



T.C.

AKSARAY ÜNİVERSİTESİ

SOSYAL BİLİMLER ENSTİTÜSÜ

YÖNETİM BİLİŞİM SİSTEMLERİ ANABİLİM DALI

**DİŞ GÖRÜNTÜLERİ ÜZERİNDE GÖRÜNTÜ İŞLEME
VE DERİN ÖĞRENME YÖNTEMLERİ KULLANILARAK
ÇÜRÜK SEVİYESİNİN SINIFLANDIRILMASI**

YÜKSEK LİSANS TEZİ

ÜMRAN ÜNSAL

DANIŞMAN

Doç. Dr. KEMAL ADEM

Aksaray 2022

AKSARAY ÜNİVERSİTESİ

SOSYAL BİLİMLER ENSTİTÜSÜ

YÖNETİM BİLİŞİM SİSTEMLERİ ANABİLİM DALI

**DİŞ GÖRÜNTÜLERİ ÜZERİNDE GÖRÜNTÜ İŞLEME
VE DERİN ÖĞRENME YÖNTEMLERİ KULLANILARAK
ÇÜRÜK SEVİYESİNİN SINIFLANDIRILMASI**

YÜKSEK LİSANS TEZİ

ÜMRAN ÜNSAL

DANIŞMAN

Doç. Dr. KEMAL ADEM

Aksaray 2022

TELİF HAKKI VE TEZ FOTOKOPİ İZİN FORMU

Bu tezin tüm hakları saklıdır. Kaynak göstermek koşuluyla tezin teslim tarihinden itibaren(...) ay sonra tezden fotokopi çekilebilir.

YAZARIN

Adı : Ümran

Soyadı : Ünsal

Bölümü : Yönetim Bilişim Sistemleri

İmza :

Teslim tarihi :

TEZİN

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

İngilizce Adı : Classification of Caries Level Using Image Processing and
Deep Learning methods on Dental images

ETİK İLKELERE UYGUNLUK BEYANI

Tez yazma sürecinde bilimsel ve etik ilkelere uyduđumu, yararlandığım tüm kaynakları kaynak gösterme ilkelerine uygun olarak kaynakçada belirttiđimi ve bu bölümler dışındaki tüm ifadelerin şahsıma ait olduđunu beyan ederim.

Yazar Adı Soyadı : Ümran ÜNSAL
İmza :

T.C.
AKSARAY ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
JÜRİ ONAY SAYFASI

Ümran ÜNSAL tarafından hazırlanan “Diş Görüntüleri Üzerinde Görüntü İşleme ve Derin Öğrenme Yöntemleri Kullanılarak Çürük Seviyesinin Sınıflandırılması” başlıklı tez çalışması aşağıdaki jüri tarafından oy birliği ile Aksaray Üniversitesi Yönetim Bilişim Sistemleri Anabilim Dalı’nda Yüksek Lisans Tezi olarak kabul edilmiştir.

İmza

Danışman: Doç. Dr. Kemal Adem

Bilgisayar Mühendisliği, Sivas Bilim ve Teknoloji Üniversitesi

Üye: Dr. Öğr. Üyesi Rahmi Baki

Yönetim Bilişim Sistemleri, Aksaray Üniversitesi

Üye: Dr. Öğr. Üyesi Halit Bakır

Bilgisayar Mühendisliği, Sivas Bilim ve Teknoloji Üniversitesi

Tez Savunma Tarihi: 30 / 09 /2022

Sosyal Bilimler Enstitüsü Yönetim Kurulu’nun tarih ve sayılı kararı ile onaylanmıştır.

Sosyal Bilimler Enstitüsü Müdürü

Doç. Dr. Sevilay USLU DİVANOĞLU

İmza

TEŞEKKÜR

Bu çalışmanın gerçekleşmesinde yardımlarını esirgemeyen ve yol gösteren danışman hocam Sayın Doç. Dr. Kemal ADEM'e, tıbbi görüntü analizinde yardımlarını esirgemeyen dış uzmanı Dt. Özcan GÖKŞEN'e, değerli fikirleri ile çalışmaya katkı sunan jüri üyelerine, her daim yanımda olan ve desteklerini esirgemeyen aileme teşekkür ederim.

AKSARAY ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
DİŞ GÖRÜNTÜLERİ ÜZERİNDE GÖRÜNTÜ İŞLEME VE
DERİN ÖĞRENME YÖNTEMLERİ KULLANILARAK
ÇÜRÜK SEVİYESİNİN SINIFLANDIRILMASI
(Yüksek Lisans Tezi)

Ümran ÜNSAL, Aksaray 2022

ÖZET

Ağızda bulunan bakterilerin ürettiği asitler dişlerin mineral dokusunu bozarak diş çürüklerine neden olmaktadır. Zamanla kişilerin ağızında bakteriler birikir ve bu bakteriler gıdalarla birleşir. Ağız bakımına yeterli özen gösterilmediğinde diş minesi zarar görür ve diş çürümeleri gerçekleşir. Yakın bir döneme kadar kökü iltihaplanmış hasta dişler, diğer bölgelere zarar vermemesi amacıyla çekilmekteydi. Fakat gelişen görüntüleme teknikleri sayesinde diş çekimi yapılmadan uygulanan tedavilerin sayısı ve başarı oranı hızla artmıştır. Diş çürükleri insanların hayatlarını olumsuz yönde etkilemektedir. 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. Görüntü işleme ve Yolov5 hibrit modelinin uygulanması sonucunda elde edilen karar destek sistemi diş kliniklerinde kullanılabilecektir.

Bilim Kodu : 92431, 92432

Anahtar Kelimeler : Panoramik Röntgen, Kanal, Dolgu, Köprü, Derin Öğrenme, Görüntü İşleme.

Sayfa Adedi : 67

Danışman : Doç. Dr. Kemal ADEM

AKSARAY UNIVERSITY
GRADUATE SCHOOL OF SOCIAL SCIENCES
CLASSIFICATION OF CARIES LEVEL
USING IMAGE PROCESSING AND DEEP LEARNING METHODS
ON DENTAL IMAGES

(M.A. Thesis)

Ümran ÜNSAL, Aksaray 2022

ABSTRACT

The acids produced by the bacteria in the mouth cause dental caries by disrupting the mineral tissue of the teeth. Over time, bacteria accumulate in the mouth of people and these bacteria combine with food. When adequate care is not given to oral care, tooth enamel is damaged and tooth decay occurs. Until recently, infected teeth were extracted in order not to damage other areas. However, thanks to developing imaging techniques, the number and success rate of treatments applied without tooth extraction has increased rapidly. Tooth decay affects people's lives negatively. 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. The decision support system obtained as a result of image processing and application of the Yolov5 hybrid model can be used in dental clinics.

Science Code : 92431, 92432

Key Words : Panoramic X-Ray, Canal, Filling, Bridge, Deep Learning, Image
Processing

Page Number : 67

Supervisor : Assoc. Prof. Dr. Kemal ADEM

İÇİNDEKİLER

TELİF HAKKI VE TEZ FOTOKOPİ İZİN FORMU.....	i
ETİK İLKELERE UYGUNLUK BEYANI	ii
JÜRİ ONAY SAYFASI.....	iii
TEŞEKKÜR	iv
ÖZET	v
ABSTRACT.....	vi
İÇİNDEKİLER	vii
TABLolar LİSTESİ.....	x
ŞEKİLLER LİSTESİ.....	xi
SİMGELER VE KISALTMALAR LİSTESİ	xiii
GİRİŞ.....	1
BİRİNCİ BÖLÜM.....	3
1 Diş Çürüğü	3
1.1 Dolgu Tedavisi	4
1.2 Kanal Tedavisi	5
1.3 Köprü Tedavisi.....	6
İKİNCİ BÖLÜM.....	11
MATERYAL VE YÖNTEM	11
2.1 Kullanılan Veri Seti.....	11
2.2 Yöntem	12
2.2.1 Ön İşlemler.....	12

2.2.2 Görüntülerin Kırpılması.....	12
2.2.3 Renk Uzayları.....	13
2.2.4 Histogram Eşitleme	15
2.2.5 Veri Etiketleme	16
2.2.6 Veri Setinin Normalize Edilmesi	18
2.2.7 Test ve Eğitim Sınıflarının Belirlenmesi.....	19
2.3 Makine Öğrenmesi	19
2.4 Derin Öğrenme.....	20
2.4.1 CNN (Convolutional Neural Network).....	21
2.4.2 Region Based CNN (R-CNN).....	25
2.4.3 Fast R-CNN.....	26
2.5 Transfer Öğrenmesi (Öğrenme Aktarımı).....	27
2.6 Kullanılan Yöntemler	27
2.6.1 Faster R-CNN.....	27
2.6.2 YOLOv5	28
2.7 Çalışmada Kullanılan Hiper Parametreler.....	29
2.8 Değerlendirme Kriterleri	31
ÜÇÜNCÜ BÖLÜM	33
BULGULAR VE TARTIŞMA	33
3.1 Model Tasarımları	34
3.1.1 Dolgu için Gerçekleştirilen Deneyler	35
3.1.2 Kanal için Gerçekleştirilen Deneyler Çalışmalar	38
3.1.3 Köprü için Gerçekleştirilen Deneyler	40
3.2 Faster R- CNN ve YOLOV5 Modelleriyle Oluşturulan Roc Eğrisi	43

SONUÇ VE ÖNERİLER	45
KAYNAKÇA	47
AKSARAY ÜNİVERSİTESİ TEZ DEĞERLENDİRME FORMU	51



TABLÖLAR LİSTESİ

Tablo 1. Diş Çürükleri Ve Tedavileri Üzerine Yapılmış Bazı Çalışmalar	10
Tablo 2. Karşıtlık Matrisi.....	31
Tablo 3. Sınıf Düzeylerinde Giriş Etiketleri	35
Tablo 4. Dolgu İçin Faster R-Cnn Ve Yolov5 Modelinde Kullanılan Parametreler.....	35
Tablo 5. Faster R-Cnn İle Dolgu Görüntülerinde Karşıtlık Matrisi	36
Tablo 6. Yolov5 Modeli İle Dolgu Görüntülerinde Karşıtlık Matrisi	36
Tablo 7. Dolgu İçin Faster R-Cnn Ve Yolo Modeli Ölçüm Parametre Sonuçları	37
Tablo 8. Kanal İçin Faster R-Cnn Ve Yolov5 Modelinde Kullanılan Parametre Değerleri.....	38
Tablo 9. Faster R-Cnn İle Kanal Görüntülerinde Karşıtlık Matrisi	38
Tablo 10. Yolov5 İle Kanal Görüntülerinde Karşıtlık Matrisi.....	39
Tablo 11. Kanal İçin Faster R-Cnn Ve Yolo Modeli Ölçüm Parametreler	39
Tablo 12. Köprü Yolo Modelinde Kullanılan Parametre Değerleri.....	41
Tablo 13. Köprü Görüntülerinde Faster R-Cnn İle Oluşturulan Karşıtlık Matrisi.....	41
Tablo 14. Köprü Görüntülerinde Yolov5 İle Oluşturulan Karşıtlık Matrisi.....	41
Tablo 15. Köprü İçin Faster R-Cnn Ve Yolo Modeli Ölçüm Parametre Sonuçları	42

ŞEKİLLER LİSTESİ

Şekil 1. Dünya Sağlık Örgütü Sistemi Numaralandırılması	2
Şekil 2. Dolgu Diş Röntgeni.....	5
Şekil 3. Kanal Diş Röntgeni	5
Şekil 4. Köprü Diş Röntgeni	6
Şekil 5. Sistem Mimarisi	11
Şekil 6. Veri Setinde Bulunan Örnek Görüntüler	12
Şekil 7. Diş Röntgenlerinde Görüntü Kırılmasına Örnek	13
Şekil 8. Renk Uzayları	14
Şekil 9. Rgb Renk Uzayı	14
Şekil 10. Köprü Röntgeni Uygulanmış Görüntü	15
Şekil 11. Histogram Eşitleme İle Kontrast Seviyesinin Düzenlenmesi	16
Şekil 12. Labellmg Veri Etiketleme Programı	17
Şekil 13. Labellmg İle Etiketlenen Görüntü Verileri Kümesi	18
Şekil 14. Yapay Zekâ Ve Alt Alanları	19
Şekil 15. Nesne Tespiti Ve Nesne Tanınması Aşamaları	20
Şekil 16. Kümeleme Ve Sınıflandırma	21
Şekil 17. Cnn Mimarisi	22
Şekil 18. Rgb Girdi Görüntüsüne Evrişim İşleminin Uygulanması	23
Şekil 19. Relu Aktivasyon Fonksiyonu.....	24
Şekil 20. Maksimum Havuzlama.....	24
Şekil 21. Tam Bağlı Katman	25
Şekil 22. R-Cnn Mimarisi	25
Şekil 23. Fast R-Cnn Mimarisi	26
Şekil 24. Transfer Öğrenme Mimarisi	27
Şekil 25. Faster R-Cnn Mimarisi	28
Şekil 26. Yolov5 Algoritması.....	28
Şekil 27. Loss Function.....	30
Şekil 28. Öğrenme Hızı.....	30
Şekil 29. Uygulama Aşamaları.....	33
Şekil 30. Image Labeler Veri Etiketleme	34

Şekil 31. Yolov5 Modelinin Uygulanması Sonucu Oluşan Örnek Görüntüler	37
Şekil 32. Yolov5 Modelinin Uygulanması Sonucu Oluşan Örnek Görüntüler	40
Şekil 33. Köprü Dedektörü Sonucu Oluşan Örnek Görüntüler	42
Şekil 34. Faster R-Cnn Modeliyle Oluşturulan Roc Eğrisi Grafiği.....	43
Şekil 35. Yolov5 Modeliyle Oluşturulan Roc Eğrisi Grafiği.....	44



SİMGELER VE KISALTMALAR LİSTESİ

ISO	: Dünya Sağlık Örgütü
FDI	: Dünya Dış Hekimleri Birliği
GV	: Genel Kavite
β	: Beta
α	: Alfa
CNN	: Konvolüsyonel Sinir Ağı
ROC	: Alıcı Çalışma Karakteristiği
RMSE	: Kök Ortalama Kare Hata
AUC	: Eğrinin Altında Kalan
LTP	: Kontrast Limitli Adaptif Histogram Eşitleme
GPU	: Grafik İşlemci Ünitesi
RGB	: Kırmızı-Yeşil-Mavi
ESA	: Evrişimsel Sinir Ağları
RNN	: Tekrarlayan Sinir Ağları
LSTM	: Uzun-Kısa Vadeli Hafıza Ağları
RBM	: Sınırlı Boltzman Makineleri
YOLOV5	: You Only Look Once
R-CNN	: Bölge Tabanlı CNN
ReLU	: Doğrultulmuş Doğrusal Aktivasyon Fonksiyonu

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 yol açmaktadır. Bu hastalıklardan bazıları; periodontal hastalık, dental yaralanmalar, florozis, diş kaybı, ağız kanserleri gibi ciddi sağlık sorunlarına sebep olabilir.

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, Üiversal Numaralandırma Sistemleridir.

Türkiye’de uzmanlarca bu yöntemlerden Dünya Sağlık Örgütü (ISO) Sistemi kullanılmaktadır. Şekil 1 de ISO’nun numaralandırılması gösterilmektedir. Bu sistemde belirli bir diş hakkında bilgi vermesi amacıyla uluslararası diş uzmanları tarafından sıklıkla kullanılmaktadır. Ayrıca Dünya Diş Hekimleri Birliğine (FDI) dayanmaktadır.



Şekil 1. Dünya Sağlık Örgütü Sistemi Numaralandırılması

BİRİNCİ BÖLÜM

1 Diş Çürüğü

Her yaşta bireyi etkileyen diş çürükleri, diş minesinin ve dişlerin dış sert yüzeyinin tahrip olması sebebinden 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 komponentlerinin demineralizasyonunu ve organik yapısının enzimatik olarak bozulmasının eşlik ettiği süreçtir (Boucher, 1974; Krutchkoff, 1981; Mellberg ve Ripa, 1983; Fejerskov ve Thylstrup, 1994; Marsh, 1999). Diş kökleri, diş yüzeyine göre daha hassastır. Bu sebeple dişler de çürümeye daha yatkındır. Çürük dişler sıcak ve soğuğa daha duyarlıdır. Daha ileriki dönemlerde endodontik (kanal) tedavisi veya diş kaybına yol açacak şiddetli ağrılı pulpa apsesine sebep olabilmektedir (Zero, 1999).

Çocuklar ve gençlerde yüzeysel diş çürükleri görülürken, 50'li yaş ve üstünde ise diş köklerinde çürükler görülebilmektedir. Çünkü insanlar yaşlandıkça dişlerde bulunan florür miktarı azalırken bu durumda çürümelere yol açar. Dişlerin çürüdüğü zaman belirtiler gösterir. Bunlar belirgin bir sebep olmaksızın görülen diş ağrıları, dişlerin normalden daha da hassas olması, tatlı, sıcak ve soğuk yiyecek yerken dişlerde oluşan ağrılar, dişlerde oluşan çürükler ve belirgin boşluklar oluşması, herhangi bir sebeple yemek yerken dişte oluşan ağrı, ağızda oluşan kokular diş çürümelerine neden olmaktadır. Eğer diş çürüğü tedavi edilmez ise diş yüzeyine ve köküne kadar iner. Bunun neticesinde diş kayıpları meydana gelebilir.

Buna ek olarak diş çürükleri bazı önemli rahatsızlıklara da neden olabilmektedir. Bunlar; şeker hastalığı, bademcik iltihabı, romatizma, kemik erimesi, kalp ve böbrek yetmezliği,

ülser gibi hastalıkların ağız sağlığıyla direkt bağlantısı bulunmaktadır. Çürük dişlerin tedavi edilmesi için farklı yöntemler kullanılmaktadır. Bunlar diş dolgusu, kanal tedavisi, köprü ve implant tedavileri uygulanmaktadır.

1.1 Dolgu Tedavisi

Çürük dişler eğer zamanında tedavi edilmez ise dişin içinde bulunan sinirler ölür. Bu durumda dolgu tedavisi uygulanmalıdır. Dolgu tedavisi çürük dişlere ve kırılmış dişlere yapılabilir. Dolgu tedavisi ile deforme olan diş eski görünümünü yeniden kazanır. Dişe uygulanan dolgu tedavisinde farklı teknikler uygulanabilir. Bunlar Amalgam dolgular, Kompozit dolgular ve Porselen dolgulardır.

Diş dolgusu hastanın alerjisi, dişin konumu ve çürüğün büyüklüğüne göre hangi dolgu çeşidi uygulanacağına diş hekimi karar verir. Hastanın görüşü de alınarak dolgu tedavisine diş hekimi başlayabilir.

Dişte dolgu çeşitleri vardır. Bunlar; amalgam dolgu, kompozit dolgu, porselen dolgulardır. Amalgam dolgular civa, gümüş, bakır ve kalaydan oluşmaktadır ve genelde dişin arka kısmına uygulanmaktadır. Basınca ve çiğneme gücüne karşı dirençli dolgulardır. Maliyet açısından oldukça uygundur. Ancak son yıllarda kullanımı giderek azalmaktadır. Gri renkli olduğundan estetik beklentileri karşılamaz. Çünkü dişe uygulandığı zaman diş minesinin siyah renkli görüntüsü sebebiyle tercih edilmemektedir. Ayrıca bazı hastaların civa maddesine alerjisi olabilmektedir. Civanın insan sağlığına olumsuz etkileri son yıllarda yapılan araştırmalar neticesinde diş hekimlerini farklı dolgulara yönlendirmiştir. Kompozit dolgular dişin görünebilir kısmında uygulanır. Bu sebepten dolayı ön dişlere ve arka dişlere de uygulanmaktadır. Kompozit dolgular silikon dioksit parçacıkları olan plastik karışımdan oluşmaktadır. Estetik bakımdan hastanın beklentilerini karşılar. Ancak amalgam dolgulara göre daha pahalı bir yöntemdir. Porselen dolgular, diğer dolgulara göre diş ile en uyumlu dolgu çeşididir. Diş hekimi ilk seansta dişi dolgu için hazırlar. Ayrıca ölçü alınıp, hastaya geçici dolgu yapılmaktadır. İkinci seansta ise laboratuvarında hazırlanan parça dişe yapıştırılır. Yapıştırılan dişe cila uygulanır. Porselen dolgular son derece dayanıklı olup dişte doku kaybı yaşanmaz. Özellikle madde kaybının çok olduğu dişlerde daha çok bu dolgular tercih edilir. Dişleri aşındırmaz ve diş etleriyle uyumlu yapıda olması sebebiyle tercih edilir. Maliyet olarak diğer dolgulara göre daha pahalıdır. Şekil 2 de örnek dolgu diş röntgeni bulunmaktadır.



Şekil 2. Dolgu Diş Röntgeni

1.2 Kanal Tedavisi

Dişin enfekte olması sonucunda çürümüş dişlere uygulanan tedavi yöntemidir. Kanal tedavisi 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. Şekil 3 de örnek bir kanal diş röntgeni bulunmaktadır.

Diş çürükleri zamanında tedavi edilmez ise çürük derinlere doğru ilerler ve dişlerin iltihaplanmasına neden olabilmektedir. Diş iltihaplanması sebebiyle hastada şiddetli diş ağrısı meydana gelmektedir. Son yıllarda geliştirilmiş olan Lazer/ Sweep tekniği ile çürüyen dişin içindeki sinirler çıkartılıp kanal tedavisinin başarı oranını artırmıştır.




Şekil 3. Kanal Diş Röntgeni

1.3 Köprü Tedavisi

Çürüyen dişin çekilmesi sonucunda, bu boşluğu kapatmak amacıyla restoratif diş tedavisi uygulanmaktadır. Protez dişleri sağlıklı dişlere sabitleyerek köprü tedavisi yapılmıştır. Bu tedavi yönteminde diş hekimine birkaç defa gidilmesi gerekir.

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.

Köprü dişler için kullanılan malzemeler; metal destekli porselen, zirkonyum destekli porselen, metal malzeme, solid zirkonyum, altın gibi maddeler kullanılır. Köprü diş çeşitleri bulunmaktadır. Bunlar Maryland(kanatlı) köprü diş, asma köprü diş, geleneksel köprü diş çeşitleri bulunmaktadır. Maryland köprü; genelde ön dişlere tercih edilir. Bu köprüde amaç sağlıklı dişlerin kesilmesinin engellenmesidir ve arka dişlere bu işlem pek önerilmez. Komşu dişlere yapıştırılarak uygulanır ve yapay diş komşu dişlerin arkasından tutturulur. Daha sonra yapay diş yapışkan madde sürülerek sabit hale getirilir. Geleneksel köprü ise diş kaybı yaşanan bölgeye protez dişin kaplama ile oturtulması ile uygulanır. Bu köprünün yapımı oldukça basittir ve sorunlu dişin yanındaki dişe tutturulur. Burada amaç boşluklar doldurularak hasarlı dişin sabitlenmesidir. Görünüm olarak belli değildir bu sebeple estetik olarak oldukça başarılıdır. Asma köprü diş ise diş kaybı olan yerde bulunan sağlıklı dişlerden sadece bir tanesine protez dişin destekle sabitlenmesi uygulamasıdır. Eğer hasta protez diş kullanmak istemediği durumda bu köprü yapılmaktadır. Yanında bulunan diş kesilip, törpülenerek asma köprüye yer açılır. Daha sonra yapıştırılarak sabit konuma getirilir. Şekil 4 de örnek köprü verisi bulunmaktadır.



Şekil 4. Köprü Diş Röntgeni

Radyografik (panoramik) diş röntgenleri ile çürük diş tespit edilmektedir. Bu tedavi yöntemleriyle en uygun tedavi biçimi uzman tarafından önerilmelidir. Son yıllarda yapılan tez çalışmaları incelendiğinde derin öğrenme ile nesne tespiti yapılmıştır ve bulunan bu algoritmalar belli eğitimden geçirilerek en başarılı yöntem bulunmaya çalışılmıştır. Bu konuda yapılan literatür çalışmaları incelenmiştir.

Lee ve ark. (2018), yaptığı araştırmalarda diş çürüğünün tespiti için derin öğrenme modellerinden Convolutional Neural Network (CNN) yöntemi kullanılmıştır. CNN yöntemi, radyoloji alanında tanı ve tahminde başarılı olmuştur. Bu çalışmada 3000 adet periapikal radyografik görüntü kullanılmıştır. Bu görüntülerin %80'i eğitim, %20'lik kısmı ise test veri kümesi olarak iki kısma ayrılmıştır. Bu çalışmada Google, LeNet ve Inceptionv3 CNN ağları kullanılmıştır. Derin öğrenmede CNN tanısallık doğruluk, duyarlılık için ROC (Alıcı çalışma karakteristiği) ve AUC (eğrinin altında kalan) hesaplandı. Diğer derin öğrenme modellerine göre en başarılı olan AUC olmuştur ve bu yöntemde %95 başarı sağlanmıştır.

Singh ve Sehgal (2021), çalışmasında ise CNN kullanarak diş çürüklerinin GV(Genel Kavite) siyah sınıflandırılması yapılmıştır. GV siyah sınıflandırma modeline göre diş çürükleri altı çeşit sınıflandırmaya (Sınıf I- Sınıf VI) ayrılmıştır. Buradaki görüntülerin işlenmesi için LTP (Long Term Potentiation) modeli kullanılmıştır ve derin öğrenme mimarilerinden AlexNet, GoogleNet modelleri kullanılmıştır. CNN' de uygulanan bu modellerden AlexNet göre doğruluk oranı %93, duyarlılık oranı %90 ve özgüllük oranı %92 ile sınıflandırmıştır.

Hiremath ve ark.(2020), yaptıkları çalışmada ise periodantal bozulmuş dişlerin klinik tanısı için CNN yöntemi kullanılmıştır. Radyografik görüntülerle klinik değerlendirmesi yapılmıştır. Bu görüntüler konunun uzmanları tarafından teşhis edilmiştir. Teknolojinin gelişimi ile yapay zekanın gelişmesiyle var olan boşluk doldurulmuştur. CNN ve makine öğrenmesinin sağlık alanında kullanılması sonucunda tıp alanında ilerlemeler olmuştur. Konunun uzmanları bu konuda doğru teşhis uygulayarak bu alanda büyük ilerlemelere neden olmuştur.

Kheraif, Wahba and Fouad(2019) yaptıkları araştırmalarda radyografik 2D diş görüntülerinden diş hastalıklarının tespiti için veri madenciliği teknikleri uygulanmıştır. Radyografik 2D diş görüntüsünde diş bozukluklarının tespitinde kullanılmıştır. Ön işlemede bu görüntüler kontrast rengini genişletmek ve parlaklığı eşitlemek için histogram kullanıldıktan sonra dental görüntüleri bölgelere ayrılmıştır. Diş görüntüsünü işlemek için

ise derin öğrenme yöntemlerinden CNN uygulanmıştır. Uygulama sonunda ise %97.07 oranında başarı sağlanmıştır.

Akpolat ve Yalçın(2019), çalışmada ise pnömoni hastalığının tespiti için derin öğrenme yöntemleri uygulanmıştır. Pnömoni hastalığı; akciğerdeki hava keseciklerinin iltihaplı bir sıvı ile dolmasıdır. Bu hastalık dünyada en yaygın ve ölümle sonuçlanma oranı yüksektir. Bu sebeple erken tanı konulursa ölüm oranı da azalmış olur. Teşhis için göğüs röntgeninin çekilmesi gerekmektedir. Bu hastalıkların teşhis edilmesinde makine öğrenmesi yöntemlerine başvurulur. Bu veriler NIH klinik merkezinin röntgenlerinden elde edilmiş olup, python programlama dili kullanılmıştır. Derin öğrenme algoritmaları CNN ve VGG16 modellerinde çalışılmıştır ve bunun sonucunda başarı oranı yüksektir.

Tataroğlu ve ark. (2017) yaptıkları incelemede ise meme kanserinde CerbB2 tümör hücrelerinin sınıflandırması için derin öğrenme yöntemlerinden CNN kullanılmıştır ve meme kanseri dokusundan veri kümesi oluşturulmuştur. Derin öğrenme modelinin eğitmesi için doku örnekleri alınmıştır. Bu hücre parçalarına ilişkin CerbB2 tümörleri evrimsel sinir ağları (ESA) yardımıyla yüksek başarı sağlamıştır. Derin öğrenme sayesinde veriler üzerinde hastalıklı bölgeler otomatik olarak teşhis edilmektedir.

Olsen ve ark. (2009) yaptıkları çalışmada ise diş çürüğü tespitinde görüntü işleme kullanılmıştır. Dijital görüntüler kullanılarak diş hekimlerimize hem nicel hem de nitel geri bildirimde bulunarak uzmanlara geri bildirim sağlanmıştır. Teknolojinin ilerlemesi ile derin öğrenme yöntemleri ile hastalıkların teşhisinde konunun uzmanlarına fayda sağlanmıştır.

Suryani ve ark.(2021) yılında yaptıkları makalede ise diş röntgeni görüntülerinde nesne algılaması için derin öğrenme yöntemleri kullanılmıştır. Diş problemlerinin teşhisinde ve vaka tespitine göre doğru tedavi yöntemine karar vermek için radyolojik röntgenler önem verilmektedir. Bu röntgenler sayesinde diş hekimlerinin yanlış tanı konmasının önüne geçilebilir. Bunun için diş restorasyonu için derin öğrenme yöntemlerinden R-CNN kullanılarak nesne tespiti edilerek bir model geliştirilmiştir. Bu model sayesinde panoramik röntgenlerdeki nesneler otomatik olarak algılanarak zamandan tasarruf edilmesi beklenmektedir. Panoramik diş görüntülerinde nesne algılama sonuçları ise 0,91 ile 0,96 arasında güven değerini gösterir.

Gürses ve Oktay (2020) yılında yaptıkları çalışmada ise diş restorasyonlarının sınıflandırılması için GoogleNet, DenseNet ve ResNet olan evrimsel sinir ağı olan CNN kullanıldı. Buradaki implant, kanal tedavileri, dolgular ve diş telleri sınıflarına ayrılmıştır.

3013 tane panoramik diř röntgeninde alıřılmıştır. DenseNet başarı oranı %94 doğruluęa ulaşmıştır.

elik ve ark (2019) yayınladıkları alıřmada ise diř eksikliklerinin tespiti iin derin renme yntemi kullanılmıştır. Bu veriler 153 panoramik rntgenden oluşmakta olup bu grntler 971 X 474 piksel olarak yeniden boyutlandırılmıştır. Phyton programlama dili kullanılmıştır. OpenCV, numpy, pandas ve matplotlib ktphaneleri etkili bir řekilde kullanılarak bir dizilim oluşturulmuřtur. Bu veri seti Google Net Inception v3 CNN aęı ile eęitilmiştir. Veri setindeki grntler test ve eęitim olarak iki kısma ayrıldı. Eęitimde kullanılan grntlerdeki başarı oranı %94,7 iken, eęitimde kullanılmayan test grntlerindeki başarı oranı ise %75 olarak tespit edilmiştir.

Osmanoęlu ve ark. (2019), alıřmasında Matrix Laboratory (Matlab) programı ile grnt iřlemeyi saęlık alanında kullanılmasını deęerlendirilmektedir. Son yıllarda geliřen teknolojiyle birlikte tıp alanında grnt iřleme teknikleri de yaygın olarak kullanılmaktadır. Bu yntemler de uzmanlara zaman, maliyet, teřhis konusunda yarar saęlamaktadır. Bu alıřmada Eskiřehir Osmangazi niversitesi Tıp Fakltesi Gz Hastalıkları Anabilim Dalına bařvuran Orbita MR endikasyonu olan hastaların verileri alınmıştır. MR grntleri Codonics Clarity Viewer programı, Matlab ve Lenster cihazı kullanılarak n Kamera Derinlięi (KD), Lens Kalınlıęı (LK) ve Aksiyel Uzunluk (AU) hesaplamaları yapılarak karřılařtırmalar yapılmıştır. lm sonucunda ise Matlab programının lm ile uyum gsterdięi sonucuna ulařılmıştır. Tablo1 de diř rkleri ve tedavileri zerine literatr alıřmaları bulunduęu yıllara ait bilgiler belirtilmiştir.

Tablo 1. Diş Çürükleri ve Tedavileri Üzerine Yapılmış Bazı Çalışmalar

Yazar	Yıl	Yöntemler	Başarı Oranı
Lee ve ark.	2018	CNN, Google, LeNet, InceptionV3	%95
Çelik ve ark.	2019	GoogleNet, Inceptionv3, CNN	%94.7
Kheraif ve ark.	2019	CNN	%97
Hiremath ve ark.	2020	CNN	%96
Gürses ve ark.	2020	CNN, GoogleNet, DenseNet ResNet	%94
Singh ve ark.	2021	CNN, AlexNet, GoogleNet	%93
Suryani ve ark.	2021	R-CNN	%91


Tablo 1’de görüldüğü gibi derin öğrenmede, görüntü işleme yöntemlerinden CNN tekniği kullanılmıştır. Bu tabloda veri setlerinde kullanılan yöntemler ve başarı oranları gösterilmiştir. Yukarıdaki başarı oranları incelendiğinde %90 ve üzeri başarı oranı tespit edilmiştir.

Bu çalışmada derin öğrenme yöntemleri kullanılarak panoramik diş röntgenlerinde çürük dişin tespiti ve uygun tedavi yöntemleri hakkında bilgi vermek amacıyla yapılmıştır. Çürük dişe uygulanacak tedavi yöntemleri hakkında hızlı ve yüksek doğruluk oranı ile tespiti sağlanmaktadır.

İKİNCİ BÖLÜM

MATERYAL VE YÖNTEM

Bu tez çalışması 3 kısımdan oluşmaktadır. Şekil 5'te gösterildiği gibi, ilk kısımda veri setinin hazırlanması ile ilgili alt işlemler, ikinci kısımda ise derin öğrenme yöntemi kullanılarak evrişimsel sinir ağının oluşturulması ve verilerin etiketlenmesi son kısımda ise elde edilen eğitim ve test verilerinin eğitilmesi için transfer öğrenmesi yöntemi kullanılarak diğer sistemlerde kullanılmak üzere modelin eğitilmesi ve değerlendirilme aşamaları yer almaktadır. Şekil 5'te derin öğrenme sistem mimarisi hakkında bilgilendirme verilmiştir.




Şekil 5. Sistem Mimarisi

2.1 Kullanılan Veri Seti

Bu çalışmada Aksaray ili içerisinde bulunan 553 hastanın röntgeni (panoramik) dış verileri alınmıştır. Görüntü temininde kişinin özel hayatı ihlal edilmemiştir. Daha sonra uzman yardımı ile bu röntgenlerin sınıflandırılması yapılmıştır. 154 hastada dolgu tedavisi, 163

hastada kanal tedavisi ve 116 hastaya ise köprü tedavisi uygulanmıştır. Ayrıca 120 tane ise sağlıklı panoramik diş röntgeni bulunmaktadır.

Şekil 6’da diş röntgenlerinden örnekler gösterilmiştir ve a olarak isimlendirilen resimde dolgu, b olarak isimlendirilen resim kanal, c olarak isimlendirilende ise köprü tedavisi uygulanmıştır.



Şekil 6. Veri Setinde Bulunan Örnek Görüntüler

2.2 Yöntem


Bu çalışmada derin öğrenme yöntemleri kullanılarak panoramik röntgenlerde diş çürükleri tespit edilip, uygulanan tedavi yöntemlerinin sınıflandırılması ve doğruluğunu artırıcı yöntemler önerilmektedir. Sınıflandırma işlemi için transfer öğrenme yaklaşımları ile popüler CNN mimarisinden biri olan Faster R-CNN ve Yolov5 yöntemi kullanılarak veri seti eğitilmiştir.

2.2.1 Ön İşlemler

Diş röntgenleri üzerinde farklı ön işlem yöntemleri kullanılmaktadır. Bu işlemin yapılmasındaki amaç ise diş röntgenlerinin kalitesini artırmak ve eğitim sürecindeki optimizasyonunun sağlanmasıdır.

2.2.2 Görüntülerin Kırpılması

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. Şekil 7’de veri setinde bulunan görüntülerde kırılma işlemi uygulanmıştır.




Şekil 7. Diş Röntgenlerinde Görüntü Kırpılmasına Örnek

Veri setinde bazı görüntüleri eğitim öncesi 800x800 piksel olarak yeniden boyutlandırılmıştır. Bunun nedeni ise görüntüler farklı boyutlarda olduğundan ve bazı röntgenlerde dolgu, kanal ve köprü aynı diş röntgeninde bulunduğu için yapılmıştır. Kullanılan görüntüleri jpeg(.jpg) formatına çevrilmiştir. Daha sonra veri setini dolgu, köprü ve kanal olarak sınıflandırılmaktadır.

2.2.3 Renk Uzayları


Renkleri tanımlamak amacıyla kullanılan matematiksel modellerdir ve 3D olarak tasarlanabilir. Renk uzayları, doğrusal veya doğrusal olmayan yöntemlerle dönüşümler yapılmaktadır.

Renk uzayları genel olarak cihaz bağımlı ve cihaz bağımsız olarak 2 gruba ayrılmaktadır. Cihaz bağımlı renk uzayında, cihazın özellikleriyle ilişkilidir. Cihaz bağımsız renk uzayları ise CIE (Uluslararası Aydınlatma Komisyonu) tarafından geliştirilmiştir. Şekil 8’de yaygın olarak kullanılan renk uzayları görülmektedir.



Şekil 8. Renk Uzayları

Bilgisayarda herhangi bir rengin görüntülenmesinde RGB renkleri kullanılmaktadır. RGB (Kırmızı- Yeşil- Mavi) renklerinden oluşmaktadır ve renkler 0 ile 255 arasında değişen değerler almaktadır. Bilgisayar monitörü gibi görüntüleme cihazlarında ve tarayıcılarda kullanılmaktadır (Yılmaz,2007). Şekil 9’da görüldüğü gibi RGB ile oluşturulmuş bir görüntü $M \times N \times 3$ boyutlarında matris uygulanmaktadır. M ve N görüntünün boyutlarını üç numaralı boyut ise kırmızı, mavi ve yeşil rengin oranlarını ifade etmektedir (Gonzalez ve Woods,2004).



Şekil 9. RGB Renk Uzayı

CIE XYZ renk uzayı RGB renk özelliklerine bağlı olarak oluşturulmuştur. Y rengin parlaklığı olarak düşünülmektedir. Buna göre aşağıdaki formüller ile XYZ değerleri hesaplanmaktadır.

$$x = \frac{X}{X+Y+Z} \quad (2.1)$$

$$y = \frac{Y}{X+Y+Z} \quad (2.2)$$

$$z = 1 - x - y \quad (2.3)$$

CIE Luv renk uzayı 1960 yılında xy değişkenlerinin uv değişkenlerine dönüştürüldü. Burada L aydınlık düzeyini, u yeşilden kırmızıya değişimleri, v ise maviden mora doğru değişimleri temsil etmektedir.

2.2.4 Histogram Eşitleme

Görüntü işlemede sık kullanılan yöntem histogram eşitleme işlemidir. Görüntü üzerinde bulunan her pikselin yoğunluk seviyesinin frekans sayısı çıkarılır ve görüntünün kontrastının düzeltilmesi sağlanmaktadır (Jaehne,1991). Görüntü düşük yoğunluk aralığında bulunabilir. Çıkan değerler görüntü üzerinde yeni bir düzeye eşlenebilmektedir. Böylece yeni histogram yoğunluk düzeyinde tüm aralığı kapsar. Histogram eşitleme; görüntü yoğunluğunu ve kontrastı ayarlamayı sağlamaktadır (Gonzales, Woods ve Hall, 2008).




Şekil 10. Köprü Röntgeni Uygulanmış Görüntü

Şekil 10'da 2 tane röntgen bulunmaktadır. A' da histogram eşitleme uygulanmamış köprü görüntüsü, b'de ise histogram eşitleme uygulanmış köprü röntgeni görüntüsü vardır. Histogram eşitleme uygulaması sonucunda uniform dağılımda olmasını yani her bir parlaklık seviyesi için aynı sayıda piksel bulunması gerekmektedir.

Adaptif Histogram Eşitleme

Histogram eşitleme işlemi, görüntünün yoğunluğunu ayarlamak için kullanılan görüntü işleme yöntemidir. Bu teknik ile görüntü üzerinde kontrast iyileştirmesi yapılmaktadır. Diş röntgenleri veri setinde dolgu, kanal ve köprü tespitleri için ağız üzerinde belirsiz görüntüler bulunmaktadır. Bu kısımlarda kontrast seviyesinin artması sınıflandırma açısından önem arz etmektedir.



Şekil 11. Histogram Eşitleme ile Kontrast Seviyesinin Düzenlenmesi

Şekil 11’de a’daki resme histogram uygulanmamış dolgu röntgeni, b ise bu görüntünün histogram grafiğini, c ise aynı resme histogram uygulanmış dolgu röntgeni, d ise onun histogram grafiğidir. 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. Adaptif histogram eşitlemede kumlanma problemlerini kontrast seviyesine limit getirilerek önlemek mümkündür. Bu yüzden bu çalışmada kontrast limitli adaptif histogram (CLAHE) kullanılmıştır. Piksel yoğunluğunu yeniden düzenleme ve gürültü azaltılması amacıyla CLAHE tekniği tıbbi görüntülerde kullanılmaktadır (Li, Wenjun ve Doayin, 1994).

2.2.5 Veri Etiketleme

Nesne tanımlamak için hazırladığımız verileri, danışmanlı öğrenme yöntemi ile yapay sinir ağında kullanmak amacıyla etiketlememiz gerekmektedir. Verileri etiketlemek için kullanılan bazı etiketleme programları bulunmaktadır. Bunlar Labellmg, Make Sense, Label Tool gibi programlar kullanılmaktadır. Öncelikle data setimizi etiketlerken python programlama dili ve tensorflow kütüphanesi kullanılarak yapılan Labellmg kullanılmıştır. Labellmg açık kaynaklı görüntü etiketleme aracıdır (Lin,2018). Bu program ile görüntülerde


istediğimiz bir veya birden çok alanın etiketlenmesi sağlanmaktadır. Etiketleme işlemi ise Anaconda Prompt programı üzerinden gerçekleştirilmiştir.

Öncelikle Labellmg programını indirilmiştir. Daha sonra etiketlemek istediğimiz görüntüleri programın içerisine aktarılması gerekmektedir. Şekil 12 de labellmg veri etiketleme programı görüntüsü bulunmaktadır. Programın sol üst kısmında bulunan **“Open Dir”** butonunu seçerek görüntülerin bulunduğu klasörü seçilmesi gerekmektedir. Daha sonra **“Change Save Dir”** butonu seçilerek etiketlenen her resim için xml dosyalarını kaydedeceği klasör adresi istenmektedir. Oluşturulan bu xml dosyaları sayesinde görüntüler sınıflandırılmaktadır.



Şekil 12. Labellmg Veri Etiketleme Programı

Şimdi ise Şekil 12 de bulunan dişin içinde bulunduğu koordinatlar gerekmektedir. Bu koordinatları **“Create Rect Box”** seçilerek dolgu olan kısım dikdörtgen içerisine alınması gerekmektedir. Bu seçim yapıldıktan sonra isim verilmelidir. Fakat isim verilirken Türkçe karakter kullanılmaması gerekmektedir. Daha sonra save butonuna basılarak etiketleme işlemi uygulanmış olmaktadır. Bu işlem yapıldıktan sonra Şekil 13 görüldüğü gibi labellmg programı sayesinde resimle aynı ada sahip bir xml dosyası oluşturulmuştur. Eğer istersek aynı resim üzerinde birden fazla etiket türü yapılabilir.



Şekil 13. Labellmg ile Etiketlenen Görüntü Verileri Kümesi

2.2.6 Veri Setinin Normalize Edilmesi

Labellmg programıyla etiketlenen görüntülerin uzunluk(dH), genişliği(dW), etiketlemiş olduğumuz nesnenin adı, görüntünün tam olarak konumunu veren X_0, Y_0, X_1, Y_1 ve görüntü üzerinde kaç adet veri olduğu kısım text dosyası içerisine kaydedilmektedir. Tüm görüntüler kullanılarak etiketli bir veri seti oluşturulmuştur. Bu veri seti YOLOv5 mimarisine uygun hale getirmek için normalizasyon işlemi yapılmaktadır ve X_0, Y_0, X_1, Y_1 koordinatları 0 ile 1 aralığına dönüştürülmektedir (Aktaş, Doğan, Demir, 2020:s;1690).

$$X = \left(\frac{X_1 + X_0}{2} \right) * \frac{1}{dW} \text{ ((Etiketli verinin orta noktasına ait X koordinatı)} \quad (2.4.)$$

$$Y = \left(\frac{Y_1 + Y_0}{2} \right) * \frac{1}{dH} \text{ (Etiketli verinin orta noktasına ait Y koordinatı)} \quad (2.5.)$$

$$W = (X_1 - X_0) * \frac{1}{dW} \text{ (Etiketli verinin genişliği)} \quad (2.6.)$$

$$H = (Y_1 - Y_0) * \frac{1}{dH} \text{ (Etiketli verinin yüksekliği)} \quad (2.7.)$$

2.2.7 Test ve Eğitim Sınıflarının Belirlenmesi

Yukarıda bulunan denkleme göre hesaplanan yeni koordinatların yükseklik ve genişlik, değerleri (X, Y, W, H) aynı isimle oluşturulan text dosyalarına kaydedilmektedir. Daha sonra veri seti rastgele %30 test kümesi ve %70 eğitim kümesi olarak iki kısma ayrılmaktadır. En son ise xml dosyaları kullanılarak csv dosyasını oluşturulup etiketleme kısmı tamamlanmış olmaktadır.

2.3 Makine Öğrenmesi

İnsanlarda zekâ ile ilgili zihinsel fonksiyonları bilgisayar uygulamaları yardımıyla inceleyip formül haline getirmek için yapay zekâ uygulanmaktadır. Makine öğrenmesi ise yapay zekanın alt dalıdır. Yapay zekalar makine öğrenmesi ile başlar. Makine öğrenmesi ise tespit edilen problemi, probleme ait ortamdan edinilen veriye göre modelleyen bilgisayar algoritmalarının genel adıdır (Durgun, 2018: s;21).

Büyük miktardaki verilerin analizi zor olmaktadır. Bu sorunu çözmek amacıyla makine öğrenmesi yöntemleri geliştirilmiştir. Makine öğrenmesi çok farklı alanlarda kullanılmaktadır. Bunlar; doğal dil işleme, nesne tanıma, bilgisayar oyunları, arama motorları, tıbbi teşhiste, müşteri ilişkileri yönetiminde, insan kaynakları gibi alanlarda uygulanmaktadır. Makine öğrenmesi için birçok yaklaşım mevcuttur. Bu yaklaşımların bir kısmı tahmin, kestirim bir kısmı da sınıflandırma yeteneğine sahiptir.

Tahmin (Prediction): Makine öğrenmesinde sistem sonucunun nicel olması durumunda kullanılmaktadır.

Sınıflandırma (Classification): Makine öğrenmesinde giriş verisine ait çıkışların nitel olduğu durumlarda kullanılmaktadır. Bu yöntemlerin her veri örneğine göre hangi sınıfa ait olduğu tespit edilmektedir.



Şekil 14. Yapay Zekâ ve Alt Alanları

Makine öğrenmesi kendi içerisinde 3 kısma ayrılır: Bunlar; Danışmanlı Öğrenme, Danışmansız Öğrenme ve Yarı Danışmanlı Öğrenme olarak bilinmektedir. Danışmanlı öğrenmede amaç girdi değerleri ile hedef değerleri arasındaki bağlantı kurularak tahmin yapılması sağlanır. Bu öğrenme ile sınıflama ve regresyon yapılabilir. Danışmansız öğrenme ise yalnız girdi değerleri vardır. Bu öğrenmenin amacı ise girdi değerleri arasındaki yakınlıkları ve düzenlilikleri bulmaktır. Yarı danışmanlı öğrenme ile kümeleme ve kestirim yapabilirsiniz. Pekiştirmeli öğrenmede ise burada ceza ve ödül sistemi vardır. Buradaki amaç doğru yolun minimum hatada bulunmasıdır.

2.4 Derin Öğrenme

Derin öğrenme makine öğrenmesi sınıfıdır. Burada özellik çıkarma ve dönüştürme yapmak amacıyla birçok işlem birimi katmanı uygulanmaktadır. Her katman önceki katmandaki çıktıyı girdi olarak almaktadır. Nesne tespiti ve tanınması derin öğrenme yöntemleri kullanılarak da yapılmaktadır. Bu derin öğrenme çalışmaları Şekil 15'te nesne tespiti ve aşamaları 4 ana başlıkta uygulanmıştır. Bunlar; veri girişi ve ön işleme, öznelik çıkarımı ve nesnenin tanımlanmasını (etiketlenmesi) aşamalarını kapsamaktadır.




Şekil 15. Nesne Tespiti ve Nesne Tanınması Aşamaları

Veri girişinde, nesne tespiti için verilerin doğal görüntü şekline uygun olmalıdır. Görüntüler belirli bir formata dönüştürülmelidir. Bu görüntüler insan, otomobil, fotoğraf makinasıyla çekilmiş fotoğraflar olabileceği gibi videolarda da nesne tespit çalışmaları yapılabilmektedir.

Ön işlemede ise veriler işlemin amacına uygun hale getirilmesi gerekmektedir. Örneğin gülen insanları tespit ederek etiketlemek istediğimizi düşünelim. Burada verileri test ve eğitim olarak iki kısma ayırdık. Ancak test için ayırdığımız verilerin bazısının piksel bozuklukları, parlamalar yaşanabilmektedir. Böyle bir durumda eğitim iyi bir sonuç vermeyebilir. Bu durumda bu veriler çıkartılarak daha sağlıklı verilere ulaşılabilir. Bu sebeple veri ön işlemede regresyon, eşitleme, kümeleme, filtreme vb. gibi birçok yöntem kullanılabilir.

Öznitelik çıkarımında ise ön işleme olan görüntü üzerinde önceden belirlenmiş olan nesnenin elde edilmesidir. Verilerdeki tüm öğeler matematiksel olarak tanımlandıktan sonra bu görüntülerde nesnenin var olup olmadığı tespit edilmektedir. Öznitelik çıkarımında SIFT (Scale Invariant Feature Transform), Haar Cascades, HOG (Histogram of Oriented Gradients), LabelImg gibi yöntemler kullanılmaktadır.

Tanımlamada ise tespit edilen görüntü üzerinde ne olduğunun anlaması sağlanmaktadır. Bu kısımda sınıflandırma ve kümeleme olarak iki kısım yer almaktadır. Sınıflandırmada önceden sınıflandırılan bir veriye dahil edilmektedir. Kümeleme ise benzer verileri aynı özellik gösterenler bir grupta toplanmıştır. Şekil 16’ da kümeleme ve sınıflandırma grafikleri gösterilmektedir.



Şekil 16. Kümeleme ve Sınıflandırma

Nesne bulma ve tespiti için son yıllarda yapılan çalışmalarda Naive Bayes, CNN, R-CNN, SVM (Destek Vektör Makinaları), K en yakın komşu modeli ve Yapay Sinir Ağları modelleri yaygın olarak kullanılmaktadır.


Derin Öğrenme Mimarileri

Bu bölümde derin öğrenme mimarilerinden en sık kullanılan 4 farklı mimari yapıdan bahsedilmiştir. Bu mimari yapılar hakkında açıklamalar aşağıda verilmiştir.

2.4.1 CNN (Convolutional Neural Network)

İlk konvolüsyonel sinir ağı 1988 yılında Yann Le Cun tarafından ortaya konulmaktadır. 1998 yılına kadar iyileştirmeleri yapılan LeNet isimli mimaridir (LeCun vd., 1989). Çok katmanlı bu konvolüsyonel sinir ağı birden fazla katmanı içermektedir. Derin öğrenme ağları içerisinde en çok kullanılan konvolüsyonel sinir ağlarıdır. Bu ağlar daha çok sınıflandırma ve tespit işlemlerinde kullanılmaktadır (LeCun vd., 2015). CNN görüntü işlemede kullanılan derin öğrenme algoritmasıdır. Resimlerdeki özellikleri yakalar ve onları sınıflandırmaya

yarayan katmanlara ayırır. CNN mimarisi, giriş, konvolüzyon, havuzlama(pooling), tam bağlantılı katman ve sınıflandırma katmanından oluşmaktadır. Şekil 17’de konvolüsyonel sinir ağı mimarisi gösterilmiştir.




Şekil 17. CNN Mimarisi

CNN Katmanları

Giriş (Input) Katmanı: Bu katmanda veri ham olarak alınır ve bu verinin boyutu ağ derinliği göz önüne alınarak yapılmaktadır. Giriş katmanında ağın eğitimi için alınan veriler birleştirilerek veri seti oluşturulur ve veri setinin boyutu ağın hızını, test süresini ve bellek ihtiyacını artırmaktadır (Inik ve Ülker,2017).


Konvolüsyon (Convolution) Katmanı: Evrişim katmanında ise resmin özellikleri algılanmaktadır. Bu katmanda görüntülerdeki özellikleri ortaya çıkartmak için bazı filtreler uygulanmıştır. Filtreler sayesinde bu veriler üzerinde bazı özellikler yakalamaya çalışılmaktadır. Filtreler 3 x 3, 5 x 5 gibi farklı boyutlarda da olabilmektedir. Evrişim işlemi sonucunda aktivasyon haritası oluşmaktadır. Bu harita her bir filtreyle ilgili öznitelikleri ortaya çıkarmaktadır. Aşağıdaki Şekil 18 de gösterildiği gibi 3x3 filtreleme yapılarak 5x5’lik görselde gezdiriliyor.



Şekil 18. RGB girdi görüntüsüne Evrişim İşleminin Uygulanması


Evrişim işlemi sonrasında 3 x 3 aktivasyon haritası elde edilmektedir. Aktivasyon haritası ise her bir filtreye özel özelliklerin keşfedildiği bölgeler olup, eğitim esnasında filtrelerin katsayıları veri kümesindeki öğrenme tekrarında değişmektedir. Aktivasyon haritasındaki değerler giriş ve çıkış boyutu arasında normalize edilmektedir. Bu normalize çalışmasında her bir renk için çıkan değerler filtre katsayılarının toplamına bölünmektedir. Aktivasyon haritasının oluşumundan sonra bazı filtreler uygulanmıştır. Konvolüsyon işlemi yapay sinir ağlarının önemli parçasıdır. Bu sebeple bu katmanda yapılan filtreleme sayesinde ağ daha başarılı bir şekilde yansıtılmaktadır. Tercih edilecek bu filtre ağın başarısını ve eğitim sürecini doğrudan etkilemektedir (Pang v.d,2017).

Aktivasyon (ReLU) Katmanı: Konvolüsyon katmanından sonra Relu katmanı gelmektedir. Bu katmanda ağ doğrusal bir yapıda olduğu için sigmoid ve ReLu gibi doğrusal olmayan aktivasyon yöntemleri kullanılarak ağ doğrusal olmayan yapıya dönüştürülür. Şekil 19 da ReLu aktivasyon fonksiyonu gösterilmiştir. ReLu katmanına düzleştirilmiş doğrusal birim katmanı da denmektedir. Bu kısımda giriş verisine yapmış olduğu etkiden dolayı negatif değerleri sıfıra çekilmesi sağlanır.



Şekil 19. ReLu Aktivasyon Fonksiyonu


Havuzlama (Pooling) Katmanı: Konvolüsyonel katmandan elde edilen matrisin yükseklik ve genişliği azaltılarak karmaşıklığın önüne geçmek için havuzlama (pooling) katmanı kullanılmaktadır (Hinton, Srivastava, Krizhevsky, Sutskever ve Salakhutdinov, 2012). Bu katmanda görüntünün yükseklik ve genişlik boyutunun azaltılması amaçlanmaktadır. Bunun sonucunda görüntüde yakalanan gereksiz özellikler yok sayılarak, önemli özelliklere odaklanılmaktadır. Bu katmanda uygun bir filtre kullanılarak işlem yapılmaktadır. $N \times N$ boyutlu filtre veri havuzunda gezdirilerek uygun değer bulunması sağlanmaktadır. Bu değerlerin bulunması için iki çeşit havuzlama tekniği kullanılmaktadır. Bunlar maksimum havuzlama ve ortalama havuzlama yöntemleridir. Havuzlama işleminde evrişim katmanındaki gibi filtreler görüntü üzerinde gezdirilerek görüntü üzerinde maksimum veya ortalama değerler bulunur. Şekil 20 de havuzlama katmanı bulunmaktadır.



Şekil 20. Maksimum Havuzlama

Tam Bağlı (Fully- Connected) Katman: Tam bağlantılı katman kendinden önceki tüm katmanın alanlarına bağlıdır ve katman sayısı ağıın mimarisine göre değişebilmektedir. Bir

önceki katmanın çıkış boyutu ile tam bağlantılı katmanın nöron sayısı çarpılarak ağırlık matrisi oluşmaktadır. Çıktılar 0 ile 1 arasındadır. 1'e yakın olan nesne ağın tespit ettiği nesnedir. Havuzlama katmanına bağlı olan nesnelerin sınıflandırılması bu katmanda yapılmaktadır (Doğan ve Türkoğlu, 2018). Şekil 21 de tam bağlı katman gösterilmiştir.




Şekil 21. Tam bağlı katman

Evrişimsel sinir ağı algoritmalarında yüz tanıma, görüntü sınıflandırma ve nesne tespiti gibi alanlarda kullanılmaktadır. Ancak bu algoritmanın bazı dezavantajları da bulunmaktadır. En büyük dezavantajı ise bir görselde aynı anda yalnız tek obje tespit edilebilmektedir. Bu sebeple içinde birden fazla sınıfta obje bulunan görselde CNN algoritması doğru bir tercih olmamaktadır. Uzmanlar bu sorunu çözebilmek için daha da derin nesne algoritmaları geliştirmişlerdir.

2.4.2 Region Based CNN (R-CNN)

R-CNN algoritması, görüntülerde bulunan objelere ait sınıfları ve sınırlayıcı kutuları tespit etmek amacıyla kullanılmaktadır. Bu algoritma çoklu objeye sahip olan görseller için kullanılmaktadır. Şekil 22 de R-CNN mimarisi gösterilmiştir. R-CNN 'de iki kısımdan oluşmaktadır.



Şekil 22. R-CNN Mimarisi


İlk kısımda seçici arama (Selective Search) yapılmaktadır ve görsellerde yakalanması gereken bölgeler belirlemek amacıyla kullanılmaktadır. Burada ufak bölgeler tespit edilir. Daha sonra ise birbirine benzeyen başka kısımlar bulunarak bu bölgeler birleştirilir, daha büyük bölgelere ulaşılır. Görselde bulunan veriler kümelenir.

İkinci kısımda ise bulunan bölgelerin her biri farklı CNN ağlarına girdi olarak girmektedir. CNN ağlarından çıkan öznitelikler ise Destek Vektör Makineleri (SVM) yardımıyla objenin sınıfı ve sınırlayıcı kutuları (bounding box) belirlenmektedir. Bu algoritmada 2000 farklı bölge ve bu bölgeler için her biri farklı 2000 adet farklı CNN ağı kullanılmaktadır. Bu sebeple biraz maliyetlidir.

2.4.3 Fast R-CNN

Fast R-CNN’de tek bir model kullanılmaktadır. Bu algoritmada evrimsel sinir ağı, destek vektör makinelerini ve regressor birleştirmiştir. Bunun sonucunda ise başarılı bir performans üstünlüğü elde edilmiştir.

Bu algoritmada tüm görsel CNN ile işlenerek bu verilerin öznitelik haritaları çıkarılmaktadır. Daha sonra her bölge için gerekli öznitelikler toplanarak, maksimum havuzlama (max pooling) ile görüntüler belirli boyutlara getirilmektedir. Bu havuzlama katmanına ise rol pooling layer denilmektedir. Şekil 23’te Fast R-CNN mimarisi gösterilmiştir.




Şekil 23. Fast R-CNN Mimarisi

Öznitelik haritaları tek boyutlu vektör halinde indirgenerek sinir ağı işlemine sokulmaktadır. Görüntüye ait sınıf sınıflayıcı kutu sayesinde belirlenmektedir.

2.5 Transfer Öğrenmesi (Öğrenme Aktarımı)

Transfer öğrenmesi için bir problem belirlenmesi gerekir. Bu problemi derin öğrenme modelleri kullanarak 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 gerekmektedir. Son olarak bilginin aktarılmasında hangi derin öğrenme yöntemleri kullanılmalı bunun belirlenmesi gerekmektedir. Mesela; Kedi-köpek sınıflandırmasını yapan bir model eğitilirken, kazanılan bilgi ağı insan-hayvan sınıflandırması içinde kullanılabilir (Samtaş ve Gülesin, 2011). Şekil 24’te gösterildiği gibi, transfer öğrenme mimarisi ile daha önce eğitilmiş olan derin öğrenme modelinin ağırlıklarını, farklı veri setleri üzerinde uygulanması amaçlanmaktadır. Bunu yaparken de zaman ve donanım tasarrufu elde edilmektedir. Transfer öğrenmesi ile yüksek başarı elde edilmesi sağlanmaktadır.




Şekil 24. Transfer Öğrenme Mimarisi

2.6 Kullanılan Yöntemler

Etiketlediğimiz verilerden transfer öğrenmesi yöntemi kullanılarak Faster RCNN ve Yolov5 modeli kullanılarak nesneyi tespit etmek amaçlanmıştır.

2.6.1 Faster R-CNN

Şekil 25’te gösterildiği gibi, Faster R- CNN modelinde bölgeleri oluştururken RPN (Region Proposal Network) algoritması kullanılmaktadır. RPN bölge önermeye yarayan evrimsel sinir ağıdır. Bu sebeple girdi olarak herhangi bir görüntüyü alır ve obje skoruna göre nesnelere ait dikdörtgen teklifi ortaya çıkarmaktadır.




Şekil 25. Faster R-CNN Mimarisi

Bu algoritma tarafından üretilen hesaplamalar Fast R-CNN mimarisine sokularak objenin sınıfı ve bounding box'u tahmin edilmektedir.

2.6.2 YOLOv5

Yolo evrimsel sinir ağları kullanılarak nesne tespiti yapabilen 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 26. 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 26’da gösterildiği gibi, Yolov5 modeli için oluşturulan ağırlık dosyaları diğer Yolo modellerine göre oldukça küçük boyuttadır. Bu sebeple gömülü cihazlara daha kolay uygulanabilmektedir.


2.7 Çalışmada Kullanılan Hiper Parametreler

Derin öğrenme mimarisine göre araştırmacı tarafından modellenen, veri setlerine göre değişiklik gösteren ve model üzerinde yüksek başarı elde etmek için tasarlanan parametrelere hiper parametre denir. Model eğitiminin başarısı için bazı hiper parametreler kullanılır. Bu hiper parametreler derin öğrenme çalışmaları için önem arz etmektedir (Huang, Hao ve Chang, 2016). Diş çürüklerini ve uygulanan tedavi yöntemlerinin tespiti için bu çalışmada uygulanan hiper parametreler şunlardır:

- *Epoch Sayısı*: Epoch(döngü) sayısı makine eğitimi esnasında tüm eğitim verilerinin ağı gösterilme sayısıdır. Eğitimin doğruluğunu arttığı zaman validation azalmaya başlayana kadar epoch sayısının artırılması gerekir. Doğruluğun en yüksek olduğu yerde epoch sayınız ideal olmaktadır.
- *Yineleme (Iteration)*: Yineleme makine öğreniminde kullanılmaktadır ve algoritmanın parametrelerini kaç kez güncellendiğini göstermektedir. Bir görüntü üzerinde yineleme yapmak için her piksel değerine uygulanmaktadır.
- *Rmse (Kök Ortalama Kare Hata)*: Kök ortalama hata tahminleyicinin tahmin ettiği değer ve gerçek değeri arasındaki uzaklığın bulunmasında kullanılan hatanın büyüklüğünü ölçmektedir. Ayrıca tahmin edilen sorunların standart sapmasıdır ve regresyon hattının veri noktalarından ne kadar uzakta olduğunun bir ölçüsüdür. Kök ortalama hata 0’dan ∞ ’a kadar değer alabilmektedir. Negatif yönelimli puanlar daha iyi performans göstermektedir. Kök ortalama hatasının sıfır olması modelin hiç hata yapmadığı anlamına gelmektedir (2.8).


$$RMSE = \sqrt{\frac{\sum_{j=1}^n e_j^2}{n}}$$
$$RMSE = \sqrt{MSE} \quad (2.8)$$

- **Loss Function ve Optimizer:** Makine öğrenmesinde sistem yaptığı tahminler için hata kontrolü yapmaktadır. Bu sebeple hatayı hesaplayıp (loss funtion) beklenen sonuca göre optimizer kullanılır ve hata oranı minimuma, indirilmeye çalışılmaktadır. Şekil 27’de hata hesaplama grafiği gösterilmektedir. Bu öğrenmede amaç en düşük hata alınacak ihtimallerin bulunması sağlanmaktadır.



Şekil 27. Loss Function

- **Öğrenme Hızı (Base Learning Rate):** Derin öğrenme parametrelerinin güncellenmesinde geriye yayılım işlemi yapılmaktadır. Bu işlemde bu güncelleme ‘chain rule’ olarak geriye doğru türev alınarak farkın bulunması ve bulunan bu değer learning rate parametresi ile çarpılması sonucunda yeni ağırlık değerinin hesaplanması yapılmaktadır. Şekil 28’de öğrenme hızı grafiği örneği bulunmaktadır. Bu işlem sırasında kullanılan learning rate parametresi sabit değer olarak belirlenebilmektedir. Öğrenme hızı değeri genelde 0.01 kullanılmakta olup belli bir döngüden sonra 0.001 oranına düşürülmektedir.



Şekil 28. Öğrenme Hızı

2.8 Değerlendirme Kriterleri

Bu çalışmada panoramik diş röntgenlerinde bulunan dolgu, köprü, kanal sınıflarını teşhis etmek için modelin performansını değerlendirmek gerekmektedir. Bunu yapmak için bazı algoritmalar kullanılmaktadır. Bunlar; “doğruluk, hassasiyet, özgüllük, geri çağırma ve hata oranı metrikleri kullanılmıştır. Karşıtlık matrisi sınıflandırma tabanlı kurulan modellerde kullanılmaktadır. Bununla birlikte hata oranları ilgili bilgi verilebilmektedir (Goutte ve Gaussier, 2005).

Tablo 2. Karşıtlık Matrisi

GERÇEK		Tahmin Edilen	
		Pozitif	Negatif
	Pozitif	Gerçek Pozitif (TP)	Yanlış Negatif (FN)
	Negatif	Yanlış Pozitif (FP)	Gerçek Negatif (TN)

Tablo 2’ de karşıtlık matrisi verilmektedir. En az ikili sınıflandırmalarda bu matris kullanılmaktadır. Bu matriste gerçek pozitif (TP), gerçek negatif (TN), yanlış negatif (FN) ve yanlış pozitif (FP) bulunmaktadır.

Gerçek Pozitif (TP): Giriş görüntüsünde Dolgu tanısı olan verilerin çıktı sonucunun Dolgu olarak tahmin edilmesidir.

Gerçek Negatif (TN): Giriş görüntüsünde normal tanısı olan verilerin çıktı sonucunu normal olarak tahmin edilmesidir.

Yanlış Pozitif (FP): Giriş görüntüsünde normal tanısı olan verilerin çıktı sonucu dolgu, kanal, köprü olarak tahmin etmesidir.

Yanlış Negatif (FN): Giriş görüntüsünde dolgu, kanal, köprü olan verilerin çıktı sonucunu normal olarak tahmin etmesidir.

Doğruluk (Accuracy): Doğruluk; eğitim ve test olarak ayırdığımız verilerin, test verilerinin eğitime tabi tutulması sonucunda ulaşılan doğru tahminler ile oranlamasıdır (2.9).

$$\text{Doğruluk} = \frac{TP+TN}{TP+TN+FP+FN} \quad (2.9)$$

Hassasiyet (Precision): Veri setinin tüm sınıflarında doğru olarak tahmin ettiğimizi bildirilmektedir. Bulunan değerin yüksek olması, doğru tahminlerin ne kadar yüksek

olmasıyla ilişkilidir. %100 değerine ne kadar yakınsa doğru sınıflandırmaya o kadar yakındır (2.10).

$$Hassasiyet = \frac{TP}{TP + FP} \quad (2.10)$$

Geri Çağırma (Recall): Algoritma sonucunda elde edilen tüm doğru sınıflandırmaların ne kadar doğru tahmin edildiğinin bilgisidir (2.11).

$$Geri \text{ Çağırma} = \frac{TP}{TP + FN} \quad (2.11)$$

Özgüllük (Belirginlik): Veri setinde başarısız bulamadığı verileri sınıflandırmasını ölçmektedir. Bu sebeple doğru negatif değerinin doğru negatif ve yanlış negatif toplamına bölümünden sonra oluşan orandır (2.12).

$$\text{Özgüllük} = \frac{TN}{TN + FP} \times 100 \quad (2.12)$$


Hata Oranı (Error Rate): Doğruluk sonuçlarının %100 başarı oranından düşülmesi ile elde edilen sonuçlardır (2.13).

$$Hata \text{ Oranı} = 1 - \text{Doğruluk} \quad (2.13)$$

ÜÇÜNCÜ BÖLÜM


BULGULAR VE TARTIŞMA

Derin öğrenme mimarileri ve modelleri üzerinden veri setinde yer alan büyük boyutta bulunan resimler için güçlü donanımsal makinelere ihtiyaç vardır. Bu çalışmada Faster RCNN ve Yolov5 ağının eğitimleri Intel Core i5 işlemcili, 8GB RAM ve NVIDIA Geforce GTX 5200U GPU'ya sahip laptop üzerinden eğitim gerçekleştirilmiştir. Yapılan deneysel çalışmaların uygulama aşamaları Şekil 29'da gösterilmiştir.



Şekil 29. Uygulama Aşamaları

Şekil 29'da görüldüğü gibi derin öğrenme mimarilerinin eğitimi için röntgenler belirlendikten sonra etiketleme işlemi uygulanması yapılmaktadır. Öncelikle bulunan röntgenler import edilerek image labeler programıyla etiketleme yapılmıştır. Daha sonra 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 30'da image labeler veri etiketleme aracı gösterilmiştir.



Şekil 30. Image Labeler veri etiketleme

Şekil 28’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 $N \times N$ 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 ve 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.

3.1 Model Tasarımları

Bu çalışmada diş röntgenlerinde uygulanan dolgu, kanal ve köprü tedavilerini tespit etmek amacıyla Matlab R20221b programı kullanılmış ve derin öğrenme yöntemlerinden Faster R-CNN ve Yolov5 modelleri kullanılmış ve performansları paylaşılmıştır. Bu çalışmada 553 adet diş röntgeninden oluşan veri seti kullanılmaktadır. 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 3’te belirtilmiştir.

Tablo 3. Sınıf Düzeylerinde Giriş Etiketleri

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

Tablo 3’te 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 işlemini yaparken Türkçe karakter kullanmamaya dikkat edilmektedir.

3.1.1 Dolgu için Gerçekleştirilen Deneyler

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 diş röntgenleri üzerinde ilgili bölgelerin (dolgu, kanal, köprü) belirgin hale getirilmesidir. Derin öğrenme modellerinin doğru şekilde nesne tespitini gerçekleştirilmesi için bazı hiper parametre (başlangıç öğrenme oranı, resmin boyutları, batch boyutu ve epoch) değerleri kullanılmaktadır. Dolgu eğitimi için Faster R-CNN ve Yolov5 modeli ile eğitimler gerçekleştirilirken Tablo 4’te kullanılan parametre değerleri gösterilmektedir.

Tablo 4. 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
Shuffle (Karıştır)	Every-epoch (Her tekrarda)
Verbose Frequency	10

Tablo 4’te 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 dolgu bölgelerinin tespiti için Faster R-CNN modelinin dış röntgenlerine uygulanması sonucu elde edilen karşıtlık matrisi Tablo 5’te verilmektedir.

Tablo 5. Faster R-CNN ile Dolgu Görüntülerinde Karşıtlık Matrisi

GERÇEK		Tahmin Edilen	
		Dolgu	Sağlıklı
	Dolgu	39	8
	Sağlıklı	3	33

Tablo 5 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. Yolov5 modelinin dış röntgenlerine uygulanması sonucu elde edilen karşıtlık matrisi Tablo 6’da verilmektedir.

Tablo 6. YOLOv5 Modeli ile Dolgu Görüntülerinde Karşıtlık Matrisi


GERÇEK		Tahmin Edilen	
		Dolgu	Sağlıklı
	Dolgu	42	5
	Sağlıklı	1	35

Tablo 6 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 7’de Faster R-CNN ve Yolov5 derin öğrenme modellerin uygulanması sonucu oluşan duyarlılık, özgüllük, doğruluk ve eğitim süreleri verilmektedir.

Tablo 7. 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 7’de 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 31’de gösterilmektedir.



Şekil 31. YOLOv5 modelinin uygulanması sonucu oluşan örnek görüntüler

Şekil 31’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. Yanlış olarak tespit edilen veya tespit edilemeyen dolgu bölgeleri incelendiğinde diş röntgenlerinin standartlara uygun bir şekilde çekilmemesi ve hastanın sabit durmaması gibi nedenlerden kaynaklandığı düşünülmektedir.

3.1.2 Kanal için Gerçekleştirilen Deneyler Çalışmalar

Kanal verileri için yapılan deneysel çalışmalarda 163 adet röntgen kullanılmıştır. Bu görüntülerin 114 tanesi eğitim, 49 tanesi ise test görüntüsüne ayrılmıştır. Dış röntgen görüntüleri üzerinde öznitelik çıkarım işlemi öncesinde, görüntüleri ayırt etmek için RGB olan görüntülere Luv renk uzayı dönüşümü uygulanmıştır. Daha sonra dış 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 şekilde nesne tespitini gerçekleştirebilmesi için bazı hiper parametre (başlangıç öğrenme oranı, resmin boyutları, batch boyutu ve epoch) değerleri kullanılmaktadır. Kanal eğitimi için Faster R-CNN ve YOLOv5 modeli ile eğitimler gerçekleştirilirken Tablo 8’de modellerde kullanılan parametre değerleri gösterilmektedir.

Tablo 8. 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
Shuffle (Karıştır)	Every-epoch (Her tekrarda)
Verbose Frequency	10

Tablo 8’de 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 modelinin dış röntgenlerine uygulanması sonucu elde edilen karşıtlık matrisi Tablo 9’da verilmektedir.

Tablo 9. Faster R-CNN ile Kanal Görüntülerinde Karşıtlık Matrisi

GERÇEK		Tahmin Edilen	
		Kanal	Sağlıklı
	Kanal	41	8
	Sağlıklı	4	32

Tablo 9 incelendiğinde, Faster R-CNN ile gerçekleştirilen kanal sınıflandırması için; toplam test verisinde 49 adet kanal bulunan dış röntgeninden 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. Yolov5 modelinin dış röntgenlerine uygulanması sonucu elde edilen karşılık matrisi Tablo 10'de verilmektedir.

Tablo 10. YOLOv5 ile Kanal Görüntülerinde Karşılık Matrisi

GERÇEK		Tahmin Edilen	
		Kanal	Sağlıklı
	Kanal	43	6
	Sağlıklı	1	35


Tablo 10 incelendiğinde, Yolov5 ile gerçekleştirilen kanal sınıflandırması için; toplam test verisinde 49 adet kanal bulunan dış röntgeninden 43'ü doğru olarak tespit edilirken, 6'sı 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 kanal sınıfında yanlış teşhis edilmiştir. Tablo 11'de Faster R-CNN ve Yolov5 derin öğrenme modellerin uygulanması sonucu oluşan duyarlılık, özgüllük, doğruluk ve eğitim süreleri verilmektedir.

Tablo 11. 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 11'de görüldüğü gibi, Faster R-CNN modelinde doğruluk oranı %85.8, duyarlılık oranı %83.6 ve özgüllük oranı ise %88.8'dir. Yolov5 modelinde ise doğruluk oranı %91.7, duyarlılık oranı %87.7 ve özgüllük oranı ise %97.2'dir. Burada özellikle her iki modelde de 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 32’de gösterilmektedir.



Şekil 32. Yolov5 modelinin uygulanması sonucu oluşan örnek görüntüler

Şekil 32’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. Yanlış olarak tespit edilen veya tespit edilemeyen kanal bölgeleri incelendiğinde diş röntgenlerinin standartlara uygun bir şekilde çekilmemesi ve hastanın sabit durmaması gibi nedenlerden kaynaklandığı düşünülmektedir.

3.1.3 Köprü için Gerçekleştirilen Deneyler

Köprü verileri için yapılan deneysel çalışmalarda 116 adet röntgen kullanılmıştır. Bu görüntülerin 81 tanesi eğitim, 35 tanesi ise test görüntüsüne ayrılmıştır. Diş röntgen görüntüleri üzerinde öznitelik 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 diş röntgenleri üzerinde köprü bölgelerinin belirgin hale getirilmesidir. Derin öğrenme modellerinin doğru şekilde nesne tespitini gerçekleştirebilmesi için bazı hiper parametre (başlangıç öğrenme oranı, resmin boyutları, batch boyutu ve epoch) değerleri kullanılmaktadır. Köprü eğitimi için Faster R-CNN ve Yolov5 modeli ile eğitimler gerçekleştirilirken Tablo 12’de modellerde kullanılan parametre değerleri gösterilmektedir.

Tablo 12. Köprü YOLO 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
Shuffle (Kariştir)	Every-epoch (Her tekrarda)
Verbose Frequency	10

Tablo 12’de 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 modelinin dış röntgenlerine uygulanması sonucu elde edilen karışıklık matrisi Tablo 13’te verilmektedir.

Tablo 13. Köprü Görüntülerinde Faster R-CNN ile oluşturulan Karışıklık Matrisi

GERÇEK		Tahmin Edilen	
		Köprü	Sağlıklı
	Köprü	29	6
	Sağlıklı	6	30

Tablo 13 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. Yolov5 modelinin dış röntgenlerine uygulanması sonucu elde edilen karışıklık matrisi Tablo 14’te verilmektedir.

Tablo 14. Köprü Görüntülerinde YOLOv5 ile oluşturulan Karışıklık Matrisi


GERÇEK		Tahmin Edilen	
		Köprü	Sağlıklı
	Köprü	31	4
	Sağlıklı	4	32

Tablo 14 incelendiğinde, YOLOv5 ile gerçekleştirilen köprü sınıflandırması için; toplam test verisinde 35 adet köprü bulunan diş röntgeninden 31'i doğru olarak tespit edilirken, 4'ü ise sağlıklı olarak yanlış sınıflandırılmıştır. Sağlıklı diş 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 15'te Faster R-CNN ve YOLOv5 derin öğrenme modellerin uygulanması sonucu oluşan duyarlılık, özgüllük, doğruluk ve eğitim süreleri verilmektedir.

Tablo 15. Köprü için Faster R-CNN ve YOLO 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 15'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 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 33'te gösterilmektedir.




Şekil 33. Köprü dedektörü sonucu oluşan örnek görüntüler

Şekil 33'te 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 dış röntgenlerinin standartlara uygun bir şekilde çekilmemesi ve hastanın sabit durmaması gibi nedenlerden kaynaklandığı düşünülmektedir.


3.2 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 karışıklık matrisinde bulunan doğru pozitif, doğru negatif, yanlış pozitif, yanlış negatif hakkında tahmin yapılmasını sağlar (Hayran, 2011). Test için yapılan en iyi kesim noktasının saptanmasında, doğru ve yanlış kararların hesaplanmasında kullanılır. Bunun yanı sıra farklı testlerin doğru sınıflandırma başarılarının karşılaştırılmasını sağlar (Pagano, Gauvreau ve Mattie 1993). Faster R-CNN derin öğrenme modeli ile elde edilen roc eğrisi sonuçları Şekil 34'te gösterildiği gibidir.



Şekil 34. Faster R-CNN Modeliyle Oluşturulan ROC Eğrisi Grafiği

Şekil 34'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 verisinde yapılan çalışmada ise % 88 oranında başarı sağlanmıştır. Köprü verisi için yapılan roc eğrisinde ise % 83 oranında başarı sağlanmaktadır.



Şekil 35. YOLOv5 Modeliyle Oluşturulan ROC Eğrisi Grafiği

Şekil 35'te 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.

SONUÇ VE ÖNERİLER

Bu çalışma, diş hekimlerine tanı koymada yardımcı olabilecek hızlı ve yüksek doğrulukta bir model geliştirilmesi amacıyla yapılmıştır. 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 getirilmiştir. Daha sonra etiketlenerek veri setimiz oluşturulmuştur.

Derin öğrenme yöntemleri kullanılarak veri seti üzerinde deneysel çalışmalar yapılmıştır. Diş çürüklerinin tedavisinde, dolgu, kanal, köprü ve sağlıklı olmak üzere toplam 553 adet diş röntgeninin yer aldığı veri seti test, eğitim ve doğrulama için ayrılmıştır. Veri seti üzerinde Matlab kullanılarak 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. 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 diş görüntülerini daha doğru bir şekilde teşhis edebilmesidir. Ayrıca Yolov5 modelinin doğru sınıflandırma performansı yanında daha kısa sürede eğitim işlemini tamamladığı tespit edilmiştir. Derin öğrenme modelleri sonucunda dolgu, kanal, köprü sınıflandırmaları için Roc eğrisi çizdirilmiştir. Yolov5 ile oluşturulan Roc eğrisi grafiğindeki değerler Faster R-CNN modeline göre daha başarılıdır. Dolgu ve kanal görüntülerinde %98 doğruluk oranına, köprü görüntülerinde ise %85 doğruluk oranı ile sınıflandırma gerçekleştirilmektedir.

Diş çürükleri ve tedavisinde panoramik diş röntgenleri ile sınıflandırma işlemlerinde yüksek doğruluk sonuçları elde edilmiştir. Derin öğrenme yöntemleri kullanılarak panoramik diş röntgenlerinde çürük dişin tespiti ve uygun tedavi yöntemleri hakkında bilgi verilebilmektedir. 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. Ayrıca derin öğrenme modeli olarak Faster R-CNN ve Yolov5 derin öğrenme modellerinin kullanılması da çalışmanın sınırlılıkları arasında yer almaktadır.

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.

KAYNAKÇA

- 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
- Akpolat G., ve Yalçın H. (2019). *Derin Öğrenme ile Pnömoni hastalığını tespit etme*.(Yüksek Lisans Tezi), İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü.İstanbul.
- Boucher, C.O., (1974). Current Clinical Dental Terminology : A Glossary of Accepted Terms in All Disciplines of Dentistry. 2.nd Ed. St. Louis: Mosby C., p.: 60.
- 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 Dent J, ODMFR 2019 Kongre Kitapçığı Özel Sayısı*.
- Doğan, F. ve Türkoğlu, İ. (2018). Derin öğrenme algoritmalarının yaprak sınıflandırma başarımlarının karşılaştırılması. *Sakarya University Journal of Computer and Information Sciences*, 1(1), 10-21.
- Durgun, S.(2018). *Türkiye'nin enerji talebinin yapay zekâ teknikleriyle uzun dönem tahmini*. (Yüksek Lisans Tezi), Necmettin Erbakan Üniversitesi Fen Bilimleri Enstitüsü. Konya.
- Fejerskov, O., Thylstrup, A. (1994). The oral environment- an introduction. In: Textbook of Clinical Cariology, Ed.: A. Thystrup, O. Fejerskov. 2nd Ed. Copenhagen: Munksgaard, p.:16.
- Gonzalez, Rafael C, Richard E Woods, ve Pearson Prentice Hall. 2008. Digital Image Processing Third Edition Pearson International Edition Prepared by Pearson Education.
- Gonzalez, Rafael C ve Woods,2004. Digital Image Processing Third Edition Pearson International Edition Prepared by Pearson Education.
- Goutte, C. ve Gaussier, E.(2005, Mart). A probabilistic interpretation of precision, recall and F-score, with implication for evaluation. In European Conference On Information Retrieval Kongresi'nde sunulmuş bildiri, Santiago de Compostela, İspanya

- Gurses, A. Oktay, A. B. (2020). Tooth Restoration and Dental Work Detection on Panoramic Dental Images via CNN. 2020 Medical Technologies Congress (TIPTEKNO).
- Hayran M, Hayran M. ROC Analizi, Sağlık Araştırmaları İçin Temel İstatistikler. Omega Araştırma Yayınları. Ankara, 2011, 403-416.
- Hinton, G. E., Srivastava, N., Krizhevsky, A., Sutskever, I. ve Salakhutdinov, R. R. (2012). Improving neural networks by preventing co-adaptation of feature detectors. *ArXiv Preprint ArXiv:1207.0580*.
- Hiremath S.K, Lavanya R., (2020). CNN in periodontology: A review. *Journal of Dental and Orofacial Research. Volume:16, Issue:1, (64-70)*
- Huang, Q., Hao, B. ve Chang, S. (2016). Adaptive digital ridgelet transform and its application in image denoising. *Digital Signal Processing*, 52(24), 45-54.
- Inik and Ülker, (2017). Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri, *Gaziosmanpasa Journal of Scientific Research. Volume:6, Number:3, (85-104)*
- Jaehne, Bernd. 1991. "Digital Image Processing: Concepts, Algorithms, and Scientific Applications." In Springer.
- Kheraif, Wahba and Fouad, (2019). Detection of dental diseases from radiographic 2d dental image using hybrid graph-cut technique and convolutional neural network. <https://www.sciencedirect.com/science/article/abs/pii/S0263224119305809?via%3Dihub>, 146,(333-342).
- Krutchkoff, D.J. (1981). The pathogenesis of dental caries. In: Pediatric Dental Medicine, Ed. D.J. Forrester, M.L. Wagner, J. Fleming. Philadelphia: Lea&Febiger, Chapter 10.
- LeCun, Y., Jackel, L. D., Boser, B., Denker, J. S., Graf, H. P., Guyon, I. ve Hubbard, W. (1989). Handwritten digit recognition: Applications of neural network chips and automatic learning. *IEEE Communications Magazine*, 27(11), 41-46
- LeCun, Y., Bengio, Y. ve Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436-444.
- Lee ve ark. (2018). *Diagnosis and prediction of periodontally compromised teeth using a deep learning-based convolutional neural network algorithm*. J Periodontal İmplant Bilimi. 30;48(2):114-123.

- Li, Yunqing, Wenjun Wang, ve Daoyin Yu. 1994. "Application of Adaptive Histogram Equalization to X-Ray Chest Images." In Second International Conference on Optoelectronic Science and Engineering '94, eds. Wang Da-Heng, Anna Consortini, and James B Breckinridge. , 513. <http://proceedings.spiedigitallibrary.org/proceeding.aspx?doi=10.1117/12.182056>.
- Lin, T. (2018). LabelIMG. Retrieved 10.04.2021 from <https://tzutalin.github.io/labelImg>
- Mellberg, J.R., Ripa, L.W. (1983). Fluoride in Preventive Dentistry: Theory and Clinical Applications. Chicago, Illinois: Quintessence Publishing Co., Chapter 1.
- Marsh, P.D. (1999). Microbiologic aspects of dental plaque and dental caries. Dent. Clin. North Am., 43: 599-614.
- Nguyen, G., Dlugolinsky, S., Bobák, M., Tran, V., Lopez Garcia, A., Heredia, I. Ve Hluchý, L. (2019). Machine learning and deep learning frameworks and libraries for large-scale data mining: a survey. *Artificial Intelligence Review*, 52(1), 77-124.
- Olsen, Brilliant, Primeaux ve K. Najarian,(2009). "Bir görüntü işleme özellikli diş çürüğü Tespit sistemi", *ICME Uluslararası Kompleks Tıp Mühendisliği Konferansı* , 2009, s. 1-8, doi: 10.1109/ICCME.2009.4906674 .
- Osmanoglu, UO., Mutlu, F., Gursay, H., Sanlısoy, S. (2019), Use of Image Processing and Analysis in Medicine and an Application, *Osmangazi Journal of Medicine*, 41 (1): 6 – 16
- Pagano, Marcello ve Gauvreau, Kimberlee (1993), Sampling Theory, Duxbury Press, California.
- Pang, Y., Sun, M., Jiang, X., & Li, X. (2017). Convolution in convolution for network in network. *IEEE transactions on neural networks and learning systems*.
- Samtaş, Gülesin, (2011), Sayısal Görüntü İşleme ve farklı alanlarındaki uygulamaları, *Electronic Journal of Vocational Colleges*.
- Singh, P., Sehgal, PGV Siyah diş çürüğü sınıflandırması ve optimal CNN-LSTM Sınıflandırıcı kullanılarak hazırlama tekniği. *Multimed Tools Appl* **80**, 5255–5272 (2021).

Suryani, D. Shoumi, M. N. Wakhidah, R.(2021). Object detection on dental x-ray images using deep learning method. IOP Conf. Series: Materials Science and Engineering 1073 (2021) 012058.

Tataroğlu, G. A., Genç, A., Kabakçı, K. A., Çapar, A., Töreyin, B. U., Ekenel, H. K. Erdoğan Çakır, A. (2017). Meme kanserinde CerbB2 tümör hücrelerinin sınıflandırılması için derin öğrenme tabanlı Bir yaklaşım. 25th Signal Processing and Communications Applications Conference (SIU). Antalya,

Yılmaz İ., 2007. Renk sistemleri, renk uzayları ve dönüşümler, Selçuk Üniversitesi Jeodezi Ve Fotogrametri Mühendisliği Öğretiminde 30. Yıl Sempozyumu, Sunulmuş Bildiri.
Zero, D.T. (1999). Dental caries process. Dent. Clin. North Am., 43: 635-664.

AKSARAY ÜNİVERSİTESİ TEZ DEĞERLENDİRME FORMU

Aksaray Üniversitesi Tez Değerlendirme Formu		
Öğrencinin Adı Soyadı: Ümran ÜNSAL		EVET
Kapak		
1	Tez Başlığı tutanaktaki başlıkla aynı mı?	EVET
2	Kapakta ay ve yıl savunmaya girilen tarihle tutarlı mı?	EVET
3	Kapak format kılavuzdaki kapak formatına uygun mu?	EVET
4	Kapakta yazılan tüm yazılar doğru olarak verilmiş mi?	EVET
İçindekiler		
5	Sayfa numaraları tam verilmiş mi?	EVET
6	Şekil, Çizelge vb. listeleri verilmiş mi? Sıralaması doğru mu?	EVET
7	Özet, Abstract, Giriş, Sonuçlar vb. bölümler var mı?	EVET
8	Yazım hataları kontrolü yapıldı mı?	EVET
Giriş		
9	Hazırlanan tezin önemini anlatıyor mu?	EVET
10	İkinci ve Üçüncü dereceden başlık içermemeli kuralına uyuldu mu?	EVET
Özet/Abstract		
11	Kılavuza uygun mu?	EVET
12	Ay ve yıl savunmaya girilen tarihle tutarlı mı?	EVET
13	Özet; tek sayfa, tek aralık, tek paragraf kuralına uygun olarak yazıldı mı?	EVET
14	Bilim kodu, sayfa adedi, anahtar kelimeler ve tez danışmanı yazıldı mı?	EVET
Kaynakça		
15	Kaynakların tamamına metin içinde atıf yapıldı mı?	EVET
16	Kaynak formatı Kılavuzdaki kaynak formatına uygun olarak hazırlanmış mı?	EVET
17	Atıf formatı kılavuzdaki atıf formatına uygun mu?	EVET
Atıf Yöntemi APA 6 ☒ CMS ☐ İSNAD ☐		
Genel Değerlendirme		
18	Etik Beyan açıklaması okundu, uyuldu ve imzalandı mı?	EVET
19	Kabul/Onay sayfası kılavuzdaki formata uygun olarak düzenlenmiş mi?	EVET
20	Kabul /Onay sayfasında belirtilen oy birliği/oy çokluğu seçeneklerinden uygun olanı savunmayla tutarlı olacak şekilde belirlenmiş mi?	EVET
21	Sayfa kenar boşluklar ve sayfa numaraları kılavuzdaki formatına uygun mu?	EVET
22	Paragraf boşlukları ve metin satır aralığı kılavuza uygun olacak şekilde düzenlenmiş mi?	EVET
23	Başlık yazımları kılavuzdaki başlık formatlarına uygun mu?	EVET
24	Yazı tipi ve boyutu kılavuzdaki yazı tipi ve boyutu formatına uygun mu?	EVET
25	Şekil, Çizelge vb. açıklama ve numaralandırmaları kılavuzdaki formata uygun olarak yazılmış	EVET