

TOBB EKONOMİ VE TEKNOLOJİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**PANORAMİK X-RAY DIŞ GÖRÜNTÜLERİNDE DIŞ BÖLGESİNİN VE
DIŞLERN MAKİNE ÖĞRENİMİ VE DERİN ÖĞRENME İLE
BÖLÜTLENMESİ**



YÜKSEK LİSANS TEZİ

Ali GÜVEN

Elektrik ve Elektronik Mühendisliği Anabilim Dalı

Tez Danışmanı: Doç. Dr. İmam Şamil YETİK

TEMMUZ 2020

TEZ BİLDİRİMİ

Tez içindeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edilerek sunulduğunu, alıntı yapılan kaynaklara eksiksiz atıf yapıldığını, referansların tam olarak belirtildiğini ve ayrıca bu tezin TOBB ETÜ Fen Bilimleri Enstitüsü tez yazım kurallarına uygun olarak hazırlandığını bildiririm.

Ali Güven

ÖZET

Yüksek Lisans Tezi

PANORAMİK X-RAY DIŞ GÖRÜNTÜLERİNDE DIŞ BÖLGESİNİN VE DIŞLERİN MAKİNE ÖĞRENİMİ VE DERİN ÖĞRENME İLE BÖLÜTLENMESİ

Ali Güven

TOBB Ekonomi ve Teknoloji Üniversitesi
Fen Bilimleri Enstitüsü
Elektrik ve Elektronik Mühendisliği Anabilim Dalı

Tez Danışmanı: Doç. Dr. İmam Şamil Yetik

Tarih: Temmuz 2020

Panoramik X-Ray diş görüntülerinden dişlerin olduğu bölgenin ve dişleri bölütlenmesi, çeşitli hastalıkların belirlenmesi için önemli hale gelmiş bulunmaktadır. Özellikle son dönemde gelişen teknoloji ile birlikte çalışmalara dahil olmaya başlayan Yapay Zeka (AI) temelli yapılar, hem dişlerin tespiti ve bölütlenmesi sürecini kısaltmayı hem de diş hekimlerine karar destek yapıları oluşturarak yanlış teşhisi ortadan kaldırmayı amaçlamaktadır. Ham görüntülerdeki diş olmayan piksellerin diş olan piksellere göre fazla olması ve görüntülerdeki kontrast ve renk seviyesinin bölgesel olarak farklılık göstermemesi görüntü işlemeyi zorlaştırmaktadır. Bu tezin amacı, panoramik x-ray görüntülerindeki dişlerin olduğu bölgeyi ve dişleri otomatik olarak bölütleyebilmektir. İlk olarak, görüntülerin boyutlarını hem her görüntü için sabit olması hem de işlemsel olarak hızlı sonuçlar almak için düşürerek alt-örnekleme yapılmıştır. Sonraki aşamada, görüntülerdeki diş alanının merkez noktası otomatik olarak belirlenmiştir. Daha sonra piksellerin yeğinlik değerleri, bulunan merkez noktasına göre x koordinatı, bulunan merkez noktasına göre y koordinatı ve 3x3 penceresinde maksimum ve minimum değerlerin çıkarılmasıyla elde edilen öznelikler kullanılarak diş bölgesinin bölütlenmesi gerçekleştirilmiştir. Bunun için bir Makine Öğrenme (ML) algoritması olan CatBoost algoritması kullanılmıştır. Makine Öğrenme (ML) modeli oluşturulurken, veri setinin ezberlenmesini önlemek için eğitim veri setinin k-kat çapraz doğrulaması

ve hiper parametrelerin ızgara arama optimizasyonu yöntemleri uygulanmıştır. Diş bölgesini tam olarak bölütleyebilmek için makine öğrenmesi modelinden elde edilen her sonucun üzerinde ağız bölgesinin deforme olabilen şekiller uydurulmuştur. Bu sayede diş bölgesi içinde bulunmayan piksellerden kurtulmuş ve diş bölgesi bölütlemesi yapılmıştır. Diş bölgesini bölütledikten sonra Derin Öğrenme (DL) modeli oluşturulup bu modele sadece bölütlenen diş bölgeleri giriş olarak verilmiştir. Model içinde karalılığı sağlamak ve işlem hızını arttırmak amacıyla elde edilen bölütlenmiş diş bölgeleri görüntülerinin boyutları düşürülerek alt-örnekleme yapılmıştır. Derin Öğrenme (DL) sonucunda her görüntü üzerinde dişlere ait olan bir pencere elde edilmiştir. Her pencere içindeki dişlerin tam bölütlenmesi için Tony F. Chan ve Luminita Vese (Chan-Vese) algoritması uygulanmıştır. Bu sayede pencereler dişlerin şeklinde küçültülmüş ve bölütmele işlemi yapılmıştır. Sonuçlar, Makine Öğrenmesi (ML) ve Derin Öğrenme (DL) için öğrenme eğrisi; dişlere ait olan piksellerin doğruluğunu ölçmek için F1, doğruluk, hatırlama ve kesinlik skorları kullanılarak analiz edilmiştir.

Anahtar Kelimeler: Panoramik X-Ray diş görüntüleri, Makine öğrenmesi, Derin öğrenme, görüntü işleme, görüntü bölütlemesi, diş tespiti, diş bölütlemesi, deforme olabilen şekil uydurma

ABSTRACT

Master of Science

SEGMENTATION OF TEETH REGION AND TEETH BOUNDARIES VIA MACHINE LEARNING AND DEEP LEARNING IN PANORAMIC X-RAY DENTAL IMAGES

Ali Güven

TOBB University of Economics and Technology
Institute of Natural and Applied Sciences
Department of Electrical and Electronics Engineering

Supervisor: Assoc. Prof. İmam Şamil Yetik

Date: July 2020

Segmentation of the region of the teeth and segmentation of the teeth from the dental panoramic X-Ray images have become important tasks in determining various diseases. Artificial Intelligence (AI) based structures, which have started to be included in the studies with the technology that has developed recently, aim to both shorten the process of detection and segmentation of the teeth and eliminate the misdiagnosis by creating decision support structures for the dentists. It becomes difficult to process images because the number of non-tooth pixels is higher than the number of tooth pixels, and the contrast and color level in the images do not differ regionally. The main goal of this thesis is to be able to automatically segment the region of the teeth and the teeth in panoramic X-Ray images. Firstly, down-sampling was done by reducing the size of the images both to be fixed for each image and to obtain fast results in terms of computational process. In the next stage, the center point of the tooth area in the images is determined automatically. Segmentation of the region of the teeth was performed by using obtained feature set. The feature set includes intensity values of pixels, x-coordinate relative to the center point of the tooth area, y-coordinate relative to the center point of the tooth area, and the pixel values obtained by subtraction of maximum and minimum values in 3x3 window. CatBoost algorithm was used for Machine Learning

(ML). While making the Machine Learning (ML) model, k-fold cross-validation and grid search optimization of hyper parameters methods were applied to prevent over-fitting of the data set. In order to fully segment the tooth region, the deform-able shapes of the mouth region are fit on each result obtained from the machine learning model. In this way, the pixels that are not in the tooth region are eliminated and the tooth region is segregated. After segmentation of the tooth region, the Deep Learning (DL) model was made and only the tooth regions that were segmented were given as an input to this model. In order to ensure the stability in the model and increase the processing speed, the down-sampling was performed by reducing the size of the segmented tooth regions obtained. As a result of Deep Learning (DL), a window belonging to the teeth was obtained on each image. Tony F. Chan and Luminita Vese (Chan-Vese) algorithm applied for the complete segmentation of the teeth in each window. In this way, the windows were reduced in the shape of the teeth and segmentation was done. The results was analyzed by using learning curve for Machine Learning (ML) and Deep Learning (DL) and by looking F1, accuracy, recall, and precision scores.

Keywords: Dental panoramic X-Ray images, Machine learning, Deep Learning, Image processing, Image segmentation, Teeth detection, Teeth segmentation, Deform-able shape fitting

TEŐEKKÜR

Çalıőmalarım boyunca deęerli yardım ve katkılarıyla beni yönlendiren hocam Doç. Dr. İmam Őamil YETİK'e, kıymetli tecrübelerinden faydalandığım TOBB Ekonomi ve Teknoloji Üniversitesi Elektrik Elektronik Mühendislięi Bölümü öğretim üyelerine, tam burs sağladığı için TOBB Ekonomi ve Teknoloji Üniversitesine ve destekleriyle her zaman yanımda olan aileme, rahmetli babam İsmail GÜVEN'e, annem Ferah GÜVEN'e, abim Mert GÜVEN'e ve arkadaşlarıma çok teşekkür ederim.

İÇİNDEKİLER

	<u>Sayfa</u>
ÖZET	iv
ABSTRACT	vi
TEŞEKKÜR	viii
İÇİNDEKİLER	ix
ŞEKİL LİSTESİ	xi
ÇİZELGE LİSTESİ	xiii
KISALTMALAR	xiv
1. GİRİŞ	1
2. METODOLOJİ	5
2.1 Tezin Katkısı	5
2.2 Tezin Akış Şeması	6
2.3 Veri Seti	7
2.3.1 X-Ray görüntüleme	7
2.3.2 Farklı x-ray görüntülemeler	9
2.3.3 Görüntülerin hazırlanması	11
2.4 ML Modeli	13
2.4.1 ML tanımı	13
2.4.2 Denetimli öğrenme	15
2.4.3 Denetimsiz öğrenme	15
2.4.4 Yarı denetimli öğrenme	15
2.4.5 Kümeleme problemi	15
2.4.6 Regresyon problemi	16
2.4.7 Sınıflandırma problemi	17
2.4.8 CatBoost algoritması	19
2.4.9 ML modeli için dişlerin etiketlenmesi	20
2.4.10 Öznetelik çıkartılması	20
2.4.11 ML modeli için eğitim, doğrulama ve test verilerinin ayrılması	22
2.4.12 ML modeli için parametre arama	23
2.4.13 ML modelinin oluşturulması ve sonuç alınması	23
2.5 Diş Bölgesinin Bölütlenmesi	24
2.5.1 Görüntü üzerinde şekil uydurma	24
2.5.2 Panoramik x-ray diş görüntülerinde otomatik ağız bölgesi bölütlemesi	24
2.5.3 Panoramik x-ray diş görüntülerinde otomatik tam diş bölgesi bölütlemesi	25
2.6 DL Modeli	26
2.6.1 DL tanımı	26
2.6.2 Bölütleme problemi	28

2.6.3 Nesne tespit problemi	29
2.6.4 Faster R-CNN	30
2.6.5 DL modeli için dişlerin etiketlenmesi	32
2.6.6 DL modeli için eğitim, doğrulama ve test verilerinin ayrılması	32
2.6.7 DL modeli için öğrenme aktarımı	33
2.6.8 DL modelinin oluşturulması ve sonuç alınması	33
2.7 Dişlerin Bölütlenmesi	34
2.8 Kullanılan Başarım Metriği	35
3. DENEYLER	37
3.1 Veri Seti	37
3.1.1 Kullanılan veri seti	37
3.1.2 Görüntülerin hazırlanması	38
3.2 ML Modeli	38
3.2.1 Öznitelik çıkartılması	38
3.2.2 ML modelinin oluşturulması	40
3.2.3 ML modelinin performansı	41
3.3 Diş Bölgesinin Bölütlenmesi	44
3.4 DL Modeli	46
3.5 Dişlerin Bölütlenmesi	48
3.6 Piksellerin Sınıflandırma Analizi	54
4. SONUÇ	55
KAYNAKLAR	57
ÖZGEÇMİŞ	62

ŞEKİL LİSTESİ

	<u>Sayfa</u>
Şekil 2.1: Uygulanan yöntemlerin yapılaş ve oluşturuluş diagramı.	6
Şekil 2.2: Farklı elektromanyetik radyasyon gruplarının dalga boyları ve frekansları.	8
Şekil 2.3: Vakum X-Ray tüpü.	9
Şekil 2.4: Dişlerin etiketlenmesi.	20
Şekil 2.5: Panoramik X-Ray diş görüntülerinde otomatik ağız bölgesi bölütlemesi optimizasyon sonucu.	25
Şekil 2.6: Panoramik X-Ray diş görüntülerinde otomatik diş bölgesi bölütlemesi optimizasyon sonucu.	27
Şekil 2.7: Tamamen evrimsel ağlar ile bölütleme işlemi.	28
Şekil 2.8: Nesne tespiti örneği.	29
Şekil 2.9: Nesne tespit algoritma mimarileri: (a), iki aşamalı dedektör mimarisi ve (b), tek aşamalı dedektör mimarisi.	30
Şekil 2.10: Faster R-CNN mimarisi.	31
Şekil 2.11: DL modeli için dişlerin etiketlenme işlemi.	32
Şekil 2.12: DL modeli için öğrenme aktarım süreci.	34
Şekil 2.13: Diş bölütleme işlemi.	35
Şekil 3.1: Veri setinden farklı hastalara ait örnekler.	37
Şekil 3.2: HE işleminin sonuçlarını içeren örnek görüntüler.	38
Şekil 3.3: ML modelinde kullanılan özneliklere ait PDF.	39
Şekil 3.4: ML modelinde kullanılan "diş" ve "diş değil" sınıflarına göre oluşturulmuş öznelikler arası ilişkiyi gösteren dağılımlar.	40
Şekil 3.5: ML modelinin öğrenme eğrisini gösteren grafik (düz çizgili eğitim verisi ve kesikli çizgili doğrulama verisi).	42
Şekil 3.6: Farklı hastalara ait ML modellerinin diş bölgesi bölütleme sonuçları.	44
Şekil 3.7: Farklı hastalara ait deforme şekil uydurma sonuçları.	45
Şekil 3.8: DL modelinin öğrenme eğrisini gösteren grafik (düz çizgili eğitim verisi ve kesikli çizgili doğrulama verisi).	47

Şekil 3.9: Farklı hastalara ait DL modelinin sonuçları.	48
Şekil 3.10: Diş bölütleme için kullanılan ML, DL modellerinin ve Chan-Vese bölütleme algortimasının ML, DL modelleri için hazırlanan eğitim verilerine ait sonuçları. (a-d) arası farklı hastalara ait şekil uydurma ile kesilmiş panoramik X-Ray diş görüntüleri, (e-h) arası ML modelinin sonuçları, (i-l) arası DL modelinin sonuçları, ve (m-p) arası Chan-Vese algoritmasının sonuçları.	50
Şekil 3.11: Diş bölütleme için kullanılan ML, DL modellerinin ve Chan-Vese bölütleme algortimasının ML, DL modelleri için hazırlanan doğrulama verilerine ait diğer sonuçlar. (a-d) arası farklı hastalara ait şekil uydurma ile kesilmiş panoramik X-Ray diş görüntüleri, (e-h) arası ML modelinin sonuçları, (i-l) arası DL modelinin sonuçları, ve (m-p) arası Chan-Vese algoritmasının sonuçları.	51
Şekil 3.12: Diş bölütleme için kullanılan ML, DL modellerinin ve Chan-Vese bölütleme algortimasının ML, DL modelleri için hazırlanan test verilerine ait diğer sonuçları. (a-d) arası farklı hastalara ait şekil uydurma ile kesilmiş panoramik X-Ray diş görüntüleri, (e-h) arası ML modelinin sonuçları, (i-l) arası DL modelinin sonuçları, ve (m-p) arası Chan-Vese algoritmasının sonuçları.	52
Şekil 3.13: Diş bölütleme için kullanılan ML, DL modellerinin ve Chan-Vese bölütleme algortimasının ML, DL modelleri için hazırlanan test verilerine ait diğer sonuçları. (a-d) arası farklı hastalara ait şekil uydurma ile kesilmiş panoramik X-Ray diş görüntüleri, (e-h) arası ML modelinin sonuçları, (i-l) arası DL modelinin sonuçları, ve (m-p) arası Chan-Vese algoritmasının sonuçları.	53

ÇİZELGE LİSTESİ

	<u>Sayfa</u>
Çizelge 3.1: Görüntülerde alt örnekleme boyutları.	39
Çizelge 3.2: ML modelinde kullanıcı girişli parametreler.	41
Çizelge 3.3: Geliştirilmiş öznetelik olmadan yapılan modele göre sınıflandırma skorları	42
Çizelge 3.4: Geliştirilmiş öznetelik ile yapılan modele göre sınıflandırma skorları	43
Çizelge 3.5: DL modelinde kullanıcı girişli parametreler.	46
Çizelge 3.6: Chan-Vese algoritmasında kullanıcı girişli parametreler.	49
Çizelge 3.7: Diş bölütleme işleminin sonucuna göre sınıflandırma skorları	54

KISALTMALAR

ACC	: Doğruluk (Accuracy)
AI	: Yapay Zeka (Artificial Intelligence)
AUC	: ROC Eğrisi Altında Kalan Alan (Area Under the ROC Curve)
BA	: Birleşim Alanı (Area of Union)
BDP	: Bulunan Diş Pikselleri (Found Teeth Pixels)
CatBoost	: Kategorik Hızlandırma (Categorical Boosting)
Chan-Vese	: Tony F. Chan ve Luminita Vese (Tony F. Chan and Luminita Vese)
CNN	: Evrimsel Sinir Ağları (Convolutional Neural Networks)
CT	: Bilgisayarlı Tomografi (Computerized Tomography)
DL	: Derin Öğrenme (Deep Learning)
DN	: Doğru Negatif (True Negative)
DNO	: Doğru Negatif Oranı (True Negative Rate)
DOP	: Diş Olmayan Pikseller (Over Detection Pixels)
DP	: Doğru Pozitif (True Positive)
DPO	: Doğru Pozitif Oranı (True Positive Rate)
Faster R-CNN	: Daha Hızlı Bölgesel Evrimsel Sinir Ağları (Faster Region Based - Convolutional Neural Networks)
F1	: F1 Skor (F1 Score)
HE	: Histogram Eşitleme (Histogram Equalization)
IoU	: Birleşim Üzerindeki Kesişim (Intersection over Union)
KA	: Kesişim Alanı (Area of Overlap)
K-CV	: K-Kat Çapraz Doğrulama (K-Cross Validaiton)
KDP	: Kaçırılan Diş Pikselleri (Missed Teeth Pixels)
K-Means	: K-Ortalama Kümeleme (K-Means Clustering)
K-NN	: K-En Yakın Komşu (K-Nearest Neighbor)
Mask R-CNN	: Maskeli Bölgesel Evrimsel Sinir Ağları (Mask Region Based - Convolutional Neural Networks)
ML	: Makine Öğrenme (Machine Learning)
MRI	: Manyetik Rezonans Görüntüleme (Magnetic Resonance Imaging)
NLP	: Doğal Dil İşleme (Natural Language Processing)
OLS	: En Küçük Kareler Yöntemi (Ordinary Least Squares)
PCA	: Temel Bileşen Analizi (Principal Component Analysis)
PDF	: Olasılık Yoğunluk Fonksiyonu (Probability Density Function)
PREC	: Kesinlik (Precision)
REC	: Hassasiyet (Recall)
RF	: Rassal Orman (Random Forest)

ROC	: Alıcı İşletim Karakteristiği (Receiver Operating Characteristic)
RoI	: İlgilenilen Bölge (Region of Interest)
SVM	: Destek Vektör Makinesi (Support Vector Machine)
X-Ray	: X-Radyasyonu (X-Radiation)
YN	: Yanlış Negatif (False Negative)
YNO	: Yanlış Negatif Oranı (False Negative Rate)
YP	: Yanlış Pozitif (False Positive)
YPO	: Yanlış Pozitif Oranı (False Positive Rate)





1. GİRİŞ

Dişlerde oluşabilecek hastalıklar ve deformasyonlar her insanda sıklıkla görülebilen bir rahatsızlıktır. Medikal görüntüleme sistemlerinin gelişmesiyle doktorlar için tanı ve takibe yardımcı görsel veriler oluşturulabilir hale gelmiştir. X-Işını görüntülemeleri diğer görüntüleme sistemlerine kıyasla daha iyi sonuç verdiği için klinik olarak tercih sebebidir. X-Ray görüntüleri dişlerin tespitinde zengin bilgiler sağlasa bile dişler arası boşluğun az olması, görüntülerdeki gürültü miktarı gibi durumlar görüntüde diş tespitini ve dişlerin ayırt edilmesini zorlaştırmaktadır. Son dönemde görüntü işleme, Yapay Zeka (AI), makine öğrenmesi (ML) ve derin öğrenme (DL) uygulamalarının alana dahil olmasıyla dışarıdan müdahale olmadan otomatik olarak dişlerin tespiti ve bölütlenmesi ve/veya tespiti ve bölütlenmesine yardımcı yapıların oluşturulması gündeme gelmiştir. Özellikle var olan diş tespiti ve bölütleme sistemlerinde belli bir standardın tutturulamaması, yanlış diş tespiti oranlarının alanda yüksek olması, hastalar arası ağız ve diş yapılarının durumuna bağlı olarak var olan tespit ve bölütleme mekanizmalarının farklı sonuçlar vermesi, oluşturulan bu yapıların önemini arttırmıştır. Örneğin [1]'de, öznel olarak çıkartılması değerlendirilmiş ve dişlerin bölütlenmesinde çıkartılan öznel değerlerin önemi belirtilmiştir. Çalışma [2]'de dişlerin bulunduğu piksellerden bir maske oluşturulmuş ve bölge büyütme (region growing), kümeleme (clustering) gibi algoritmalar kullanılarak dişlerin bulunduğu bölge tespit edilebilmiştir. Başka bir çalışma olan [3]'de derin öğrenme (DL) algoritmalarından (Mask R-CNN) yapısı kullanılarak dişlerin piksel bölütlenmesi yapılmıştır.

Bahsedilen bu bölütleme uygulamalarında X-Ray görüntülerin öncelikli olarak işlenmesi dişlerin bölütlenmesinde performansı arttırmaktadır [1]. Genel olarak kontrast problemi olan görüntülerde bölütleme sistemlerinden önce HE uygulanarak gerçekleştirilmektedir [4]. Bu uygulamalarda yapılan HE işleminin bölgesel olup olmaması hakkında bilgi verilmemiştir. Örneğin bir önceki paragrafta bahsi geçen [1]'de HE uygulanmış fakat bölgesel olup olmadığına ilişkin bir açıklamaya yer verilmemiştir. [1] ve [5]'de kullanılan görüntülemeler panoramik olmayıp diş bölgesi bulma işlemi yapılmamıştır ve dişler arası boşluk daha açık bir biçimde görülmektedir. [2]'de kullanılan yöntemde diş bölgesi otomatik olarak bulunmamış ve elde edilen sonuçlar dişlerin bölütlenmesi için yeterli olamamıştır.

Literatürde [1] ve [5] gibi panoramik olmayan X-Ray görüntüleri kullanılarak diş

bölgesi bölütlenmesi veya dış bölütlemesi yapılmaktadır. Çalışma [6]'da otomatik bir şekilde dış bölütlemesi aktif küçülen sınırlar ile yapılmış ancak panoramik X-Ray dış görüntüleri kullanılmamıştır. Bunun yerine kullanılan görüntüleme dişlerin sınırlarının ve dış bölgesinin tespitine gerek olmamıştır. Çalışma [7]'de ise panoramik X-Ray dış görüntüleri kullanılmış ancak dış bölütleme işlemi başarılı olmadığı gibi dişlerin bulunduğu bölgenin tespiti otomatik değildir. Benzer şekilde [2]'de panoramik X-Ray dış görüntüleri kullanılmış ve dış bölütlenmesi başarılı bir biçimde yapılamamıştır. Çalışma [3]'de panoramik X-Ray dış görüntüleri kullanılmış ve derin öğrenme (DL) kullanılarak dişlerin bölütlenmesi otomatik olarak gerçekleştirilmiştir. Ancak gerçekleştirilen bu bölütleme işleminde diş implantları ve görüntülerde diş piksel değerlerine yakın değerlerde olan diş etlerinin bulunduğu pikselleri de diş olarak bölütlediği görülmüştür. Ayrıca [3]'de kullanılan görüntü sayısı bu tez kapsamında kullanılan görüntü sayısına oranla çok daha yüksek sayıda olup tezde daha az görüntü ile otomatik yüksek doğrulukta dış bölütlemesi yapılmıştır. Benzer çalışmalara panoramik X-Ray dış görüntüleri için fazla rastlanmaz iken panoramik olmayan X-Ray dış görüntüleri için literatürde sıkça rastlanmaktadır. Panoramik X-Ray dış görüntüleri için yapılan çoğu çalışmada dişlerin olduğu bölge otomatik bölütlenmemiştir. Bununla birlikte dış bölütlenmesinin performansı da yeterli olamamıştır.

Daha önceki çalışmalarda olduğu gibi bu tezdeki çalışmada da ilk önce görüntülerde histogram eşitleme (HE) kullanılarak iyileştirme yapılmıştır [1]. Bu sayede dişler arasında kalan diş arası boşlukların tespit edilmesi kolaylaştırılmıştır. Bir sonraki aşamada görüntülerin sabit olmayan boyutlarından ve görüntü işlemede zamandan tasarruf yapılması gerektiğinden dolayı görüntülerin boyutları alt örneklenmiştir. Elde edilen yeni alt örneklenmiş görüntülerden dişlerin bulunduğu eliptik ağız bölgesini tanımlayacak öznitelikler çıkarılmıştır [8]. Çıkarılan en önemli öznitelik dış bölgesinin merkez noktasıdır. Bu merkez noktasına göre oluşturulan koordinat sistemi ile x ve y yönünde değerler elde edilmiştir. Kullanılan makine öğrenimi (ML) yönteminde bu öznitelik kullanılmış ve dış bölgesinin bölütlenmesi otomatik olarak yapılmıştır. Makine Öğrenimi için kullanılan yöntem CatBoost kullanılmıştır. Bu yöntemin kullanılmasının sebebi, dişlere ait piksellerin sayısının dişlere ait olmayan piksellerin sayısına göre çok daha az olmasıdır. Sınıflandırma problemlerinde, sınıflar arası dengesizlik olduğunda öznitelikler arası bağımlılık olduğunu varsayan ve bu varsayıma göre uygun karar ağaçları oluşturup zayıftan güçlüye kadar ağaçlar oluşturan bir algoritma bu dengesizliği giderebilir. Bu algoritma ile az sayıdaki diş piksellerini bulan bir model oluşturulmuştur. Algoritmanın eğitim aşamasından önce ayarlanması gereken parametreleri vardır. Bu parametreler dışarıdan bir kullanıcı tarafından belirlenebildiği gibi en iyi sonucu veren parametreleri bulan bir arama algoritması tarafından da belirlenebilmektedir.

Mevcut yapıda parametreler bir arama algoritması tarafından belirlenmiştir. Oluşturulan makine öğrenimi (ML) modelinin eğitimi var olan 50 görüntünün %60'ı kullanılarak yapılmıştır. Eğitimde modelin eğitim verilerini ezberlemesini engellemek için K-CV yöntemi kullanılmıştır. Bu yöntemde modelin doğruluğunun ölçülmesi için modelin eğitimi sırasında eğitim verisinden farklı olarak başka veri kümesi kullanılmış ve bu ölçüme göre modeldeki parametreler güncellenmiştir. Sonuç olarak var olan 50 görüntüde %40'ı eğitim için %20'si doğrulama için kullanılarak toplamda %60'ı makine öğrenmesi modelinin oluşturulmasında kullanılmıştır. Modelin verdiği çıkış, görüntülerdeki piksellerin diş ve diş değil şeklinde sınıflandırılması şeklinde olmaktadır. Modelin sonucunda elde edilen yeni çıktı diş bölgesinin bölütlenmesi için yeterli olsa da dişlerin bölütlenmesi için yeterli olamamıştır. Bu yüzden bu çıktıları, ağzın tam şeklini bulabilmek için şekil uydurma yöntemi uygulanmıştır. Bu sayede makine öğrenimi modelinden gelen istenmeyen veya yanlış sınıflandırılmış pikseller atılmıştır. Diş bölgesinin bölütlenme işlemi bu sayede en iyi biçimde yapılmış ve bir sonraki aşama için görüntüler hazırlanmıştır. Sonraki aşamada derin öğrenme (DL) modeli Mask R-CNN kullanılarak oluşturulmuştur. Kullanılan algoritma CNN yapısına sahip olup dişin boyutuna, şekline ve dönüş açısına bağlı olmaksızın dişleri bulabilmektedir. Bu algoritmanın da makine öğrenmesinde olduğu gibi dışarıdan değiştirilmesi gereken parametreleri mevcuttur. Bu parametreler modelin en iyi sonuç verebilmesi için uygun olarak seçilmiştir. Bu modelde dişler, dikdörtgen kutularda belli bir çerçeve içinde bulunmuştur. Model için kullanılan eğitim ve doğrulama verileri, makine öğrenmesi modeli için kullanılan veri oranları ile aynı olacak şekilde oluşturulmuştur. Derin öğrenme (DL) modelinde bulunan dişlere ait çerçeveler bazı görüntülerde aynı dişin bir uzantısı olarak veya iki diş birden alacak şekilde sonuç vermiştir. Bu durumda fazla diş uzantıları üst üste gelen çerçevelerden hangisi daha büyük ise onu baz alarak elimine edilmiştir. İki diş tek diş olarak gösteren çerçeveler için ise en son aşamada dişlerin otomatik tam bölütlenmesi için kullanılan Chan-Vese bölütleme algoritması kullanılmıştır. Kullanılan bu yöntem ile makine öğrenmesi (ML) modelinin ve şekil uydurmanın sonucunda ortaya çıkan maske maske ile ve derin öğrenme (DL) modelinin sonucunda ortaya çıkan çerçeveler birleştirilerek Chan-Vese bölütleme algoritması ile çerçevelerin makine öğrenmesi (ML) modelinin sonucunda ortaya çıkan maske maske etrafında küçülmesi sağlanmıştır. Bu sayede dişlerin tam ve otomatik olarak bölütlenme işlemi tamamlanmıştır. Elde edilen ölçüm performansları daha fazla görüntü kullanan ve diş implantları ve diş etleri ile gürbüz çalışmayan çalışma [3]'ün sonuçlarına çok yakın olup diş implantları ve diş etleri ile gürbüz bir biçimde çalışmaktadır. Derin öğrenme (DL) modeli ile bulunan çerçevelerde iki dişin tek bir çerçeve içinde çıkması sorunun çözümü olarak Chan-Vese algoritması ile küçülen çerçevelerde artan diş pikselleri bir

diş olarak belirlenmiştir.

Bu tez temel olarak takiben dört kısımdan oluşmaktadır. Bölüm 2’de Metodoloji başlığı altında panoramik X-Ray diş görüntüleri ve dişlerin bölütlenmesi hakkında bilgi verilecek, genel olarak X-Ray görüntülerinin nasıl elde edildiğinden bahsedilecek ve çalışmada kullanılan yapılar hakkında bilgi verilecektir. Bölüm 3 Deneyler kısmında ise bu yapıların çalışma için ne şekilde uyarlandığı, çalışmanın nasıl planlandığı ve hangi sonuçların elde edildiğinden bahsedilecektir. Son olarak Dördüncü Bölüm olan Sonuç kısmında ise elde edilen önemli noktalar özetlenecek ve yapılabilecek iyileştirmelerden bahsedilecektir.



2. METODOLOJİ

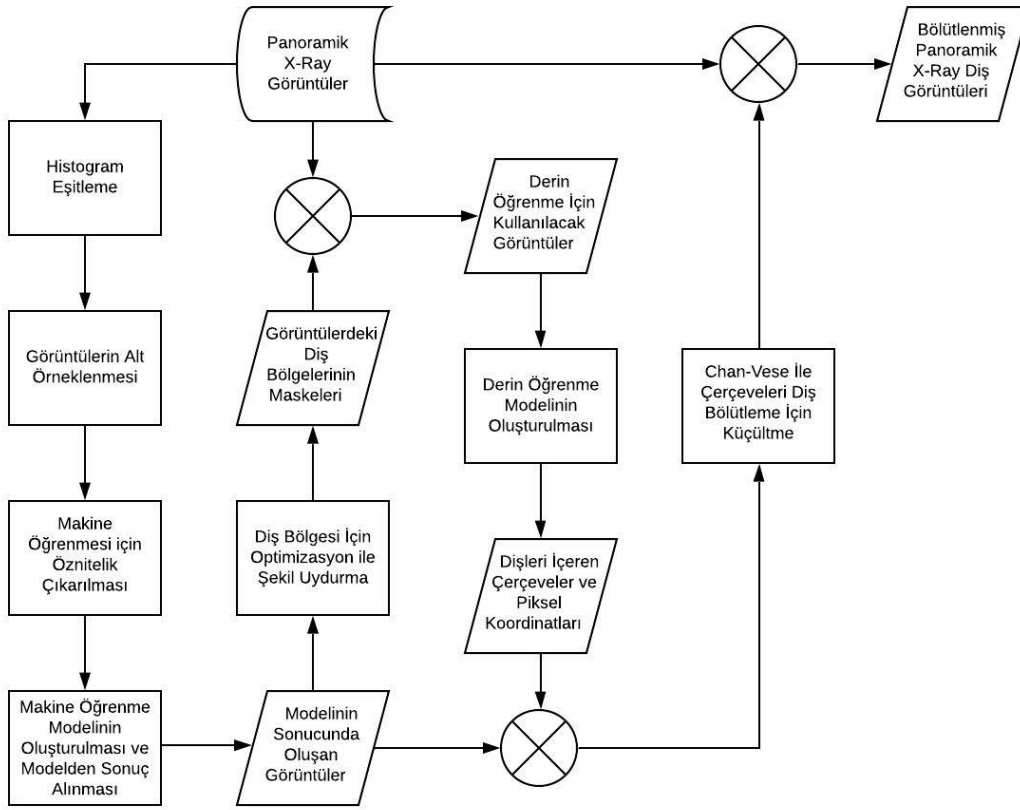
Bu bölümde öncelikli olarak panoramik X-Ray diş görüntüleri hakkında kısa bilgiler verilecek, daha sonra da çalışmada kullanılan verilerin elde edilmiş detayları ve metodların altyapısı anlatılacaktır. Görüntülerin iyileştirilmesi ve dişler arasındaki sınırların ayırt edilmesini bulan soysal bir yapı oluşturabilmek için genel akışta öncelikle görüntülerin genelinde ve görüntülerin yerel alanlarında histogram eşitleme (HE) ile sınırlar belirginleştirilecek daha sonra görüntülerin boyutları belirlenen boyutlara alt örneklenerek analiz edilecektir. Sonrasında F1 skor metriğine göre oluşturulan makine öğrenme modeli ile sınıflayıcıda pikseller etiketlenecek ve diş bölgesi için şekil uydurma ile optimizasyon yapılacak ve öğrenme eğrisi analizi gerçekleştirilecektir. Sonrasında derin öğrenme modeli ile dişlerin içinde bulunduğu çerçeveler elde edilecek ve öğrenme eğrisi ile modelin başarısı analiz gerçekleştirilecektir. Son olarak ise elde edilen piksellere ait diş etiketleri ve dişlerin çerçeveleri ile çerçeve küçültmesi (Chan-Vese) yapılacak ve bulunan dişlere ait piksellere göre doğruluk, kesinlik, hassasiyet ve F1 analizi yapılacaktır. Tüm diş bölütleme yapan soysal yapıyı oluşturabilmek için kullanılacak metrikler, sınıflayıcılar, filtrelemeler ve diğer metodlar ile ilgili bilgi bu başlık altında sırası ile verilecektir.

2.1 Tezin Katkısı

Literatürde yer alan çalışmalar [1] ve [5]'de panoramik olmayan X-Ray diş görüntüleri kullanılmış ve dişlerin olduğu bölgenin bölütleme işlemine gerek duyulmamıştır. Ayrıca dişler arası boşlukların görüntülemeye kaynaklı olarak daha belirgin olması problemin uygulanabilirliğini kolaylaştırmıştır. Öte yandan, benzer çalışmalarda dişlerin bölütlenmesinde makine öğrenmesi olarak kümeleme algoritmaları yani gözetimsiz öğrenme uygulanmıştır [1]. Bu yöntem ile oluşturulan yapılarda dişlerin bölütlenmesi sağlanamamıştır. Tez kapsamında, gözetimli öğrenme kullanılmış ve bu yöntem için daha önce kullanılmayan yeni bir öznelik çıkartılmıştır. Çalışma [3]'de derin öğrenme modelinde kullanılan görüntüler bu tez kapsamında kullanılanlardan çok daha fazla sayıda olmakta ve modelin implantların olduğu ve diş etlerine ait piksellerin özyeğinlerinin dişlere ait olanlara yakın olduğu durumlarda iyi çalışmamaktadır. Bu tez kapsamında daha az görüntü kullanılarak yanlış bulunma problemi giderilmiştir.

2.2 Tezin Akış Şeması

Bu bölümde geliştirilen yöntemlerin sırasıyla oluşturulma şekilleri görsel olarak değinilecektir. Şekil 2.1’de görüldüğü üzere tezde yapılan işlemler ve bu işlemlerin sırası akış şeması içinde gösterilmiştir: i) panoramik x-ray görüntüler, ii) histogram eşitleme, iii) görüntülerin alt-örnekleme, iv) makine öğrenmesi için öznitelik çıkarılması, v) makine öğrenme modelinin oluşturulması ve modelden sonuç alınması, vi) modelin sonucunda oluşan görüntüler, vii) diş bölgesi için optimizasyon ile şekil uydurma, viii) görüntülerdeki diş bölgelerinin maskeleri ile panoramik x-ray görüntülerin birleştirilerek diş bölgesinin derin öğrenme modeli için belirlenmesi, ix) derin öğrenme modelinin oluşturulması, x) chan-veve için dişleri içeren çerçeveler ve piksel lokasyonları ile makine öğrenme modelinin sonucunun birleştirilmesi, xi) dişlerin bölütlenmesi.



Şekil 2.1: Uygulanan yöntemlerin yapılış ve oluşturuluş diagramı.

X-Ray cihazından gelen görüntüler neredeyse gerçek zamanlı olarak işlenerek görüntüler içindeki dişlerin bölütlenmesi gerçekleştirilmiştir. İlk önce görüntüler makine öğrenme modeli için hazırlanmış ve veri kümesine dönüştürülmüştür. Makine öğrenmesi modelinin sonucunda oluşan yeni görüntüler şekil uydurma optimizasyonu ve dişlerin bölütlenmesi için kullanılmıştır. Derin öğrenme modeli sonucu ile şekil uydurma optimizasyonunun

sonucu birleştirilerek dişlerin bölütlenme işlemi Chan-Vese ile yapılmıştır.

2.3 Veri Seti

Bu bölümde kullanılan veri setinin eldesine ilişkin altyapılara kısaca değinilecektir.

2.3.1 X-Ray görüntüleme

X-Ray, elektromanyetik ışınlar grubuna aittir, bu nedenle elektromanyetik radyasyon kurallarına uyarlar. Elektromanyetik radyasyon, radyant enerji olarak da adlandırılan enerjiiyi, tıpkı radyo dalgaları, görünür ışık veya mikrodalgalar gibi dalgalar ve fotonlar aracılığıyla uzayda taşır. Fotonlarla veya bir dalga modeliyle temsil edilebilir. Radyasyon, dalganın bir periyodunun uzunluğu olan dalga boyu λ_p ile sınıflandırılabilir. Dalga boyu ayrıca frekans f_p ve dalgaların yayılma hızı, yani ışık hızı c_0 , ile temsil edilebilir [9].


$$\lambda_p = \frac{c_0}{f_p} \quad (2.1)$$

Denklem (2.1)'de fotonların enerjisi verilir, burada h , Planck sabitini ($\approx 6.626,069 \times 10^{-34} Js$) ve c_0 , ışık hızını ($\approx 2.997,92 \times 10^8 ms^{-1}$) gösterir. Enerji doğrudan fotonun dalga boyu λ_p veya frekansı f_p ile ilişkilidir ve birimi elektron voltur (eV). Foton enerjisinin frekansı ile orantılı ve dalga boyuyla ters orantılı olduğunu kolayca elde edebiliriz, yani frekansı ne kadar yüksekse enerjisi o kadar yüksek olur[9].

$$E_p = \frac{hc_0}{\lambda_p} = f_p h \quad (2.2)$$

Enerji ayrıca elektromanyetik radyasyonu, radyo dalgaları, mikrodalgalar, kızılötesi (IR), görünür ışık, ultraviyole (UV) ışık, X-Ray ve γ -ays gibi farklı gruplara ayırmak için kullanılır. Şekil 2.2 bu grupları karakteristik frekans ve dalga boyu aralıklarına göre göstermektedir. Çoğu X-Ray dalga boyunun 0.01 nm ila 10 nm arasındadır. Bu 100 keV ila 100 eV arasında bir enerji aralığına karşılık gelir [9].


X-Ray, farklı malzemelerden geçtiğinde belirli bir miktarda enerji kaybeder. Enerji kaybı, malzemenin emme davranışına bağlıdır. Örneğin, X-Ray 10 cm sudan geçerse, 10 cm kemikten geçeceklerinden daha az enerji kaybederler. Enerjinin azalmasına geleneksel röntgen görüntülemenin ana prensibi olan emilim neden olur. Genel olarak, X-Ray radyografisi enerji kaybı miktarını ölçer. Bu enerji kaybı farklı malzemeler için farklılık gösterdiğinden, görüntüde belirli bir kontrast görebiliriz. Örneğin, bir X-Ray görüntüsü yumuşak doku için yüksek yoğunlukları ve X-Ray kemiklerden geçtiği düşük yoğunlukları gösterir [9].



Şekil 2.2: Farklı elektromanyetik radyasyon gruplarının dalga boyları ve frekansları [9].

Klasik bir X-Ray tüpü: X-Ray fotonlarını oluşturmak için elektronların katottan anoduna nasıl hızlandığını gösteren bir şematik Şekil 2.3'de gösterilmektedir. Bir X-Ray tüpü temel olarak bir katot ve içinde bir katı metal anot bulunan camdan yapılmış boşaltılmış bir tüptür. Termiyonik emisyon katottaki ısıtılmış filaman tarafından meydana gelir. Isıyla indüklenen elektronlar e^- üretilir, çünkü filaman malzemesine uygulanan termal enerji bağlama enerjisinden daha büyüktür. Daha sonra elektronlar, tüpün negatif katot ile pozitif anot arasındaki hızlanma voltajı ile hızlandırılır. Bu hızlı elektronlar anoda çarptığında, yavaşlar ve anot malzemesinin atomlarının elektrik alanı tarafından saptırılır. Yüklenen partiküllerde herhangi bir hızlanma elektromanyetik dalgalara neden olur. Anot, ortaya çıkan X-Ray doğru yönde yönlendirmek için belirli bir açıyla eğilir. Tipik olarak her elektron birkaç kez yavaşlatılır veya döndürülür, böylece birkaç foton oluşturulmasına neden olur. Bununla birlikte, bir elektronun tüm hızını ve dolayısıyla enerjisini bir adımda kaybetmesi de olabilir. Bu durumda, elektronun tam enerjisini içeren sadece bir foton oluşturulur [9].

Radyografi, X-Ray ilgi duyulan bir anatomiyi açığa çıkararak ve nesneden geçerken maruz kaldıkları zayıflamayı ölçerek iki boyutlu projeksiyon görüntüleri oluşturma sürecidir. X-ışını görüntülemenin çok yaygın bir şeklidir ve dünyadaki kliniklerde kullanılır. Ana uygulama alanı dişlerin ve iskelet sistemindeki kırıkların ve değişikliklerin incelenmesidir. Burada, çevreleyen dokuya kıyasla kemiklerin ve dişlerin yüksek zayıflama katsayısı iyi bir kontrast sağlar ve kırıkların belirgin bir şekilde saptanmasına ve sınıflandırılmasına izin verir. Ayrıca, radyografi bir kemiğin veya dişin kıvamındaki veya yoğunluğundaki değişiklikleri tespit etmek için kullanılabilir [9].



Şekil 2.3: Vakum X-Ray tüpü [9].

2.3.2 Farklı x-ray görüntülemeler

İki ana tip dış röntgeni vardır: i) intraoral (röntgen filmi ağız içinde) ve ii) ekstraoral (röntgen filmi ağız dışında) [10].

Intraoral röntgenler en yaygın röntgen türüdür. Birkaç tip intraoral röntgen vardır. Her biri dişlerin farklı yönlerini gösterir [10].

- Bitewing X-Ray, ağızın bir bölgesindeki üst ve alt dişlerin ayrıntılarını gösterir. Her bitewing, dişini tepesinden (açıkta kalan yüzey) destek kemiğin seviyesine kadar gösterir. Bitewing X-Ray dişler arasındaki çürümeyi ve dişeti hastalığının neden olduğu kemik kalınlığındaki değişiklikleri tespit eder. Bitewing X-Ray ayrıca bir kronun (dişi tamamen çevreleyen bir kapak) veya diğer restorasyonların (köprüler gibi) uygun uyumunun belirlenmesine yardımcı olabilir. Ayrıca diş dolgularının yıpranmasını veya bozulmasını da görebilir [10].
- Periapikal X-Ray tüm dişi gösterir. Her periapikal röntgen, tüm dişleri üst veya alt çenenin bir bölümünde gösterir. Periapikal X-Ray, kök ve çevresindeki kemik yapılarında olağandışı değişiklikleri tespit eder [10].
- Oklüzal röntgenler, üst veya alt çeneye tüm diş kemerinin gelişimini ve yerleşimini izler [10].

Ekstraoral röntgenler çene ve kafatasındaki diş problemlerini tespit etmek için kullanılır. Birkaç tip ekstraoral röntgen vardır [10].

- Panoramik röntgenler tüm ağız bölgesini - hem üst hem de alt çenelerdeki tüm dişleri - tek bir röntgende gösterir. Bu röntgen, tamamen ortaya çıkan ve aynı zamanda ortaya çıkan dişlerin konumunu tespit eder, gömülü dişleri görebilir ve tümörlerin teşhis edilmesine yardımcı olur [10].
- Tomogramlar ağızda belirli bir katman veya “dilim” gösterir ve diğer katmanları bulanıklaştırır. Bu röntgen, yakınlardaki diğer yapıların görüşü engellediği için açıkça görülmesi zor yapıları inceler [10].
- Sefalometrik projeksiyonlar kafanın tüm tarafını gösterir. Bu röntgen dişleri bireyin çene ve profiline göre inceler. Ortodontistler bu röntgeni her hastanın kendine özgü diş hizalama yaklaşımını geliştirmek için kullanırlar [10].
- Sialogram, tükürük bezlerine enjekte edilen bir boya kullanır, böylece X-ışını filminde görülebilirler. (Tükürük bezleri, bir röntgen ile görülmeyecek yumuşak dokulardır.) Diş hekimleri, bu testi tıkanıklık veya Sjogren sendromu (ağız kuruluğu ve kuru gözler dahil semptomları olan bir bozukluk; bozukluk diş çürütmesinde rol oynayabilir) [10].
- Dental bilgisayarlı tomografi (BT), iç yapılara 3 boyutlu (üç boyutlu) bakan bir görüntüleme türüdür. Bu tip görüntüleme, kist, tümör ve kırık gibi yüzün kemiklerindeki problemleri bulmak için kullanılır [10].
- Koni ışınlı BT, diş yapıları, yumuşak doku, sinirler ve kemiğin 3 boyutlu görüntülerini oluşturan bir X-ışını türüdür. Diş implantının yerleştirilmesine yardımcı olur ve ağız ve yüzdeki kistleri ve tümörleri değerlendirir. Ayrıca diş etlerinde, diş köklerinde ve çenelerde problemler de görülebilir. Konik ışın BT bazı yönlerden normal dental BT’ye benzer. Her ikisi de doğru ve yüksek kaliteli görüntüler üretir. Ancak, görüntülerin alınma şekli farklıdır. Koni ışınlı CT makinesi hastanın kafasının etrafında döner ve tüm verileri tek bir dönüşte yakalar. Geleneksel CT taraması, makine hastanın başı çevresinde birkaç devir yaparken “düz dilimler” toplar. Bu yöntem ayrıca hastaları daha yüksek bir radyasyon seviyesine maruz bırakır. Koni ışın CT’sinin benzersiz bir avantajı, bir dişçi ofisinde kullanılabilmesidir. Dental bilgisayarlı BT ekipmanı yalnızca hastanelerde veya görüntüleme merkezlerinde bulunur [10].
- Dijital görüntüleme, görüntülerin doğrudan bir bilgisayara gönderilmesini sağlayan 2 boyutlu bir dental görüntüleme türüdür. Görüntüler birkaç saniye içinde ekranda izlenebilir, kaydedilebilir veya basılabilir. Dijital görüntülemenin geleneksel X-ışınlarına kıyasla başka avantajları da vardır. Örneğin bir dişten

alınan görüntü büyütülebilir ve büyütülebilir. Bu, diş hekiminizin sözlü sınavda görülemeyen en küçük değişiklikleri görmesini kolaylaştırır. Ayrıca, gerekirse, görüntüler ikinci bir görüş için başka bir diş hekimine veya uzmanına veya yeni bir dışçıye elektronik olarak gönderilebilir. Dijital görüntüleme ayrıca X-ışınlarından daha az radyasyon kullanır [10].

- MR görüntüleme, çene ve dişler de dahil olmak üzere ağız boşluğunun 3-D görüntüsünü alan bir görüntüleme yöntemidir [10]. (Bu yumuşak doku değerlendirmesi için idealdir.)

Tez kapsamında kullanılan görüntüler, ekstraoral röntgenlerden panoramik X-Ray görüntüleme ile oluşturulmuştur.

2.3.3 Görüntülerin hazırlanması

Görüntülerin hazırlanmasında iki temel aşama vardır: i) Histogram eşitleme (HE) ve ii) görüntülerin alt-örnekleme.

Histogramlar sayısız uzamsal alan işleme tekniklerinin temelini oluşturur. Histogram manipülasyonu görüntü geliştirme için kullanılabilir, faydalı görüntü istatistikleri sağlar ve histogramlardaki doğal bilgiler görüntü sıkıştırma ve segmentasyonda oldukça faydalıdır. Kontrast geliştirmeye istinaden, karanlık bir görüntünün histogramındaki bileşenlerin yoğunluk ölçeğinin alt tarafında yoğunlaştığı gözlemlenir. Düşük kontrastlı bir görüntü, tipik olarak yoğunluk ölçeğinin ortasına doğru yerleştirilmiş dar bir histograma sahiptir. Tek renkli bir görüntü için bu donuk, yıkanmış gri bir görünüm anlamına gelir. Yüksek kontrastlı bir görüntüde, histogram bileşenleri genişlik yoğunluk ölçeğini kapsar, piksellerin dağılımı düzgün olmaktan çok uzak değildir, çok az dikey çizgi diğerlerinden çok daha yüksektir [11].

Histogram Eşitleme, yüksek verimlilik ve sadeliği nedeniyle görüntü kontrastını artırmak için en yaygın kullanılan yöntemlerden biridir. Kümülatif dağılım fonksiyonu kullanılarak yoğunluk dağılımının normalleştirilmesiyle elde edilir, böylece elde edilen görüntü, düzgün bir yoğunluk dağılımına sahip olabilir. Kullanılan dönüşüm fonksiyonuna göre küresel veya yerel olmak üzere iki branşta sınıflandırılabilir: Küresel histogram eşitleme (GHE) basit ve hızlıdır, ancak kontrast geliştirme gücü nispeten düşüktür. Yerel histogram eşitleme (LHE) ise genel kontrastı daha etkili bir şekilde artırabilir. HE geliştirmenin yararlı uygulamaları arasında tıbbi görüntü işleme, genellikle histogram modifikasyonu ile kullanılan konuşma tanıma ve doku sentezi vardır. Görüntü geliştirme için histogram tabanlı teknikler çoğunlukla görüntünün histogramını eşitlemeye ve görüntüye karşılık gelen dinamik aralığı arttırmaya dayanır [11].

Diyelim ki $X = X(i, j)$ dijital bir görüntüyü ifade etsin, burada $X(i, j)$ (i, j) noktalarında pikselin gri seviyesini belirtir. Görüntü piksellerinin toplam sayısı n 'dir ve görüntü yoğunluğu $X_0, X_1, X_2 \dots X_{L-1}$ olan L seviyelerine dönüştürülür. Dolayısıyla $\forall X(i, j) \in X_0, X_1, X_2 \dots X_{L-1}$ olduğu açıktır. n_k 'nin görüntüdeki gri X_k seviyesine sahip toplam piksel sayısını ifade ettiğini varsayalım, o zaman X_k 'nin olasılık yoğunluğu [11]:

$$p(X_k) = \frac{n_k}{n} \quad k = 0, 1, \dots, L-1 \quad (2.3)$$

$p(X_k)$ ve X_k arasındaki ilişki olasılık yoğunluk fonksiyonu (PDF) olarak tanımlanır ve PDF'nin grafik görünümü histogram olarak bilinir. PDF görüntülerine dayanarak, kümülatif dağıtım işlevi şu şekilde tanımlanmıştır [11]:

$$c(X_k) = \sum_{j=0}^{L-1} p(X_j) = \sum_{j=0}^{L-1} \frac{n_j}{n} \quad (2.4)$$

Burada, $k = 0, 1 \dots L-1$ ve $c(X_{L-1}) = 1$ olduğu görülmektedir. Kümülatif yoğunluk fonksiyonuna dayalı bir dönüşüm fonksiyonu $f(x)$ tanımlanırsa [11]:

$$f(x) = X_0 + (X_{L-1} - X_0)c(x) \quad (2.5)$$

Daha sonra HE'nin çıktı görüntüsü, $Y = Y(i, j)$, olarak ifade edilebilir:

$$Y = f(x) = f(X(i, j)) \quad \forall X(i, j) \in X \quad (2.6)$$

Görüntü hazırlama sürecinin son aşamasında ise HE kullanılarak elde edilen yeni görüntülerin alt-örnekleme yapılmasıdır.

Görüntü ölçeklemenin temel konsepti, yeni örnekleme ızgarasında iki boyutlu bir işlevi yeniden örnekleme. Kutu-filtre seçiminin bir başka nedeni hesaplama karmaşıklığıdır. Hesaplama karmaşıklığı, aşağı ölçeklendirme için kullanılan iki-küçük ve iki-doğrusal filtreler gibi diğer filtreler kıyasla çok düşüktür [12].

Kutu filtresi en basit doğrusal filtredir. Hesaplanan her piksel, o pikselde ortalanmış bir kare (filtre penceresi) içindeki piksel değerlerinin ortalamasıdır. Kutu filtresi ve diğer doğrusal filtreler arasındaki fark, geri kalanının ağırlıklı bir ortalama kullanmasıdır. Hesaplama hedef pikseli, ortalama penceresini yatay veya dikey olarak hareket ettirmektir. P , hedeflenen pikselin piksel değeri olsun. $F_{i,j}$, $i, j = 1, \dots, n$ orijinal görüntüdeki piksel değerlerini gösterebilir. Burada r , filtrenin yarıçapı olsun. Hedeflenen piksel değerinin formülü [12]:

$$P_{i,j} = \frac{1}{4r^2} \sum_{k=0}^m \sum_{l=0}^n F_{i+k,j+l} \quad i, j = (m+1), \dots, (n-m) \quad (2.7)$$

2.4 ML Modeli

Bu bölümde kullanılan ML modelinin eldesine ilişkin altyapılara kısaca değinilecektir.

2.4.1 ML tanımı

Makine öğrenimi, bilgisayarlara açıkça programlanmadan nasıl öğrenileceğini ve hareket edileceğini öğretmeyi amaçlayan bir bilgisayar bilimi alanıdır. Daha spesifik olarak, makine öğrenimi, programların deneyim yoluyla "öğrenmesine" izin veren modeller oluşturmayı ve uyarlamayı içeren veri analizine bir yaklaşımdır. Makine öğrenimi, tahmin yapma yeteneklerini geliştirmek için modelleri uyarlayan algoritmaların oluşturulmasını içerir. Makine öğreniminin ilk kullanımları ve tartışmaları 1950'lere dayanır ve benimsenmesi son yıllarda önemli ölçüde artmıştır. Makine öğreniminin yaygın uygulamaları arasında görüntü tanıma, doğal dil işleme, yapay zeka tasarımı, kendi kendine giden araba teknolojisi ve web arama algoritmaları bulunur. Makine öğrenme yöntemlerinin uygulanabileceği birçok farklı uygulama vardır. Aşağıda, makine öğrenme stratejileri ve yöntemlerinin birçok uygulamasından birkaçı bulunmaktadır [13]:

- **Doğal dil işleme (NLP)**, bilgisayar ve doğal (insan) diller arasındaki etkileşimlerle ilgilenen bir bilgisayar bilimi alanıdır. Doğal dil işlemenin başlıca vurguları arasında konuşma tanıma, doğal dil anlama ve doğal dil oluşturma sayılabilir. Makine öğrenme yöntemleri bu alanların her birine uygulanabilir [13].
- **Sigorta endüstrisi** makine öğrenmesini çeşitli şekillerde uygulamaktadır. En ilginç yanı, birçok şirket, sigorta primlerini fiyatlandırmak ve kullanılacak gelecek iddiaları hakkında tahminlerde bulunmak için makine öğrenme algoritmaları kullanıyor. Buna ek olarak, sigorta ve bankacılık sektörlerindeki bazı şirketler dolandırıcılığı tespit etmek için makine öğrenimini kullanıyor [13].
- **Biyolojik verilerin** miktarları araştırmacılar tarafından derlenerek katlanarak artıyor. Bu, verimli veri depolama ve yönetimi ile birlikte bu verilerden yararlı bilgiler alabilme sorunlarına yol açmıştır. Halen biyolojik verileri verimli ve kullanışlı bir şekilde saklamak ve depolanan verilerden akıllıca anlam çıkarmak için makine öğrenme yöntemleri geliştirilmektedir. Ayrıca çeşitli hastalıkları sınıflandırmak ve daha iyi anlamak için makine öğrenimi ve örüntü tanıma tekniklerini tıbbi kayıtlara uygulamak için çaba harcanmaktadır. Bu yaklaşımların ayrıca belirli hastalık için en fazla risk altında olan popülasyon bölümlerini belirleyerek hastalığın teşhisine yardımcı olması beklenmektedir [13].

- **Görüntü işleme ve kalıp tanımlamada** makine öğrenmesini çeşitli şekillerde uygulamaktadır. Kalıpları tanımlamak ve görüntüler, videolar ve diğer medya dosyalarındaki nesnelere tanımlamak için bilgisayar kullanmak, makine öğrenme teknikleri olmadan çok daha az pratiktir. Tanımlamak istediğiniz her nesne için belirli bir kodun yazılması gerekiyorsa, bir görüntü içindeki nesnelere tanımlamak için program yazmak çok pratik olmaz. Bunun yerine, görüntü sınıflandırıcılar olarak da adlandırılan görüntü tanıma algoritmaları, görüntüleri içeriklerine göre sınıflandırmak için eğitilebilir. Bu algoritmalar, önceden sınıflandırılmış birçok örnek görüntüyü işleyerek eğitilir. Önceden işledikleri görüntülerin benzerliklerini ve farklılıklarını kullanarak, bu programlar her yeni görüntüyü işlediklerinde modellerini güncelleyerek gelişir. Görüntü işlemede kullanılan bu tür makine öğrenimi genellikle yapay bir sinir ağı kullanılarak yapılır ve derin öğrenme olarak bilinir [13].
- **Web araması** makine öğrenmesini çeşitli şekillerde uygulamaktadır. Web araması ayrıca, arama sonuçlarını iyileştirmek ve kullanıcı sorgularını daha iyi anlamak için kullanarak derin öğrenmenin kullanılmasından da yararlanır. Sorgu ve sunulan sonuçlara karşı kullanıcı davranışını analiz ederek, Google gibi şirketler arama sonuçlarını iyileştirebilir ve belirli bir sorgu için en iyi sonuç kümesinin ne olduğunu anlayabilir. Arama önerileri ve yazım düzeltmeleri, tüm kullanıcıların toplu sorgularında makine öğrenme taktikleri kullanılarak da oluşturulur [13].
- **Algoritmik ticaret ve piyasa analizi**, finansal piyasalarda makine öğrenimi ve yapay zekanın ana kullanımı haline gelmiştir. Fon yöneticileri artık trendlerdeki değişiklikleri belirlemek ve hatta işlem yapmak için derin öğrenme algoritmalarına güveniyor. Bu otomatik yaklaşımı kullanan fonlar ve tüccarlar, eğilimleri tespit etmek ve işlem yapmak için el ile bir yaklaşım benimsiyorlarsa, işlemleri mümkün olandan daha hızlı hale getirir [13].

Makine öğrenimi algoritmalarının tümü, daha fazla veri kümesi işledikçe doğruluklarını öğrenmeyi ve geliştirmeyi amaçlar. Makine öğrenimi algoritmalarının çözdüğü görevleri sınıflandırabilmemizin bir yolu, sisteme ne kadar geri bildirim sunduklarıdır. Bazı senaryolarda, bilgisayara denetimli öğrenme adı verilen önemli miktarda etiketlenmiş eğitim verisi sağlanır. Diğer durumlarda, etiketli veri sağlanmaz ve bu denetimsiz öğrenme olarak bilinir. Son olarak, yarı-denetimli öğrenmede, bazı etiketlenmiş eğitim verileri sağlanır, ancak eğitim verilerinin çoğu etiketsizdir [13].

Daha önceki çalışmalarda [2], denetimsiz öğrenme kullanılarak dışların bölütlenmesi düzgün yapılamamıştır. Bu yüzden tezde kullanılan yöntem, daha iyi sonuçlar alabilmek için denetimli öğrenmedir.

2.4.2 Denetimli öğrenme

Denetimli öğrenme, makine öğreniminin en pratik ve yaygın olarak benimsenen şeklidir. Giriş değişkenlerini tercih edilen çıkış değişkenleriyle ilişkilendiren bir matematiksel fonksiyon oluşturmayı içerir. Bilgisayarın işleyeceği verilere örnekler veren büyük miktarda etiketlenmiş eğitim veri seti sağlanır. Denetimli öğrenme görevleri ayrıca "sınıflandırma" veya "regresyon" problemleri olarak kategorize edilebilir. Sınıflandırma sorunları, "dış" veya "dış değil" gibi bir sınıflandırma çıktısı almak için istatistiksel sınıflandırma yöntemlerini kullanır. Regresyon problemleri ise sayısal çıktılar sağlamak için istatistiksel regresyon analizini kullanmaktadır [13].

Denetimli makine öğrenme algoritmaları, dış yardıma ihtiyaç duyan algoritmalarıdır. Giriş veri kümesi eğitim ve test veri kümesine ayrılmıştır. Eğitim veri kümesinin tahmin edilmesi veya sınıflandırılması gereken çıktı değişkeni vardır. Tüm algoritmalar, eğitim veri kümesinden bir tür desen öğrenir ve tahmin veya sınıflandırma için test veri kümesine uygular [14].

2.4.3 Denetimsiz öğrenme

Doğru yanıtlar veya hedefler sağlanmaz. Denetimsiz öğrenme tekniği, girdi verileri arasındaki benzerlikleri bulmaya çalışır ve bu benzerliklere dayanarak, denetimsiz öğrenme tekniği verileri sınıflandırır. Bu aynı zamanda yoğunluk tahmini olarak da bilinir. Denetimsiz öğrenme kümeleme içerir [15].

Denetimsiz öğrenme algoritmaları verilerden çok az özellik öğrenir. Yeni veriler eklendiğinde, verilerin sınıfını tanımak için önceden öğrenilen özellikleri kullanır. Temel olarak kümeleme ve özellik azaltma için kullanılır [14].

2.4.4 Yarı denetimli öğrenme

Yarı denetimli öğrenme algoritmaları, hem denetimli hem de denetimsiz öğrenmenin gücünü birleştiren bir tekniktir. Etiketlenmemiş verilerin zaten mevcut olduğu ve etiketli verilerin elde edilmesinin sıkıcı bir süreç olduğu makine öğrenimi ve veri madenciliği alanlarında kullanışlı olabilir [14].

Yarı denetimli öğrenme tekniği, denetimli öğrenme tekniklerinin bir sınıfıdır. Bu öğrenme aynı zamanda eğitim amaçlı etiketlenmemiş verileri de kullanmıştır (genellikle çok miktarda etiketlenmemiş veri içeren minimum miktarda etiketlenmiş veri) [15].

2.4.5 Kümeleme problemi

Kümeleme, verilerin benzer nesne gruplarına bölünmesidir. Küme adı verilen her grup, kendi aralarında benzer ve diğer grupların nesnelere göre farklı nesnelere

oluşur. Verileri daha az kümeyle temsil etmek zorunlu olarak bazı ince ayrıntıları kaybeder, ancak basitleştirme sağlar. Birçok veri nesnesini birkaç kümeyle temsil eder ve bu nedenle verileri kümelerine göre modeller. Küme analizi, desenlere (genellikle bir ölçüm vektörü veya çok boyutlu bir alanda bir nokta olarak temsil edilir) benzerlik temelinde kümeler halinde organize edilmesidir. Geçerli bir kümedeki kalıplar, farklı bir kümeyle ait bir kalıptan daha benzerdir. Bu kümeleme (denetimsiz sınıflandırma) ve ayrımcılık analizi (denetimli sınıflandırma) arasındaki farkı anlamak önemlidir. Denetimli sınıflandırmada, etiketli (önceden sınıflandırılmış) desenlerden oluşan bir koleksiyon sağlanır; sorun yeni karşılaşılan, ancak etiketlenmemiş bir deseni etiketlemektir. Tipik olarak, verilen etiketli (eğitim) desenler yeni bir kalıbı etiketlemek için kullanılan sınıfların tanımlarını öğrenmek için kullanılır. Kümeleme durumunda sorun, belirli bir etiketlenmemiş kalıp koleksiyonunu anlamlı kümeler halinde gruplandırmaktır. Bir anlamda, etiketler kümelerle de ilişkilidir, ancak bu kategori etiketleri veriye dayalıdır; yani, sadece verilerden elde edilirler. [16].

Aşağıda en çok kullanılan kümeleme algoritmalarından ikisi bulunmaktadır:

- ***K-Means***

Kümeleme, bir veri kümesini belirli sayıda gruba bölme yöntemidir. Popüler yöntemlerden biri K-Means yöntemidir. K-Means kümelemede, bir veri kümesini k kadar veri grubuna ayırır. Belirli bir veri kümesini ayrık kümenin k sayısına sınıflandırır. K-Means algoritması iki ayrı aşamadan oluşur. İlk aşamada k kadar merkez hesaplar ve ikinci aşamada her noktayı ilgili veri noktasından en yakın merkeze olan kümeyle götürür. En yakın merkeze mesafesini tanımlamak için farklı yöntemler vardır ve en çok kullanılan yöntemlerden biri Öklid mesafesidir [17].

- ***PCA***

PCA, bir dizi olası ilişkili değişkeni, temel bileşenler olarak adlandırılan daha az sayıda ilişkisiz değişkene dönüştüren matematiksel bir prosedürdür. PCA genel olarak aşağıda gösterildiği gibi “görüntü vektörünün öznelik vektörüne doğrusal bir dönüşümü” olarak ifade edilebilir [18]:

2.4.6 Regresyon problemi

Regresyon birçok ortamda tahmin için yaygın olarak kullanılmaktadır (örneğin, sigorta veya kredi riski tahmini, kişiselleştirilmiş ilaç, pazar analizi). Bir regresyon görevinde, bir kayıp fonksiyonunu en aza indiren bir model öğrenerek, bir dizi öngörücü değişken kullanılarak sayısal bir cevap değişkeni tahmin edilir. Regresyon,

sayısal öngörülen değerleri sınıf etiketleriyle eşleştirerek sınıflandırma görevleri için de kullanılabilir olduğundan güçlüdür [19].

Aşağıda en çok kullanılan regresyon algoritmalarından üçü bulunmaktadır:

- **OLS**

OLS regresyon algoritması, eğitim veri kümesinde gözlenen y_i ve doğrusal model tarafından öngörülen $f(x_i)$ değerleri arasındaki kalan kareler toplamını en aza indirerek doğrusal bir modelleme yapar [20].

Bununla birlikte, OLS regresyonu, veri gürültülü olduğunda aşırı ezberleme eğilimindedir, bu nedenle, elde edilen model, eğitim örneklerini tahmin ederken iyi performans gösterir, ancak yeni / görünmeyen bir örnek tahmin edilirken başarısız olur [20].

- **Elastik ağ**

Elastik-ağ regresyonu, OLS maliyet fonksiyonunda L1-norm ve L2-norm düzenlemelerini birleştirilmesi ile olmaktadır [20].

Eğitim verilerindeki tahmin hatası ile düzenlenmesi arasındaki dengeyi, yani yanlılık ile sapma arasındaki cezaların dengelenmesini kontrol etmek için bir düzenleme parametresi λ kullanılır [20].

- **SVM**

Regresyon problemleri için Destek Vektör Makineleri (SVM) ikinci dereceden bir optimizasyon problemi çözülerek eğitilir Destek vektörler arasındaki ilişki bir tolerans parametresi ile ayarlanabilir. Bu sayede daha gürbüz bir model oluşturulabilir [21].

2.4.7 Sınıflandırma problemi

Sınıflandırma, insan faaliyetlerinin en sık karşılaşılan karar verme görevlerinden biridir. Bir nesnenin, önceden tanımlanmış bir grup veya sınıfa, o nesneyle ilgili gözlenen birkaç özneliğe göre atanması gerektiğinde bir sınıflandırma sorunu ortaya çıkar. Sınıflandırma problemleri olarak tanımlanan birçok endüstriyel problem vardır. Örnek olarak, borsa tahmini, hava tahmini, iflas tahmini, tıbbi teşhis, konuşma tanıma, karakter tanıma verilebilir [22].

Aşağıda en çok kullanılan sınıflandırma algoritmalarından üçü bulunmaktadır:

- **Lojistik regresyon**

Lojistik regresyon, bağımlı değişkenin ikilik (ikili) olduğu bir veri kümesini analiz etmek için istatistiksel bir yöntemdir. Lojistik regresyon, bir bağımlı ikili

değişken ile bir veya daha fazla bağımsız değişken arasındaki ilişkiyi bulmak için kullanılır. Her bağımsız değişken ağırlıklarla çarpılır ve toplanır. Bu sonuç, 0 ile 1 arasında bir sonuç bulmak için sigmoid fonksiyonuna eklenecektir. 0.5'in üzerindeki değerler 1 ve 0.5'in altındaki değerler 0 olarak kabul edilir [23, 24].

- **K-NN**

K-NN algoritması, basitliği ve düşük hata oranı ile desen tanıma ve veri madenciliğinde sınıflandırma için yaygın olarak uygulanır. Algoritmanın prensibi, öznitelik uzayındaki bir sorgu noktası q_i 'ye en çok benzeyen k örneklerinin çoğunun belirli bir kategoriye ait olması durumunda, sorgu noktasının q_i 'nin bu kategoriye girdiği sonucuna varılabilir. Benzerlik, öznitelik uzayındaki mesafe ile ölçülebilir, bu nedenle bu algoritmaya K-En Yakın Komşu algoritması denir [25]. Eğitim veri setinin kalitesi doğrudan sınıflandırma sonuçlarını etkiler. Aynı zamanda, k parametresinin seçimi de çok önemlidir, çünkü farklı k farklı sınıflandırma etiketlerine neden olabilir [25].

- **RF**

Rassal orman algoritması, karar ağacı modeline dayanan bir grup sınıflandırıcı algoritmasıdır. Ön yükleme örnekleme yaklaşımı kullanılarak orijinal veri kümesinden k farklı eğitim veri alt kümeleri oluşturur ve ardından bu alt kümeleri eğiterek k karar ağaçları oluşturulur. Sonunda bu karar ağaçlarından rastgele bir orman inşa edilir. Test veri kümesinin her bir örneği tüm karar ağaçları tarafından tahmin edilir ve bu ağaçların oylarına bağlı olarak nihai sınıflandırma sonucu döndürülür. Orijinal eğitim veri kümesi $S = (x_i, y_j), i = 1, 2, \dots, N; j = 1, 2, \dots, M$ şeklinde belirtilmiştir, burada x örnek olarak ve y öznitelik olarak verilmiştir. Orijinal eğitim veri kümesi N örnek içerir ve her örnekte M öznitelik değişkenleri vardır [26].

RF algoritmasının yapım aşamaları aşağıdaki gibidir[26]:

1. k eğitim alt kümeleri, orijinal eğitim veri kümesi S 'den bir önyükleme örnekleme biçiminde örneklenir. Yani N kayıtları, her bir örnekleme zamanında rastgele bir örnekleme ve değiştirme yöntemiyle S 'den seçilir. Mevcut adımdan sonra, k eğitim alt kümeleri S_{Train} eğitim alt kümelerinin bir koleksiyonu olarak oluşturulur[26]:

$$S_{Train} = \{S_1, S_2, \dots, S_k\} \quad (2.8)$$

2. Karar ağaçları oluşturulur. Her ağacın büyüme sürecinde, veri kümesi S_i 'nin m öznitelik değişkenleri, M değişkenlerinden rastgele seçilir. Her

ağaç düğümünün bölme işleminde, her öznitelik değişkeninin kazanç oranı hesaplanır ve en iyisi bölme düğümü olarak seçilir. Bu ayırma işlemi, bir yaprak düğümü üretilene kadar tekrarlanır. Son olarak, k karar ağaçları aynı şekilde k eğitim alt kümelerinden eğitilir[26].

3. Eğitilmiş k kadar karar ağaçları bir RF modelinde toplanır[26].

$$H(X, \theta_j) = \sum_{i=1}^k h_i(x, \theta_j), (j = 1, 2, \dots, m) \quad (2.9)$$

Burada $h_i(x, \theta_j)$ bir meta karar ağacı sınıflandırıcısıdır. X , eğitim veri kümesinin girdi özniteliği vektörleridir ve θ_j , ağacın büyüme sürecini belirleyen bağımsız ve aynı şekilde dağıtılmış rastgele bir vektördür.

Tez kapsamında kullanılan ML algoritması, görüntülerdeki piksellerin "diş" veya "diş değil" şeklinde sınıflandırılmasını sağlamaktadır.

2.4.8 CatBoost algoritması

Gradyan yükseltme, çeşitli pratik görevlerde en son sonuçları elde eden güçlü bir makine öğrenme tekniğidir. Uzun süre boyunca, heterojen özniteliklerle, gürültülü verilerle ve karmaşık bağımlılıklarla ilgili problemleri öğrenmek için birincil yöntem olmaya devam etmiştir: web araması, öneri sistemleri, hava tahmini ve diğerleri. Fonksiyonel alanda gradyan inişine karşılık gelen açgözlü bir prosedürle daha zayıf modelleri (baz tahmincileri) birleştirerek yineleyicilerin nasıl güçlü bir şekilde oluşturulabileceğini açıklayan güçlü teorik sonuçlarla desteklenmektedir. Gradyan artırımının en popüler uygulamaları karar ağaçlarını temel öngörücüler olarak kullanır. Karar ağaçlarını sayısal öznitelikler için kullanmak uygundur, ancak pratikte birçok veri seti, tahmin için de önemli olan kategorik öznitelikler içerir. Kategorik öznitelikler, birbiriyle karşılaştırılması gerekmeyen ayrı bir değer kümesine sahip bir özniteliktir [27].

CatBoost, sıralı ve düz olmak üzere iki yükseltme moduna sahiptir[28].

$D = \{(x_k, y_k)\}_{k=1, \dots, n}$ örneklerinin bir veri kümesini gözlemlediğimizi varsayalım, burada $x_k = (x_k^1, \dots, x_k^m)$ m özniteliklerin rastgele bir vektörü ve $y_k \in R$ hedeftir; ikili veya sayısal bir yanıt olabilir. Asıl amaç F fonksiyonu eğiterek beklenen maliyet fonksiyonunu ($L(F)$) minimize etmektir. Eğitilen F fonksiyonu için bulunacak değer bir önceki eğitim değerine bağlıdır: $F^t = F^{t-1} + \alpha h^t$. Burada α öğrenme oranıdır [28].

$$h^t = \arg \min_{h \in H} E[L(F^{t-1}(x) + h(x))] \quad (2.10)$$


h^t bulmak için genellikle en küçük kareler yaklaşımı kullanılır [28]:

$$h^t = \arg \min_{h \in H} E[-g^t(x, y) - h(x)]^2 \quad (2.11)$$

Burada $g^t(x, y) = \frac{\partial L(y, F^{t-1}(x))}{\partial F^{t-1}(x)}$ olarak alınır [28].

2.4.9 ML modeli için dişlerin etiketlenmesi

Çalışma [2]'de olduğu gibi dişlerin bulunduğu pikselleri içine alacak şekilde dişlerin sınırları işaretlenmiştir. Şekil 2.4'de dişlerin etiketlenme işlemi gösterilmiştir.



Şekil 2.4: Dişlerin etiketlenmesi [2].

2.4.10 Öznitelik çıkartılması

Görüntülerdeki dişleri bulmak için kullanılan öznitelikler şunlardır [8]:

- Piksellerin yeğlilik değerleri, her görüntüde bulunan piksellerin değerleri alınmıştır [8].

- Dişlerin bulunduğu alanın ağırlık merkezine göre x-koordinat değerleri, görüntüdeki yatay eksende ağırlık noktasının merkez (sıfır) olduğu sola doğru azalan ve sağa doğru artan görüntüden görüntüye değişebilen bir koordinat sisteminin her piksel için olan değerleridir. Denklem 2.15'den elde edilen ağırlık merkezi noktasına göre koordinat sistemi oluşturulmuştur [8].
- Dişlerin bulunduğu alanın ağırlık merkezine göre y-koordinat değerleri, görüntüdeki dikey eksende ağırlık noktasının merkez (sıfır) olduğu aşağı doğru azalan ve yukarı doğru artan görüntüden görüntüye değişebilen bir koordinat sisteminin her piksel için olan değerleridir. Denklem 2.15'den elde edilen ağırlık merkezi noktasına göre koordinat sistemi oluşturulmuştur [8].
- Filtre çıktısı, görüntü üzerinde üçe üçlük bir pencere alınarak bu pencere içindeki piksellerin maksimum ve minimum yeşinlik değerlerinin birbirinden çıkarılarak elde edilen yeni piksellerin yeşinlik değerleridir [8].

İlk defa bu tezde ve tezden türetilen bildiride bizim önerdiğimiz ve en önemli ayırt edici öznelik olan göreceli koordinatlar için gereken merkez noktası şu şekilde bulunmuştur: Bir görüntünün (I) yapısı 3x3 pencere içindeki bir diske benzeyen element (V) tarafından genişleme işlemi şu şekilde olmaktadır (Burada I ve V, E^N 'nin alt kümesidir.)[29]:

$$I \oplus V = \{c \in E^N \mid c = a + b, a \in I \text{ ve } b \in V\} \quad (2.12)$$

Benzer şekilde erozyon işlemi şu şekilde olmaktadır (Burada I ve V, E^N 'nin alt kümesidir.)[29]:

$$I \ominus V = \{c \in E^N \mid c + b \in I, b \in V\} \quad (2.13)$$

Denklem (2.12)'den (2.13) çıkarılarak görüntülerdeki enerji noktaları bulunur [8].

$$\nabla I = (I \oplus V) - (I \ominus V) \quad (2.14)$$

Denklem (2.14)'den elde edilen yeni görüntüde sobel filtresi kullanılarak mevcut görüntüde kenarlar bulunmuştur [30]. Bu kenarların dişlerin bulunduğu bölgede yoğunlaştığı gözlemlenmiştir. Sadece bulunan kenarları içeren görüntü S olarak temsil edilmektedir. S_x , görüntüdeki x yönündeki kenarlar; S_y , görüntüdeki y yönündeki kenarlardır. Bu yönlere bağlı kenarların toplamının tüm görüntüdeki kenarlara bölünmesinin sonucunda görüntüde dişlerin bulunduğu alanın ağırlık merkezi bulunmaktadır [8].

$$\alpha = \frac{\sum_x S_x}{\sum_x \sum_y S}, \quad \beta = \frac{\sum_y S_y}{\sum_x \sum_y S} \quad (2.15)$$

Burada α ve β sırasıyla görüntüdeki dışlerin bulunduğu ağırlık merkezinin x ve y noktalarıdır ve bu noktalar merkez kabul edilerek görüntüde bir koordinat sistemi oluşturulmuştur [8].

2.4.11 ML modeli için eğitim, doğrulama ve test verilerinin ayrılması

Elde var olan 50 görüntüden seçilen 20 görüntü test verisi olarak modele hiç gösterilmeden muhafaza edilmiştir ve geri kalan 30 görüntü, K-CV ile eğitim ve doğrulama verileri olarak modelin eğitimi için ayrılmıştır.

Makine öğreniminde temel gereksinimlerden biri, yüksek tahmin ve genelleme yeteneklerine sahip hesaplama modelleri oluşturmaktır. Denetimli öğrenme durumunda, bilinmeyen bir hedef fonksiyonun çıktılarını tahmin etmek için bir karma model eğitilir. Eğitim sürecinin sonunda, son model T 'den gelen giriş örnekleri için doğru çıktıları tahmin etmeli, ancak daha önce görülmemiş verilere iyi genelleme yapabilmelidir. Kötü genelleme, aşırı eğitim ile karakterize edilebilir. Model aşırı eğitiyorsa, sadece eğitim örneklerini ezberler ve eğitim veri kümesinde olmayan kalıplar için de doğru çıktılar veremez. Bu iki önemli talep (ve iyi genellemede iyi tahmin) çelişkilidir ve sapma ve varyans ikilemi olarak da bilinir. Minimum sapma ile modelin minimal varyansı arasında denge sağlamak için kullanılan yaygın bir teknik çapraz doğrulamadır. Bununla birlikte, bu tekniğin temel problemi, uygun veri bölünmesini temsil etmektedir. Veri kümesinin yanlış bölünmesi, özellikle model performansında aşırı yüksek bir varyansa yol açabilir, ancak bu sorunla başa çıkmak için çeşitli karmaşık örnekleme yöntemleri kullanılabilir. Çapraz doğrulama teknikleri, iyi genelleme sağlamak ve aşırı eğitimden kaçınmak için kullanılan geleneksel yaklaşımlara aittir. Temel fikir, veri kümesi T 'yi iki alt kümeye bölmektir - bir alt küme eğitim için kullanılırken, diğer alt küme dışarıda bırakılır ve son modelin performansı değerlendirilir. Çapraz doğrulamanın temel amacı, model performansının istikrarlı ve kendinden emin bir tahminini elde etmektir. Çapraz doğrulama teknikleri, daha fazla model, çeşitli eğitim algoritmaları değerlendirilirken ve karşılıklı olarak karşılaştırılırken veya en uygun model parametreleri aranırken de kullanılabilir. K-CV, model hatasının kararlı bir tahminini elde etmek için daha fazla testin bir kombinasyonunu kullanır. Veri kümesi T , aynı boyuttaki k bölümlerine ayrılmıştır. Bir kısım T_v setini doğrulama (test), diğer kısım ise T_{tr} eğitim setini oluşturur. Bu işlem verinin her bir kısmı için tekrarlanır. Doğrulama ve eğitim verilerinde de "dış" ve "dış değil" sınıflarının bulunması için T veriseti bu duruma göre ayrılır. K-CV algoritmasının adımları aşağıda verilmiştir [31]:

1. T veriseti k sayıda alt veri kümelerine bölünür [31].
2. $T_v \leftarrow T_i$ ve $T_{tr} \leftarrow \{T \setminus T_i\}$ işlemi $i = 1, 2, \dots, k$ için yapılır [31].

3. Model, T_{tr} üzerinde eğitilir ve model performansını değerlendirmek için periyodik olarak T_v kullanılır.

2.4.12 ML modeli için parametre arama

Genellikle, makine öğrenme algoritmalarının çoğu, parametreleri düzgün ayarlanmazsa en iyi sonuçları elde etmez. Yüksek doğruluklu bir sınıflandırma modeli oluşturmak için, güçlü bir makine öğrenme algoritması seçmek ve parametrelerini ayarlamak çok önemlidir. Parametre optimizasyonu, özellikle öğrenme algoritmasının birçok parametresi olduğunda manuel olarak yapılırsa çok zaman alabilir. Parametre arama, aslında hiper parametre uzayının tanımlanmış alt kümesine dayanan kapsamlı bir aramadır. Hiper parametreler minimum değer (alt sınır), maksimum değer (üst sınır) ve adım sayısı kullanılarak belirtilir. Kullanılabilecek üç farklı ölçek vardır: doğrusal ölçek, kuadratik ölçek ve logaritmik ölçek. Her kombinasyonun performansı bazı performans metrikleri kullanılarak değerlendirilir [32].

2.4.13 ML modelinin oluşturulması ve sonuç alınması

Makine öğrenimi için veri seti hazırlanması, eldeki 50 görüntünün eğitim ve test verisi olarak ikiye ayrılması ile yapılmıştır. Bu ayırmada 30 görüntü eğitim ve 20 görüntü test için kullanılmıştır. Makine öğrenmesi modelinin oluşturulmasından önce ise eğitim verisi k-kat çarpaz doğrulama yöntemi ile eğitim ve doğrulama veri setlerine ayrılmıştır [31]. Veri seti hazırlanırken piksellerin yeşillik değerleri ilk sütuna, diğerlerinin bulunduğu bölgenin ağırlık merkezine göre oluşturulmuş x ve y koordinat değerleri sırasıyla ikinci ve üçüncü sütuna ve 3x3 pencere içindeki piksellerin maksimum ve minimum değerlerini çıkartarak elde edilen görüntünün dokusunu veren filtrenin değerlerini dördüncü ve son sütuna yerleştirilmiştir. Her satırı bir pikseli ifade eden bir matris oluşturulmuştur. Makine öğrenme modeli CatBoost algoritması ile oluşturulmuştur [27, 28]. CatBoost algoritması bir gradyan artırma algoritmasıdır. Bu algoritmalar, bu makaledeki gibi özellikle sınıflar arasında dengesizlik olan sınıflandırma problemlerinde diğer algoritmalara göre daha iyi çalışmaktadır. İlk başta CatBoost algoritması eğitim verisinde mevcut özellik sayısının bir fazlası kadar birbirinden bağımsız rastgele permütasyonlar oluşturur. Bu permütasyonların skorlarına bakılarak en iyi eğitim veri seti kümesi oluşturulur ve algoritmaya verilen doğrulama veri setinin skoruna göre sonraki iterasyonda özelliklerin modeli oluşturmadaki ağırlıkları değişir. Model oluşturulmadan önce algoritmaya kullanıcı tarafından verilen hiper parametreler arama algoritması ile otomatik olarak bulunmuştur. Modelin veriyi ezberlememesi ve en iyi sonucu vermesi için karar ağaçlarının derinliği ve dallanma sayısı parametreleri arama algoritması ile belli bir aralıkta aranmıştır. Algoritma, doğrulama veri seti için model

daha iyi sonuç vermiyorsa modelin iterasyonunu durdurma özelliğine sahiptir. Bu yolla model veriyi daha iyi öğrenmiştir [8].

2.5 Dış Bölgesinin Bölütlenmesi

Bu bölümde bu tez için geliştirilen ve bizim önerdiğimiz bir yöntem olan dış bölgesi bölütleme optimizasyon modelinin eldesine ilişkin altyapılara kısaca değinilecektir.

2.5.1 Görüntü üzerinde şekil uydurma

İlgilenilen nesne geometrik bir şekil ile tanımlanabilirse, nesnenin özellikleri geometrik şekil modelinin parametreleri ile tanımlanabilir. Hem aktif şekil modelleri hem de aktif kontur modelleri, modelin görüntü üzerinde belirli bir vektör kuvveti alanına göre yapılandırılmasıyla uygulanır; her vektör, görüntüdeki ilgilenilen bölgelerin kenarlarına veya sırtlarına işaret eder. Aktif şekil modellerinde, her model noktası (aynı zamanda yer işareti olarak da adlandırılır), her yinelemedeki kuvvet alanı boyunca hareket eder [33].

2.5.2 Panoramik x-ray dış görüntülerinde otomatik ağız bölgesi bölütlemesi

Tezden türetilen bildiri ve tez için geliştirilmiş ML modeli için kullanılan öznitelik, dış bölgesinin merkez noktası, kullanılarak ağız bölgesini içine alan tek bir eliptik şekil uydurulmuştur. Bu işlemi gerçekleştirmek için optimizasyon modeli ML modelinin çıktısı üzerine geliştirilmiştir. ML modelinden elde edilen dış bölgesi bölütlemesinde, $I_{ML}(x,y)$, ortaya çıkan ayırık pikselleri elemek için aşağıdaki optimizasyon yöntemi kullanılmıştır:

$$\min_{maliyet} \quad maliyet = KDP + \frac{DOP}{5} - BDP \quad (2.16a)$$

$$\text{Öyle ki} \quad model = \frac{(x - R_x)^2}{R_a^2} + \frac{(y - R_y)^2}{R_b^2} - 1, \quad (2.16b)$$

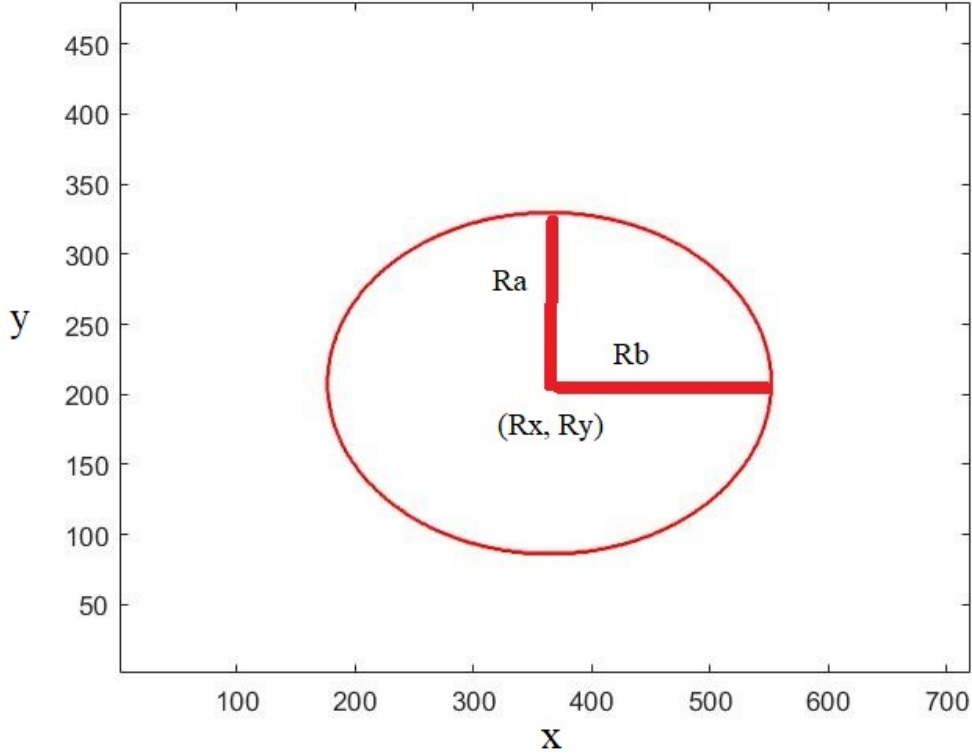
$$BDP = \sum_x \sum_y (model \cap I_{ML}(x,y)), \quad (2.16c)$$

$$KDP = \sum_x \sum_y (I_{ML}(x,y) \setminus model), \quad (2.16d)$$

$$DOP = \sum_x \sum_y (model \cap I_{ML}(x,y)) \setminus BDP. \quad (2.16e)$$

Burada, $I(x,y)$ görüntüsü için *maliyet*, amaç fonksiyonunu; *model*, eliptik şekli; *BDP*, *model* ve $I_{ML}(x,y)$ içinde kalan "dış" şekilde sınıflandırılan piksellerin sayısını; *KDP*,

$I_{ML}(x,y)$ içinde ve *model* dışında kalan "diş" şeklinde sınıflandırılan piksellerin sayısını; DOP , *model* ve $I_{ML}(x,y)$ içinde kalan "diş değil" şeklinde sınıflandırılan piksellerin sayısını vermektedir. Bu optimizasyon denklemleri gradyan azaltma ile belli bir öğrenme oranı kullanılarak bulunmuştur. Şekil 2.5'de geliştirilen optimizasyon yönteminin örnek bir sonucu verilmektedir.



Şekil 2.5: Panoramik X-Ray diş görüntülerinde otomatik ağız bölgesi bölütlemesi optimizasyon sonucu.

2.5.3 Panoramik x-ray diş görüntülerinde otomatik tam diş bölgesi bölütlemesi

Tezden türetilen bildiri ve tez için geliştirilmiş ML modeli için kullanılan öznelik, diş bölgesinin merkez noktası, kullanılarak tam diş bölgesini içine alan ve diş etlerini içermeyecek şekilde iki eliptik şekil uydurulmuştur. Bununla birlikte ML modelinden elde edilen sonucun sağdaki ve soldaki "diş" olarak bulunan son pikseller oluşturulacak şeklin sağdaki ve soldaki sınırları kabul edilmiştir. Bu işlemi gerçekleştirmek için optimizasyon modeli ML modelinin çıktısı üzerine geliştirilmiştir. ML modelinden elde edilen diş bölgesi bölütlemesinde, $I_{ML}(x,y)$, ortaya çıkan ayrık pikselleri elemek için

aşağıdaki optimizasyon yöntemi kullanılmıştır:

$$\min_{\text{maliyet}} \quad \text{maliyet} = KDP + \frac{DOP}{5} - BDP \quad (2.17a)$$

$$\text{Öyle ki} \quad \text{model}_1 = \frac{(x - R_x)^2}{R_a^2} + \frac{(y - R_y)^2}{R_b^2} - 1, \quad (2.17b)$$

$$\text{model}_2 = \frac{(x - R_x \varepsilon)^2}{(R_a \beta)^2} + \frac{(y - R_y)^2}{(R_b \beta)^2} - 1, \quad (2.17c)$$

$$\text{model}_3 = \text{model}_1 \setminus (\text{model}_1 \cap \text{model}_2), \quad (2.17d)$$

$$BDP = \sum_x \sum_y (\text{model}_3 \cap I_{ML}(x, y)), \quad (2.17e)$$

$$KDP = \sum_x \sum_y (I_{ML}(x, y) \setminus \text{model}_3), \quad (2.17f)$$

$$DOP = \sum_x \sum_y (\text{model}_3 \cap I_{ML}(x, y)) \setminus BDP, \quad (2.17g)$$

$$\beta = 1, \quad (2.17h)$$

$$\varepsilon = 0.1, \quad (2.17i)$$


Burada, $I(x, y)$ görüntüsü için *maliyet*, amaç fonksiyonunu; *model*, eliptik şekli; *BDP*, *model*₃ ve $I_{ML}(x, y)$ içinde kalan "diş" şeklinde sınıflandırılan piksellerin sayısını; *KDP*, $I_{ML}(x, y)$ içinde ve *model*₃ dışında kalan "diş" şeklinde sınıflandırılan piksellerin sayısını; *DOP*, *model*₃ ve $I_{ML}(x, y)$ içinde kalan "diş değil" şeklinde sınıflandırılan piksellerin sayısını; β , diş etlerini içine alacak eliptik bölgenin alanını düzenleyen parametreyi; ε , ağız bölgesindeki üst diş etlerinin olduğu alanın x-koordinatını vermektedir. Bu optimizasyon denklemleri gradyan azaltma ile belli bir öğrenme oranı kullanılarak bulunmaktadır. Şekil 2.6 gösterilen optimizasyon yönteminin örnek bir sonucunu vermektedir.

2.6 DL Modeli

Bu bölümde kullanılan derin öğrenme (DL) modelinin eldesine ilişkin altyapılara kısaca değinilecektir. ML modelinde olduğu gibi denetimli, denetimsiz, yarı denetimli yöntemleri mevcuttur. Bu tez kapsamında denetimli öğrenme yöntemi, nesne tespiti (Faster R-CNN) için kullanılmıştır.

2.6.1 DL tanımı

Derin öğrenme, çoklu işleme katmanlarından oluşan hesaplama modellerinin, birden fazla soyutlama seviyesine sahip verilerin temsillerini öğrenmesini sağlar. Bu yöntemler,



Şekil 2.6: Panoramik X-Ray diş görüntülerinde otomatik diş bölgesi bölütlemesi optimizasyon sonucu.

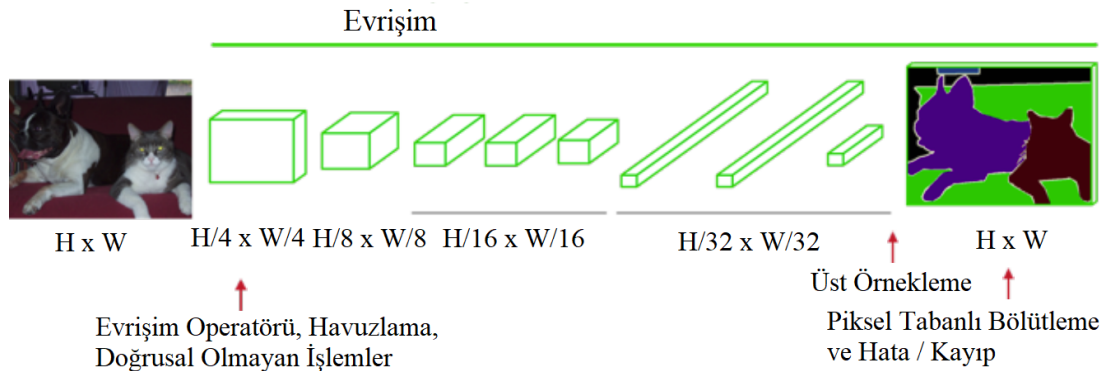
konuşma tanıma, görsel nesne tanıma, nesne algılama ve ilaç keşfi ve genomik gibi diğer birçok alandaki son teknolojiyi önemli ölçüde geliştirmiştir. Derin öğrenme, bir makinenin her katmandaki temsili hesaplamak için kullanılan iç parametrelerini önceki katmandaki gösterimden nasıl değiştirmesi gerektiğini göstermek için geri yayılma algoritmasını kullanarak büyük veri kümelerindeki karmaşık yapıyı keşfeder. Derin evrimsel ağlar, görüntü, video, konuşma ve sesin işlenmesinde atılımlara yol açarken, tekrarlayan ağlar metin ve konuşma gibi sıralı verilere ışık tutar [34].

Temsili öğrenme, bir makinenin ham verilerle beslenmesine ve algılama veya sınıflandırma için gerekli gösterimleri otomatik olarak keşfetmesine izin veren bir dizi yöntemdir. Derin öğrenme yöntemleri, her biri temsili bir düzeyde (ham girdiden başlayarak) daha yüksek, biraz daha fazla bir temsile dönüştüren basit ama doğrusal olmayan modüller oluşturarak elde edilen çoklu temsil seviyelerine sahip temsili öğrenme yöntemleridir. Bu tür dönüşümlerin yeterli bileşimi ile çok karmaşık fonksiyonlar öğrenilebilir. Sınıflandırma görevleri için, daha yüksek temsil katmanları, girdinin ayrımcılık için önemli olan yönlerini güçlendirir ve alakasız varyasyonları bastırır. Örneğin bir görüntü bir dizi piksel değeri biçiminde gelir ve ilk gösterim katmanındaki öğrenilen özellikler tipik olarak görüntüdeki belirli yönlerde ve konumlarda kenarların

varlığını veya yokluğunu temsil eder. İkinci katman tipik olarak, kenar konumlarındaki küçük değişikliklerden bağımsız olarak belirli kenar düzenlemelerini tespit ederek motifleri algılar. Üçüncü katman, motifleri, tanıdık nesnelerin parçalarına karşılık gelen daha büyük kombinasyonlara birleştirebilir ve sonraki katmanlar, nesnelere bu parçaların kombinasyonları olarak algılar. Derin öğrenmenin kilit yönü, bu özellik katmanlarının insan mühendisler tarafından tasarlanmamış olmasıdır: genel amaçlı bir öğrenme prosedürü kullanılarak verilerden öğrenilirler. Derin öğrenme, yapay zeka topluluğunun yıllarca en iyi girişimlerine direnen sorunların çözümünde büyük ilerlemeler kaydetmektedir. Yüksek boyutlu verilerdeki karmaşık yapıları keşfetme konusunda çok iyi olduğu ortaya çıktı ve bu nedenle bilim, iş dünyası ve devletin birçok alanına uygulanabilir. [34].

2.6.2 Bölütleme problemi

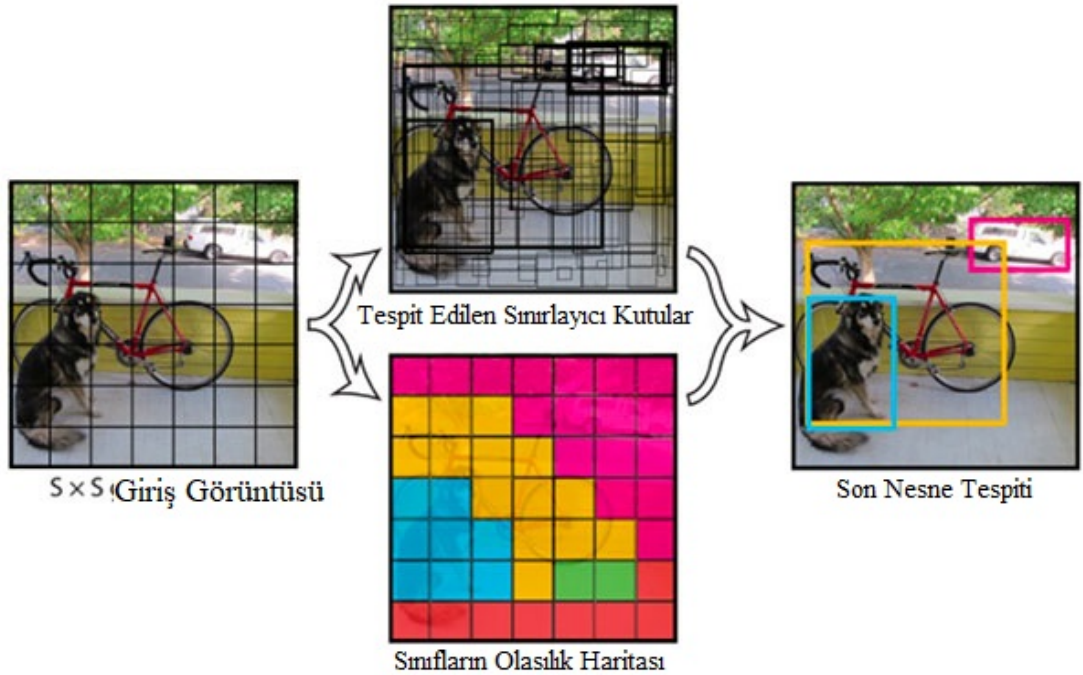
Çeşitli yüksek seviyeli bilgisayar görme görevlerinde derin öğrenme tekniklerinin amansız başarısı - özellikle görüntü sınıflandırması veya nesne tespiti için Evrişimli Sinir Ağları (CNN) gibi süper görüşlü yaklaşımlar - araştırmacıları bu tür ağların piksel seviyesi etiketleme yeteneklerini bölütleme problemleri için keşfetmeye motive etti. Geleneksel yöntemlere üstünlük sağlayan bu derin öğrenme tekniklerinin temel avantajı, eldeki problem için uygun özellik temsillerini, örneğin belirli bir veri kümesinde piksel etiketlemeyi uçtan uca bir şekilde öğrenme yeteneğidir. Şekil 2.7'de görüldüğü üzere, tamamen bağlı katmanları, örnekleme için bir dekonvolüsyon katmanı da dahil olmak üzere kıvrımlı katmanlarla değiştirerek mekansal ısı haritaları üretmek için CNN amaçlı bir sınıflandırmanın dönüştürülmesi, piksel başına etiketleme için yoğun çıkarım ve öğrenmeye izin verir [35].



Şekil 2.7: Tamamen evrişimsel ağlar ile bölütleme işlemi [36].

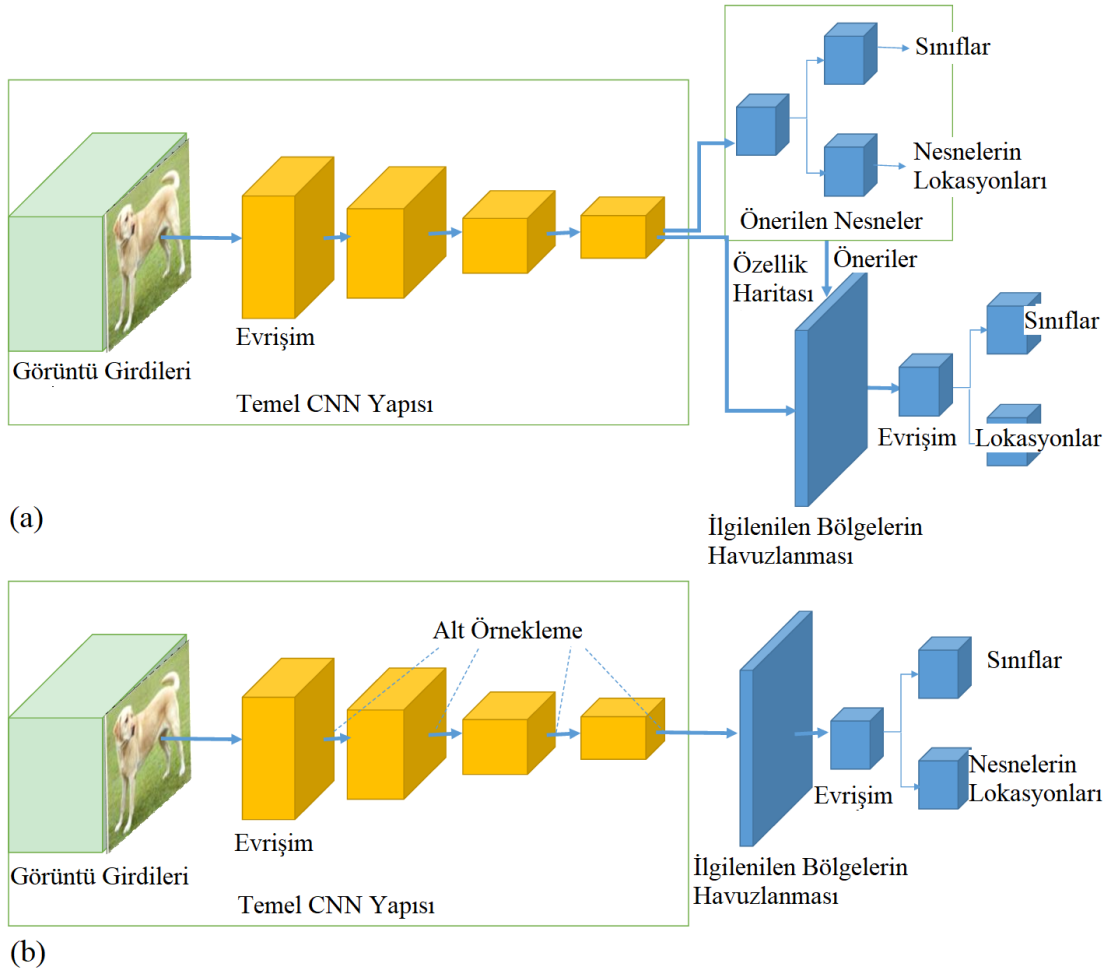
2.6.3 Nesne tespit problemi

Bilgisayar görmedeki en temel ve zorlu sorunlardan biri olan nesne algılama, doğal görüntülerde önceden tanımlanmış çok sayıda kategoriden nesne örneklerini bulmaya çalışır. Derin öğrenme teknikleri, özellik sunumlarını doğrudan verilerden öğrenmek için güçlü bir strateji olarak ortaya çıkmıştır ve genel nesne tespiti alanında dikkate değer atılımlara yol açmıştır. Nesne tespitinin amacı, bir görüntüde belirli kategorilerden (örneğin insanlar, arabalar, bisikletler, köpekler veya kediler gibi) nesnelere olup olmadığını belirlemek ve varsa, her nesne örneğinin uzamsal konumunu ve kapsamını döndürmektir. Görüntü anlayışı ve bilgisayar vizyonunun temel taşı olan nesne algılama, segmentasyon, sahne anlayışı, nesne izleme, görüntü altyazısı, olay algılama ve etkinlik tanıma gibi karmaşık veya üst düzey görme görevlerini çözmek için temel oluşturur. Nesne algılama, robot vizyonu, tüketici elektroniği, güvenlik, otonom sürüş, insan bilgisayar etkileşimi, içeriğe dayalı görüntü alma, akıllı video gözetimi ve artırılmış gerçeklik gibi çok çeşitli uygulamaları destekler [37]. Şekil 2.8 ve 2.9'da nesne tespit uygulamaları ve mimarisi gösterilmiştir. Nesne tespiti hem nesnelere sınıflandırılmasını hem de nesnelere ait pozisyon bilgilerinin tahminini yapmaktadır [37].



Şekil 2.8: Nesne tespiti örneği [37].

Tez kapsamında DL modeli için kullanılan yöntem, denetimli öğrenme olup dış nesnelere tespiti yapılmıştır. Şekil 2.9'da nesne tespiti için kullanılan algoritmanın mimarisi gösterilmektedir: (a) Bölge önerilerini sınıflandırıcı ve regresöre beslemek için bölge teklif ağından oluşan iki aşamalı dedektörlerin temel mimarisini sergiler.



Şekil 2.9: Nesne tespit algoritma mimarileri: (a), iki aşamalı dedektör mimarisi ve (b), tek aşamalı dedektör mimarisi [38].

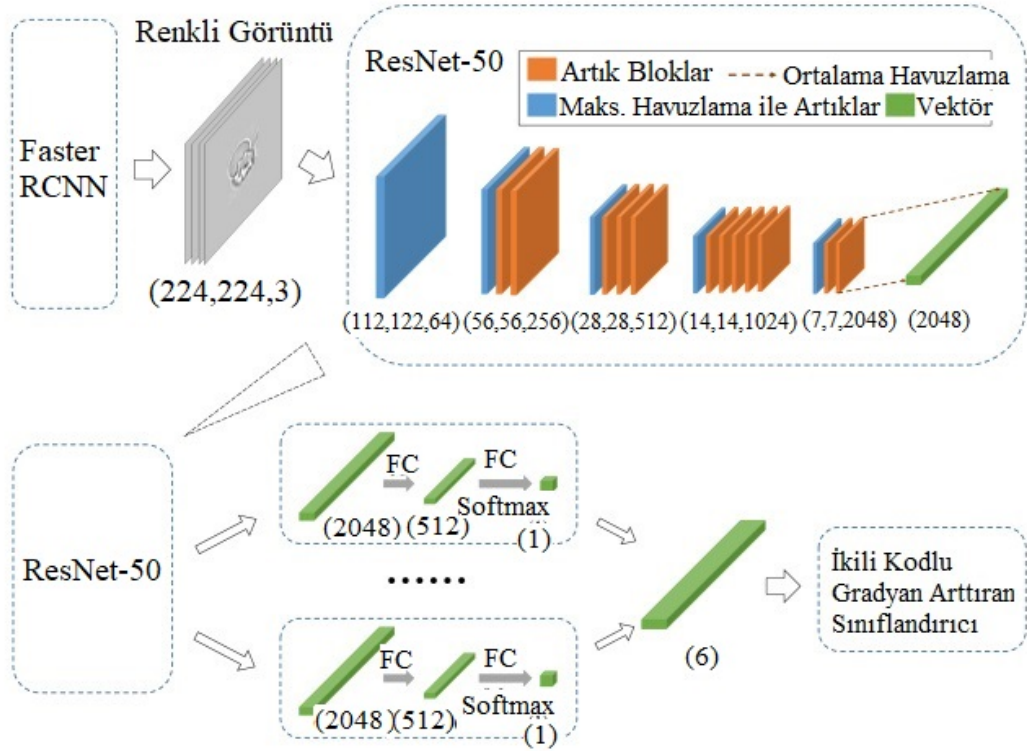
(b) Doğrudan giriş görüntülerinden sınırlayıcı kutuları tahmin eden tek aşamalı dedektörlerin temel mimarisini gösterir. Sarı küpler, omurga ağında aynı çözünürlükte bir dizi kıvrımlı katmanlardır (bir blok olarak adlandırılır), çünkü bir bloktan sonra aşağı örnekleme işlemi nedeniyle, aşağıdaki küplerin boyutu yavaş yavaş küçülür. Kalın mavi küpler, bir veya daha fazla kıvrımlı katman içeren bir dizi kıvrımlı katmandır. Düz mavi küp, aynı boyuttaki nesnelere için özellik haritaları üretir [38].

2.6.4 Faster R-CNN

Bir Faster R-CNN ağı girdi olarak tüm görüntüyü ve bir dizi nesneyi alır. Ağ ilk önce tüm görüntüyü çeşitli evrişimli CNN ve maksimum havuzlama katmanlarıyla işleyerek bir evre özellik haritası oluşturur. Daha sonra, her nesne için bir ilgi alanı (ROI) havuzlama katmanı, özellik haritasından sabit uzunluklu bir özellik vektörü çıkarır. Her özellik vektörü, sonunda iki çıktı katmanına dallanan tam bağlı (FC) katmanlar dizisine

beslenir: biri K nesne sınıfları üzerinde softmax olasılık tahminleri üretir ve çıktı veren başka bir katman K nesne sınıfları için dört gerçek değerli pozisyon sayılarını üretir. Her 4 değer kümesi, K sınıflarından biri için rafine edilmiş kutu konumlarını kodlar [39].


RoI katmanı, ilgilenilen herhangi bir geçerli bölgedeki özellikleri, sabit uzamsal $H \times W$ boyutuna sahip küçük bir özellik haritasına dönüştürmek için maksimum havuzlama kullanır; burada H ve W , belirli bir yatırım getirisinden bağımsız katman hiper parametreleridir. Her RoI, sol üst köşesini (r, c) ve yüksekliğini ve genişliğini (h, w) belirten dört bir demetle (r, c, h, w) tanımlanır. RoI maksimum havuzlama, $h \times w$ RoI penceresini yaklaşık $\frac{h}{H} \times \frac{w}{W}$ boyutundaki alt pencerelerin $H \times W$ ızgarasına bölerek ve ardından her bir alt penceredeki değerleri karşılık gelen çıktı ızgara hücrelerine maksimum havuzda toplayarak çalışır. Havuzlama, standart maksimum havuzlamada olduğu gibi her özellik harita kanalına bağımsız olarak uygulanır [39]. Şekil 2.10'da Faster R-CNN mimarisi verilmiştir [40].



Şekil 2.10: Faster R-CNN mimarisi [40].

2.6.5 DL modeli için dişlerin etiketlenmesi

Çalışma [41]'de olduğu gibi dişlerin bulunduğu sınırlar bir dikdörtgen çerçeve içinde kalacak şekilde etiketlenmiştir. Çalışma [41]'den farklı olarak kullanılan görüntü sayısı çok daha az olup öncesinde dişlerin bulunduğu bölgenin bölütlenmesinin ve sonrasında ise tam diş bölütlenmesinin otomatik olarak yapılmasıdır. Ayrıca tezde oluşturulan DL modeli hem dişleri hem de implantları bulmaktadır. Şekil 2.11'de etiketleme işlemi gösterilmiştir.



Şekil 2.11: DL modeli için dişlerin etiketlenme işlemi [41].

2.6.6 DL modeli için eğitim, doğrulama ve test verilerinin ayrılması

Elde var olan 50 görüntüden seçilen 14 görüntü test verisi olarak modele hiç gösterilmeden muhafaza edilmiştir ve geri kalan 36 görüntü, K-CV ile eğitim ve doğrulama verileri olarak modelin eğitimi için ayrılmıştır.

Derin öğreniminde temel gereksinimlerden biri, tahmin ve genelleme yeteneklerine sahip hesaplama modelleri oluşturmaktır. Denetimli öğrenme durumunda, bilinmeyen bir hedef fonksiyonun çıktılarını tahmin etmek için bir karma model eğitilir. Eğitim sürecinin sonunda, son model T 'den gelen giriş örnekleri için doğru çıktılar tahmin etmeli, ancak daha önce görülmemiş verilere iyi genelleme yapabilmelidir. Kötü genelleme, aşırı eğitim ile karakterize edilebilir. Model aşırı eğitiyorsa, sadece eğitim örneklerini ezberler ve eğitim veri kümesinde olmayan kalıplar için de doğru çıktılar veremez. Bu iki önemli talep (ve iyi genellemede iyi tahmin) çelişkilidir ve sapma ve varyans ikilemi olarak da bilinir. Minimum sapma ile modelin minimal varyansı arasında denge sağlamak için kullanılan yaygın bir teknik çapraz doğrulamadır. Bununla birlikte, bu tekniğin temel problemi, uygun veri bölünmesini temsil etmektedir. Veri kümesinin yanlış bölünmesi, özellikle model performansında aşırı yüksek bir Varyansa yol açabilir, ancak bu sorunla başa çıkmak için çeşitli karmaşık örnekleme yöntemleri kullanılabilir. Çapraz validasyon teknikleri, iyi genelleme sağlamak ve aşırı eğitimden kaçınmak için kullanılan geleneksel yaklaşımlara aittir. Temel fikir, veri kümesi T 'yi iki

alt kümeye bölmektir - bir alt küme eğitim için kullanılırken, diğer alt küme dışarıda bırakılır ve son modelin performansı değerlendirilir. Çapraz doğrulamanın temel amacı, model performansının istikrarlı ve kendinden emin bir tahminini elde etmektir. Çapraz doğrulama teknikleri, daha fazla model, çeşitli eğitim algoritmaları değerlendirilirken ve karşılıklı olarak karşılaştırılırken veya en uygun model parametreleri aranırken de kullanılabilir. K-CV, model hatasının kararlı bir tahminini elde etmek için daha fazla testin bir kombinasyonunu kullanır. Veri kümesi T , aynı boyuttaki k bölümlerine ayrılmıştır. Bir kısım T_v setini doğrulama (test), diğer kısım ise T_{tr} eğitim setini oluşturur. Bu işlem verinin her bir kısmı için tekrarlanır. K-CV algoritmasının adımları aşağıda verilmiştir [31]:

1. T veriseti k sayıda alt veri kümelerine bölünür [31].
2. $T_v \leftarrow T_i$ ve $T_{tr} \leftarrow \{T \setminus T_i\}$ işlemi $i = 1, 2, \dots, k$ için yapılır [31].
3. Model, T_{tr} üzerinde eğitilir ve model performansını değerlendirmek için periyodik olarak T_v kullanılır [31].

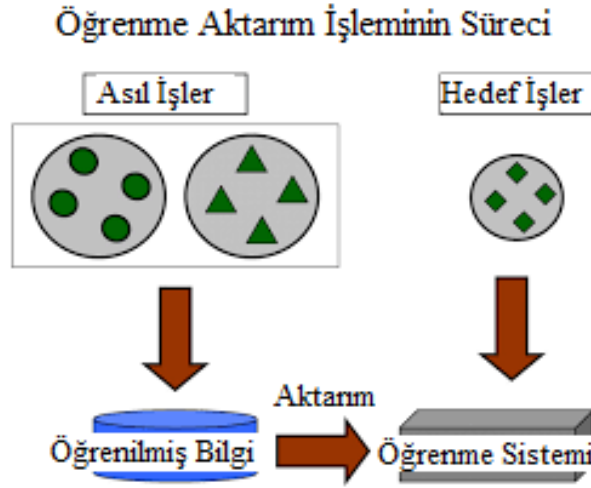
2.6.7 DL modeli için öğrenme aktarımı

Bir kaynak etki alanı D_S ve öğrenme görevi T_S , bir hedef etki alanı D_T ve öğrenme görevi T_T göz önüne alındığında, öğrenme aktarımı D_S ve D_T 'deki bilgileri kullanarak D_S ve T_S 'deki bilgileri kullanarak D_T 'deki hedef tahmin işlevinin $f_T(\Delta)$ öğrenmesini geliştirmeyi amaçlamaktadır ($D_S \neq D_T$ veya $T_S \neq T_T$) [42].

Yukarıdaki tanımda, bir etki alanı $D = \{X, P(X)\}$ çiftidir. Böylece $D_S \neq D_T$ koşulu, $X_S \neq X_T$ veya $P_S(X) \neq P_T(X)$ olduğunu ima eder. Örneğin, belge sınıflandırma örneğimizde, bu, bir kaynak belge kümesi ile hedef belge kümesi arasında, ya özellik kümesinin iki grup arasında farklı olduğu (örneğin, farklı diller kullandıkları) ya da marjinal dağılımlarının farklı olduğu anlamına gelir. Kendi kendine öğrenilen öğrenme ayarında, kaynak ve hedef alanlar arasındaki etiket boşlukları farklı olabilir, bu da kaynak alanın yan bilgilerinin doğrudan kullanılamayacağını gösterir. Bu nedenle, kaynak etki alanındaki etiketli verilerin kullanılmadığı endüktif öğrenme aktarımıdır. Bir kaynak etki alanı D_S ve bir öğrenme görevi T_S , bir hedef etki alanı D_T ve bir öğrenme görevi T_T göz önüne alındığında, endüktif transfer öğrenme D_S 'deki ve T_S 'deki bilgileri kullanarak D_T 'deki hedef öngörücü fonksiyonunun ($f_T(\Delta)$) öğrenilmesini geliştirmeyi amaçlamaktadır [42]. Şekil 2.12'de öğrenme aktarım süreci gösterilmiştir.

2.6.8 DL modelinin oluşturulması ve sonuç alınması

Derin öğrenimi için veri seti hazırlanması, eldeki 50 görüntünün eğitim ve test verisi olarak ikiye ayrılması ile yapılmıştır. Bu ayırmda 36 görüntü eğitim ve 14 görüntü




Şekil 2.12: DL modeli için öğrenme aktarım süreci [42].

test için kullanılmıştır. Derin öğrenmesi modelinin oluşturulmasından önce ise eğitim verisi k-kat çarpaz doğrulama yöntemi ile eğitim ve doğrulama veri setlerine ayrılmıştır [31]. Derin öğrenme modeli için daha önce eğitilmiş bir model kullanılmıştır. Bu model, CNN alt yapısında Faster R-CNN algoritmasına sahiptir. Derin öğrenmenin en büyük avantajlarından biri, öznetelik çıkarılmasının model alt yapısında kullanılan CNN mimarisinin yapıyor olmasıdır. DL modelinin çıkışında, dışlara ait pikselleri ve çevresini içine alan dikdörtgen bir kutunun lokasyon bilgisi bulunmaktadır. Görüntü içindeki her dış için model bir dikdörtgen kutu sonucu vermektedir. Kullanılan görüntü sayısının az olması nedeniyle bazı görüntüler için üst üste kutu bulunması veya iki dışı tek bir dış olarak tespit edilmesi gibi aykırı durumlar bulunabilmektedir. Bir sonraki aşamada dışların otomatik tam bölütlenmesi için ve aykırı durumların üstesinden gelmenin yöntemleri anlatılacaktır.

2.7 Dışların Bölütlenmesi

Birçok bölütleme yöntemi bir şekilde kenar algılamaya dayanırken, Chan ve Vese'nin [43, 44] "Kenarsız Aktif Konturlar" yöntemi kenarları tamamen yok sayar. Bunun yerine, yöntem, verilen görüntüye iki fazlı parçalı sabit bir modele en uygun şekilde uyar. Segmentasyon sınırı, segmentasyonun topolojik değişiklikleri açık yılan yöntemlerinden daha kolay idare etmesini sağlayan bir seviye ayar fonksiyonu ile dolaylı olarak temsil edilir. Aktif kontur modellerinde veya yılanlarda temel fikir, o görüntüdeki nesnelere algılamak için belirli bir görüntüdeki u_0 kısıtlamalarına tabi olan bir eğri geliştirmektir. Örneğin, algılanacak nesnenin etrafındaki bir eğri ile başlayarak, eğri görüntüdeki bazı kısıtlamalar altında iç normale doğru hareket eder ve nesnenin sınırında durmak zorundadır [45]. Şekil ??'de örnek bir Chan-Vese uygulaması gösterilmektedir [43].

Şekil 2.13’de daha önce yapılmış bir çalışma olan [46]’da gösterilmiş diş bölütleme uygulaması gösterilmektedir.



Şekil 2.13: Diş bölütleme işlemi [46].

2.8 Kullanılan Başarım Metriği

ML, DL modellerinin ve diş bölütleme işlemi bu başlık altında verilen başarım metriklerine göre yapılmıştır.

Yapılan çalışmaya bağlı olarak bir çok başarım metriği oluşturulabilir. Özellikle insan eliyle etiketlenen verileri kullanan veya sınıflar arası dengeli sonuçlar vermeyen yapılarda sınıflandırmalar sınıf bazında belli çarpanlara sahip olur. Kullanılan başarım metrikleri de bu dağılımlara uygun olarak gerçekleştirilir. Medikal olarak YP ve YN ağırlıkları genel olarak eşit kullanılmaz. Keza incelenen duruma bağlı olarak oluşturulan modellerde problemi belirleyememek veya problemlenmeyen bir bölgeye problemlenmiş demek aynı etkiye sahip olmayabilir. ML modelinde piksellerin sınıflandırma problemi olduğu için ve sınıflar arası dengesizliğin olmasından dolayı F1 skoru kullanılmıştır. Sınıflandırma problemlerinde doğru pozitif (DP), doğru negatif (DN), yanlış pozitif (YP) ve yanlış negatif (YN) kavramları mevcuttur. DP, diş olarak belirlenen gerçek etiket değeri ile model sonucunda diş olarak belirlenen değerin uyduğunu gösterir. DN, diş olarak belirlenmeyen gerçek etiket değeri ile model sonucunda diş olarak belirlenmeyen değerin uyduğunu gösterir. YP, modelde diş olarak belirlenen bir değerin gerçek etiket değerinin diş olarak belirlenmeyen bir değere ait olmasıdır. YN, modelde diş

olmayarak belirlenen bir deęerin gerek etiket deęerinin diř olarak belirlenen bir deęere ait olmasıdır. Modeli deęerlendirmede kullanılan Doęruluk (2.18), Hassasiyet (2.19), Kesinlik (2.20) ve F1 (2.21) skorları řu řekilde bulunur [8]:

$$\frac{DP + DN}{DP + DN + YP + YN} \quad (2.18)$$

$$\frac{DP}{DP + YN} \quad (2.19)$$

$$\frac{DP}{DP + YP} \quad (2.20)$$

$$\frac{2 \frac{DP}{DP+YN} \frac{DP}{DP+YP}}{\frac{DP}{DP+YN} + \frac{DP}{DP+YP}} \quad (2.21)$$

DL modelinin bařarım metrięi ise IoU metrięi ile belirlenmiřtir. IoU hesabı, iki dikdörtgenin keřiřtikleri alanın bu iki dikdörtgenin bileřiminin alanına bölümü olarak hesaplanır (2.22).

$$\frac{KA}{BA} \quad (2.22)$$

3. DENEYLER

Bu bölümde kullanılan veriler ve yapılan çalışma anlatılacaktır.

3.1 Veri Seti


3.1.1 Kullanılan veri seti

Dişlerin bölütlenme işlemi, panoramik X-Ray diş görüntüleri kullanılarak yapılmaktadır. Tek tip görüntüleme ile dişlerin bölütlenmesi klinik olarak yeterli olmasa da tezde kullanılan yöntemlerle bölütleme işlemi gerçekleştirilmiştir. Çalışmada kullanılan veri seti bu çalışmaya özel olup 50 farklı insana ait anonimleştirilmiş görüntülerdir. Kullanılan veri seti hasta bazında oldukça küçük bir veri setidir. Tüm görüntülerde X-Ray cihazı için aynı parametreler geçerlidir.

Çalışmada, gri-seviyeli görüntüler kullanılmıştır. Çalışmada 50 hastanın dişlere ait olan pikselleri diş hekimleri ile beraber işaretlenmiştir. Örnek olarak dört farklı hastanın görselleri Şekil 3.1'de, (a) implantlı dişlere sahip hastaya, (b) implantlı ve eksik dişlere sahip hastaya, (c) tam diş yapısına sahip hastaya ve (d) eksik dişlere sahip hastaya ait görüntüler gösterilmektedir.



(a)



(b)



(c)

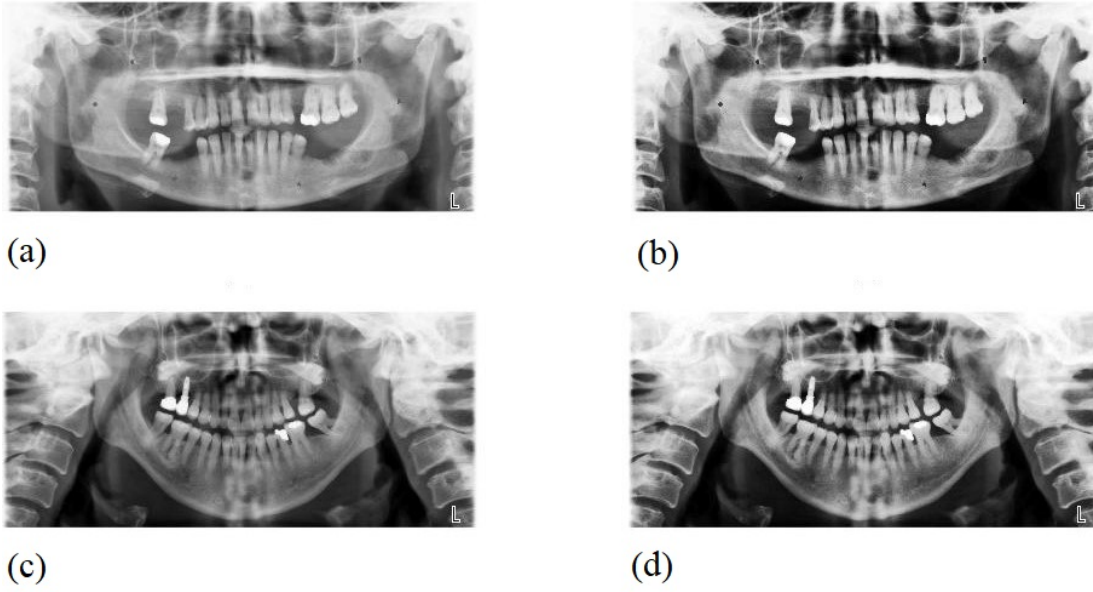


(d)

Şekil 3.1: Veri setinden farklı hastalara ait örnekler.

3.1.2 Görüntülerin hazırlanması

Görüntüler hazırlanırken ilk önce HE uygulanmış ve sonra farklı boyutlardaki diş görüntülerine işlem kolaylığı olması için ve sabit olması için alt örnekleme yapılmıştır. Çalışmada görüntülerin sabit boyutu, dişler arasındaki boşluk bilgisinin kaybolmaması ve işlemsel kolaylık sağlanması adına 480x720 boyutları olarak belirlenmiştir. Örnek olarak iki farklı hastanın HE işleminden sonraki görselleri Şekil 3.2’de, (a) bir hastaya ait görüntü, (b) (a)’daki hastaya ait görüntü üzerinde HE işlemi uygulanmış görüntü, (c) başka bir hastaya ait görüntü ve (d) (c)’deki hastaya ait görüntü üzerinde HE işlemi uygulanmış görüntü gösterilmektedir. 10 farklı hastaya ait görüntülerin alt örnekleme yapılmadan ve yapıldıktan sonraki boyutları, Çizelge 3.1 üzerinden ulaşılabilir.



Şekil 3.2: HE işleminin sonuçlarını içeren örnek görüntüler.

3.2 ML Modeli

Çalışmada diş bölgesinin bölütlenmesinde doğrudan ve dişlerin bölütlenmesinde dolaylı olarak kullanılmış bir modeldir.

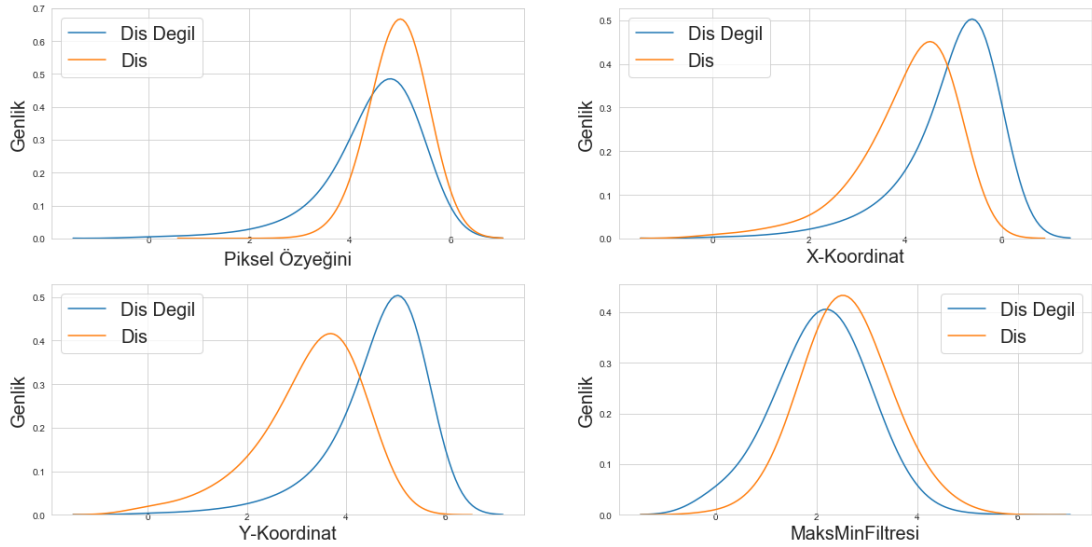
3.2.1 Öznitelik çıkartılması

Öznitelikler, piksellerin yeğlilik değerleri, her pikselin dişlerin bulunduğu alana için otomatik olarak oluşturulmuş merkez noktasına göre koordinatları ve 3x3 filtre penceresi ile oluşturulmuş filtre içinde kalan piksellerin maksimum ve minimum değerlerinin farklarıdır. Öznitelikler çalışmada kullanılmadan önce PDF çıktılarına ve "diş" ve "diş değil" sınıflarına göre oluşturulmuş öznitelikler arası ilişkiyi gösteren dağılımlarına

Çizelge 3.1: Görüntülerde alt örnekleme boyutları.

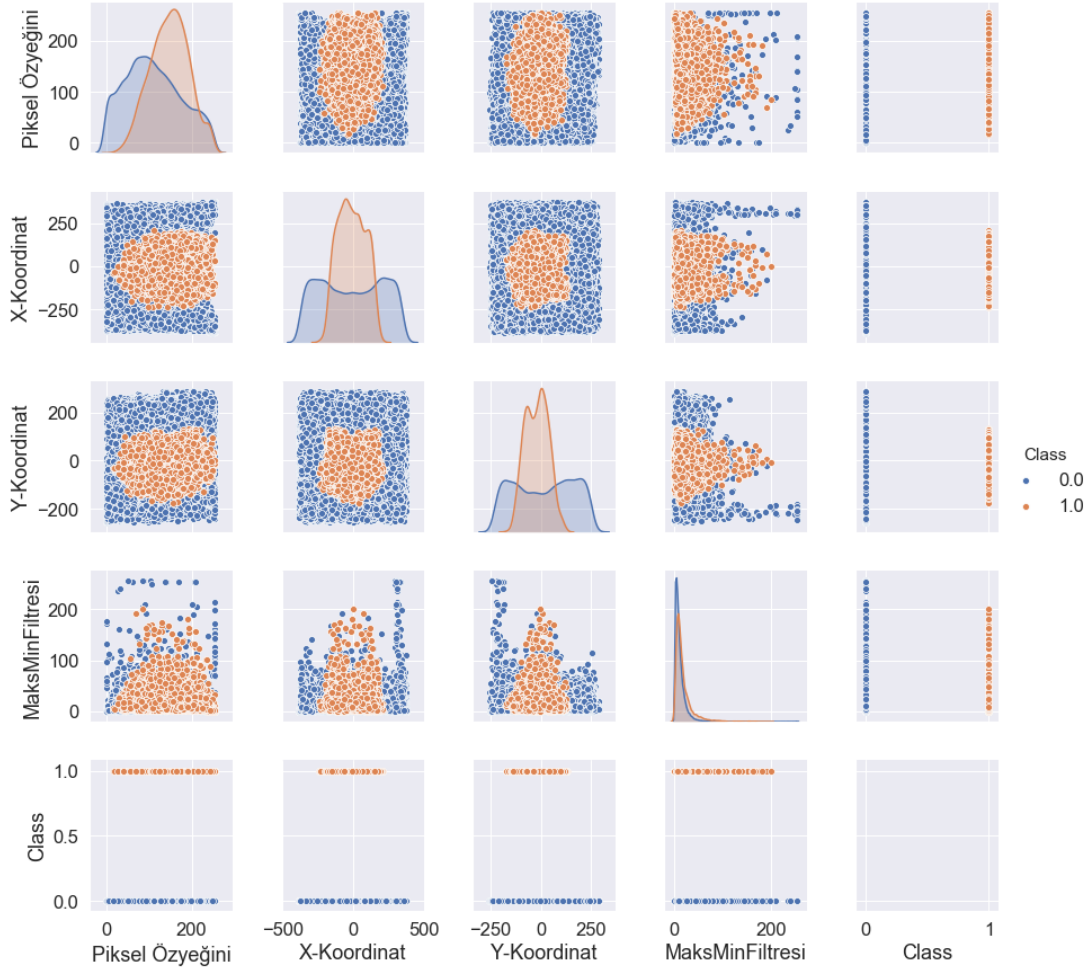
Hasta Numarası	Alt Örnekleme Öncesi Görüntü Boyutu	Alt Örnekleme Sonrası Görüntü Boyutu
1	1462x3268	480x720
2	1223x2783	480x720
3	1227x2771	480x720
4	1219x2783	480x720
5	1219x2775	480x720
6	1459x3227	480x720
7	1221x2777	480x720
8	1221x2751	480x720
9	1227x2779	480x720
10	1227x2781	480x720

bakılmıştır. Şekil 3.3’de sol üstteki grafik, piksellerin özyeğin değerlerine ait; sağ üstteki grafik, her pikselin dışların bulunduğu alana için otomatik olarak oluşturulmuş merkez noktasına göre x-koordinatlarına ait; sol alttaki grafik, her pikselin dışların bulunduğu alana için otomatik olarak oluşturulmuş merkez noktasına göre y-koordinatlarına ait; sağ alttaki grafik, 3x3 filtre penceresi ile oluşturulmuş filtre içinde kalan piksellerin maksimum ve minimum değerlerinin farklarına ait PDF grafiklerini gösterilmektedir.



Şekil 3.3: ML modelinde kullanılan özniteliklere ait PDF.

Şekil 3.3 ve 3.4’de görüldüğü üzere en önemli öznitelik, bu tez ve bu tezden türetilmiş bildiri [8] için geliştirilmiş ve daha önce denenmemiş bir öznitelik olan her pikselin dışların bulunduğu alan için otomatik olarak oluşturulmuş merkez noktasına göre koordinatlarıdır. Şekil 3.4’de "dış" ve "dış değil" sınıflarına göre oluşturulmuş öznitelikler arası ilişkiyi gösteren dağılımlar verilmiştir. Şekil 3.4’de ilk satır ve ilk sütun piksellerin özyeğinlerine, ikinci satır ve ikinci sütun x-koordinatına, üçüncü satır



Şekil 3.4: ML modelinde kullanılan "dış" ve "dış değil" sınıflarına göre oluşturulmuş öznitelikler arası ilişkiyi gösteren dağılımlar.

ve üçüncü sütun y-koordinatına ve dördüncü satır ve dördüncü sütun ise filtreli çıkışa ait öznitelikleri göstermektedir. Grafiğin sol baştan sağ son kısma uzanan çaprazında özniteliklerin sınıflara göre dağılımlarını ve geri kalan grafiklerde ise birbirlerine göre dağılımlarını göstermektedir. Sınıfları ayırmak için doğrusal bir sınıflandırıcı ML modeli bu öznitelikler ile yeterli doğrulukta sonuç vermeyeceği özniteliklerin dağılımından ve PDF sonuçlarından görülmüştür. Bu nedenle doğrusal olmayan bir sınıflandırıcı ve sınıflar arası dengesizlikle düzgün çalışabilen bir ML modeli seçilip geliştirilmiştir.

3.2.2 ML modelinin oluşturulması

ML modeli için kullanılan algoritma karar ağaçları ile çalışan ve öznitelikler arası ilişkilere bakıp birden çok karar ağaçları oluşturarak bir sonuç döndüren bir algoritmadır. Bu algorithmanda sonuçlar, oluşturulan karar ağaçlarının sonuçlarının oylanması ile oluşmaktadır. En yüksek oyu alan sonuç sınıflandırma sonucu olmaktadır. Bu algoritma

CatBoost algoritmasıdır. Sınıflar arası dengesizliklerden çok fazla etkilenmeden, öznitelikler arası ilişkilere bakarak ve doğrusal olmayan modeller oluşturularak sınıflandır problemini çözmektedir.

ML modeli oluşturulmadan önce veri seti eğitim, doğrulama ve test olarak 3 gruba ayrılmıştır. Bu gruplama, içerisinde iki sınıftan da ("diş" ve "diş değil") bulunacak şekilde yapılmıştır. Gruplama algoritması K-CV kullanılarak yapılmıştır. Burada k parametresi 3 seçilmiştir. Bununla beraber gruplama 3 kez farklı olarak yapılmış ve her gruplama seti için model eğitilerek sınıflandırma sonuçlarının ortalaması alınmıştır. Bu sayede test verisinde elde edilecek sonuçlara yaklaşılmış ve modelin veriyi ezberlememesi sağlanmıştır.

CatBoost algoritmasında kullanılan kullanıcı girişli parametreler bir arama algoritması ile belirli sınırlar dahilinde belirlenmiştir. Algoritmada kullanılan parametreler Çizelge 3.2'de verilmiştir.

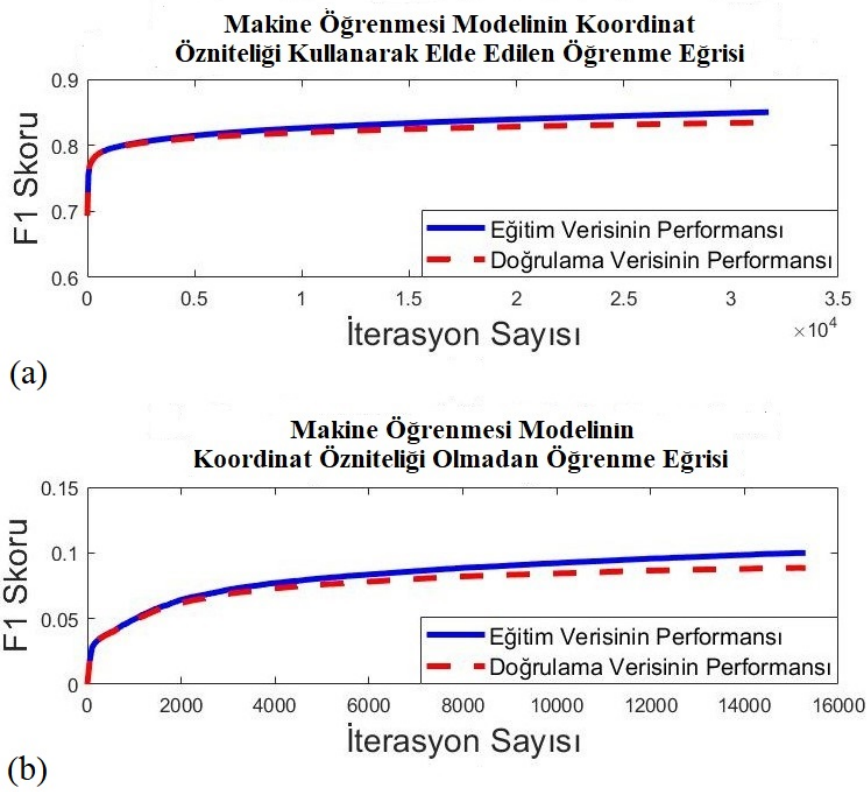
Çizelge 3.2: ML modelinde kullanıcı girişli parametreler.

ML Modeli Parametresi	ML Modeli Parametresinin Değeri	Açıklama
iterations	100000	Modelin eğitimi için gereken maksimum iterasyon sayısı
learning_rate	0.1	Model içindeki parametrelerin güncellenme adım miktarı
max_depth	5	Model içinde kullanılan karar ağaçlarının maksimum derinliği
loss_function	Logloss	Maliyet fonksiyonu
eval_metric	F1	Eğitim ve doğrulama verileri ile oluşturulan modelin başarı metriği
task_type	GPU	Modelin eğitimi için kullanılan donanım seçimi
use_best_model	True	Model eğitimini sırasında en iyi modelin seçilmesi
early_stopping_rounds	200	Model eğitiminde modelin başarı metriği düştüğünde veya veri ezberlenmeye başladığında durdurma iterasyon sayısı

3.2.3 ML modelinin performansı

ML modelinin performansını ölçmek için modelin öğrenme eğrisine, sınıflandırma raporuna ve eğitim ve doğrulama verileri için Doğruluk, Hassasiyet, Kesinlik ve F1 skorlarına bakılır. Bu tez ve tezden türetilmiş bildiri [8] için geliştirilip çıkarılan özniteliklerin önemini o öznitelikler olmadan oluşturulan model için yapılan performans

analizinde görülebilir. Şekil 3.5’de geliştirilmiş öznitelik olmadan (b) ve geliştirilmiş öznitelik ile yapılan (a) modellerin öğrenme eğrileri verilmiştir. Çizelge 3.3’de geliştirilmiş öznitelik olmadan yapılan modele ait; Çizelge 3.4’de geliştirilmiş öznitelik ile yapılan modele ait Doğruluk, Hassasiyet, Kesinlik ve F1 skorları verilmiştir.



Şekil 3.5: ML modelinin öğrenme eğrisini gösteren grafik (düz çizgili eğitim verisi ve kesikli çizgili doğrulama verisi).

Şekil 3.5’de görüldüğü üzere tez kapsamında geliştirilip çıkarılan öznitelik olan her pikselin dışların bulunduğu alan için otomatik olarak oluşturulmuş merkez noktasına göre koordinatlar dış bölgesinin bölütlenmesinde önemli bir rol oynamaktadır. Geliştirilen özniteliğin kullanılması ile oluşturulan ML modeli çok daha iyi F1 skoru vermektedir. Şekilde eğitim verisi ile doğrulama verisi için gelen skorların öğrenme eğrilerinde paralel gitmesi modelin veriyi ezberlemediği anlamına gelmektedir.

Çizelge 3.3: Geliştirilmiş öznitelik olmadan yapılan modele göre sınıflandırma skorları

Veri Setleri	Sınıflandırma Skorları			
	Doğruluk	Hatırlama	Kesinlik	F1
Eğitim	0.9047	0.0536	0.7318	0.0999
Doğrulama	0.9036	0.0475	0.6571	0.0886
Test	0.8985	0.0298	0.6116	0.0782


Çizelge 3.3’de sadece Doğruluk ve Kesinlik üzerinden bir başarıım metriğine bakılsaydı, model istenen sonucu veremeyeceği görülmektedir. Bunun nedeni veri setindeki sınıflardan "diş değil" sınıfının "diş" sınıfına göre bariz fazla olmasıdır.

Çizelge 3.4: Geliştirilmiş öznitelik ile yapılan modele göre sınıflandırma skorları

Veri Setleri	Sınıflandırma Skorları			
	Doğruluk	Hatırlama	Kesinlik	F1
Eğitim	0,9708	0,8388	0,8615	0,8500
Doğrulama	0,9678	0,8229	0,8465	0,8346
Test	0,9618	0,8157	0,8412	0,8305

Çizelge 3.3 ile benzer şekilde Çizelge 3.4’de sadece Doğruluk ve Kesinlik üzerinden bir başarıım metriğine bakılsaydı, model istenen sonucu veremeyeceği görülmektedir. Bunun nedeni veri setindeki sınıflardan "diş değil" sınıfının "diş" sınıfına göre bariz fazla olmasıdır. Çizelgelerden anlaşılacağı üzere geliştirilen öznitelik, skorlarda ciddi artışa sebep olmuş ve modelin istenilen sonuçları vermesini sağlamıştır.

Şekil 3.6’da ML modellerinin sonuçları üç farklı sütun üç farklı hasta için olmak üzere; birinci satırda panoramik X-Ray diş görüntüleri, ikinci satırda gerçek diş piksellerine ait etiketler, üçüncü satırda koordinat özniteliği olmadan elde edilen makine öğrenme sonuçları, ve dördüncü satırda geliştirilen koordinat özniteliği kullanarak elde edilen makine öğrenme modeli sonuçları görülmektedir. Geliştirilen öznitelik kullanılarak elde edilen sonuçların daha iyi olduğu görsel olarak gösterilmiştir. Bu model çıktısı kullanılarak otomatik diş bölgesi bölütleme ve daha sonra da otomatik diş bölütleme işlemleri yapılmıştır. Sadece ML modeli kullanılarak dişlerin bölütlenme işlemi gerçekleştirilememiştir. Bunun sebebi, dişler arasındaki boşlukların ve diş olan piksellerin yeterli ölçüde bulunamamasıdır. Sadece Doğruluk başarıım metriği ile modelin iyi çalıştığı varsayılabilir ancak bu tez kapsamındaki diş bölütleme işleminde dişlere ait piksel değerlerinin diş olmayan piksel değerlerine göre daha az olması Doğruluk başarıım metriğinin bu çalışma için uygun değerlendirme ölçütü olmadığı görülmüştür. Bu yüzden Hatırlama, Kesinlik ve özellikle F1 başarıım metriklerine de bakılmıştır. ML modelinin tek başına diş bölgesi bölütleme işlemi için yeterli olmasının yanında dişlerin bölütlenmesi işleminde yeterli olmadığı görülmüştür. Bu sebeple çalışmada yapılan işlere ek olarak şekil uydurma, DL modeli geliştirme ve uygulama ve Chan-Vese bölütleme algoritması kullanma işlemleri yapılmıştır.




Şekil 3.6: Farklı hastalara ait ML modellerinin diş bölgesi bölütleme sonuçları.

3.3 Diş Bölgesinin Bölütlenmesi

Çalışmada diş bölgesinin tam olarak bölütlenmesini sağlayan şekil uydurma yönteminin kullanıldığı ve ML modelinin performansının arttırıldığı bölümdür. ML modelinden elde edilen sonuçlarda ilk önce ağız bölgesinin sağ ve sol sınırları her görüntü için belirlenir. Daha sonra bu sınırların değişmeyeceği varsayılarak sınırların arasında kalan dişlere ait piksellere ve dişlere ait olmayan piksellere göre optimizasyon problemi belirlenip çözülür. Çözüm yöntemi olarak gradyan azaltma yöntemi kullanılmıştır. Optimizasyon uygulamasında diş bölgesine uyacak iki eliptik şekil piksellere göre uydurulur. Uydurulan şekillerde büyük eliptik şeklin merkez noktası ML modelinde kullanılan ve daha önce denenmemiş tez için geliştirilen öznelik, diş bölgesinin merkez noktası, kullanılmıştır. Merkez noktasının y-koordinat düzleminde olan bileşeninin 0.1 kadarı ikinci eliptik şekil için parametre olarak kullanılmıştır.

Şekil 3.7’de ML modeli sonucunun üzerine uydurulmuş diş bölgesi şekli verilmiştir ve şekildeki her bir görüntü farklı hastaya ait ML modeli sonucunu ve şekil uydurma sonucunu içermektedir.



Şekil 3.7: Farklı hastalara ait deforme şekil uydurma sonuçları.

Şekil uydurma sonucunda ortaya çıkan en önemli sonuç, üst çene bölgesinde diş etinin bulunduğu alanın alınmaması olmuştur. Bu sayede diş eti ve üzerindeki kemikleri içeren piksellerin yanlış sınıflandırılmasının önüne geçilmiş ve ML modelinin sonucunda elde edilen sınıflandırma skorlarında (Çizelge 3.4) iyileştirme yapılmıştır. Sonraki aşama olan DL modelinde de şekil uydurma sonuçları kullanılarak üst çene üstünde diş etlerinin veya çene kemiğinin diş olarak tespit edilmesi şekil uydurma işlemi ile engellenmiştir.

3.4 DL Modeli

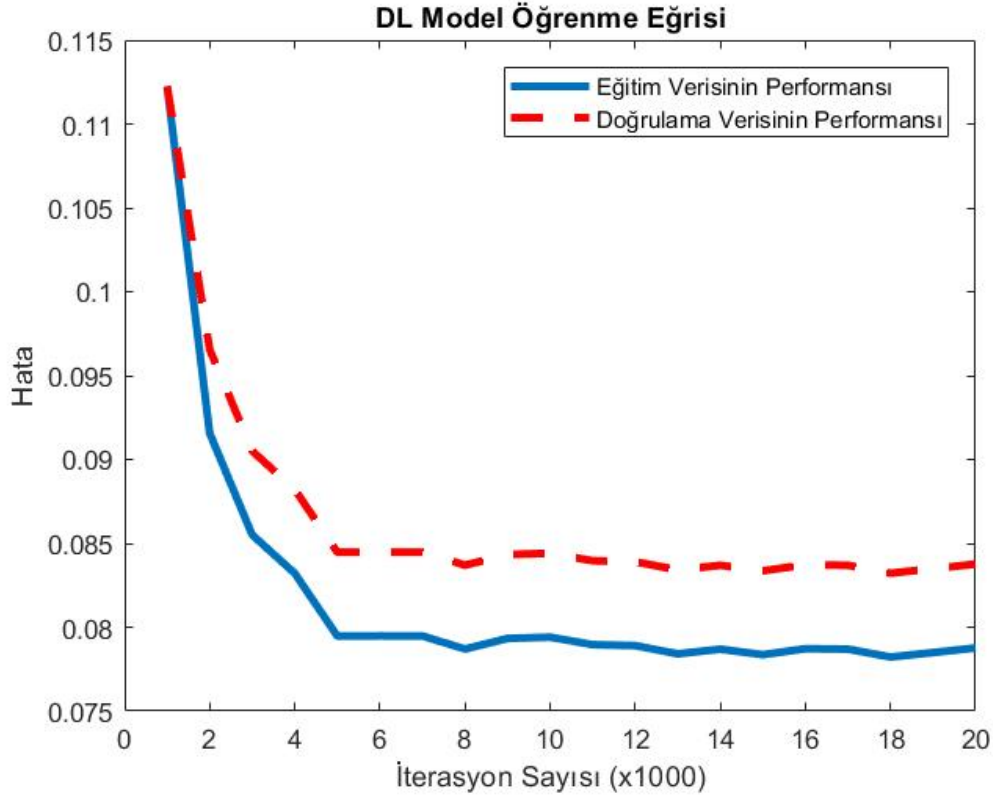
Çalışmada, diş bölgesinin bölütlenmesi yapıldıktan sonra dişlerin bölütleme işleminin yapılabilmesi için önce dişler tespit edilmiştir. DL modelinin oluşturulması için bir dizi işlemler yapılmış ve parametreler belirlenmiştir.

İlk şekil uydurma ve ML modeli ile otomatik olarak bulunan diş bölgesi alt örnekleme yapılan orijinal görüntüler üzerinde kullanılmıştır. Daha sonra orijinal görüntülerden diş bölgesinin olduğu alanlar kesilmiştir. Bir sonraki aşamada, her görüntü için dişlerin bulunduğu bölgeler dikdörtgen kutular içinde etiketlenmiştir. Son olarak DL modeli olan Faster R-CNN algoritmasına parametreler girilerek modelin eğitimi başlatılmıştır.

Algoritmada kullanılan parametreler Çizelge 3.5’de verilmiştir. DL modeline ait öğrenme eğrisi, kırmızı kesikli çizgi doğrulama ve mavi düz çizgi eğitim verisinin performansı olmak üzere Şekil 3.8’de gösterilmiştir.

Çizelge 3.5: DL modelinde kullanıcı girişli parametreler.

DL Modeli Parametresi	DL Modeli Parametresinin Değeri	Açıklama
num_classes	2	"diş" ve "diş değil" nesnelere ve sınıfları
maxpool_kernel_size	2	CNN için maksimum değer bulma filtresinin matris boyutu
maxpool_stride	2	Maksimum değer bulma filtresinin görüntü üzerinde kaydırılma adım sayısı
max_detections_per_class	100	Görüntüdeki her sınıf için maksimum tespit sayısı
score_converter	SOFTMAX	Sınıf tespiti için kullanılan aktivasyon fonksiyonu
initial_learning_rate	0.0003	Model içindeki parametrelerin güncellenme adım miktarı
iou_threshold	0.6	IoU başarımlarının (2.22) eşik değeri
from_detection_checkpoint	true	Model eğitimi sırasında modelin başarımlarını düşürdüğünde veya veri ezberlenmeye başladığında en iyi modelin kaydedilmesi
num_steps	200000	Modelin eğitimi için gereken maksimum iterasyon sayısı

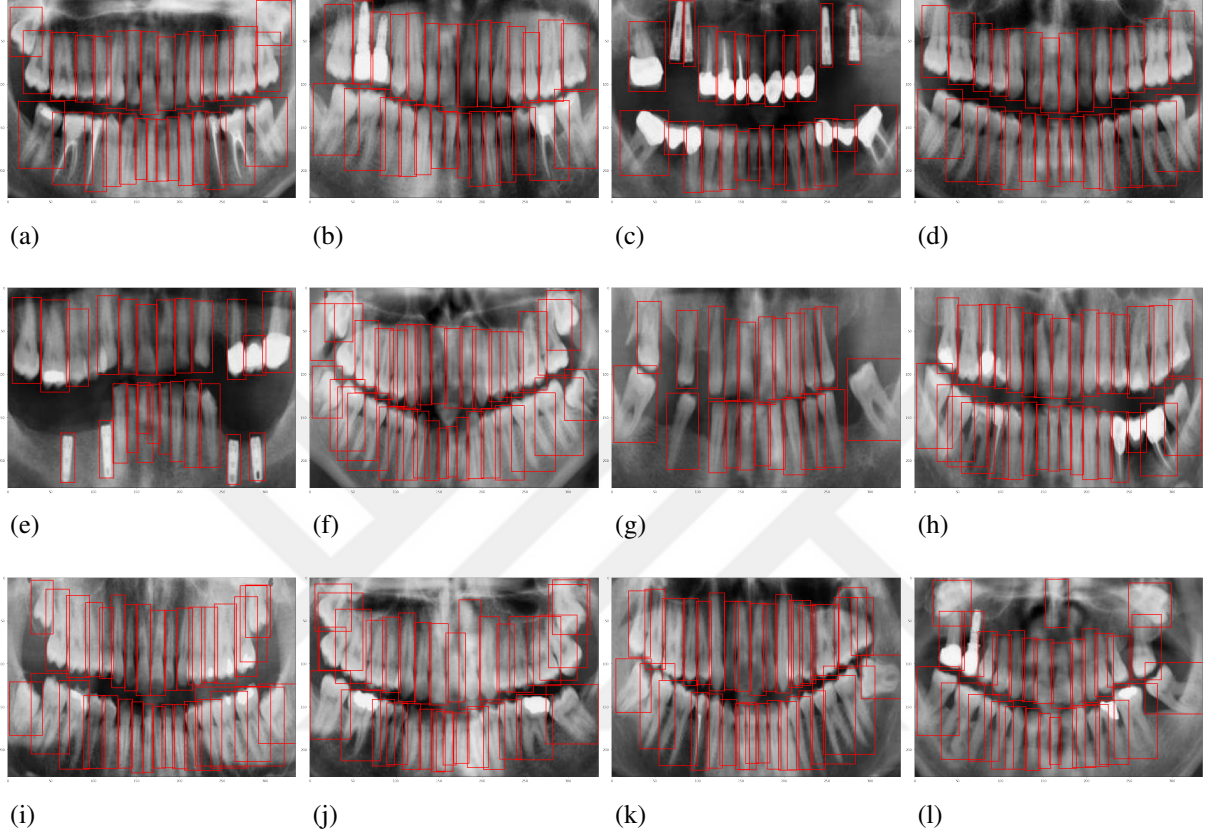


Şekil 3.8: DL modelinin öğrenme eğrisini gösteren grafik (düz çizgili eğitim verisi ve kesikli çizgili doğrulama verisi).

Şekil 3.8’de görüldüğü üzere eğitim verisi ile doğrulama verisi için gelen hata değerlerinin öğrenme eğrilerinde paralel gitmesi ve aralarındaki farkın çok olmaması modelin veriyi ezberlemediği anlamına gelmektedir. DL modeline giriş olarak, görüntüler orijinal görüntülerin ML modelinde bulunan dış bölgesinin sınırları içinde kalan kesilmiş halleri verilmiştir. Görüntü kesme işlemi, dış bölgesi için oluşturulan şekil uydurma optimizasyonu ile yapılmıştır. Bu alan içinde kalan orijinal görüntüler DL modeline girdi olarak verilip çıktısı incelenmiştir.

Farklı hastalar için DL modelinin çıktısı, kırmızı düz çizgili dikdörtgen kutular içinde bulunan dişleri göstermek ve (a-d) arası eğitim verisindeki bazı görüntülerin sonuçları, (e-h) arası doğrulama verisindeki bazı görüntülerin sonuçları, ve (i-l) arası test verisindeki bazı görüntülerin sonuçları olmak üzere Şekil 3.9’da verilmiştir. Şekil 3.9’da görüldüğü üzere dişlerin tespiti eğitim, doğrulama ve test görüntülerinde iyi sonuçlar olarak yapılmıştır. Şekilde görüldüğü üzere DL modeli çıkışında dişler, diş ile beraber dolgular, sadece dolgular ve implantlar başarılı bir şekilde bulunmuştur. Ancak bazı görüntülerde diş olmayan nesnelerin veya iki dişin tek diş olarak tespiti gözlenmiştir. Örneğin, Şekil 3.10i ve 3.10k’de dişler arası boşluğun yeterince fazla olmaması nedeniyle iki dişi tek diş gibi görmüş veya bir dişin kökü diğer dişin

bulunduğu alana girmesi nedeniyle ilgili diş iki kere bulunmuştur. Başka bir örnekte, Şekil 3.10l'de üst çene bölgesinde diş olmayan bir alan diş olarak tespit edilmiştir. Bu problemleri çözmek ve tam otomatik diş bölütlemesi yapabilmek için Chan-Vese algoritması bir sonraki aşamada kullanılmıştır.



Şekil 3.9: Farklı hastalara ait DL modelinin sonuçları.

3.5 Dişlerin Bölütlenmesi

Çalışmada dişleri içeren dikdörtgen kutular DL modeli ile bulunduktan sonra dişler, tek tek hem ML hem şekil uydurma hem de DL sonuçlarından faydalanılarak bölütlenmiştir. ML modeli sonucundan elde edilen diş bölgesindeki dişler ve diş olmayan bazı kısımları bölütlenme sonucu elde edilmiştir. Bu sonuç üzerinde diş bölgesindeki diş olmayan piksellerin bir kısmını elemek için şekil uydurma işlemi yapılmıştır. DL modelinde ise şekil uydurma ile oluşan diş bölgesi sınırları orijinal görüntülerde kullanılmış ve diş bölgesi kesilerek bu bölge üzerinde dişlere ait kutular bulunmuştur. Bu kutuların küçültülerek tam diş bölütleme işlemi yapılabilmesi için Chan-Vese algoritması kullanılmıştır. Bu algoritma ile dişlere ait DL modelinin çıktısı ve ML modelinin çıktısı birleştirilerek dişlere ait pikselleri içeren tam otomatik diş bölütleme işlemi gerçekleştirilmiştir. Chan-Vese algoritmasında kullanıcı giriшли parametreler ve

parametrelerin otomatik arama ile bulunan deęerleri Çizelge 3.6'da verilmiřtir.

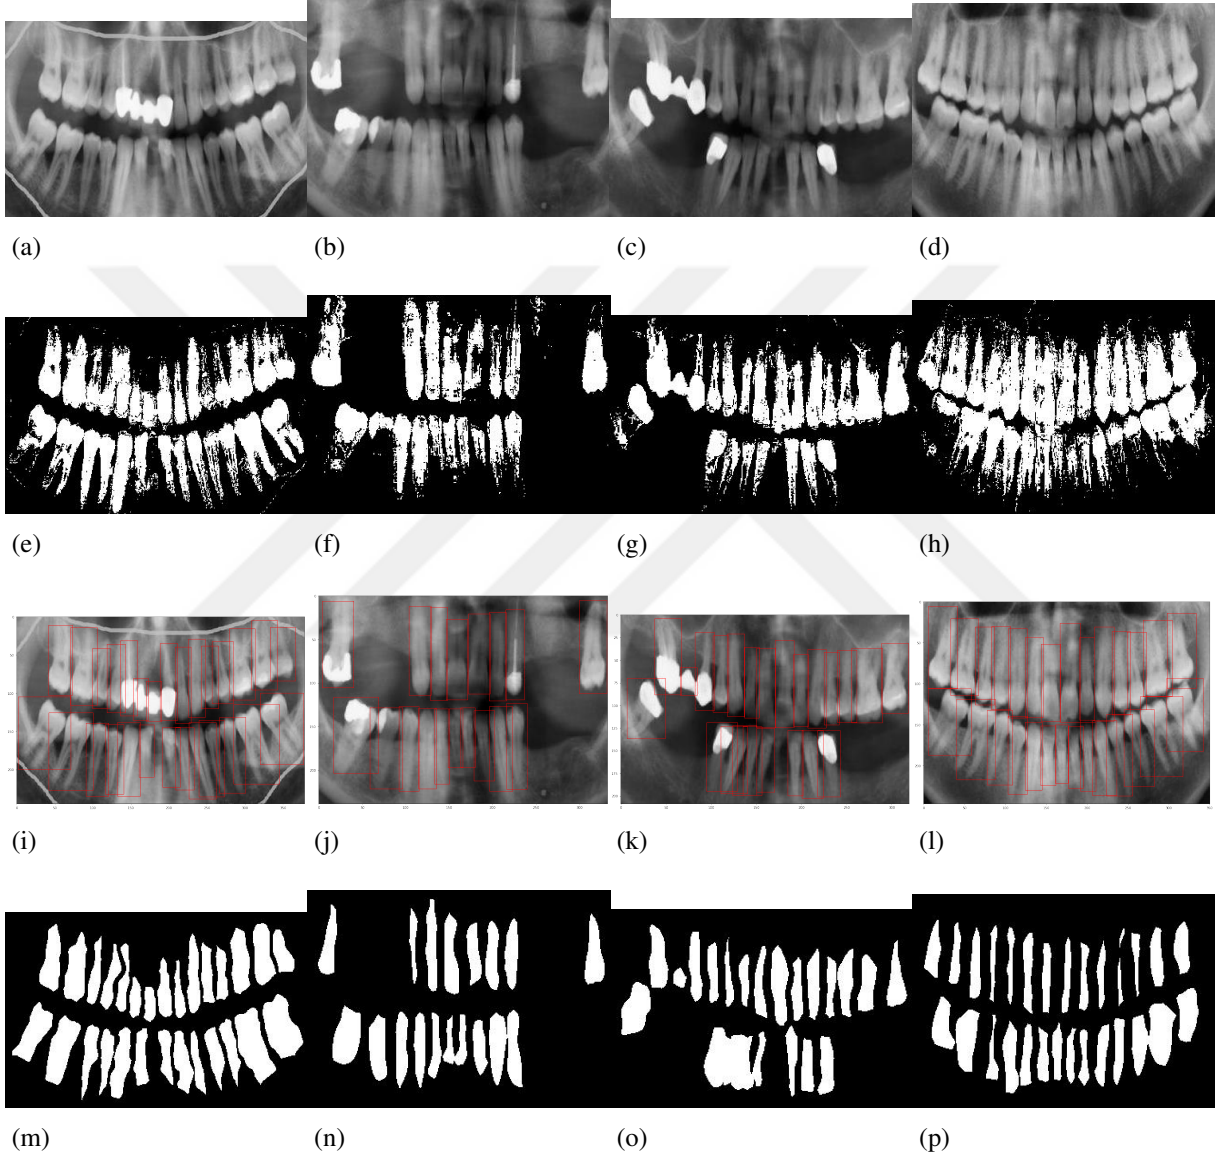
Çizelge 3.6: Chan-Vese algoritmasında kullanıcı giriřli parametreler.

Algoritma Parametresi	Algoritma Parametresinin Deęeri	Açıklama
σ	1	Gauss filtre varyansı
α	0.4	Noktalar arası gerginlięi kontrol eder.
β	0.2	Sınırların bükülmesini kontrol eder.
γ	1	Sınırlar için öğrenme adım sayısı
κ	0.15	Görüntüdeki yüksek enerjili sınırları kontrol eder.
w_l	0.3	Sınırlar için aęırlık katsayısı
w_e	0.4	Görüntüdeki kenarlar için aęırlık katsayısı
w_t	0.7	Görüntüdeki gürültü için aęırlık katsayısı height
iterations	200	Algoritma için gereken maksimum iterasyon sayısı

Diř bölütleme için tasarlanan algoritmanın çalışma adımları her görüntü için řu şekilde olmaktadır:

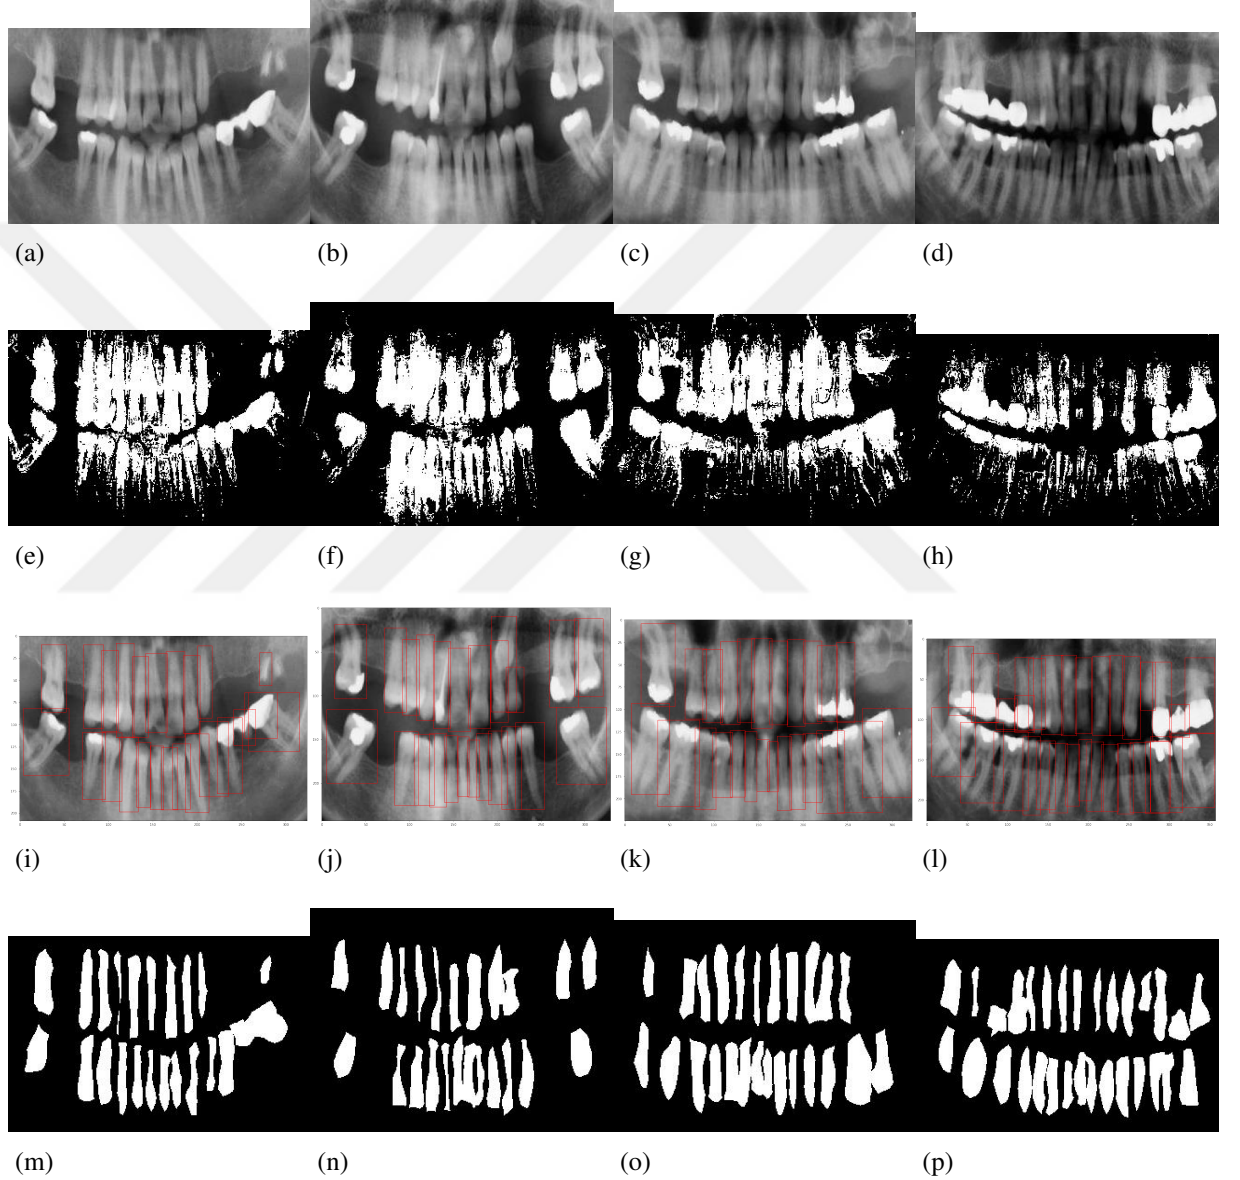
1. DL modelinden elde edilen diřleri ięine alan kutunun koordinatları alınır.
2. ML modeli sonucu olan sadece "diř" ve "diř deęil" sınıflarını ięeren görüntü, Gauss filtresinden geęirilir.
3. DL modelinden elde edilen kutular, ML sonucu üzerine yerleřtirilerek ięin Chan-Vese algoritması uygulanır.
4. Chan-Vese algoritması sonucunda bulunan diře ait maske eęer 4450 eřik deęerinden büyükse iki diři ięerdięini gösterir ve diř maskesi olarak alınmaz.
5. Chan-Vese algoritması sonucunda bulunan diře ait maske ięerisinde ML modelinden elde edilen "diř" sınıflarını ięermiyorsa diře ait bir maske olmadıęını gösterir ve diř maskesi olarak alınmaz.
6. Adım (4) ve (5) kontrol edildikten sonra diře ait maskelerin Chan-Vese algoritması sonucunda çok geniř olmasını engellemek ięin maskelerin geniřlięi ve yükseklięi küçültülür.
7. Adım (1) - (6) arası DL modelinde ilgili görüntü ięin bulunana diře ait olan her kutu ięin tekrarlanır.

Şekil 3.10'da kırmızı düz çizgili dikdörtgen kutular, bulunan dişleri göstermekte olup her sütun farklı bir hastaya ait görüntüler gösterilmiştir. Şekil 3.10'da görüldüğü üzere ML ve DL modellerinde eğitim verisi olarak kullanılan görüntülere ait sonuçlar, diş bölgesi bölütleme ve diş bölütleme için yeterli ve başarılı olmuştur. Chan-Vese algoritması ve diş bölütleme için geliştirilen algoritma sonucunda bazı dişlerin genişliği azalmıştır ancak tespit ve bölütlenme işlemleri için yeterli seviyede olduğu görülmüştür.



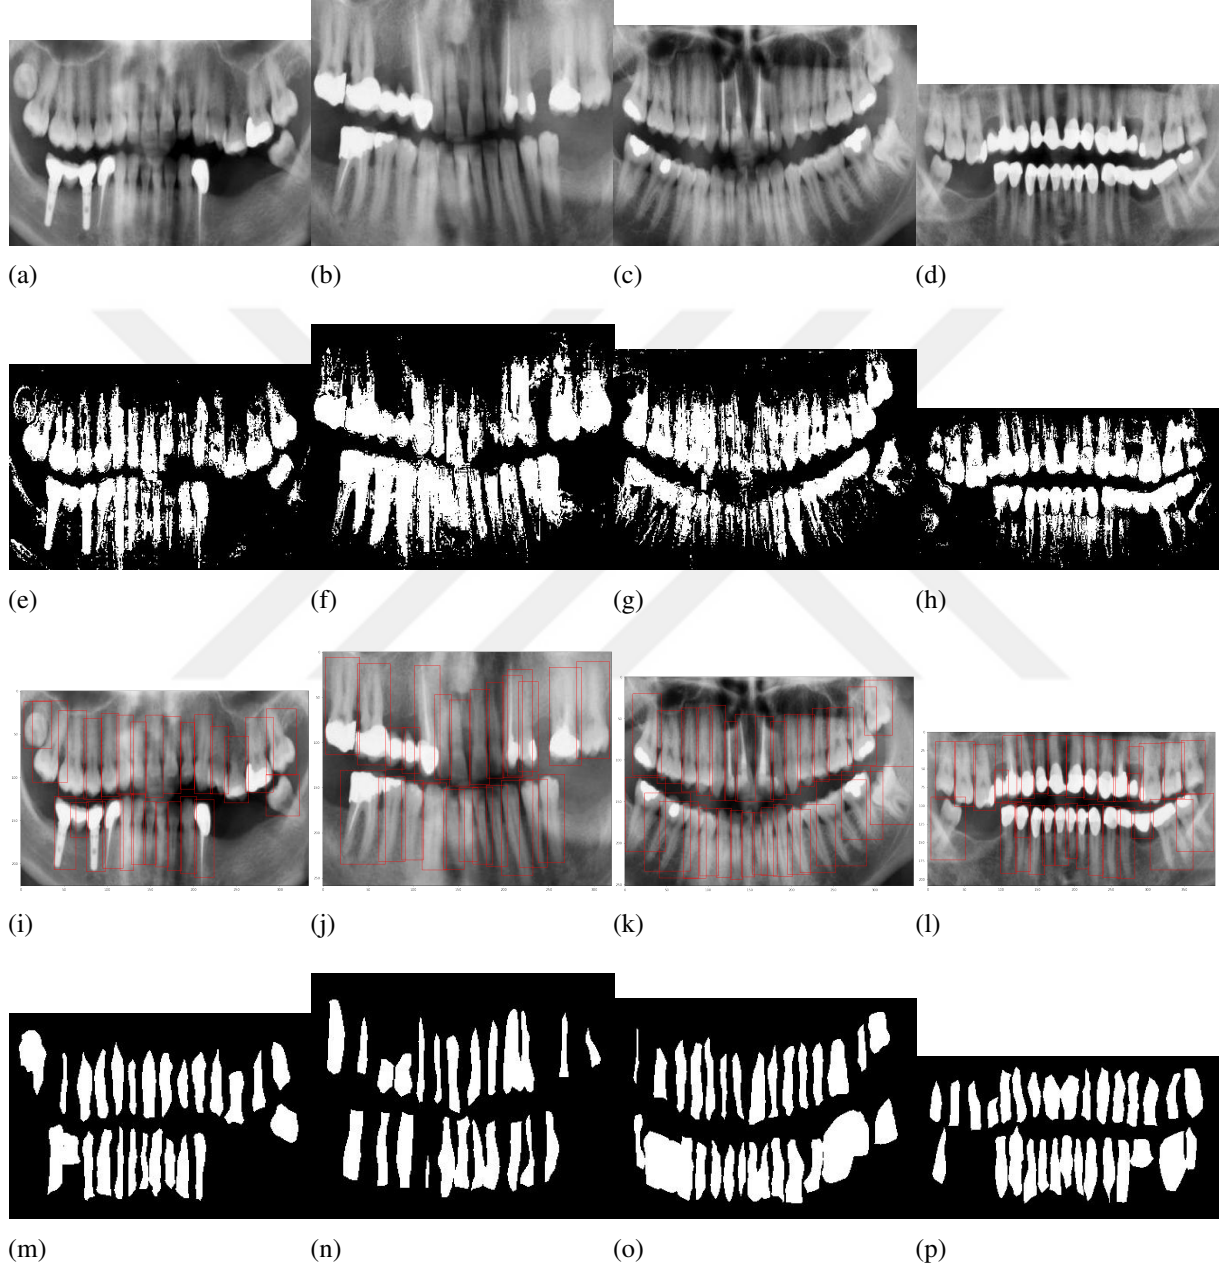
Şekil 3.10: Diş bölütleme için kullanılan ML, DL modellerinin ve Chan-Vese bölütleme algoritmasının ML, DL modelleri için hazırlanan eğitim verilerine ait sonuçları. (a-d) arası farklı hastalara ait şekil uydurma ile kesilmiş panoramik X-Ray diş görüntüleri, (e-h) arası ML modelinin sonuçları, (i-l) arası DL modelinin sonuçları, ve (m-p) arası Chan-Vese algoritmasının sonuçları.

Şekil 3.11’de kırmızı düz çizgili dikdörtgen kutular, bulunan dişleri göstermekte olup her sütun farklı bir hastaya ait görüntüler gösterilmiştir. Şekil 3.11’de görüldüğü üzere ML ve DL modellerinde Şekil 3.10’dan farklı olarak doğrulama verisi olarak kullanılan görüntülere ait sonuçlar, diş bölgesi bölütleme ve diş bölütleme için yeterli ve başarılı olmuştur. Chan-Vese algoritması ve diş bölütleme için geliştirilen algoritma sonucunda bazı dişlerin genişliği azalmıştır ancak tespit ve bölütlenme işlemleri için yeterli seviyede olduğu görülmüştür.



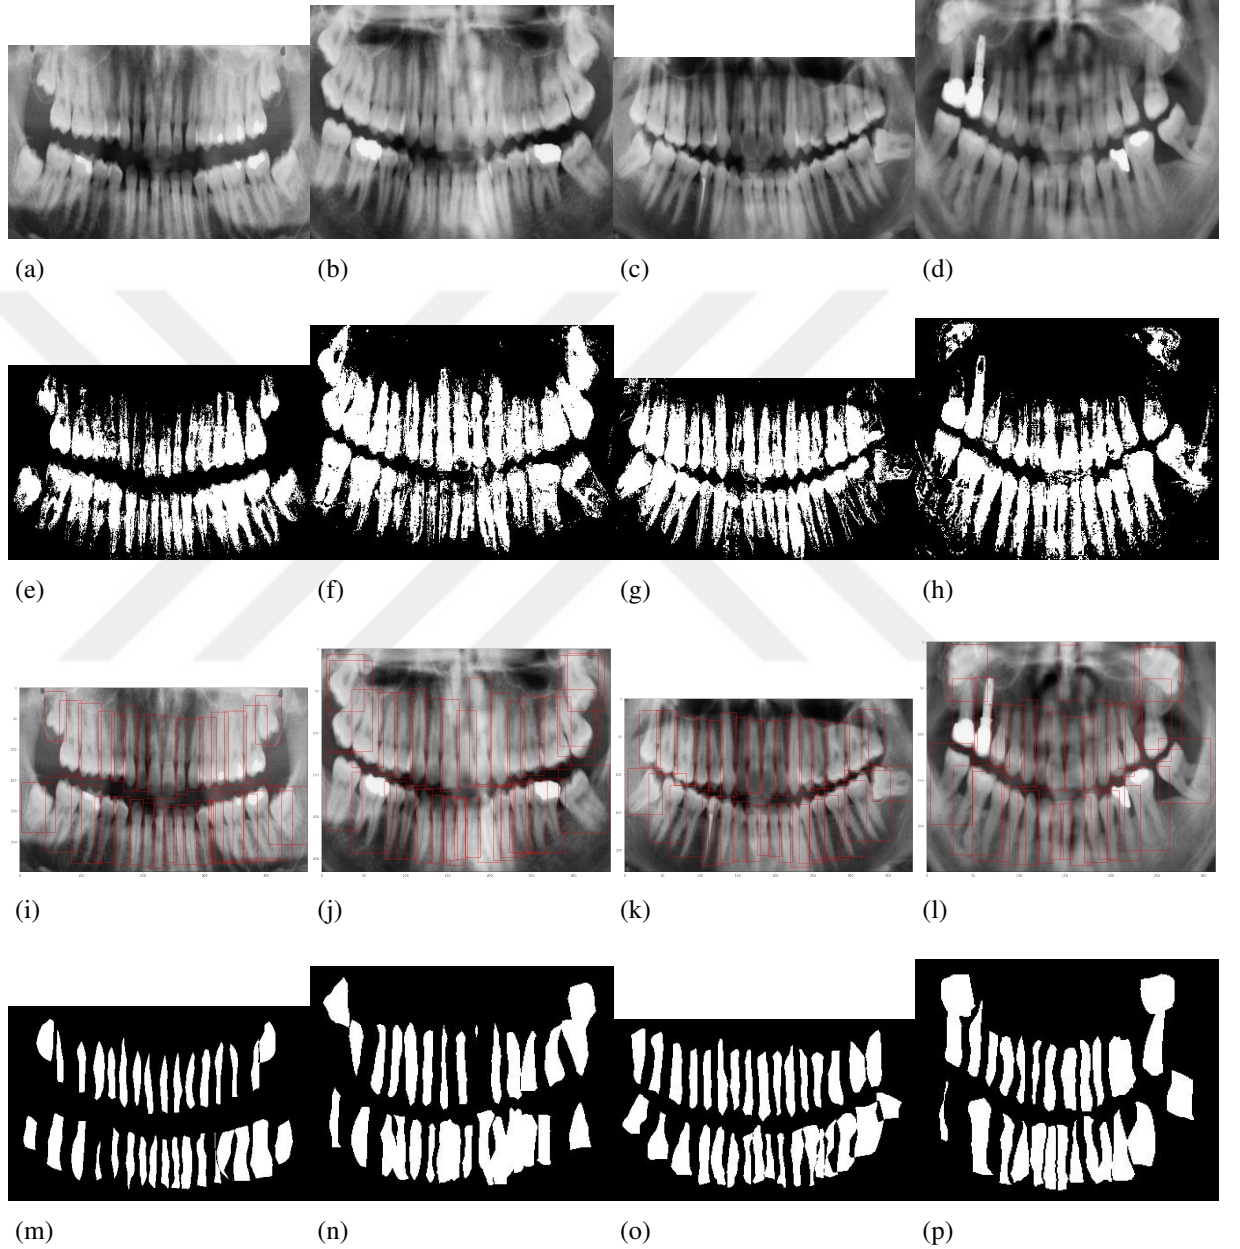
Şekil 3.11: Diş bölütleme için kullanılan ML, DL modellerinin ve Chan-Vese bölütleme algortimasının ML, DL modelleri için hazırlanan doğrulama verilerine ait diğer sonuçlar. (a-d) arası farklı hastalara ait şekil uydurma ile kesilmiş panoramik X-Ray diş görüntüleri, (e-h) arası ML modelinin sonuçları, (i-l) arası DL modelinin sonuçları, ve (m-p) arası Chan-Vese algoritmasının sonuçları.

Şekil 3.12’de görüldüğü üzere ML ve DL modellerinde Şekil 3.11’den farklı olarak test verisi olarak kullanılan görüntülere ait sonuçlar, diş bölgesi bölütleme ve diş bölütleme için yeterli ve başarılı olmuştur. Chan-Vese algoritması ve diş bölütleme için geliştirilen algoritma sonucunda bazı dişlerin genişliği azalmıştır ancak tespit ve bölütlenme işlemleri için yeterli seviyede olduğu görülmüştür.



Şekil 3.12: Diş bölütleme için kullanılan ML, DL modellerinin ve Chan-Vese bölütleme algoritmasının ML, DL modelleri için hazırlanan test verilerine ait diğer sonuçları. (a-d) arası farklı hastalara ait şekil uydurma ile kesilmiş panoramik X-Ray diş görüntüleri, (e-h) arası ML modelinin sonuçları, (i-l) arası DL modelinin sonuçları, ve (m-p) arası Chan-Vese algoritmasının sonuçları.

Şekil 3.13’de görüldüğü üzere ML ve DL modellerinde Şekil 3.12’den farklı olarak test verisi olarak kullanılan farklı görüntülere ait sonuçlar, diş bölgesi bölütleme ve diş bölütleme için yeterli ve başarılı olmuştur. Chan-Vese algoritması ve diş bölütleme için geliştirilen algoritma sonucunda bazı dişlerin genişliği azalmıştır ancak tespit ve bölütlenme işlemleri için yeterli seviyede olduğu görülmüştür.



Şekil 3.13: Diş bölütleme için kullanılan ML, DL modellerinin ve Chan-Vese bölütleme algoritmasının ML, DL modelleri için hazırlanan test verilerine ait diğer sonuçları. (a-d) arası farklı hastalara ait şekil uydurma ile kesilmiş panoramik X-Ray diş görüntüleri, (e-h) arası ML modelinin sonuçları, (i-l) arası DL modelinin sonuçları, ve (m-p) arası Chan-Vese algoritmasının sonuçları.

Dişlerin bölütleme işlemi, görüntü iyileştirme, ML, değişken şekil uydurma, DL ve Chan-Vese sırasıyla kullanılarak tamamlanmıştır. Bir sonraki aşamada diş bölütleme performansı, diş hekimleri yardımıyla elle etiketlenen dişlere ait pikseller ile diş bölütleme işlemi sonucunda tam otomatik bir şekilde bilgisayar yardımıyla elde edilen piksellerin karşılaştırılması ve sınıflandırma skorları ile ölçülmüştür.

3.6 Piksellerin Sınıflandırma Analizi

Bu aşamada çalışma sonucunda elde edilen dişlere ait pikseller ile diş hekimleri yardımıyla elle etiketlenmiş dişlere ait pikseller karşılaştırılmıştır. Sonuçlar Çizelge 3.7’de verilmiştir.

Çizelge 3.7: Diş bölütleme işleminin sonucuna göre sınıflandırma skorları

Veri Setleri	Sınıflandırma Skorları			
	Doğruluk	Hatırlama	Kesinlik	F1
Eğitim	0,9825	0,8854	0,9162	0,9068
Doğrulama	0,9798	0,8802	0,9078	0,8974
Test	0,9722	0,8747	0,8966	0,8901

Çizelge 3.7’de verilmiş olan sınıflandırma skorlarının, ML modelinde elde edilen ve Çizelge 3.4’de gösterilen skorlara göre daha iyi olduğu görülmektedir. Ayrıca dişlerin bulunduğu noktalar ve dişlere ait olan tam sınırlar otomatik olarak bulunmuştur.

4. SONUÇ

Bu çalışmada panoramik X-Ray diş görüntüleri üzerinde yapılan dişlerin bölütlemesinin tam otomatik olarak yapılamaması temel çıkış noktası olmuştur. Panoramik X-Ray diş görüntülerinin diğer X-Ray diş görüntülemelerine göre daha ucuz olması birçok hasta için yaygın kullanılan görüntüleme çeşidi olmasını sağlamıştır. Bunun ile beraber dişlerin tespitini ve bölütlenmesini zorlaştırmıştır. Çalışma kapsamında dişlerin bölütlemesi için panoramik X-Ray diş görüntülerinde kullanılmak üzere dişleri bölütlenmesini otomatik olarak yapan bir yapı tasarlanmıştır. Çalışmada 50 farklı hastanın dolgular ve implantlar dahil olmak üzere diş olduğu kesin olan bölgeler diş hekimleri yardımıyla etiketlenen panoramik X-Ray diş görüntüleri kullanılmıştır. Çalışmada görüntü eniyileme tekniği HE, ML modeli geliştirme, diş bölgesi bölütlemesi için değişken şekil uydurma, DL modeli geliştirme ve Chan-Vese ile geliştirilen diş bölütleme algoritması yapılmıştır. ML, DL ve değişken şekil uydurma metotları ile metotların her birindeki kullanıcı giriqli parametreler optimizasyon ile belirlenmiştir. ML ve diş bölütleme kullanılarak yapılan bölütleme işleminde başarıml metriği olarak F1 skor seçilmiştir. DL kullanılarak yapılan diş tespiti işleminde başarıml metriği olarak IoU seçilmiştir.

ML modelinin başarımlını, *max_depth*, *learning_rate* ve *iterations* parametrelerinin ciddi şekilde arttırdığı gözlenmiştir. Bu tez kapsamında geliştirilmiş ve daha önce denenmemiş ML modeli için en önemli öznelik, diş bölgesinin merkezinin otomatik çıkartılması olarak belirlenmiştir. ML modelinin eğitilmesinde K-CV algoritmasının verinin ezberlenmemesindeki ve modelin başarılı olmasındaki etkisi gözlenmiştir. Ayrıca *max_depth* parametresinin CatBoost algoritmasında verinin ezberlenmemesi için önemli bir parametre olduğu görülmüştür. ML modeli tek başına dişlerin tek tek bölütlenmesinde yeterli olmadığı Şekil 3.6'da görülmektedir. Bu yüzden bu modelin çıktısı, diş olmayan bazı piksellerin elemesinde ve tam diş bölgesi bölütlenmesinde kullanılmak üzere değişken şekil uydurma optimizasyonunda kullanılmıştır.

Değişken şekil uydurma yönteminin başarımlını, ML modelinin çıktısından elde edilen diş bölgesi sınırlarının ve bu tez kapsamında çıkartılmış ve geliştirilmiş öznelik olan diş bölgesinin merkez noktasının ciddi şekilde arttırdığı gözlenmiştir. Uygulanan optimizasyon yönteminde diş bölgesi içinde kalan "diş" olarak bulunan pikseller, "diş değil" olarak bulunan pikseller ve uydurulacak şekil dışında kalmış "diş" olarak bulunan pikseller maliyet fonksiyonunda kullanılmıştır. Sonuç olarak alt çenenin

şekli, diş bölgesinin sağ ve sol sınırları ve üst çenenin şekli düzgün bir biçimde elde edilmiştir. Çıkarılan şekiller orijinal görüntüler üzerinde kullanılarak diş bölgesi orijinal görüntüden ayrılmıştır. Ayrılan görüntüler DL modelinin girdisi olarak kullanılmıştır. Yapılan optimizasyon sayesinde DL modelinin düzgün çıktı vermesi sağlanmıştır.

DL modelinin başarımını, *maxpool_kernel_size*, *maxpool_stride*, *score_converter* ve *iou_threshold* parametrelerinin ciddi şekilde arttırdığı gözlenmiştir. Dişlere ait sınırlar dikdörtgen bir kutu içerisinde bulunmuştur. Bu kutuların diğer dişlerin bir kısmını içerdiği durumlar olduğu gibi iki diş bir diş olarak aldığı veya diş olmayan alanları diş olarak tespit ettiği de nadir de olsa görülmüştür. DL modelinin tam panoramik X-Ray görüntülerinde az veri ile düzgün çalışmadığı tespit edildiği için öncesinde tam diş bölgesi bölütleme işlemi gerçekleştirilmiştir. Genel olarak DL modelinin dişlerin tespitinde başarılı olduğu görülmüştür.

Diş bölütleme işleminde ML ve DL modellerinin çıktıları Chan-Vese algoritmasının girdisi olarak kullanılmıştır. Diş bölütleme yönteminin başarımını, Chan-Vese algoritmasının parametreleri (σ , α , β , γ , κ , w_l , w_e , w_t ve *iterations*), ML modeli çıktısı ve DL modelinin çıktısı ciddi şekilde etkilediği ve arttırdığı gözlenmiştir. ML modeli sonucundaki görüntüler üzerinde DL modelinden elde edilen kutular Chan-Vese algoritması ile küçültülerek dişlere ait sınırlar bulunmuştur. ML modelinden gelen sınıflandırma skorları iyileştirilmiştir. DL modelinden gelen iki diş bir diş alınması veya diş olmayan alanı diş olarak tespit edilmesi gibi hatalar diş bölütleme işleminde geliştirilen algorithmada giderilmiştir.

Genel olarak çalışmada benzer çalışmalara göre çok daha az görüntü verisi kullanılmış ve en iyi sonuçlardan birine sahip çalışma [3] ile benzer sonuçlar elde edilmiştir. Ayrıca çalışmada daha önce denenmemiş ve geliştirilmemiş bu tez kapsamında çıkarılan öznelik, diş bölgesinin merkez noktası, kullanılmıştır. Diş bölgesinin tam otomatik olarak bölütlenmesinde ise değişken şekil uydurma yöntemi diğer çalışmalardan farklı olarak ilk bu çalışmada kullanılmıştır.

Çalışma kapsamında oluşturulan bu yapı büyütülebilir ve modüler bir şekilde başka bölütleme modelleri veya başarımları ile kullanılıp performans artırılabilir. Oluşturulan bu yapı ile diş bölütleme işlemi kullanıcının deneyiminden bağımsız olarak tam otomatik bir biçimde yapılarak daha genel bir yaklaşım oluşturulabilir.

Yapılan çalışma aşağıda belirtilen yöntemlerle daha da ileriye taşınabilir.

- ML ve DL modelleri için daha fazla görüntü verisi elde edilip modellerin bu verilerle eğitilmesi yapılabilir. Örneğin, eldeki verilerde yeterli çeşitliliğe sahip diş görüntüleri olsa da 20'lik dişlere sahip bir bireye veya yeni diş çıkaran bir bireye ait görüntüler yeteri kadar yoktur.
- Diş bölgesi bölütlenmesinde kullanılan değişken şekil uydurma yönteminde tek

bir şekil yerine hem üst çene için hem de alt çene için iki farklı değişken şekil uydurma optimizasyonu yapılarak dişlere ait olmayan alanların elenmesi daha kesin bir biçimde yapılabilir.

- DL modelinde sadece diş tespiti yerine son dönemde genel olarak CNN temelli derin öğrenme modeli olan Mask R-CNN algoritması ile hem dişlerin tespiti hem de tespit edilen dişlerin bölütlenmesi gerçekleştirilebilir.
- ML modeli için diş bölgesinin merkez noktası gibi ayırt edici ve önemli daha çok öznelik çıkartılabilir.
- Diş bölütleme işleminde kontrollü bir biçimde dişlerin bölütlenmesinden sonra çevresinin küçültülmesi ve tam diş şeklinin alınması sağlanabilir.





KAYNAKLAR

- [1] **Ehsani, R. A.** et al. (2012). Dental X-Ray Image Segmentation and Multiple Feature Extraction. In: *TELKOMNIKA Indonesian Journal of Electrical Engineering* 11, pp. 188–197.
- [2] **Gil Silva Luciano Oliveira, M. P.** (Feb. 2018). Automatic segmenting teeth in X-ray images: Trends, a novel data set, benchmarking and future perspectives. In: *Expert Systems with Applications* 107, pp. 15–31.
- [3] **Jader, G.** et al. (2018). Deep Instance Segmentation of Teeth in Panoramic X-Ray Images. In: pp. 400–407.
- [4] **Naushad Ali, M. M.** and **Abdullah-Al-Wadud, M.** (2012). Image Enhancement Using a Modified Histogram Equalization. In: *Computer Applications for Web, Human Computer Interaction, Signal and Image Processing, and Pattern Recognition*. Ed. by **Kim, T.-h.** et al. Berlin, Heidelberg: Springer Berlin Heidelberg, pp. 17–24.
- [5] **Ali, R. B., Ejbali, R.,** and **Zaied, M.** (2015). GPU-based segmentation of dental X-ray images using active contours without edges. In: *2015 15th International Conference on Intelligent Systems Design and Applications (ISDA)*, pp. 505–510.
- [6] **Shah, S.** et al. (2006). Automatic tooth segmentation using active contour without edges. In: *2006 biometrics symposium: special session on research at the biometric consortium conference*. IEEE, pp. 1–6.
- [7] **Lira, P. H., Giraldi, G. A.,** and **Neves, L. A.** (2013). Using the mathematical morphology and shape matching for automatic data extraction in dental X-ray images. In: *IX Workshop de Visao Computacional*.
- [8] **Güven, A.** et al. (2020). Panoramik X-Ray Diş Görüntülerinde Diş Bölgesinin Makine Öğrenimi ile Bölütlenme. In: *28. Sinyal İşleme ve İletişim Uygulamaları Kurultayı*.
- [9] **Martin Berger, Q. Y.** and **Maier, A.** (2018). *Medical Imaging Systems*. Springer International Publishing.
- [10] **Jordan, D.** (2020). *Handbook of X-ray Imaging: Physics and Technology*. 1st Edition. Medical Physics.
- [11] **Raj, S., Raj, S.,** and **Kumar, S.** (2015). An Improved Histogram Equalization Technique for Image Contrast Enhancement. In:
- [12] **Parthipan, V.** (2017). Image Down-Scaler Using the Box Filter Algorithm. In:
- [13] **Mitchell, T. M.** (2006). *The discipline of machine learning*. Vol. 9. Carnegie Mellon University, School of Computer Science, Machine Learning ...

- [14] **Ayyon, D.** (2016). Machine learning algorithms: a review. In: *International Journal of Computer Science and Information Technologies* 7.3, pp. 1174–1179.
- [15] **Fatima, M., Pasha, M., et al.** (2017). Survey of machine learning algorithms for disease diagnostic. In: *Journal of Intelligent Learning Systems and Applications* 9.01, p. 1.
- [16] **Abbas, O. A.** (2008). Comparisons Between Data Clustering Algorithms. In: *International Arab Journal of Information Technology (IAJIT)* 5.3.
- [17] **Dhanachandra, N., Manglem, K., and Chanu, Y. J.** (2015). Image segmentation using K-means clustering algorithm and subtractive clustering algorithm. In: *Procedia Computer Science* 54, pp. 764–771.
- [18] **Kumar, K. S., Semwal, V. B., and Tripathi, R. C.** (2011). Real time face recognition using adaboost improved fast PCA algorithm. In: *arXiv preprint arXiv:1108.1353*.
- [19] **Jagielski, M.** et al. (2018). Manipulating machine learning: Poisoning attacks and countermeasures for regression learning. In: *2018 IEEE Symposium on Security and Privacy (SP)*. IEEE, pp. 19–35.
- [20] **Cui, Z. and Gong, G.** (2018). The effect of machine learning regression algorithms and sample size on individualized behavioral prediction with functional connectivity features. In: *Neuroimage* 178, pp. 622–637.
- [21] **Collobert, R. and Bengio, S.** (2001). SVMtorch: Support vector machines for large-scale regression problems. In: *Journal of machine learning research* 1.Feb, pp. 143–160.
- [22] **Sathya, R. and Abraham, A.** (2013). Comparison of supervised and unsupervised learning algorithms for pattern classification. In: *International Journal of Advanced Research in Artificial Intelligence* 2.2, pp. 34–38.
- [23] **Manogaran, G. and Lopez, D.** (2018). Health data analytics using scalable logistic regression with stochastic gradient descent. In: *International Journal of Advanced Intelligence Paradigms* 10.1-2, pp. 118–132.
- [24] **Gasso, G.** (2019). Logistic regression. In:
- [25] **Kuang, Q. and Zhao, L.** (2009). A practical GPU based kNN algorithm. In: *Proceedings. The 2009 International Symposium on Computer Science and Computational Technology (ISCSCI 2009)*. Citeseer, p. 151.
- [26] **Chen, J.** et al. (2016). A parallel random forest algorithm for big data in a spark cloud computing environment. In: *IEEE Transactions on Parallel and Distributed Systems* 28.4, pp. 919–933.
- [27] **Dorogush, A. V., Ershov, V., and Gulin, A.** (2018). CatBoost: gradient boosting with categorical features support. In: *arXiv preprint arXiv:1810.11363*.
- [28] **Prokhorenkova, L.** et al. (2018). CatBoost: unbiased boosting with categorical features. In: *Advances in neural information processing systems*, pp. 6638–6648.
- [29] **Haralick, R. M., Sternberg, S. R., and Zhuang, X.** (1987). Image analysis using mathematical morphology. In: *IEEE transactions on pattern analysis and machine intelligence* 4, pp. 532–550.

- [30] **Gupta, S., Mazumdar, S. G., and Student, M. T.** (2013). Sobel Edge Detection Algorithm. In:
- [31] **Reitermanova, Z.** (2010). Data splitting. In: *WDS*. Vol. 10, pp. 31–36.
- [32] **Syarif, I., Prugel-Bennett, A., and Wills, G.** (2016). SVM parameter optimization using grid search and genetic algorithm to improve classification performance. In: *Telkonnika* 14.4, p. 1502.
- [33] **Wang, Q. and Boyer, K. L.** (2012). The active geometric shape model: A new robust deformable shape model and its applications. In: *Computer vision and image understanding* 116.12, pp. 1178–1194.
- [34] **LeCun, Y., Bengio, Y., and Hinton, G.** (2015). Deep learning. In: *nature* 521.7553, pp. 436–444.
- [35] **Garcia-Garcia, A. et al.** (2017). A review on deep learning techniques applied to semantic segmentation. In: *arXiv preprint arXiv:1704.06857*.
- [36] **Long, J., Shelhamer, E., and Darrell, T.** (2015). Fully convolutional networks for semantic segmentation. In: *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 3431–3440.
- [37] **Liu, L. et al.** (2020). Deep learning for generic object detection: A survey. In: *International journal of computer vision* 128.2, pp. 261–318.
- [38] **Jiao, L. et al.** (2019). A survey of deep learning-based object detection. In: *IEEE Access* 7, pp. 128837–128868.
- [39] **Girshick, R.** (2015). Fast r-cnn. In: *Proceedings of the IEEE international conference on computer vision*, pp. 1440–1448.
- [40] **Qiu, W. et al.** (2019). Multi-label Detection and Classification of Red Blood Cells in Microscopic Images. In: *arXiv preprint arXiv:1910.02672*.
- [41] **Tuzoff, D. V. et al.** (2019). Tooth detection and numbering in panoramic radiographs using convolutional neural networks. In: *Dentomaxillofacial Radiology* 48.4, p. 20180051.
- [42] **Pan, S. J. and Yang, Q.** (2009). A survey on transfer learning. In: *IEEE Transactions on knowledge and data engineering* 22.10, pp. 1345–1359.
- [43] **Chan, T. F. and Vese, L. A.** (2001). Active contours without edges. In: *IEEE Transactions on Image Processing* 10.2, pp. 266–277.
- [44] **Chan, T. and Vese, L.** (1999). An active contour model without edges. In: *International Conference on Scale-Space Theories in Computer Vision*. Springer, pp. 141–151.
- [45] **Getreuer, P.** (2012). Chan-veese segmentation. In: *Image Processing On Line* 2, pp. 214–224.
- [46] **Lee, J.-H. et al.** (2019). Application of a fully deep convolutional neural network to the automation of tooth segmentation on panoramic radiographs. In: *Oral Surgery, Oral Medicine, Oral Pathology and Oral Radiology*.

ÖZGEÇMİŞ

Ad-Soyad : Ali Güven
Uyruđu : T.C.
Dođum Tarihi ve Yeri : 11.12.1995 Altındađ, Ankara
E-posta : aliguven@etu.edu.tr

ÖĐRENİM DURUMU:

- **Yüksek Lisans** : 2020, TOBB ETÜ, Elektrik ve Elektronik Müh.
- **Lisans** : 2018, TOBB ETÜ, Elektrik ve Elektronik Müh.

MESLEKİ DENEYİM VE ÖDÜLLER:

Yıl	Yer	Görev
2019 - 2020	TOBB ETÜ	Tam Burslu Yüksek Lisans Öğrencisi
2018 - 2019	Aselsan A.Ş.	Radar Sistemleri Mühendisi

YABANCI DİL: İngilizce, Almanca

TEZDEN TÜRETİLEN YAYINLAR, SUNUMLAR VE PATENTLER:

- **Güven, A.** and Yetik, İ. Ş. and Çulhaođlu, A. and Orhan, K. and Kılıçarslan, M. K.(2020). Panoramik X-Ray Diş Görüntülerinde Diş Bölgesinin Makine Öğrenimi ile Bölütlenmesi. In: 28. *Sinyal İşleme ve İletişim Uygulamaları Kurultayı (SIU 2020)*. Gaziantep