: Dolgu verisi için yapılan sınıflandırmada %90 ve üzeri orana ulaştığı görülmektedir. Kanal verisi için yapılan çalışmada ise % 88 oranında başarı sağlanmıştır. Köprü verisi için yapılan roc eğrisinde ise % 83 oranında başarı sağlanmaktadır.



Şekil 15. YOLOv5 modeliyle oluşturulan ROC eğrisi grafiği

Şekil 15'de görüldüğü gibi YOLOv5 modeli ile yapılan değerlendirmelerde dolgu, kanal ve köprü verileri bulunmaktadır. Dolgu verisi için yapılan sınıflandırmada %98 ve üzeri orana ulaştığı görülmektedir. Kanal verisinde yapılan çalışmada ise %98 oranında başarı sağlanmıştır.

Köprü verisi için yapılan roc eğrisinde ise %85 oranında başarı sağlanmaktadır. Faster R-CNN ve YOLOv5 modelleri karşılaştırıldığında YOLOv5 modeli daha yüksek eğriler çizerek Faster R-CNN göre daha başarılı performans verdiği belirlenmiştir.

SONUÇLAR

Nesne tespiti için panoramik diş röntgenleri çürük tedavisi için önemli tanı araçları arasında yer almaktadır. Bu durum diş hekimlerinin teşhis aşamasında işlerini kolaylaştırmakta ve erken teşhis ile diş kaybına engel olabilmektedir. Bu sebeple dolgu, kanal ve köprü tedavi süreçlerini içerecek şekilde röntgen filmleri elde edilmiştir. Bu veri setine veri artırma teknikleri uygulanmış ve veri seti artırılarak modelimizin eğitilmesi için kullanıma hazır hale getirilmesi sağlanmıştır. Daha sonra etiketlenerek veri setimiz oluşturulmuştur. Derin öğrenme yöntemleri kullanılarak veri seti üzerinde deneysel çalışmalar yapılmıştır. Bu deneysel çalışmalar adaptif histogram eşitlemek, görüntü kontrastını artırmak veya parlaklık düzeylerini dengeli bir hale getirmek için kullanılan bir yöntemdir. Bu işlem, her bir pikselin çevresindeki bölgeye göre histogram eşitleme işlemini uygulayarak görüntünün genel kalitesini artırır. Derin öğrenme modellerinde kullanılan veri öncesi işleme teknikleri, genellikle giriş verisinin kalitesini artırarak veya daha anlamlı özellikler çıkararak model performansını iyileştirmeyi amaçlar. Özellikle düşük kontrastlı veya kalitesiz görüntülerle çalışıldığında, adaptif histogram eşitleme gibi teknikler modelin daha tutarlı ve doğru özellikler çıkarmasına yardımcı olabilir.

LUV-V kanalı, bazı durumlarda özellik çıkarma sürecinde kullanılan bir bileşen olabilir. Renk uzayı dönüşümleri, belirli görevlerde veya veri setlerinde daha iyi performans elde etmek için kullanılabilir. Sonuç olarak, LUV-V kanalı ve adaptif histogram eşitleme gibi teknikler, önceden işleme adımları olarak derin öğrenme modellerinin performansını artırabilir. Ancak, her birinin etkinliği ve kullanımı, spesifik görevler ve veri setleri üzerinde detaylı olarak değerlendirilmelidir. Veri seti Faster R-CNN ve YOLOv5 gibi son teknoloji derin öğrenme modellerinde deneysel çalışmalar gerçekleştirilmiş ve sonuçlar eğitim süreleri, duyarlılık, özgüllük ve doğruluk parametreleri açısından karşılaştırılmıştır. Bulunan doğruluk oranlarına göre en başarılı yöntemin YOLOv5 modeli olduğu görülmüştür.

YOLOv5, nesne tespiti görevlerinde yüksek hassasiyet sağlarken, aynı zamanda hızlı çalışma yeteneğiyle öne çıkar. Bu, daha iyi performans ve doğru tespitlerle sonuçlanabilir. YOLOv5 modeli pytorch kütüphanesiyle geliştirilmiş olması nedeniyle daha geniş bir destek sunar. YOLOv5, sürekli olarak geliştirilen bir yapıya sahiptir ve aktif bir topluluk tarafından desteklenir. Bu, yeni güncellemelerin yayınlanması ve performansın sürekli olarak iyileştirilmesi anlamına gelmektedir. Diş hastalığını tespit etmek amacıyla geliştirilen

çalışmanın sonucunda en yüksek doğruluk % 92.7, duyarlılık % 89.3, özgüllük oranının ise % 97.2 olduğu tespit edilmiştir. Bu iki modelin sonuçları incelendiğinde özgüllük değerinin duyarlılık değerine göre daha yüksek çıktığı gözlemlenmiştir. Bunun nedeni derin öğrenme modellerinin sağlıklı dış görüntülerini daha doğru bir şekilde teşhis edebilmesidir.

Geliştirilen bu yöntemler sağlık çalışanlarının iş yükünü hafifletmek açısından önem arz etmektedir. Gerçekleştirdiğimiz tez çalışmasının bazı sınırlılıkları bulunmaktadır. Çalışmada kullanılan derin öğrenme modellerinin performansı veri seti sayısı ile doğrudan bağlantılıdır. Veri setindeki görüntülerin daha fazla olması derin öğrenme modellerinden elde edilen performansı artıracığı düşünülmektedir. Çalışmanın veri toplama sürecinde pandemi dönemine denk gelmesi ulaşılan örneklem büyüklüğünün sınırlanmasına neden olmuştur. Gelecekte yapılacak çalışmalarda, daha geniş ve özgün veri setleri ile derin öğrenme modelleri incelenebilir. Ayrıca bu çalışmada iki adet derin öğrenme modelinin sonuçları kıyaslanmış olup, gelecekteki çalışmalarda farklı derin öğrenme modelleri ile deneyler gerçekleştirilerek başarılı sonuçlara erişilebileceği düşünülmektedir.

KAYNAKLAR

Adem, K. 2017. Prediction of gold prices using artificial neural networks. *International Journal of Engineering Research and Development*, 9(3): 83-89, 2017.

Adem, K. 2018. Diagnosis of chronic kidney disease using random subspace method with particle swarm optimization. *International Journal of Engineering Research and Development*, 10(3): 1-5.

Aktaş, A., Doğan., B., Demir, Ö. 2020. Tactile paving surface detection with deep learning methods. *Journal of the Faculty of Engineering and Architecture of Gazi University*, 35(3): 1685-1700.

Çelik, Ö., Odabaş, A., Bayrakdar, İ.Ş., Bilgir, E., Akkoca, F. 2019. Derin öğrenme yöntemi ile panoramik radyografiden diş eksikliklerinin tespiti: Bir yapay zekâ pilot çalışması. *Selcuk Dental Journal*, 6(4): 168-172.

Cömert, O., Hekim, M., Adem, K. 2017. Weight and diameter estimation using image processing and machine learning techniques on apple images. *International Journal of Engineering Research and Development*, 9(3): 147-154.

Diş numaralandırma [Internet]. Wikipedia, 2023 [cited 2023 December 29]. Available from:

https://tr.wikipedia.org/w/index.php?title=Di%C5%9F_numaraland%C4%B1rma&oldid=30775373.

Gurses, A., Oktay, A.B. 2020. Tooth restoration and dental work detection on panoramic dental images via CNN. *Medical Technologies Congress (TIPTEKNO)*, 19-20 Kasım, p: 1-4.

Kılıçarslan, S. 2022. Kurum üzüm tanelerinin sınıflandırılması için hibrit bir yaklaşım. *Mühendislik Bilimleri ve Araştırmaları Dergisi*, 4(1): 62-71.

Kılıçarslan, S. 2023. PSO + GWO: a hybrid particle swarm optimization and Grey Wolf optimization based Algorithm for fine-tuning hyper-parameters of convolutional neural networks for Cardiovascular Disease Detection. *Journal of Ambient Intelligence and Humanized Computing*, 14: 87–97.

Lee, J.H., Kim, D.H., Jeong, S.N., Choi, S.H. 2018. Diagnosis and prediction of periodontally compromised teeth using a deep learning-based convolutional neural network algorithm. *Journal of Periodontal & Implant Science*, 48(2): 114-123.

Orhan, U, Adem, K., Cömert, O. 2012. Least squares approach to locally weighted naive bayes method. *Journal of New Results in Science*, 1(1): 71-80.

Osmanoglu, U.O., Mutlu, F., Gursoy, H., Sanlısoy, S. 2019. Use of image processing and analysis in medicine and an application. *Osmangazi Journal of Medicine*, 41 (1): 6 – 16.

Suryani, D., Shoumi, M.N., Wakhidah, R. 2020. Object detection on dental x-ray images using deep learning method. *IOP Conf. Series: Materials Science and Engineering*, vol. 1073, no. 1, article 012058.

Yılmaz, E.K., Adem, K., Kılıçarslan, S. 2023a. Classification of lemon quality using hybrid model based on Stacked AutoEncoder and convolutional neural network. *European Food Research and Technology*, 249: 1655–1667.

Yılmaz, E.K., Akcayol, M.A. 2022. SUST-DDD: A real-drive dataset for driver drowsiness detection. In *Conference of Open Innovations Association (FRUCT) (Vol. 6)*.

Yılmaz, E.K., Bakır, H. 2023. Hyperparameter tuning and feature selection methods for malware detection. *Politeknik Dergisi*, 1-1.

Yılmaz, E.K., Oğuz, T., Adem, K. 2023b. A CNN-based hybrid approach to classification of raisin grains. In *International Conference on Frontiers in Academic Research (Vol. 1)*.

Zero, D.T. 1999. Dental caries process. *Dental Clinics of North America*, 43: 635-664.