

T.C.
İSTANBUL MEDENİYET ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
BİYOLOJİK VERİ BİLİMİ

DERİN ÖĞRENME İLE RESTORASYONLARIN TESPİT
EDİLEREK PANORAMİK DENTAL GÖRÜNTÜLERDEN
KİMLİK TESPİTİ

YÜKSEK LİSANS TEZİ

KAYHAN ULAMA

AĞUSTOS 2021

T.C.
İSTANBUL MEDENİYET ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
BİYOLOJİK VERİ BİLİMİ

DERİN ÖĞRENME İLE RESTORASYONLARIN TESPİT
EDİLEREK PANORAMİK DENTAL GÖRÜNTÜLERDEN
KİMLİK TESPİTİ

YÜKSEK LİSANS TEZİ

KAYHAN ULAMA

DANIŞMAN

DOÇ. DR. AYŞE BETÜL OKTAY

AĞUSTOS 2021

BİLDİRİM

Hazırladığım tezin tamamen kendi çalışmam olduğunu, akademik ve etik kuralları gözeterek çalıştığımı ve her alıntıya kaynak gösterdiğimi taahhüt ederim

Kayhan ULAMA

Danışmanlığını yaptığım işbu tezin tamamen öğrencinin çalışması olduğunu, akademik ve etik kuralları gözeterek çalıştığını taahhüt ederim.

Doç. Dr. Ayşe Betül OKTAY

ONAY

Kayhan ULAMA tarafından hazırlanan Derin Öğrenme ile Restorasyonların Tespit Edilerek Panoramik Dental Görüntülerden Kimlik Tespiti başlıklı bu yüksek lisans tezi, Biyolojik Veri Bilimi Bilim Dalında hazırlanmış ve jürimiz tarafından kabul edilmiştir.

JÜRİ ÜYELERİ

İMZA

Tez Danışmanı:

Doç. Dr. Ayşe Betül OKTAY

Kurumu: İstanbul Medeniyet Üniversitesi

Üyeler:

Prof. Dr. Hasan GÜÇLÜ

Kurumu: İstanbul Medeniyet Üniversitesi

Dr. Ulaş VURAL

Kurumu: Kocaeli Sağlık ve Teknoloji Üniversitesi

Tez Savunma Tarihi: 03.08.2021

TEŞEKKÜR

Tez çalışmasını yakından takip ederek akademik ve deneyimlerini benimle paylaşan, tezin her aşamasında bilimsel katkı, ilgi ve desteğini hiçbir zaman esirgemeyen, sabırla yönlendiren, kendisinden çok şey öğrendiğim değerli danışman hocam, Sayın Doç. Dr. Ayşe Betül OKTAY'a çok teşekkür ederim.

Fedakârlıkları ve bana olan güveni ile tez çalışmam boyunca her zaman yanımda olan aileme, arkadaşlarıma ve özellikle Anıl GÜRSES ve Mustafa Sabri İNCE'ye tüm kalbimle teşekkür ederim.

İÇİNDEKİLER

BİLDİRİM	i
ONAY	ii
TEŞEKKÜR	iii
KISALTMALAR	vii
TABLO LİSTESİ	viii
ŞEKİL LİSTESİ	ix
ÖZET	x
ABSTRACT	xi
BÖLÜM I	1
BÖLÜM II	4
2. LİTERATÜR ÖZETİ	4
2.1 CAPMI	4
2.2 WinID	5
2.3 AĞIZ İÇİ GÖRÜNTÜLER	7
2.4 PANORAMİK GÖRÜNTÜLER	7
2.5 3B LAZER TARAYICI GÖRÜNTÜLERİ	9
BÖLÜM III	11
3. MATERYAL VE METOT	11
3.1 YAPAY ZEKA	11
3.2 MAKİNE ÖĞRENMESİ	11
3.3 YAPAY SİNİR AĞLARI	12
3.4 DERİN ÖĞRENME	13
3.5 EVRİŞİMLİ SİNİR AĞLARI (ESA)	14
3.5.1 Evrişim (Konvolüsyon)	14
3.5.2 Havuzlama	15
3.5.3 Tam Bağlı Katman	16

3.5.4 Hiperparametre.....	16
3.5.4.1 Adım	16
3.5.4.2 Dolgu	16
3.5.4.3 Filtre (Çekirdek)	17
3.5.4.4 Aktivasyon Fonksiyonu	17
3.6 DIŞ RESTORASYONU SINIFLANDIRMA ESA MİMARİSİ.....	18
3.7 RASTGELE ORMAN METODU	21
3.7.1 ID3 (Yinelemeli Dikotomizer 3)	22
3.7.2 C4.5.....	23
3.7.3 Sınıflama ve Regresyon Ağacı (CART).....	24
3.8 DESTEK VEKTÖR MAKİNALARI (DVM).....	25
3.9 SMO ALGORİTMASI	26
BÖLÜM IV	27
4.1 VERİ KÜMESİ	27
4.1.1 Öklid Uzaklığı.....	30
4.1.2 Hamming Uzaklığı	31
4.1.3 Jaccard Uzaklığı.....	31
4.1.4 Kosinüs Uzaklığı.....	31
4.2 DOĞRULUK METRİKLERİ.....	31
BÖLÜM V.....	33
5.1 TEKNİK AYRINTILAR.....	33
5.1.1 Python	33
5.1.2. Tensorflow	33
5.1.3. Keras	34
5.1.4. Google Colab	34
5.2 KLASİK UZAKLIK METRİKLERİYLE KİMLİKLENDİRME.....	37
5.3 KİŞİ KİMLİKLENDİRMEDE SINIFLANDIRMA SONUÇLARI.....	39
5.4 KİŞİ KİMLİKLENDİRMEDE SIRALAMA SONUÇLARI	43
BÖLÜM VI.....	46
6. TARTIŞMA ve SONUÇ	46

EKLER.....	48
EK-1. TEZ ÇALIŞMASINA AİT KODLAR	48
KAYNAKÇA	55

KISALTMALAR

CAPMI: Bilgisayar Destekli Ölüm Sonrası Tanımlama Sistemi (İng. Computer Assisted Postmortem Identification System)

WinID: Windows Tanılama Yardımcısı (İng. Windows Identification Utility)

ESA: Evrişimli Sinir Ağları

BT: Bilgisayarlı Tomografi

3B: 3 Boyutlu

2B: 2 Boyutlu

KIBT: Konik Işınli Bilgisayarlı Tomografi

M-BESA: Maske Bölgesel Evrişimsel Sinir Ağı (İng. Mask RCNN)

DH-BESA: Daha Hızlı Bölgesel Evrişimli Sinir Ağı (İng. Faster RCNN)

ODTS: Otomatik Diş Tanıma Sistemi

YGPH: Yönelimli Gradyanların Piramidal Histogramı (İng. Pyramid Histogram of Oriented Gradients)

HGÖ: Hızlandırılmış Gürbüz Öznitelikler (İng. SURF)

ReLU: Düzeltilmiş Doğrusal Birim (İng. Rectified Linear Unit)

ELU: Üstel Lineer Birim (İng. Exponential Linear Unit)

ID3: Tekrarlı İkilişikçi Ağacı (İng. Iterative Dichotomiser 3)

SRA: Sınıflama ve Regresyon Ağacı (İng. CART)

DVM: Destek Vektör Makinesi (İng. Support Vector Machine)

SMO: Sıralı Minimum Optimizasyon (İng. Sequential Minimal Optimization)

KP: Kuadratik Programlama

DDB: Dünya Dişhekimleri Birliği (Fr. FDI - Fédération Dentaire Internationale)

YSA: Yapay Sinir Ağları

TABLO LİSTESİ

Tablo 1. Derin Öğrenme ile Diş Algılama ve Segmentasyon Çalışmaları.....	6
Tablo 2. Diş Biyometrisi ile İnsan Kimliklendirme Çalışmaları.....	9
Tablo 3. Karmaşıklık Matrisi.....	36
Tablo 4. Her Diş Kategorisine ait Kesinlik, Duyarlılık, F-Ölçütü Değerler.....	37
Tablo 5. Dişlerin Uzaklıklara Göre Kaçıncı Sırada Eşleştiklerini Gösterir Tablo.....	39
Tablo 6. Eğitim Kümesindeki Örnek Bazı l_{12}^x kombinasyonları ve Adetleri	41
Tablo 7. Rastgele Orman Metodu Sınıflandırma Sonuçları	42
Tablo 8. Sıralı Minimum Optimizasyon Metodu Sınıflandırma Sonuçları	43
Tablo 9. DVM ile Kişi Kimliklendirme Sıralama Tablosu	44
Tablo 10. Rastgele Orman Metodu ile Kişi Kimliklendirme Sıralama Tablosu.....	45

ŞEKİL LİSTESİ

Şekil 1. Aynı Kişiyeye Ait Farklı Zamanlarda Çekilmiş Panoramik Diş Görüntüsü	2
Şekil 2. Örnek Perseptron Modeli	12
Şekil 3. Yapay Zeka-Makine Öğrenmesi-Derin Öğrenme Arasındaki Farklar	13
Şekil 4. ESA Mimari Modeli	14
Şekil 5. . Konvolüsyon İşlemi	15
Şekil 6. Havuzlama İşlemi	15
Şekil 7. Tam Bağlı Katman	16
Şekil 8. Dolgu	17
Şekil 9. Filtre	17
Şekil 10. Tez Çalışmasına Ait Mimari	19
Şekil 11. Örnek Karar Ağacı	22
Şekil 12. Destek Vektör Makinası	25
Şekil 13. Restorasyon Veri Seti Örnek Görüntüleri	28
Şekil 14. Kimliklendirme Veri Seti Örnek Görüntüleri	29
Şekil 15. Dental Notasyon	30
Şekil 16. Farklı Kişilerin Benzerliği	38
Şekil 17. Aynı Kişilerin Benzerliği	38

ÖZET

Dental biyometri ile; dental bilgi ve bulguları kullanarak kişi kimliklendirme yapılmaktadır. Genellikle afet ve kaza gibi yumuşak dokuların zarar gördüğü durumlarda ölmüş kişilerin ölüm öncesi ve ölüm sonrası diş görüntülerini diş konturları (sınırları), restorasyonlar, dişlerin sayısı ve şekli ile dişlerin konumları gibi özellikleri birbirleriyle karşılaştırarak kişi kimliklendirme gerçekleştirilir. Günümüzde görüntüleri eşleştirmek için diş numaralarına ve restorasyon türlerine göre metin araması yapan CAPMI (Computer Assisted Postmortem Identification System – Bilgisayar Destekli Ölüm Sonrası Tanımlama Sistemi) ve WinID (Windows Identification Utility- Windows Tanılama Yardımcısı) gibi metin bazlı karşılaştırma yapan programlar kullanılmaktadır. Ayrıca, son yıllarda literatürde makine öğrenmesi kullanarak dental görüntülerden kimliklendirme yapmak için de çalışmalar bulunmaktadır.

Bu tezde, dental biyometri için diş restorasyonlarının derin öğrenme yöntemlerinden Evrişimli Sinir Ağları (ESA) ile tespit edilmesi ve kişi kimliklendirmenin tespit edilen restorasyon çizelgelerinin karşılaştırılarak yapılması hedeflenmiştir. Bölütlenen dişler için bir ESA oluşturularak beş farklı restorasyon tipi öğrenilmiştir. Bir panoramik dental görüntünün her dişi sınıflandırılarak diş çizelgesi oluşturulmuştur. Diş çizelgelerinin karşılaştırılarak kimliklendirme yapılması için Destek Vektör Makinesi (DVM) ve Rastgele Orman yöntemleri kullanılmıştır. Geliştirilen metot 183 kişiye ait 261 panoramik dental görüntü üzerinde denemiş ve Rastgele Orman Metodu %94, DVM ise %96 başarımla göstermiştir.

Anahtar Kelimeler: Dental Biyometri, İnsan Kimliklendirme, Dental Restorasyon, Derin Öğrenme, Evrişimli Sinir Ağları

ABSTRACT

Person identification is performed by comparing the features, such as tooth contours, number and shape of teeth, tooth restorations and relative teeth positions, of ante-mortem and post-mortem dental images of deceased people where soft tissues are damaged in disasters and accidents. Text-based comparison programs such as CAPMI (Computer Assisted Postmortem Identification System) and WinID (Windows Identification Utility) are used to match images according to tooth numbers and restoration types. Recently, there are studies for human identification from dental images with machine learning in the literature.

In this thesis, it is aimed to detect dental restorations with Convolutional Neural Networks (CNN) and to perform person identification according to these detected restorations. Five different restoration types were learned by constructing a CNN for segmented the teeth. A dental chart was created by classifying each tooth of a panoramic dental image. Support Vector Machine (SVM) and Random Forest methods were used for identification by comparing tooth charts. The developed method was tested on 261 different X-ray images of 183 different people. The identification accuracy of the random forest method was 94%, and the SVM was 96%.

Keywords: Dental Biometrics, Human Identification, Dental Restoration, Deep Learning, Convolutional Neural Networks

BÖLÜM I


Büyük felaketler, uçak kazaları, kasırgalar ve tsunamiler gibi diğer doğal afetler nedeniyle hayatını kaybeden birçok insanın kimliği teşhis edilememektedir. Parmak izi ve yüz gibi yumuşak dokulara sahip fiziksel özellikler çabucak deforme olabildiğinden, yüksek basınç ve sıcaklığa dayanıklı yapıları nedeniyle ölen kişinin kimliğini doğrulamak için diş dokuları kullanılır (Utsuno; 2019). Örneğin, Tayland'daki Hint Okyanusu tsunami felaketinden sonra, cesetlerin % 46.20'si için diş kayıtları birincil tanımlayıcı olarak kullanılmıştır (Petju, Suteerayongprasert, Thongpud ve Hassiri; 2007).

Adli odontoloji alanı, diş yapılarından toplanan bilgileri kullanarak insanların kimliğinin teşhis edilmesi ile ilgilenir. Tanımlama yöntemleri tipik olarak ölüm öncesi (ante-mortem) ve ölüm sonrası (post-mortem) dental görüntülerin diş şekilleri, restorasyonlar, diş sayısı vb. gibi çeşitli diş özelliklerine göre karşılaştırılmasına dayanmaktadır. CAPMI (Lorton, Rethman ve Friedman; 1988) ve WinID (WEB 1) gibi diş numaralarına ve restorasyon türlerine göre metin araması yapan bilgisayar programları diş görüntülerini eşleştirmek için kullanılır. Bu programları kullanırken uzmanlar her görüntüyü ve dişi analiz etmeli ve bu programlara dental metin bilgilerini manuel olarak girmelidir. Bu nedenle, farklı dental görüntülerin manuel olarak analiz edilmesi ve görselleştirilmesi süreci yoğun emek gerektirir ve çok zaman alır. Bu süreyi kısaltmak için diş görüntülerini otomatik olarak analiz eden bilgisayar destekli dental insan tanımlama yöntemleri, hızlı tanımlama için gereklidir.

Kliniklerde röntgen, BT ve 3B lazerler gibi farklı dental görüntüleme yöntemleri kullanılmaktadır (Shah, Bansal ve Logani; 2014). Radyografi, klinik muayenede, dişlerin iç yapısına ilişkin bilgi sağlamak için yaygın olarak kullanılır. Ağız içi (ısıрма, periapikal, oklüzal görüntüler) ve ağız dışı görüntüler (panoramik ve sefalometrik

görüntüler) olmak üzere iki ana X-ışını görüntüsü türü vardır. Dental BT, ağız içi yapılara 3B olarak bakan bir görüntüleme türüdür. Konik Işınlı Bilgisayarlı Tomografi (KIBT) ise dişlerin ve çevre dokuların 3 boyutlu olarak görüntülenmesini sağlayan düşük doz bir kesit tekniğidir. KIBT'nin BT'ye göre en büyük avantajı, oldukça düşük etkili radyasyon dozuna sahip olmasıdır.

Dental biyometri, diş özelliklerini kullanarak ölü kişileri teşhis etmek için dental görüntüleri/örnekleri otomatik olarak analiz eder. Literatürde, farklı görüntüleme modelleri kullanılarak çeşitli dental görüntü tabanlı insan tanımlama yöntemleri sunulmuştur (Fahmy, Nassar, Haj-Said, Chen, Nomir, Zhou, Howell, Ammar, Abdel-Mottaleb, Jain, 2005; Lee, Lim, Huh, Han, Kim, Heo, Yi, Lee, Choi, 2019). Bu çalışmalarda kullanılan temel yaklaşım iki ana adımı içermektedir: İlk adım diş özelliklerinin çıkarılmasıdır. İkinci adım, eşleştirme için ölüm öncesi ve ölüm sonrası görüntülerin ayıklanmış özelliklerinin karşılaştırılmasıdır. Yaygın olarak kullanılan özellikler dişe ait kontur bilgisi, görüntü yoğunluğuna dayalı olarak çıkarılan özellikler ve dental restorasyonlardır (Lin, Lai ve Huang, 2012; Oktay, 2017). Eşleştirme işlemi için farklı uzaklık metrikleri dental görüntülerin benzerliğini bulmak için kullanılmıştır (Atheeswaran, Karunya ve Amir, 2014; Fejlichowski ve Czapiewski, 2013). Gerçek ölüm sonrası diş görüntülerini içeren bir veri tabanı oluşturmak oldukça zordur. Bu nedenle, önceki tüm çalışmalarda, aynı canlı kişilerin farklı zamanlarda çekilmiş diş görüntüleri yöntemlerin test edilmesi ve doğrulanması için kullanılmıştır. Şekil 1, aynı kişiye ait farklı zamanlarda çekilmiş panoramik diş görüntülerinin örneklerini göstermektedir.



Şekil 1. Aynı Kişiye Ait Farklı Zamanlarda Çekilmiş Panoramik Diş Görüntüsü

Diş biyometrisinin insan tanıma ve ölen kişilerin kimliklerinin teşhis edilmesi için etkin kullanılma potansiyeline rağmen, diş görüntüleri içeren otomatik bir kişi tanımlama aracı henüz yeterince araştırılmamıştır (Heinrich, Güttler, Schenkl, Wagner ve Teichgräber; 2020). Örneğin, diş segmentasyonu görevi için 1500 dental panoramik X-ray görüntüsü içeren bir kıyaslama veri seti sunulmuştur (Jader, Oliveira ve Pithon, 2018). Bununla birlikte, insan tanımlama yöntemlerinin karşılaştırılması için ölüm sonrası (post-mortem) ve ölüm öncesi (ante-mortem) dental görüntüleri içeren erişilebilir büyük bir veri kümesi yoktur. Bu tezde, dental biyometri için derin öğrenmeye dayalı olarak dental restorasyonları tanıma ve onları eşleştirme amaçlanmıştır. Başka bir deyişle, insan tanımlaması için dental biyometri ile farklı özellik çıkarma yöntemlerini panoramik diş görüntülerinden farklı mesafe fonksiyonlarıyla karşılaştırmak hedeflenmiştir. Özellikler, 5 farklı kategoride toplam 3013 panoramik dental görüntü içeren bir veri setinden çıkarılmış, çıkarılan diş öznetelikleri, insan kimlik doğrulaması ve tanımlama için kullanılmıştır. Bu tezin ana katkılarından bazıları şu şekilde özetlenebilir:

- a) Dental biyometri ile kişi kimliklendirme için otomatik sistem geliştirilmesi,
- b) Diş restorasyonlarının otomatik tespiti için bir derin öğrenme algoritmasının sunulması,
- c) Tespit edilen restorasyonlar üzerinden makine öğrenmesi ile kişi kimliklendirme yapılması.

Bölüm 2’de literatür taraması kapsamında kişi kimliklendirme için yapılan önceki çalışmalara yer verilmiştir. Bölüm 3’te ESA’ya uzanan süreçte neler olduğuna kısaca değinilerek, yapay zeka, derin öğrenme ve evrişimli sinir ağlarının adımlarından bahsedilmektedir. Bölüm 4’te çalışma kapsamında kullanılan veri kümelerinden ve tezde değerlendirme amaçlı kullanılan metrikler sunulmaktadır. Bölüm 5’te kullanılan yöntemler, yapılan deneyler ve onların sonuçları yer almaktadır. Bölüm 6’da yapılan çalışmanın sonuç değerlendirmesi sunulmuştur.

BÖLÜM II

Panoramik dental görüntüler ilgili kavramsal bilgilere bu bölümde yer verilmektedir

2. LİTERATÜR ÖZETİ

Bu bölümde aktif olarak kullanılan yazılımlar ile literatürde bulunan dental biyometri ile kişi kimliklendirme çalışmaları detaylı olarak sunulmuştur.

2.1 CAPMI

CAPMI (Bilgisayar Destekli Ölüm Sonrası Tanımlama), hükümet, sivil veya insani yardım kuruluşları tarafından ücretsiz olarak kullanılabilen bir program olarak ABD Ordusu Diş Araştırma Enstitüsü'nde, 1985'teki Gander uçak kazasını takiben yapılan gözlemler sonucunda geliştirilmiş bir sistemdir (Lorton ve diğerleri, 1988). CAPMI, tüm olası ölüm öncesi ve ölüm sonrası kayıtların, tekrarlı kayıt bazında karşılaştırmalarını gerçekleştirmek üzere tasarlanmış, böylece adli tıp çalışanlarının pozitif tanılama yapma üzerine daha verimli bir şekilde yoğunlaşabilmelerini sağlamıştır. Parçalanmış ve dağınık kalıntılar üzerinden cesetlerin kimlik teşhisinin yapılabilmesi için 162 ölüm öncesi ve ölüm sonrası diş kaydı kullanılmıştır. CAPMI, 162 olası kayıt eşleşmesinin %74'ünde ilk 20 olasılık arasında gerçek kayıt eşleşmesini başarıyla listelemiş, orijinal algoritmada test edilen varyasyonlar, çoğu teknik orijinal algoritmadan daha iyi performans göstererek,% 38 ila %83 oranında başarı elde etmiştir.

2.2 WinID

WinID (Windows Tanılama), kimliği belirsiz insan kalıntılarıyla kayıp kişileri eşleştiren bir başka bilgisayar yazılımıdır. WinID, olası eşleşmeleri sıralamak için dental ve antropometrik özellikleri (İnsan vücudunun çeşitli kısımlarının ölçümüyle insan yapısının ilişkilerini saptama yöntemi) kullanır. Restore edilmiş diş yüzeyleri, fiziksel tanımlayıcılar, patolojik ve antropolojik bulgular hakkındaki bilgiler WinID veritabanına girilebilir. WinID, büyük felaket durumlarında ve kayıp kişi veritabanlarının oluşturulması ve sürdürülmesinde yararlı olduğu kanıtlanmış bir programdır. WinID verileri bir Microsoft Access veritabanında depolar, Windows ortamında çalışır ve grafikleri * .bmp, * .gif , * .jpg formatında gösterir.

Literatürde, diş tespiti ve segmentasyonu için dental görüntüler ile ilgili birkaç çalışma yapılmıştır (Barboza, Marana ve Tostes Oliveira, 2012; Joseph, George, Shabna, Susmi ve Santhi, 2016; Lin, Lai ve Huang, 2010). İlk araştırmaların çoğunda, Bölge Büyütme (Zoroo ve Shirani, 2009), Havza Algoritması (İng. Watershed Algorithm) (Fan, Beare, Matthews, Schneider, Kilpatrick, Clement, Claes, Penington ve Adamson, 2018) ve Aktif Kontur Yöntemi (İng. Snake- gürültülü bir 2D görüntüden bir nesne taslağını belirleme) (Wang, S. Liu, Wang ve Y. Liu, 2018) gibi klasik görüntü işleme yöntemlerinden yararlanılmıştır.

Klasik görüntü işleme yöntemleri eşik tabanlı, bölge tabanlı, küme tabanlı, sınır tabanlı ve havza tabanlı olarak beş kategoriye ayrılmıştır. Jader ve diğerleri (2018), Frejlichowski ve Wanat (2011), integral projeksiyonlar kullanmayı önererek dental görüntüyü Havza Algoritması ile bölümlere ayırmış ve ortaya çıkan her bölgeyi ya dişe ya da arka plana ait olarak sınıflandırmışlardır. Barboza ve diğerleri (2012), Görüntü Ormanlaştırma Dönüşümü (İng. Image Foresting Transform) ile yarı otomatik grafik tabanlı bir bölümleme yöntemi sunmuştur. Eşikler kullanılarak birçok segmentasyon yönteminden yararlanılmaktadır (Ajaz ve Kathirvelu, 2013; Jain ve Chen, 2004).

Son birkaç yılda diş segmentasyonu için derin öğrenmeye dayalı yöntemler (Jader ve diğerleri, 2018; J.H. Lee, Han, Y. Kim, C. Lee, I. Kim, 2019; Miki, Muramatsu, Hayashi, Zhou, Hara, Katsumata ve Fujita, 2017; Tuzoff, Tuzova, Bornstein, Krasnov,

Kharchenko, Nikolenko, Sveshnikov ve Bednenko, 2019) sunulmuştur. Derin öğrenmeye dayalı yöntemler, klasik görüntü işleme yöntemlerinden daha iyi performans göstermiştir.

Diş hekimliği, oral ve maksillofasiyal (ağız, yüz ve çene cerrahisi) radyoloji alanında derin öğrenme yöntemleri önerilmiştir Hwang, Jung, Cho ve Heo (2019) ile Jader ve diğerleri (2018), M-BESA kullanarak dişleri bölütlemiş ve 1224 dental panoramik görüntü üzerinde %98 doğruluk elde etmiştir. Bu bölütleme işleminde tüm dental görüntü diş ve diş değil olarak iki sınıfa ayırmıştır. Tuzoff ve diğerleri (2019), panoramik görüntüler üzerinde DH-BESA (İng. Faster R-CNN) metodu kullanmış ve diş tespit etmede %99 doğruluk elde etmiştir. Cui, Li ve Wang (2019), KIBT görüntülerinden dişlerin segmentasyonu ve tanımlanması için öğrenilmiş benzerlik matrisine sahip 3-boyutlu bölge öneri ağı olan bir yöntem sunmuştur. Önerilen yöntemin Dice benzerliği oranı %92 olarak ölçülmüştür. Miki ve diğerleri (2017), bilgisayarlı tomografi görüntülerinin 2-boyutlu dilimlerinde diş sınıflandırması yapmak için ESA kullanmayı önermiştir. 52 KIBT volümünde 42 tanesini eğitim ve 10 tanesini test için kullanarak %88,8 başarımla elde etmişlerdir. Bu çalışmalar, derin öğrenme tabanlı yöntemlerin panoramik ve bilgisayarlı tomografi görüntülerinde dişlerin tespiti ve segmentasyonu için yüksek doğruluğa sahip olduğunu göstermiştir. Tablo 1, diş tespiti ve segmentasyonu için önerilen derin öğrenme yöntemlerini özetlemektedir.

Tablo 1. Derin Öğrenme ile Diş Algılama ve Segmentasyon Çalışmaları

Çalışma	Amaç	Metot	Görüntü Tipi	Veri Sayısı	Doğruluk
Jader, Fontineli, Ruiz, Lima, Pithon, Oliveira (2018)	Segmentasyon	M-BESA	Panoramik Görüntü	193 Eğitim 1224 Test	0.98
Tuzoff vd. (2019)	Tanıma	DH-BESA	Panoramik Görüntü	1352 Eğitim 222 Test	0.99
Cui, Li ve Wang (2019)	Segmentasyon	3B Bölge Teklif Ağı	3B KIBT	12 Eğitim 8 Test	0.93
Miki vd. (2017)	Sınıflandırma	Alexnet	2B KIBT Dilimi	42 Eğitim 10Test	0.91

2.3 AĞIZ İÇİ GÖRÜNTÜLER

Ağız içi, panoramik ve 3B lazer tarayıcı görüntü tiplerine göre insan kimliğini tanılama çalışmaları da son yıllarda hız kazanmıştır.

Jader ve diğerleri (2018), diş ile ilgili çalışmaların % 80'inin birkaç dişi içeren ağız içi görüntüler için önerildiği belirtilmektedir. İlk otomatik insan tanımlama çalışmaları, FBI tarafından desteklenen Otomatik Diş Tanıma Sistemi (ODTS) projesinde periapikal ve ısırık görüntüleri gibi ağız içi dental görüntüler için gerçekleştirilmiştir. Fahmy ve diğerleri (2005), Jain ve Chen (2004), kenar algılama yöntemleri ile yarı otomatik olarak belirlenen ve konturları eşleştiren diş konturlarını kullanmışlardır. Diş konturlarının özellikleri kenar tabanlı algoritmalar ile bulunmakta ve dişler bu şekilde konumlandırılmaktadır. Başka bir çalışmada, dişler yatay izdüşümü ile izole edilmiş ve dişlerin konturları, konturların çıkıntılı noktalarından elde edilen imza vektörleri kullanılarak eşleştirilmiştir (Abdel-Mottaleb, Nomir, Nassar, Fahmy ve Ammar; 2003). Başka bir çalışmada (Nomir ve Abdel-Mottaleb; 2017), dişler Kuvvet Alanı Enerji Fonksiyonu ve Fourier tanımlayıcılarından elde edilen öznitelik vektörleriyle gösterilmiş ve 162 ağız içi görüntü içeren bir veri kümesi üzerinde doğrulanmıştır. Ölberg ve Goodwin (2016), dişler ve diş çalışma hatlarını Hausdorf Mesafesi ile çıkarmış ve eşleştirmiştir. Saptanan dental kod konturları Aktif Kontur Modeli (snake) ile bulunmuş ve Levenshtein Mesafesi ile karşılaştırılmıştır (Hofer ve Marana, 2007). Lin ve diğerleri (2010), diş konturları ve diş çalışmalarını kullanmış ve bunları Ağırlıklandırılmış Hausdorf Mesafesi ile eşleştirmiştir. Schwendicke ve diğerleri (2020), yapay zekanın dental çalışmalarda kullanımlarını özetlemiş ve dental veri azlığı ve standardizasyonunun olmaması gibi nedenlerden dolayı günlük rutin klinikte yazılımların henüz verimli kullanılmadığını belirtmişlerdir.

2.4 PANORAMİK GÖRÜNTÜLER

Panoramik diş görüntüleri tüm ağız, burun bölgesini, sinüsleri, alt-üst çeneyi ve bunları çevreleyen kemikleri içerir. Bu görüntüler diş çürükleri, kistleri, tümörleri, kemik

düzensizlikleri gibi diş problemlerini göstermesi nedeniyle kliniklerde tedavi planlaması için yaygın olarak kullanılmaktadır. Panoramik görüntülerin otomatik analizi, görüntülerin 2B dönüşümü sırasında dişlerin üst üste gelebilmesi sebebiyle ağız içi görüntülere göre daha zordur.

Panoramik diş görüntüleri için birçok insan kimliklendirme yöntemi önerilmiştir. Barboza ve diğerleri (2012), grafik tabanlı bir diş segmentasyon yöntemi sunmuş ve eşleşen görüntüler için panoramik görüntülerden ışın açısı istatistikleri ve şekil bağlamı tanımlayıcılarını çıkarmıştır. Oktay (2017), dişlerin tespiti için YGPH yöntemini kullanmış, geometrik ve görünüm özelliklerine göre veri füzyonu yaparak dişleri eşleştirmiştir. Frejlichowski ve Czapiewski (2013), diş şekillerinden öznitelik çıkarımı için eğrilik ölçek uzay algoritması sunulmuştur ve bu algoritmalarla panoramik görüntülerdeki dişleri tespit etmiştir. Ajaz ve Kathirvelu (2013), eşikler ve morfolojik operatörler kullanılarak tespit edilen dental çalışma ile dental görüntüleri eşleştirmiştir. Heinrich ve diğerleri (2020), HGÖ (İng. SURF) kullanmış ve panoramik görüntüleri algılanan kilit noktalara göre eşleştirmiştir. Vijayakumari, Kirubalini ve Manisha (2019), izoperimetrik bir algoritma ile diş konturlarını tespit etmiş ve yöntemi hem ağız içi hem de ağız dışı görüntülerde doğrulamıştır. Başka bir çalışmada (Banday ve Mir, 2019), insan tanınması için dişler yerine çene konturu kullanılmıştır.

Fan, Ke, Wu, Tian, Lyu, Liu, Liao, Dai, Chen ve Deng (2020), DentNet adlı bir ESA mimarisi önermiştir. DentNet, ESA ile öznitelik çıkarımı yapar ve bunları kosinüs mesafesi ile karşılaştırır. Model, 6300 kişiden alınan 15369 panoramik dental görüntü üzerinde eğitilmiştir. Modelin Sıra-1 doğruluğu % 85,16 ve Sıra-5 doğruluğu % 97,74 olarak ölçülmüştür. Başka bir çalışmada (Lai, Fan, Wu, Ke, Liao, Deng, Chen ve Zhang; 2020) insan tanılama için Dikkat Kanalı (İng. Channel Attention-ESA'nın yararlı olmayan arka plan bilgilerini öğrenmek yerine önemli bilgilere daha fazla odaklanmasını ve öğrenmesini sağlamaya yarayan bir modül) da içeren bir ESA önerilmiş, modelin Sıra-1 doğruluğu % 87,21 ve Sıra-5 doğruluğu % 95,34 olarak ölçülmüştür. Oktay ve Gurses (2020), dental restorasyonları transfer öğrenmesi yöntemiyle tespit etmişlerdir.

2.5 3B LAZER TARAYICI GÖRÜNTÜLERİ

3B dental tarayıcılarla oluşturulan görüntüler için de insan tanılama yöntemleri önerilmiştir. Reesu, Woodsend, Açnıca, Revie, Brown ve Mossey (2020), AutoIDD adlı bir yöntem sunmuş ve eşleştirme için yinelemeli en yakın nokta algoritmasını kullanmıştır. Zhang, Ong, Zhong ve Foong (2016), anahtar nokta eşleştirmeli bir histogram yöntemi önermiştir. Ayrıca, 3B taramalar belirgin noktalara göre eşleştirilmiştir (Zhong, Yu, Wong, Sim, Lu, Foong ve Cheng; 2013).

Yukarıda belirtilen yöntemlerde, insan tanımlama için el yapımı öznitelik çıkarma yöntemleriyle elde edilen farklı öznitelikler kullanılmıştır. Diş biyometrisi ile insan kimliklendirmesi için önceki çalışmalara ait bir liste, kullanılan görüntü türü ve görüntü sayısı ile birlikte Tablo 2'de verilmiştir. Veritabanında ante-mortem görüntü olarak ve sorgu / hedef / ölüm sonrası görüntü olarak kullanılan görüntülerin sayısı da verilmektedir. Her çalışmada görüntü sayısı değişkenlik göstermekte, bazı çalışmalarda 20 görüntü bulunurken diğer bazı çalışmalarda veri tabanında 61545 görüntü bulunmaktadır. Derin öğrenme ile birlikte kullanılan veri miktarı ciddi miktarda artmıştır. Halen bu görüntüleri içeren bir açık bir veri tabanının bulunmaması bir eksikliktir.

Tablo 2. Diş Biyometrisi ile İnsan Kimliklendirme Çalışmaları

Çalışma	Metot	Görüntü Tipi	Veri Miktarı
Nomir ve Abdel-mottalib	Kuvvet Alanı Fonksiyonu	Ağız İçi	162
Jain ve Chen	Yarı Otomatik Integral Projeksiyon Ve Kontur Eşleştirme	Ağız İçi	130 eğitim 38 test
Olberg ve Goodwin	Eşik Ve Görüntü İşleme	Ağız İçi	134
Hofer ve Marana	Aktif Kontur Yöntemi	Ağız İçi	68
Lin vd.	Görüntü İşleme	Diş Filmi	93 eğitim 35 test
Barboza vd.	Grafik Ve Işın Açısı İstatistikleri	Panoramik	40
Oktay	YGPH Ve Destek Vektör Makinaları	Panoramik	261
Frejlichowski ve Wanat	Eğrilik Ölçeği Uzay Şekli Tanımlayıcısı	Panoramik	30
Ajaz vd.	Morfolojik Operasyonlar	Panoramik	30

Heinrich vd.	Hızlandırılmış Gürbüz Öznelikler	Panoramik	61545 eğitim 43 test
Vijayakumari vd.	İzoperimetrik Ve Dügümsel Yaklaşım	Ağız İçi & Panoramik	250
Reesu vd.	Temel Bileşen Analizi Ve Yinelemeli En Yakın Nokta	3B lazer taraması	240
Zhang vd.	İmzalı Özellik Histogramı	3B lazer taraması	200 eğitim 20 test
Zhong vd.	Belirginlik Değeri, Gauss Eğriliği Ve Integral Hacmi	3B lazer taraması	200 eğitim 60 test
Fan vd.	Esa Dentnet	Panoramik	6300 eğitim 173 test
Lai vd.	ESA Lcanet	Panoramik	9490 eğitim 503 test
Wu vd Sıra-1: % 88.72 Sıra -5: % 95.79	Human Identification With Dental Panoramic Images Based On Deep Learning	Panoramik	22172 eğitim 665 test
Lai vd [52] Sıra -1: % 87.21 Sıra -5: % 95.34	Lcanet: Learnable Connected Attention Network For Human Identification Using Dental Images	Panoramik	1168
Fan vd Sıra -1: % 85.16 Sıra -5: % 97.74	Automatic Human Identification From Panoramic Dental Radiographs Using The Convolutional Neural Network	Panoramik	15868 eğitim
Oktay, Gurses	Tooth Restoration And Dental Work Detection On Panoramic Dental Images Via CNN	Panoramik	3013

BÖLÜM III

Tezin bu bölümünde kullanılan materyal ve metotlara dair bilgilere yer verilmektedir

3. MATERYAL VE METOT

3.1 YAPAY ZEKA


Akıllı makineler, özellikle akıllı bilgisayar programları yapma bilimi ve mühendisliğidir. İlk olarak 1956'da Dartmouth College'daki çalışma atölyesinde John McCarthy'nin başını çektiği bir grup araştırmacı tarafından akademik bir disiplin olarak kurulmuş ve ilk çerçevesi “öğrenmenin her yönünün veya zekanın diğer herhangi bir özelliğinin prensipte, onu simüle etmek için bir makinenin yapılabileceği kadar kesin bir şekilde tanımlanabileceği varsayımı temelinde ilerleyecektir.” şeklinde ifade edilmiştir (1955).

3.2 MAKİNE ÖĞRENMESİ

1956'da Ray Solomonoff'un yazdığı makale ile ortaya çıkmış (Solomonoff, 1956), 1959'da Arthur Samuel'in çalışmalarıyla popülerliği artmış olan bilim dalıdır (Samuel, 1959). Bilgisayarların ayrıntılı şekilde programlanmadan öğrenme yeteneği kazanmasını ifade eder. İlk olarak dama oyunu üzerinde incelenmiş, bilgisayara oyunun yalnızca kuralları, yön duygusu ve bazı parametrelerin listesi verilmiş, 8 veya 10 saatlik kısa bir oynama süresi sonunda bilgisayarın oyunu oynamayı öğrenebildiği gözlemlenmiştir.

3.3 YAPAY SİNİR AĞLARI

İlk olarak 1943'te Warren McCulloch ve Walter Pitts'in, nöronların nasıl çalışabileceğine dair yazdıkları makale ile ortaya atılmıştır (McCulloch ve Pitts, 1943). McCulloch ve Pitts, beyindeki nöronların nasıl çalıştığını açıklamak için, elektrik devrelerini kullanarak basit bir sinir ağını modellemişlerdir. 1958'de Frank Rosenblatt, fiziksel dünya hakkındaki bilginin nasıl algılandığı, bilginin hangi biçimde hatırlandığı ve bellekte tutulan bilginin tanıma ve davranışı nasıl etkilediği sorularını yanıtlamak için perseptron adı verilen varsayımsal bir sinir sistemi teorisi geliştirmiştir (Rosenblatt, 1959). Perseptron, tek katmanlı bir sinir ağıdır ve aktivasyon işlemi uygulanan bir dizi ağırlıklı girdi olarak tanımlanabilir. Ağırlıklı girdiler bir toplam üretir ve eğer bu toplam belli bir eşik değerin üzerindeyse 1, değilse 0 çıktısı üretir. Şekil 2'de örnek bir perseptron modeli gösterilmiştir.




Şekil 2. Örnek Perseptron Modeli

3.4 DERİN ÖĞRENME

Makine öğrenmesi, web aramalarından sosyal ağlarda içerik filtreleme, e-ticaret web sitelerindeki öneriler, kameralar ve akıllı telefonlar gibi tüketici ürünlerinde giderek daha fazla yer alarak modern toplumun birçok yönüne etki etmektedir. Makine öğrenmesi sistemleri, görüntülerdeki nesneleri tanımlamak, konuşmaları metne dönüştürmek, haber öğelerini, gönderileri veya ürünleri kullanıcıların ilgi alanları ile eşleştirmek ve ilgili arama sonuçlarını seçmek için kullanılmaktadır. Bu uygulamalar derin öğrenme adı verilen teknikler sınıfından her geçen gün daha çok yararlanmaktadır.


Derin öğrenme yöntemleri, her biri temsili bir düzeyde dönüştüren basit ancak doğrusal olmayan modüller oluşturularak elde edilen, birden çok temsil düzeyine sahip temsil-öğrenme yöntemleri bütünüdür. Derin öğrenmenin kilit noktası, bu özellik katmanlarının mühendisler tarafından tasarlanmayıp, bu katmanların bir öğrenme prosedürü kullanılarak verilerden öğrenilmesidir (Lecun, Bengio ve Hinton; 2015) Şekil 3'te yapay zeka, makine öğrenmesi ve derin öğrenmenin iç içe bağlantısı gösterilmektedir.



Şekil 3. Yapay Zeka-Makine Öğrenmesi-Derin Öğrenme Arasındaki Farklar (WEB 2)

3.5 EVRİŞİMLİ SİNİR AĞLARI (ESA)

3 boyutlu şekillerin değişkenliğiyle başa çıkmak için özel olarak tasarlanmış bir Derin Öğrenme algoritmasıdır (Lecun ve Bengio; 1995). Bir ESA, bir resmi girdi olarak alıp, bu resimdeki objelere öğrenilebilir ağırlık ve kutuplama (bias) değerleri atayarak sonrasında bunları birbirinden ayırt edebilir. ESA’da gerekli olan ön işleme, diğer sınıflandırma algoritmalarına kıyasla çok daha düşüktür. Hesaplama maliyetinin diğer sinir ağlarına göre önemli derece düşük olması ESA’yı görüntü tanıma problemleri için ideal kılar. Şekil 4’te örnek bir evrişimli sinir ağı mimarisi gösterilmiştir.




Şekil 4. ESA Mimari Modeli (Lecun ve Bengio; 1995)

Evrişimli sinir ağları, evrişim, ortaklama ve tam bağlantı olmak üzere 3 temel katman ve bunların yanında bazı hiperparametreler içerir.

3.5.1 Evrişim (Konvolüsyon)


Konvolüsyon katmanı, evrişim işlemlerini gerçekleştiren filtreleri, girişin boyutlarına göre tararken kullanılır. Konvolüsyon işlemi, bir dizi ağırlığın girdi ile çarpılmasını içeren doğrusal bir işlemdir. Çarpma işlemi, bir dizi giriş verisi ile filtre veya çekirdek adı verilen iki boyutlu bir ağırlık dizisi arasında gerçekleştirilir. Şekil 5’te örnek bir konvolüsyon işlemi gösterilmiştir. 3x3 boyutunda bir filtre görüntünün sol üst köşesine uygulanmıştır. Konvolüsyondaki çarpma ve toplama işlemleri Şekil 5 üzerinde gösterilmiştir. Konvolüsyon işlemi, filtrenin tüm giriş verisi üzerine uygulanmasıyla tamamlanır.



Şekil 5. Konvolüsyon İşlemi (WEB 3)

3.5.2 Havuzlama


Bir konvolüsyon işleminden sonra boyutu azaltmak için genellikle havuzlama yapılır. Böylece parametre sayısı azalır. Bu da eğitim süresini kısaltır ve aşırı öğrenmeyi engeller. Özellikle, maksimum ve ortalama havuzlama, sırasıyla maksimum ve ortalama değerin alındığı özel havuzlama türleridir.



Şekil 6. Havuzlama İşlemi (WEB 4)

3.5.3 Tam Bağlı Katman

Konvolüsyon ve havuzlama katmanlarından sonra, sınıflandırma kısmı birkaç tam bağlı katmandan oluşur. Ancak, tamamen bağlantılı bu katmanlar yalnızca bir boyutlu verileri kabul edebilir. Üç boyutlu verileri bir boyutluya dönüştürmek için python'da düzleştirme işlevi kullanılır. Bu işlev esasen üç boyutlu veriyi bir boyutlu vektöre indirgemiş olur.



Şekil 7. Tam Bağlı Katman (WEB 5)

3.5.4 Hiperparametre

Veriden doğrudan öğrenilemeyen, çoğunlukla modeli tasarlayan kişi tarafından sezgisel olarak konulan parametrelere hiperparametre denir (WEB 6). Örneklem sayısı, filtre sayısı ve boyutu, aktivasyon fonksiyonu, öğrenme katsayısı gibi parametreler bazı hiperparametre örnekleridir.

3.5.4.1 Adım

Adım, evrişim işlemi için ağırlık matrisi olan filtreyi görüntü üzerinde birer piksellik adımlarla ya da daha büyük adımlarla kaydıracağının bilgisini verir. Adım boyutu genellikle 1'dir, yani filtre her adımda 1 piksel kaymış olur.

3.5.4.2 Dolgu

Eğer özellik haritasının boyutunun her konvolüsyon işleminden sonra küçülmesi istenmiyorsa, boyutu korumak için girdiyi sıfırlarla çevreleyen dolgu kullanılır. Aksi


takdirde özellik haritalarının boyutu her katmanda küçülür. Bu istenen bir durum değildir.

0	0	0	0	0	0	0
0	x_{00}	x_{01}	x_{02}	x_{03}	x_{04}	0
0	x_{10}	x_{11}	x_{12}	x_{13}	x_{14}	0
0	x_{20}	x_{21}	x_{22}	x_{23}	x_{24}	0
0	x_{30}	x_{31}	x_{32}	x_{33}	x_{34}	0
0	x_{40}	x_{41}	x_{42}	x_{43}	x_{44}	0
0	0	0	0	0	0	0

Şekil 8. Dolgu (WEB 7)

3.5.4.3 Filtre (Çekirdek)


Filtreler görüntülerden özellikleri çıkarmak için kullanılır. Filtre, giriş verileri üzerinde hareket ederek bu bölgeler ile nokta çarpımı gerçekleştiren ve çıktıyı nokta çarpım matrisi olarak alan bir matristir.



Şekil 9. Filtre (WEB 8)


3.5.4.4 Aktivasyon Fonksiyonu

Aktivasyon Fonksiyonu, sinir ağlarının sonuna veya arasına yerleştirilen bir düğümdür. Nöronun aktive edilip edilmeyeceğine karar vermeye yardımcı olurlar. Düzeltilmiş Doğrusal Birim (ReLU), Sızıntı ReLU, ELU gibi değişik aktivasyon fonksiyonları vardır. ReLU, en yaygın olarak kullanılan aktivasyon fonksiyonlarından biridir. Aşağıda örnek birkaç aktivasyon fonksiyonu gösterilmiştir:




$$g(z) = \max(0, z)$$

Grafik 1. RELU



$$g(z) = \max(\epsilon z, z)$$

Grafik 2. Sızıntı RELU




$$g(z) = \max(\alpha(e^z - 1), z)$$

Grafik 3. ELU

3.6 DİŞ RESTORASYONU SINIFLANDIRMA ESA MİMARİSİ

Bu tezde, diş restorasyonlarını sınıflandırmak için bir evrişimli sinir ağı mimarisi oluşturulmuştur. Mimari girdi olarak diş görüntülerini almakta ve 5 farklı sınıfta restorasyon tespiti yapmaktadır. Bu sınıflar dolgu, implant, kanal, restorasyonsuz ve tel şeklinde ifade edilmiştir. Şekil 10'da tez çalışmasına ait mimari yer almaktadır. Oluşturulan mimaride toplam 3 konvolüsyon katmanı, 3 havuzlama katmanı, 1 seyreltme katmanı ve 1 yoğun katman bulunmaktadır. Mimarideki toplam parametre sayısı 2.678.565'tir.



Şekil 10. Dış Restorasyonu için Geliştirdiğimiz ESA Mimarisi

Bu çalışmaya ait mimari şu şekilde yapılandırılmıştır:


1. Tüm veri setini ağa tek seferde vermek bellek yetersizliği sorunlarına sebebiyet verdiğinden veri 32'lik paketlere (İng. batch) ayrılmıştır.
2. Veri setindeki tüm resimler 150x150 piksel boyutlarına getirilmiştir.
3. Veri seti %80 eğitim %20 validasyon şeklinde ayrılmıştır.
4. Veri setindeki dişlerin yönleri, eğimleri ve resim içinde kapladıkları alanlar farklı olduğundan, modeli buna uydurmak üzere değişik oranlarda yatay ve dikey çevirme, döndürme ve yakınlaştırma gibi genişletme (İng. augmentation) işlemleri uygulanmıştır.
5. Model inşasında yeniden bir ölçeklendirme (ing. Rescale), üç konvolüsyon, üç havuzlama (İng. Pooling), bir seyreltme (İng. Dropout), bir düzleştirme (İng. Flatten) ve iki yoğun (İng. Dense) katman olmak üzere toplam on bir katman kullanılmıştır.
6. Ölçeklendirme katmanı ile piksel değerleri 0-1 arasına indirgenmiş ve veriyi hesaplama maliyeti düşürülmüştür.
7. Konvolüsyon katmanlarında dolgu uygulanmış, dolgu parametresi aynı yani "same" seçilerek çıktının girdiyle aynı yükseklik aynı boyuta sahip olacak şekilde girdinin dört yönü de sıfırlarla doldurulmuş, böylece veri kaybının olmaması sağlanmıştır. Aktivasyon fonksiyonu olarak ReLU seçilmiştir.
8. İlk konvolüsyon katmanında on altı, ikincisinde otuz iki, üçüncüsünde altmış dört nöron kullanılmış, bu filtreler üzerinde 3x3'lük filtrelerle konvolüsyon işlemi uygulanmıştır.
9. Sekizinci katmanda modelin aşırı öğrenmesini engellemek amacıyla seyreltme (İng. Dropout) uygulanmıştır.
10. Dokuzuncu katmanda, verileri bir sonraki katmana girmek için bir boyutlu bir dizi haline getirmemizi sağlayan Düzleştirme (İng. Flatten) işlemi uygulanmıştır.
11. Onuncu katmanda yüz yirmi sekiz nöronluk bir yoğun katman bulunmaktadır. Yoğun bağlı bir katman, önceki katmanın tüm özellik kombinasyonlarından öğrenmeyi sağlayan katmandır.

12. 11. Katmanda bulunan beş nöron, veri setinde bulunan beş farklı sınıfı belirlemek için kullanılır. Çok sınıflı sınıflandırma problemlerinde Softmax aktivasyonu kullanıldığından ilgili parametre de bu katmana eklenmiştir.
13. Derleme, bir model oluşturma sürecinin son adımıdır. Derleme tamamlandıktan sonra eğitim aşamasına geçilebilir. Derleme aşamasında modele verilmesi gereken üç parametre bulunur. Bunlar:
- 13.1 Kayıp (İng. Loss): Kayıp işlevi, öğrenme sürecindeki hata veya sapmayı bulmak için kullanılır. Keras, model derleme işlemi sırasında kayıp işlevinin belirtilmesini gerektirir. Teze ait modelde kayıp fonksiyonu olarak “Seyrek Kategorik Çapraz Entropi (İng. Sparse Categorical Cross Entropy) kullanılmıştır.
- 13.2 Optimizer: Makine öğreniminde optimizasyon, tahmini ve kayıp fonksiyonunu karşılaştırarak girdi ağırlıklarını optimize eder. Tez modelinde Adam optimizer kullanılmış ve öğrenme oranı 0,001 olarak belirlenmiştir.
- 13.3 Metrikler: Makine öğreniminde, modelin performansını değerlendirmek için metrikler kullanılır. Metrikler kayıp işlevine benzer, ancak eğitim sürecinde kullanılmazlar (WEB 9). Tez modelinde “accuracy” (İng. Doğruluk) metriki kullanılmıştır.

3.7 RASTGELE ORMAN METODU

Karar Ağaçları, sınıflandırma ve regresyon için kullanılan parametrik olmayan denetimli bir öğrenme yöntemidir. Amaç, veri özelliklerinden çıkarılan basit karar kurallarının öğrenilerek bir hedef değişkenin değerini tahmin eden bir model oluşturulmasıdır. Ağaç bir kök düğüm ile başlar. Bu düğümden, kullanıcılar her düğümü karar ağacı öğrenme algoritmasına göre özyinelemeli olarak ayırır. ID3

(Tekrarlı İkililikçi Ağacı), C4.5 ve CART, en yaygın karar ağacı öğrenme algoritmalarından bazılarıdır. Şekil 11’de örnek bir karar ağacı gösterilmektedir.



Şekil 11. Örnek Karar Ağacı

3.7.1 ID3 (Yinelemeli Dikotomizer 3)

ID3 (Yinelemeli Dikotomizer 3) algoritması, 1986 yılında Ross Quinlan tarafından geliştirilmiş (Quinlan, 1986), Maksimum Bilgi Kazancı (BK) veya minimum Entropi (E) sağlayan en iyi özneliği seçerek bir karar ağacı oluşturmaya yönelik açgözlü yaklaşım izleyen bir sınıflandırma algoritmasıdır.

Entropi, S veri kümesindeki belirsizlik miktarının bir ölçüsüdür.

Denklem 1. Entropi

$$E(S) = -\sum p(c) * \log_2 p(c)$$

Denklemde,

S - Entropinin hesaplandığı mevcut veri kümesini,

C - S'deki sınıfların kümesini {ör: C = {evet, hayır}} ,

p(c) - c sınıfındaki öğelerin sayısının S kümesindeki öğelerin sayısına oranını ifade etmektedir.

ID3'te, kalan her özellik için entropi hesaplanır. En küçük entropiye sahip öznitelik, S kümesini o iterasyonda bölmek için kullanılır.

Bilgi Kazanımı (BK(A)), S özniteliğinde A kümesini ayırdıktan sonra S'deki belirsizliğin ne kadar azaldığını söyler.

Denklem 2. Bilgi Kazancı

$$BK(A, S) = E(S) - \sum_{t \in T} p(t) E(t)$$

Denklemde,

$E(S)$ - S kümesinin entropisini,

T - S kümesini A özniteliğine göre bölerek oluşturulan alt kümeleri ($S = \bigcup_{t \in T} t$),

$p(t)$ - t'deki öge sayısının S kümesindeki öge sayısına oranını,

$E(t)$ - t alt kümesinin ifade etmektedir.

3.7.2 C4.5

Ross Quinlan tarafından 1993'te geliştirilmiştir (Quinlan, 1993). Shannon'ın Bilgi Kuramı'ndan (Shannon, 1948) yararlanarak karar ağacını optimize etmeyi amaçlar. Bunun için de değişkenlerin entropi değerlerini baz alır.

Ağacın her bir düğümünde, C4.5, örnek kümesini bir sınıfta veya diğerinde zenginleştirilmiş alt kümelere en etkili şekilde bölen verilerin özniteliğini seçer. Bölme kriteri, normalleştirilmiş bilgi kazancıdır. En yüksek normalleştirilmiş bilgi kazancına sahip özellik, karar vermek için seçilir. Ağaç bu değişkenden itibaren dallandırılmaya başlanır. Böylece verilerin dengeli biçimde dağılımı sağlanmış olur. Aynı işlem bölünmüş alt kümelerde de devam ettirilerek tüm değişkenler ağaca yerleşene kadar devam ettirilir. C4.5, ID3'ün geniş karar ağaçları lehine olan yanlılığını ortadan kaldırır.

3.7.3 Sınıflama ve Regresyon Ağacı (CART)

1984 yılında geliştirilmiştir bir algoritmadır (Breiman, Friedman, Olshen ve Stone, 1984). Hem sınıflandırma hem de regresyonda kullanılır. SRA tarafından yapılan sınıflandırma ağacı yapısı, özniteliklerin her karar düğümünde ikiye ayrılması ilkesine dayanır. SRA algoritması, dallanma kriterinin hesaplanmasında Gini İndeksini kullanır. Gini İndeksi, rastgele seçilen bir ögenin ne sıklıkta yanlış tespit edildiğini ölçmek için kullanılan bir metriktir (Gini, 1912). Gini indeksi düşük olması o özelliğin tercih edilmeye daha uygun olduğunu gösterir. SRA, ikili bölmeler oluşturmak için Gini İndeksini kullanır.

Denklem 3. Gini İndeksi

$$\text{Gini}(T) = 1 - \sum (p_i)^2$$

Denklemde,

T, tüm veri setini


p_i , bir nesnenin belli bir sınıfa ait olma olasılığını ifade eder.

Rastgele Orman Algoritması, karar vermek için birden fazla karar ağacının gücünden yararlanan ağaç tabanlı bir makine öğrenimi algoritmasıdır. Birden fazla bireysel modelin (zayıf öğrenciler) çıktılarını birleştirme işlemine topluluk öğrenmesi (İng. Ensemble Learning) denir. Rastgele Orman Algoritması, nihai çıktıyı oluşturmak için birden çok (rastgele oluşturulmuş) karar ağacının çıktısını birleştirir. Rastgele ormandaki her bir ağaç, bir sınıf tahmini verir ve en çok oyu alan sınıf, modelin tahmini olmuş olur. Buradaki önemli nokta modeller arasındaki korelasyonun düşük olmasıdır. Bu sayede ağaçlar birbirlerini kendi bireysel hatalarından korumuş olur. Rastgele Ormanın karar ağaçlarına göre üstün olduğu yönler, aşırı uyma (İng. Overfitting) riskinin düşük olması, isabet oranının daha yüksek olması ve daha kompleks yöntemler uyguluyor olmasıdır.

Rastgele Orman, sınıf homojenliğini ölçmek için Gini İndeksini kullanır. Gini İndeksi ne kadar düşüğe sınıf o kadar homojendir (Breiman, 2001).

3.8 DESTEK VEKTÖR MAKİNALARI (DVM)

Destek Vektör Makinesi (DVM) (İng. Support Vector Machine, SVM), nesnelere etiket atamayı öğrenen denetimli bir makine öğrenmesi algoritması olarak 1992 yılında ortaya konmuştur (Boser, Guyon ve Vapnik; 1992). Makine öğreniminde sınıflandırma problemleri için sıklıkla kullanılır. DVM algoritmasının amacı, yeni bir veri noktasını doğru kategoriye koyabilmek için n-boyutlu uzayı sınıflara ayırabilen en iyi çizgi veya karar sınırını oluşturmaktır. Bu en iyi karar sınırına hiperdüzlem denir. DVM, hiper düzlemi oluşturmaya yardımcı olan uç noktaları/vektörleri seçer. Bu uç durumlara destek vektörleri denir ve bu nedenle algoritma destek vektör makinesi olarak adlandırılır.



Şekil 12. Destek Vektör Makinası (WEB 10)

Şekil 12'deki denklemde:

$w \cdot x + b = 0 \rightarrow$ düzlem denklemi. $X = (x_1, x_2)$, $w = (a, -1)$ w, x, b

$h(x_i) = +1$, eğer $w \cdot x + b \geq 0$

$h(x_i) = -1$, eğer $w \cdot x + b < 0$

$2 / \|w\|$: maksimum ayırma düzlemini ifade eder.

3.9 SMO ALGORİTMASI


Bir DVM'yi eğitmek, çok büyük bir ikinci dereceden programlama -optimizasyon probleminin (Kuadratik Programlama, KP) çözümünü gerektirir. KP, ikinci dereceden fonksiyonları içeren matematiksel optimizasyon problemlerini çözme sürecini ifade eder. Sıralı Minimum Optimizasyon (SMO), DVM problemini sayısal KP optimizasyon adımlarını hiç kullanmadan hızlı şekilde çözebilen bir algoritmadır. SMO, her adımda mümkün olan en küçük optimizasyon problemini çözmeyi seçer (Platt, 1998)

BÖLÜM IV

Çalışmanın dördüncü bölümünde, veri kümesi ile ilgili bilgilere yer verilmektedir.

4.1 VERİ KÜMESİ


Bu tezde, Jader ve diğerleri (2018) tarafından oluşturulan veri kümesi derin öğrenmeyle restorasyonların tespiti için restorasyon veri kümesi olarak kullanılmıştır. Bu veri kümesi esasen dental restorasyonları tespit etmek için değil, panoramik dental görüntülerden dişlerin segmentasyonu için hazırlanmıştır. Bir uzman tarafından işaretlenmiş olan ve toplamda 5 farklı kategorideki 3013 dental panoramik görüntüden oluşan veri kümesi, farklı dental çalışma türlerine sahip birçok görüntüyü içermektedir. Veri kümesinde, tekil diş görüntüleri kırpılmış ve kategorisi işaretlenmiş olarak bulunmaktadır. 3013 adet görüntü, 521 dolgu, 505 implant, 544 kanal, 928 restorasyonsuz ve 515 adet tel olmak üzere toplam 5 alt kategoriye ayrılmıştır. Şekil 13'te her kategoriye ait 5'er adet örnek görüntü Şekil 13'te yer almaktadır.



Şekil 13. Restorasyon Veri Seti Örnek Görüntüler

Bu tezde evrişimli sinir ağı restorasyon veri kümesinde eğitildikten sonra kimlik tanıma için 183 farklı kişinin farklı zamanlarda çekilmiş en az 1 adet panoramik diş görüntüsünü içeren bir kimliklendirme veri kümesi oluşturulmuştur. Bu küme yukardaki veri setiyle eğitilen restorasyon derin öğrenme modelinin testi için kullanılmaktadır. Kimliklendirme veri kümesinde toplamda 183 farklı kişiye ait 261 farklı ağız içi görüntülerini içeren 7106 panoramik dental diş görüntüsü yer almaktadır. Bu 183 farklı kişiden 31'sinin 2, 16'sının 3, 3'ünün 4 ve 1 tanesinin 7 görüntüsü yer almakta, geri kalan 132 kişinin ise 1'er adet görüntüsü bulunmaktadır.

Bu görüntülerdeki dişler, M-BESA modeliyle tespit edilmiş ve bölütlenmiştir (He, Gkioxari, Dollar ve Girshick; 2017). Şekil 14’te kimliklendirme veri kümesinden alınmış farklı dişler gösterilmiştir.



Şekil 14. Kimliklendirme Veri Seti Örnek Görüntüleri

Bölütlenen her bir diş, Dünya Dişhekimleri Birliği (DDB) notasyonuna göre numaralandırılmıştır. Ağız 4 kısma bölünmüş, sağ üstteki dişlerin numaralandırması 1, sol üstteki dişlerin numaralandırması 2, sağ alttaki dişlerin numaralandırması 4, sol alttaki dişlerin numaralandırması 3 rakamı ile başlamaktadır. Ön dişlerden azılara diş numaraları 1’den 8’e doğru artmaktadır. Mesela, sağ üst kanin 13 ile, sağ alt kanin 43 ile gösterilmektedir. Şekil 15’te DDB notasyonu gösterilmiştir.

UR8	UR7	UR6	UR5	UR4	UR3	UR2	UR1	UL1	UL2	UL3	UL4	UL5	UL6	UL7	UL8
8	7	6	5	4	3	2	1	1	2	3	4	5	6	7	8
18	17	16	15	14	13	12	11	21	22	23	24	25	26	27	28
RM ³	RM ²	RM ¹	RP ⁴	RP ³	RC ⁻	RI ²	RI ¹	LI ¹	LI ²	LC ⁻	LP ³	LP ⁴	LM ¹	LM ²	LM ³
Büyük Azı			Küçük Azı		Kesici		Dişler		Küçük Azı		Büyük Azı				
Büyük Azı			Köpek Dişi		Kesici		Dişler		Köpek Dişi		Büyük Azı				
RM ₃	RM ₂	RM ₁	RP ₄	RP ₃	RC ₋	RI ₂	RI ₁	LI ₁	LI ₂	LC ₋	LP ₃	LP ₄	LM ₁	LM ₂	LM ₃
48	47	46	45	44	43	42	41	31	32	33	34	35	36	37	38
8	7	6	5	4	3	2	1	1	2	3	4	5	6	7	8
LR8	LR7	LR6	LR5	LR4	LR3	LR2	LR1	LL1	LL2	LL3	LL4	LL5	LL6	LL7	LL8

Şekil 15. Dental Notasyon (WEB 11)

Ağızda eksik diş bulunduğundan dolayı panoramik görüntülerdeki eksik dişler M-BESA tarafından tespit edilmemektedir. DDB numaralandırma sistemine göre eksik olan ve M-BESA tarafından bulunmayan dişler çalışmamızda ayrı bir sınıf olarak değerlendirilmiştir. Var olan 5 sınıfın yanında 6. sınıf olarak da eksik diş kategorisi oluşturulmuştur.

Dişler arasındaki mesafeyi ölçmek için Öklid, Hamming, Jaccard ve Kosinüs mesafeleri kullanılmıştır.

4.1.1 Öklid Uzaklığı

Öklid Uzaklığı = $d(x,y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2}$, x,y 2-boyutlu uzaydaki iki noktadır.

4.1.2 Hamming Uzaklığı

$D_H = \sum_{i=1}^n |x_i - y_i|$, $x=y \Rightarrow D=0$, $x \neq y \Rightarrow D=1$, x ve y iki dizi arasındaki karşılıklı sembollerini göstermektedir (Eşit uzunluktaki iki sembol dizisi arasında, karşılık gelen sembollerin farklı olduğu konumların sayısıdır).

4.1.3 Jaccard Uzaklığı

Jaccard katsayısı, sonlu örnek kümeleri arasındaki benzerliği ölçer ve kesişimin boyutunun örnek kümelerinin birleşiminin boyutuna bölümü olarak tanımlanır.

Denklem 4. Jaccard Katsayısı

$$J(A,B) = |A \cap B| / [|A| + |B| - |A \cap B|]$$

Jaccard mesafesi, kümeler arasındaki farklılığı ölçer ve Jaccard katsayısının 1'den çıkarılmasıyla elde edilir.

Denklem 5. Jaccard Mesafesi

$$d_j(A,B) = 1 - J(A,B) = |A \cup B| - |A \cap B| / |A \cup B|$$

4.1.4 Kosinüs Uzaklığı

Benzerlik $= \cos(\theta) = \sum_{i=1}^n (A_i B_i) / \sqrt{\sum_{i=1}^n A_i^2} \sqrt{\sum_{i=1}^n B_i^2}$, A_i , B_i A ve B vektörlerinin bileşenleridir.

4.2 DOĞRULUK METRİKLERİ

Bu tezde, sınıflandırma başarımını ölçmek için aşağıda verilen metrikler kullanılmıştır:

Doğruluk (İng. Accuracy) : $(TP+TN) / (TP+TN+FP+FN)$

Kesinlik (İng. Precision): $TP/(TP+FP)$

Duyarlılık (İng. Recall): $TP/(TP+FN)$

F1-Ölçütü (İng. F1-Score): $(2*Kesinlik*Duyarlılık) / (Kesinlik + Duyarlılık)$

True positive = doğru onaylanmış (TP)

False positive = hatalı onaylanmış (TN)

True negative = doğru reddedilmiş (FP)

False negative = hatalı reddedilmiş (FN)

BÖLÜM V

Bu bölümde kullanılan yöntemler, yapılan deneyler ve onların sonuçları yer almaktadır.

5.1 TEKNİK AYRINTILAR

5.1.1 Python

Python, dinamik semantik ile yorumlanmış, nesne yönelimli, üst düzey bir programlama dilidir. Aralık 1989'da Guido van Rossum tarafından geliştirilmeye başlanmıştır (WEB 12). Dinamik yazma ve dinamik bağlama ile birleştirilmiş yüksek düzeyde yerleşik veri yapıları, python dilini hızlı uygulama geliştirme ve mevcut bileşenleri birbirine bağlamak köprü işlevi görecektir bir yazılım dili olması konusunda avantajlı kılmaktadır. Python, tüm işlevlerini tek bir çekirdekte barındırmak yerine, genişletilebilir modüller şeklinde tasarlanmıştır. Bu durum da, mevcut uygulamalara programlanabilir arayüzler eklemenin bir yolu olarak onu özellikle popüler hale getirmiştir.

5.1.2. Tensorflow

TensorFlow, ilk olarak, makine öğrenmesi ve derin sinir ağları araştırması yapmak için Google'ın Makine Zekası Araştırma organizasyonu içindeki Google Beyin ekibinde çalışan araştırmacılar ve mühendisler tarafından geliştirilmiş, makine öğrenmesi için uçtan uca bir açık kaynak platformudur (WEB 13).

- CPU, GPU veya TPU üzerinde düşük seviyeli tensör işlemlerini verimli bir şekilde yürütme,
- Keyfi türevlenebilir ifadelerin gradyanını hesaplama,
- Hesaplamayı birçok cihaza ölçeklendirme,

- Programları sunucular, tarayıcılar, mobil ve gömülü cihazlar gibi harici çalışma zamanlarına dışa aktarma gibi dört temel yeteneği birleştirir.

5.1.3. Keras

Keras, TensorFlow 2'nin üst düzey uygulama programlama arayüzüdür (WEB 14). Bu arayüz, modern derin öğrenmeye odaklı ve makine öğrenmesinde karşılaşılan sorunların çözmek için üretken bir arayüz sağlar. Keras, mühendis ve araştırmacılara TensorFlow 2'nin ölçeklenebilirlik ve platformlar arası özelliklerinden tam olarak yararlanmaları için yardımcı olur.

5.1.4. Google Colab

Google Colaboratory, bir Google Research ürünüdür. Colab, tamamen bulutta çalışan ücretsiz bir Jupyter notebook ortamıdır. İsteyen herkesin tarayıcı aracılığıyla python kodu yazmasına ve çalıştırmasına olanak sağlar. Özellikle makine öğrenmesi, veri analizi ve eğitim için uygundur (WEB 15).

Bölüm 4'te bahsedilen, Jader ve diğerleri tarafından oluşturulan veri kümesi derin öğrenmeyle restorasyonların tespiti için restorasyon veri kümesi olarak kullanılmıştır.

- Veri kümesinde dolgu, implant, kanal, restorasyonsuz ve tel olmak üzere 5 alt kategoriye ait toplam 3013 adet panoramik dental görüntü bulunmaktadır. Derin öğrenme modelinin oluşturulması aşamasında görüntü boyutu 150x150 piksel boyutlarına indirgenmiş ve görüntüler 32'lik paketler (İng. Batch) haline getirilmiştir. Sonraki adımda veri kümesi %80 eğitim %20 validasyon olarak bölünmüştür. Veriye, yatayda ve dikeyde Rastgele Çevirme (İng. Horizontal and Vertical Flip), %95-%105 oranında Rastgele Döndürme (İng. Random Rotation) ve %98-%102 oranında Rastgele Odaklama (İng. Random Zoom) olarak 3 farklı genişletme (İng. Augmentation) işlemi uygulanmıştır.
- Modelin oluşturulmasında toplam 12 katman kullanılmıştır. İlk katmandaki genişletme işlemlerinden sonra veri 1./255 oranında yeniden ölçeklendirilmiştir. Sonrasında 3 adet konvolüsyon ve 3 adet maksimum havuzlama katmanı bulunmaktadır.

- Konvolüsyon katmanlarında sırasıyla 16,32 ve 64'er adet filtre (3-boyut) kullanılmış, bu filtrelere 3x3 boyutlarında kernel (2-boyut) uygulanmıştır.
- Konvolüsyon katmanlarında dolgu parametresi olarak “same” kullanılmış, böylece konvolüsyon işlemi sırasında dolgu işlemi (İng. padding) uygulanarak girdinin boyutunun küçülmesi önlenmiştir.
- Aktivasyon fonksiyonu olarak ReLU kullanılmıştır. ReLU fonksiyonunu diğer aktivasyon fonksiyonlarına göre kullanmanın ana avantajı, tüm nöronları aynı anda aktive etmemesidir. Böylece, sinir ağını çalıştırmak için gereken işlem maliyetinin üstel olarak büyümesi önlenmiştir.
- Sonraki adımda modele 0.25 oranında seyreltme (İng. Dropout) uygulanmış, böylece konvolüsyon katmanlarındaki her 4 nöronun 1 tanesi rastgele devre dışı bırakılarak modelin aşırı öğrenmesinin önüne geçilmiştir.
- Modeli yoğun katmana aktarmadan önce düzleştirme (İng. Flatten) işlemi uygulanır. Bunun sebebi yoğun katman (İng. Dense Layer) 1-boyutlu girdi kabul etmesidir. Böylece girdi 18x18x64 boyutlarından 1x20736 boyutlarına getirilmiş ve yoğun katmana verilmek üzere hazır hale gelmiştir.
- Birinci yoğun katman, bir önceki katmandaki tüm nöronlardan girdiyi alıp bir matris-vektör çarpımı gerçekleştirir. Matriste kullanılan değerler aslında geri yayılım yardımı ile eğitilebilen ve güncellenebilen parametrelerdir. Bu katmanda 128 nöron kullanılmıştır.
- İkinci yoğun katman 5 nöron içerir. Bunun sebebi sınıflandırmak istediğimiz verilerin 5 sınıfa ait olmasıdır. Bu katmanda SOFTMAX aktivasyonu kullanılmıştır. Softmax, çok terimli bir olasılığı tahmin eden sinir ağı modellerinin çıkış katmanında etkinleştirme işlevi olarak kullanılır.
- Eğitim aşamasına geçilmeden önce eğitim sürecinin yapılandırılması gerekir. Bu yapılandırma derleme (İng. Compile) aşamasında gerçekleştirilir. Burada

belirtilmesi gereken 2 ana argüman vardır: bunlar optimize edici (İng. Optimizer) ve kayıp (İng. Loss)’tur. Modelde optimize edici olarak “Adam Optimizer” kullanılmış, öğrenme oranı 0.001 seçilmiştir. Çoklu sınıflandırma yapıldığı için kayıp fonksiyonu olarak kategorik çapraz entropi (İng. Categorical Cross-Entropy) kullanılmıştır. Kategorik çapraz entropinin türleri içinde “SparseCategoricalCrossentropy” kullanılmasının sebebi model etiketlerinin kodlanmamış (İng. encode) olmasıdır. Ayrıca “doğruluk (İng. Accuracy)” metriki ilave edilerek her adımdaki doğruluk ve kayıp oranları takip edilmiştir.

- Eğitim aşamasında model 25 epok çalıştırılmıştır. Her çalıştırmada rastgele veri kümeleri seçildiğinden doğruluk ve geçerlilik (İng. Validation) oranları değişmekle birlikte, son epok sonrası bu oran %94 olarak gerçekleşmiştir.
- Model, eğitim aşaması tamamlandıktan sonra, dağılımı aşağıda verilmiş olan 205 veri üzerinde test edilmiş olup, karmaşıklık matrisi, doğruluk, kesinlik ve duyarlılık değerleri ile F1 puanı değerleri Tablo 3 ve Tablo 4’te gösterilmiştir.

Tablo 3. Karmaşıklık Matrisi

		Gerçek Değer				
		Dolgu (40)	İmplant (25)	Kanal (60)	Restorasyonsuz (45)	Tel (35)
Tahmin Değeri	Dolgu	33	0	4	2	0
	İmplant	0	21	0	0	0
	Kanal	1	1	53	0	1
	Restorasyonsuz	4	2	2	43	0
	Tel	2	1	1	0	34

Tablo 4. Her Diş Kategorisine ait Kesinlik, Duyarlılık, F-Ölçütü Değerleri

Genel Doğruluk: %89,75	Dolgu	İmplant	Kanal	Restorasyonsuz	Tel
Doğruluk (İng. Accuracy)	0,825	0,84	0,883	0,955	0,971
Kesinlik (İng. Precision)	0,856	1	0,946	0,843	0,919
Duyarlılık (İng. Recall)	0,825	0,840	0,883	0,956	0,971
F1-Ölçütü (İng. F1-Score)	0,835	0,913	0,913	0,896	0,944

5.2 KLASİK UZAKLIK METRİKLERİYLE KİMLİKLENDİRME


CAPMI gibi programlarda uzmanlar dişteki restorasyonları yazılıma manuel olarak işlemektedir ve kişilerin diş bazında restorasyon çizelgeleri oluşturulmaktadır. Kimliği belirsiz kişinin diş çizelgesi veritabanındaki çizelgelerle karşılaştırılmakta ve kimliklendirme için veritabanından eşleşen adaylar tespit edilmektedir. Tezin ilk aşamasında otomatik ESA ile bulunan diş restorasyonlarının tıpkı CAPMI programındaki gibi eşleştirilmesi incelenmiştir. Bunun için restorasyon çizelgesi en benzeyen adaylar veri tabanındaki yine ESA ile oluşturulan diş çizelgeleri ile geleneksel benzerlik/uzaklık metrikleri ile ölçülmüştür.

Diş etiketleri Bölüm 5.1’de anlatılan ESA ile bulunduktan sonra kişi kimliklendirme için aynı ve farklı kişilerin diş görüntüleri kullanılmıştır.


Bir i numaralı kişinin dental görüntüsü I_i olsun ve bu görüntüdeki x numaralı bir diş d_i^x , $x=\{11,12,13,...,18; 21,22,...,28; 31,32,...,38; 41,42,...,48\}$ DDB notasyonuna göre etiketlensin. I_i ve I_k görüntülerindeki aynı x numaralı iki diş d_i^x ve d_k^x arasındaki uzaklık Bölüm 4’te Denklem 1 ile verilen Öklid, Denklem 2 ile verilen Hamming

Denklem 3 ile verilen Jaccard ve Denklem 4’te verilen Kosinüs uzaklıkları ile hesaplanmıştır. Daha sonra bu uzaklıkların ortalaması alınarak I_1 ve I_k arasındaki uzaklık bulunmuştur. Eksik dişler ortalamaya katılmamıştır.

Aynı kişinin farklı görüntüleri arasındaki uzaklığın küçük, farklı kişilerin görüntüleri arasındaki uzaklığın büyük olması beklenmektedir. Şekil 16 ve 17’de bu uzaklıklara göre farklı ve aynı kişilerin uzaklıklarının dağılımları gösterilmiştir.



Şekil 16. Farklı Kişilerin Benzerliği



Şekil 17. Aynı Kişilerin Benzerliği

Şekillerde de görüldüğü üzere aynı kişilerin uzaklıkları daha düşük çıkmıştır. Daha sonra veritabanında birden fazla dental görüntüsü bulunan kişiler için benzerlikler

bulunarak sıralanmıştır. Sıra-1 minimum uzaklığa sahip olan kişiyi yani en benzeyen kişiyi göstermektedir ve kişi kimliklendirme için veritabanından arama yapıldığında Sıra-1’de bulunan kişi ile sorgu yapılan kişinin aynı olması beklenmektedir. Sıra-N ise aranan kişinin N sıra içinde bulunduğunu göstermektedir.

Buna göre aşağıda Tablo 5’te uzaklıklara göre kaçınıcı sırada eşleştikleri verilmiştir:

Tablo 5. Dişlerin Uzaklıklara Göre Kaçınıcı Sırada Eşleştiklerini Gösterir Tablo

	Sıra 1	Sıra 2	Sıra 3	Sıra 4	Sıra 5	Sıra > 5
Öklid	0.65	0.71	0.76	0.76	0.77	0.22
Hamming	0.81	0.82	0.82	0.82	0.83	0.17
Jaccard	0.74	0.79	0.80	0.81	0.82	0.17
Kosinüs	0.65	0.70	0.73	0.74	0.74	0.26

Tablo 5’e göre Hamming uzaklığı birden fazla görüntüye sahip olan kişilerin %81’ini ilk sıra bulmaktadır ve ikisi de kişilerin %83’ünü ilk 5 sırada bulmaktadır. Cosine kişi kimliklendirmede en kötü performansı sergilemiştir.

5.3 KİŞİ KİMLİKLENDİRMEDE SINIFLANDIRMA SONUÇLARI

Klinikte dental restorasyonlar sonrasında, dental görüntüleme tekrar gerçekleşmeyebilir. Bu nedenle, kimliği belirsiz kişinin diş çizelgesi ile veritabanındaki eski görüntüsünün çizelgesi birebir örtüşmek zorunda değildir. Mesela, önceden çekilen bir görüntüdeki bir eksik diş yerine implant yerleştirilmiş olabilir. Ya da restorasyonsuz bir dişe dolgu yapılmış olabilir. Aslında sonradan yapılan restorasyonları kurallar olarak manuel olarak tanımlamak mümkündür. Tezin bu kısmında, eski ve yeni diş çizelgelerinin arasındaki benzerliklerin ya da olabilecek

değişiklerin (eksik diş yerine implant ya da dolgu yerine kanal tedavisi gibi) otomatik olarak öğrenilmesi ve buna göre kimliklendirme yapılması gerçekleştirilmiştir. Dişlerdeki restorasyon değişiklikleri ve otomatik eşleştirmenin gerçekleştirilmesi için makine öğrenmesi yöntemlerinden Rastgele Orman ve DVM yöntemleri kullanılmıştır.

I_1 ve I_2 iki farklı diş görüntüsü olsun. I_1 görüntüsündeki x numaralı diş ve I_2 görüntüsündeki x numaralı diş olsun. Bu iki görüntüdeki aynı x numaralı iki diş d_1^x ve d_2^x ’nin karşılaştırılması gerekmektedir. Makine öğrenmesinin girdisi iki diş d_1^x ve d_2^x ’nin restorasyon etiketleri ve çıktısı ise iki dişin aynı kişiye ait olması ya da olmamasıdır ve bu da ikili sınıflandırma sonucunu $y=\{0,1\}$ olmak üzere vermektedir.

Makine öğrenmesi I_1 ve I_2 görüntülerindeki 32 adet dişin ESA restorasyon sınıflandırma etiketini girdi olarak almalı ve sonuç olarak bu iki görüntü aynı kişiye ait ise 1 değil ise 0 ($y=\{0,1\}$) sonucunu vermelidir. Aslında makine öğrenmesi ile aynı kişilerin diş etiketlerindeki olabilecek değişimler de öğrenilecektir. Aynı zamanda, farklı kişilerin diş görüntüleri arasındaki farklılıkların da öğrenilmesi beklenmektedir.

Makine öğrenmesine ESA sonuçlarının girdi olarak verilmesi için şöyle bir yol izlenmiştir:

- ESA sonucunda bulunan etiket $l=\{0,1,2,\dots,5\}$ olsun.
- d_1^x ’in etiketi l_1^x ve d_2^x ’in etiketi l_2^x olsun. Bu iki dişin etiketinin aynı anda girdi olarak verilmesi için ikisi şu şekilde birleştirilmiştir: $l_{12}^x = l_1^x + 10 * l_2^x$. 32 adet diş bu şekilde birleştirilerek, her ikili için 32lik bir öznitelik vektörü oluşturulmuştur.
- Eğitim kümesi aynı kişilerin farklı görüntüleri ($y=1$) ve her bir görüntü için rastgele seçilen başkasına ait 3 görüntü ile ($y=0$) aynı olmayan kişilerin görüntüleri ile oluşturulmuştur.

Şekil 18’de eğitim kümesindeki farklı l_{12}^x kombinasyonları ve adetleri gösterilmiştir. Mesela , 0 00’a karşılık gelip her iki görüntüde de dişin eksik olması durumudur ve 14 adet diş bu şekildedir. 21, ilk görüntüde dişin etiketinin 2, sonrakinde ise 1 olması durumudur.

Bu numerik değerler kategorik veriye çevirilerek eğitim yapılmıştır.

Tablo 6. Eğitim Kümesindeki Örnek Bazı l_{12}^x kombinasyonları ve Adetleri

	6	106	23	33	3	43	22	0	0	55	22	33	33	33	22	0	55	55	33	33	33	22	22	0	22	55	33	33	33	22	22	20	0	55	1		
6	105	165	306	20	30	0	40	25	5	5	55	20	30	30	35	20	0	55	55	35	35	35	25	25	5	25	55	35	35	35	25	25	25	5	55	0	
6	105	177	339	25	32	2	45	25	5	5	55	22	32	30	35	25	2	55	55	33	33	33	20	25	5	25	50	33	33	33	23	23	25	5	55	0	
6	105	24	132	23	33	3	43	20	5	1	55	23	33	33	33	24	5	51	55	33	33	33	23	23	3	23	55	33	31	33	23	23	25	0	55	0	
11	111	11	112	33	33	33	33	33	33	33	33	33	33	33	3	3	33	33	55	33	33	33	33	33	0	33	33	33	33	33	33	33	33	33	33	1	
11	111	82	214	33	33	33	33	30	30	33	33	33	33	30	30	0	30	33	53	33	33	33	33	33	3	33	33	33	33	33	33	33	30	30	33	0	
11	111	144	279	32	32	30	30	30	31	31	35	30	30	30	30	5	31	31	55	31	31	32	32	30	2	33	35	33	31	32	32	32	32	30	35	0	
11	111	182	356	35	35	35	35	35	35	35	35	35	35	35	35	5	35	35	55	33	30	32	35	35	5	30	33	33	33	30	35	35	35	30	33	0	
12	113	12	114	33	33	33	34	30	0	32	33	33	33	33	33	33	33	33	31	33	33	33	33	33	33	33	31	33	33	33	33	33	33	33	33	1	
12	113	72	200	32	32	32	30	32	5	35	35	32	30	33	35	35	35	35	35	33	33	33	33	32	32	35	35	33	33	33	33	33	33	35	35	0	
12	113	171	323	34	30	30	34	30	0	33	35	34	34	30	30	30	32	33	35	34	34	30	30	30	35	30	33	34	34	30	30	30	30	33	35	0	
12	113	27	135	30	30	33	30	30	5	35	30	30	35	30	30	30	32	30	35	33	33	33	33	30	35	30	33	33	33	33	33	33	35	30	33	0	
12	113	12	115	33	33	33	33	33	3	32	33	33	33	33	33	33	33	33	33	33	33	33	33	33	33	33	35	33	33	33	33	33	33	33	33	1	
12	113	71	198	33	33	33	33	33	3	33	33	33	33	33	33	33	33	33	33	33	33	33	33	33	33	33	33	33	33	33	30	30	35	32	33	0	
12	113	47	160	33	33	33	32	32	3	33	33	33	33	33	33	32	33	33	33	33	33	33	30	32	30	33	33	33	33	33	33	33	33	33	33	33	0
12	113	62	181	34	34	30	34	30	2	30	33	30	34	30	34	34	30	34	33	34	34	34	34	30	32	30	33	34	34	34	30	30	32	30	33	0	
12	114	12	115	33	33	33	43	3	3	22	33	33	33	33	33	33	33	33	13	33	33	33	33	33	33	33	15	33	33	33	33	33	33	33	33	1	
12	114	128	262	33	33	33	44	3	1	23	33	33	33	33	33	34	32	33	11	31	33	31	33	32	30	33	15	33	33	33	33	33	33	33	33	0	
12	114	162	299	35	35	35	45	5	5	25	35	35	35	35	30	30	35	30	15	33	33	33	33	30	30	33	15	33	33	33	33	30	30	33	35	0	
12	114	108	242	31	31	30	44	4	1	21	33	33	30	30	34	30	30	30	11	33	33	33	31	31	31	30	11	31	31	33	31	31	31	33	33	0	
13	116	13	117	31	53	33	55	55	55	55	53	31	33	0	55	1	55	55	55	33	33	33	23	53	55	55	55	13	33	33	33	20	23	55	55	1	
13	116	143	278	31	53	32	54	54	50	50	53	31	31	2	54	4	52	51	51	33	33	32	20	52	52	51	51	13	33	30	30	20	20	50	51	0	
13	116	183	358	33	53	33	53	50	55	55	55	33	33	3	52	5	50	53	55	33	33	33	23	53	55	55	50	13	33	33	33	25	25	50	55	0	
13	116	169	319	30	52	30	50	52	52	55	55	30	30	0	50	2	50	50	55	33	33	33	23	53	55	55	50	13	32	30	30	25	25	55	55	0	
13	116	13	118	30	53	33	55	55	55	55	55	33	33	0	55	0	55	55	55	31	33	33	22	55	55	55	55	11	33	33	33	22	22	55	55	1	
13	116	135	270	33	51	33	55	55	50	51	55	33	33	1	55	5	50	51	55	31	33	33	23	51	50	50	55	11	31	30	30	22	20	50	55	0	
13	116	63	183	33	53	33	53	53	50	50	53	33	33	3	53	4	55	50	53	33	33	33	23	52	50	50	53	13	33	33	33	23	25	50	53	0	
13	116	80	212	33	53	33	53	53	51	53	53	33	33	3	53	3	53	53	53	33	33	33	23	53	53	53	53	13	33	33	33	23	23	53	53	0	

Rastgele Orman Metodunda 10 çapraz doğrulama kullanılmıştır. 472 test verisinin 445'i doğru sınıflandırılarak %94,279 oranında isabet sağlanmış olup, sınıflandırmaya ait doğruluk, kesinlik ve duyarlılık istatistikleri Tablo 7’de verilmiştir.

Tablo 7. Rastgele Orman Metodu Sınıflandırma Sonuçları

Doğru Sınıflandırılmış Örnekler	445	94,28%							
Yanlış Sınıflandırılmış Örnekler	27	5,72%							
Kappa İstatistiği	0.8388								
K&B Görelî Bilgi Skoru	57,41%								
K&B Bilgi Skoru	219,867 bit								
Sınıf Karmaşıklığı Sıra 0	382,9541 bit								
Sınıf Karmaşıklığı Şema	153,8799 bit								
Karmaşıklık İyileştirme	229,0742 bit								
Ortalama Mutlak Hata	0,1766								
Ortalama Hata Kare Kökü	0,2424								
Görelî Mutlak Hata	47,03%								
Bağıl Karesel Hatanın Karekökü	55,98%								
Toplam Örnek Sayısı	472								
~Sınıflara Göre Ayrıntılı Doğruluk~									
	Doğru Onaylanmış Oranı	Doğru Reddedilmiş Oranı	Kesinlik	Duyarlılık	F-Ölçütü	Matthews Korelasyon Katsayısı	Alıcı İşletim Karakteristiği Alanı	Kesinlik-Duyarlılık Eğrisi Alanı	Sınıf
	0,989	0,195	0,938	0,989	0,963	0,844	0,974	0,989	0
	0,805	0,011	0,96	0,805	0,876	0,844	0,974	0,953	1
Ağırlıklandırılmış Ortalama	0,943	0,149	0,944	0,943	0,941	0,844	0,974	0,98	
~Karmaşıklık Matrisi~									
	a	b							
	350	4	a=0						
	23	95	b=1						

SMO seçilerek yapılan sınıflandırmada 10 katlı çapraz doğrulama (İng. 10-fold cross validation) kullanılmış, 472 test verisinin 454’ü doğru sınıflandırılarak %96,186 oranında isabet sağlanmış olup, sınıflandırmaya ait doğruluk, kesinlik ve duyarlılık istatistikleri Tablo 8’de verilmiştir.

Tablo 8 . Sıralı Minimum Optimizasyon Metodu Sınıflandırma Sonuçları

Doğru Sınıflandırılmış Örnekler	454	96,19%							
Yanlış Sınıflandırılmış Örnekler	18	3,81%							
Kappa İstatistiği	0,8983								
K&B Görelî Bilgi Skoru	88,67%								
K&B Bilgi Skoru	339,5596 bit	0,7194 bit							
Sınıf Karmaşıklığı Sıra 0	382,9541 bit	0,8113 bit							
Sınıf Karmaşıklığı Şema	19332 bit	40,9576 bit							
Karmaşıklık İyileştirme	-18949,0459 bit	-40,1463 bit							
Ortalama Mutlak Hata	0,0381								
Ortalama Hata Kare Kökü	0,1953								
Görelî Mutlak Hata	10,15%								
Bağıl Karesel Hatanın Karakökü	45,10%								
Toplam Örnek Sayısı	472								
~Sınıflara Göre Ayrıntılı Doğruluk~									
	Doğru Onaylanmış Oranı	Doğru Reddedilmiş Oranı	Kesinlik	Duyarlılık	F-Ölçütü	Matthews Korelasyon Katsayısı	Alıcı İşletim Karakteristiği Alanı	Kesinlik-Duyarlılık Eğrisi Alanı	Sınıf
	0,975	0,076	0,975	0,975	0,975	0,898	0,949	0,969	0
	0,924	0,025	0,924	0,924	0,924	0,898	0,949	0,872	1
Ağırlıklandırılmış Ortalama	0,962	0,064	0,962	0,962	0,962	0,898	0,949	0,945	
~Karmaşıklık Matrisi~									
	a	b							
	345	9	a=0						
	9	109	b=1						

5.4 KİŞİ KİMLİKLENDİRMEDE SIRALAMA SONUÇLARI

Makine öğrenmesinin farklı kişi ve aynı kişilerin dental çizelgelerini yüksek başarımla ayırt edebildiği Bölüm 5.3'te gösterilmiştir. Bu bölümde ise gerçek bir kişi

kimliklendirme sisteminde, derin öğrenme ile oluşturulmuş dental çizelgelerden kişi kimliklendirmenin değerlendirilmesi yapılmıştır.

Veri tabanında 183 kişinin 261 dental panoramik görüntüsü bulunmaktadır. 51 kişinin farklı zamanlarda çekilmiş birden fazla görüntüsü bulunmaktadır. Bir kişinin N adet görüntüsü var ise, ilk görüntü hariç tüm görüntüler sorgu/test görüntüsü olarak kullanılmıştır. Mesela, üç görüntüsü olan bir kişinin hem ikinci hem ESA ile oluşturulan çizelgeler kullanılarak, her seferinde en az iki görüntüsü bulunan kişiden her birinin görüntüsü kimliklendirilecek olan sorgu/test görüntüsü olarak verilmiş ve veritabanında bulunan tüm görüntülerle benzerlik/eşleşme skorları elde edilmiştir. Skorlar büyükten küçüğe sıralanmıştır ve ilk sıradaki görüntü en benzeyen yani kimliğinin o kişiye ait olması en fazla ihtimal olan kişidir.

Her seferinde birden fazla olan kişinin diğer tüm görüntülerle oluşturulan çizelgeleri test olacak ve kalan tüm farklı kişilerin görüntülerinden oluşturulan çizelgelerin eğitim için kullanılacağı şekilde birini dışarı bırak (leave-one-out) stratejisi ile deneyler yapılmıştır. İki görüntüsü olan bir kişi için test verisinde 182 satır varken, eğitim verisinde diğer kişilerin çizelgelerinin olduğu 2260 satır bulunmaktadır. Eğitim için yine Rastgele Orman ve DVM metotları kullanılmıştır. Tablo 9 ve Tablo 10’da sıralama sonuçları verilmiştir.

Tablo 9. DVM ile Kişi Kimliklendirme Sıralama Tablosu

Sıra	1	2	3	4	5	6	7	8	9	10
Kişi	87	9	7	4	3	0	1	1	1	1
Yüzde	0,76	0,08	0,06	0,04	0,03	0,00	0,01	0,01	0,01	0,01
Kümülatif yüzde	0,76	0,84	0,90	0,94	0,96	0,96	0,97	0,98	0,99	1,00

Tablo 9’da 114 kimliği belirlenecek hedef görüntü verildiği zaman DVM sonuç skorları büyükten küçüğe sıralandığında bunlardan 87 tanesinin ilk sırada, 9 tanesinin ikinci sırada, 7 tanesinin üçüncü sırada eşleştiği görülmüştür. Kümülatif olarak

bakıldığı zaman bir hedef görüntü, veritabanına sorulduğunda kişinin eski görüntüsü %96 oranında ilk 5 sırada bulunabilecektir.

Tablo 10. Rastgele Orman Metodu ile Kişi Kimliklendirme Sıralama Tablosu

Sıra	1	2	3	4	5	6	7	8	9	>10
Kişi	102	5	3	1	1	0	0	0	1	1
Yüzde	0,89	0,04	0,03	0,01	0,01	0,00	0,00	0,00	0,01	0,01
Kümülatif yüzde	0,89	0,94	0,96	0,97	0,98	0,98	0,98	0,98	0,99	1

Rastgele Orman metodu ile aynı eğitim yapılmış ve sonuçlar Tablo 10’da verilmiştir. 114 kimliği belirlenecek kişiden 102 tanesinin veritabanındaki görüntüsü ilk sırada eşleşmektedir. 5 tanesinin ikinci sırada, üç tanesinin ise üçüncü sırada eşleştiği görülmektedir. Kümülatif sonuçlara göre, hedef bir görüntü verildiği zaman %89 oranında ilk sırada, %98 oranında ilk 5 sırada eşleşme gerçekleşmektedir. Bir kişinin görüntüsü kendisinin başka görüntüsü ile 19. Sırada eşleşmiştir ve >10 olarak tabloda gösterilmiştir.

Tablo 9 ve Tablo 10 karşılaştırıldığı zaman Rastgele Orman Metodunun DVM’den daha iyi sonuç verdiği gözlemlenmiştir. Geliştirilen metodun gerçek hayattaki kullanımı için çok daha büyük veri kümeleri üzerinde test edilmesi gereklidir.

BÖLÜM VI

6. TARTIŞMA ve SONUÇ

Bu tezde derin öğrenme yöntemleri ile restorasyonları içeren dental çizelgelerin makine öğrenmesi yöntemleri ile kimliklendirmede kullanılması için yeni bir metot geliştirilmiştir. 2B dental panoramik görüntülerdeki dişler M-BESA ile bölütlenmiş ve etiketlenmiştir. İlk olarak bir ESA oluşturulmuş ve verilen diş görüntüleri ESA ile beş farklı sınıfa ayırmak üzere eğitilmiştir. Sınıflar dolgu, implant, kanal, restorasyonsuz ve telden oluşmaktadır. Ayrıca M-BESA ile bulunmayan eksik dişler de ayrı bir sınıf olarak etiketlenmiştir. ESA ile bir dental görüntüdeki tüm dişler böylece 6 sınıfa ayrılmakta ve her kişinin dental panoramik görüntüsü için bir dental çizelge oluşturulmaktadır.

Restorasyonlar bulunduktan sonra ikinci adım kimliği belirsiz dental görüntünün veritabanındaki kimliği bilinen görüntüler ile en benzeyeninin bulunmasıdır. Bunun için restorasyon çizelgesi en benzeyen adaylar veri tabanındaki yine ESA ile oluşturulan diş çizelgeleri ile geleneksel benzerlik/uzaklık metrikleri ile ölçülmüştür. Geleneksel benzerlik metriklerinin yanında, makine öğrenmesi yöntemlerinden Rastgele Orman ve DVM ile de eşleştirme yapılmıştır. Bunun için dental çizelgeler birleştirilerek restorasyonlar arası oluşabilecek farklılıkların makine öğrenmesi ile tanınması hedeflenmiştir. Mesela bir kişinin önceden restorasyonsuz olarak etiketlenen dişi daha sonra dolgu olabilir fakat implant olan bir diş daha sonra dolgu olamaz. Makine öğrenmesi ile bu kimliklendirmede bu tarz kuralların otomatik olarak öğrenilerek geleneksel uzaklık metriklerinden daha iyi bir sonuç verdiği gözlemlenmiştir. Kimliklendirme için 183 farklı kişinin farklı zamanlarda çekilmiş en az 1 adet panoramik diş görüntüsünün bulunduğu bir veri kümesi kullanılmıştır. Geleneksel uzaklık metriklerinden Hamming uzaklığı Sıra-1'de %81 başarımla

sağlarken, Rastgele Orman %94 ve DVM %96 başarımları sağlamıştır. Bunun sebebi şu şekilde açıklanabilir: Geleneksel uzaklık metriklerinde eski ve yeni görüntülerdeki restorasyon sınıfının aynı olmasına göre uzaklık hesaplanmaktadır. Mesela, çizelgesi aynı olan iki farklı görüntü arasındaki uzaklık 0'dır ve bu iki görüntü arasındaki benzerlik maksimumdur. Makine öğrenmesi ise hem dişlerde olabilecek restorasyonları hem de eski ve yeni görüntüler arasındaki farkları öğrenmektedir.

Çalışmamızda sadece beş farklı restorasyon sınıfı öğrenilmiştir fakat gerçek dünyada kaplama, köprü vb. gibi çok daha fazla sayıda sınıf vardır. Bizim çalışmamızda bu örnekler beş sınıfta birleştirilmiştir. Mesela, köprü ve kaplama dolgu olarak sınıflandırılmıştır. Daha ayrıntılı bir sınıflandırma ile kimlik tanıma için daha yüksek başarımlar elde edilmesi olasıdır.

Tezdeki bir başka husus kimliklendirme için tüm dental görüntünün değil sadece M-BESA ile bölütlenmiş görüntülerin kullanılmasıdır. Literatürdeki çalışmalar M-BESA ile %98 üzerinde başarımlar elde etmiştir. Dişlerin hatalı bulunması ve etiketlenmesindeki hata oranı oldukça azdır. Tüm dental görüntüde maksillanın (üst çene) özellikleri ya da sinüsler gibi kimliklendirmeye yardımcı olabilecek biyometrik başka veriler olabilir. Bu yapıların bulunup kimliklendirmeye etkisinin araştırılması gelecek bir çalışma konusudur.

Tezde, restorasyon tahmini ve kimliklendirme için farklı veri kümeleri kullanılmıştır. Dolayısıyla, eğitim ve test kümelerinde ortak görüntü bulunmamaktadır. Restorasyon başarımları sınıflar için %82 ve %97 arasındadır. Telin doğruluğu %97 iken en düşük doğruluk oranı %82 ile dolgudur. Özellikle kompozit dolgular bazen çok küçük olmakta ve bu küçük dolguların bulunamamasından kaynaklı olarak başarımları düşmektedir. Bir başka husus da implant tespiti için kesinliğin 1 olmasıdır. Yani tüm implantlar bulunmuştur fakat duyarlılık düşüktür.

Tezde küçük bir veri kümesi üzerinde dental restorasyonlar ile kimliklendirme için makine öğrenmesi ile bir metod sunulmuştur. Gelecekte çok daha büyük veride sistemin test edilmesi ve gerçek post-mortem görüntülerde denenmesi sistemin gerçek hayatta kullanımı için gereklidir.

EKLER

EK-1. TEZ ÇALIŞMASINA AİT KODLAR

#1-RESTORASYON TESPİTİ

```
from google.colab import drive
drive.mount("/content/gdrive")

#necessary libraries
import matplotlib.pyplot as plt
import numpy as np
import os
import PIL
import tensorflow as tf

from tensorflow import keras
from tensorflow.keras import layers
from tensorflow.keras.models import Sequential

#data directories
TRAIN_DIRECTORY = os.path.join('/content/gdrive/MyDrive/Colab Notebooks/TEZ (Kodlar)/train data')
TEST_DIRECTORY = os.path.join('/content/gdrive/MyDrive/Colab Notebooks/TEZ (Kodlar)/test data')

#deciding batch and image size
batch_size = 32
IMG_SIZE = 150

#train-validation split
train_ds = tf.keras.preprocessing.image_dataset_from_directory(
    TRAIN_DIRECTORY,
    validation_split=0.2,
    subset="training",
    seed=123,
    image_size=(IMG_SIZE, IMG_SIZE),
    batch_size=batch_size)

val_ds = tf.keras.preprocessing.image_dataset_from_directory(
    TRAIN_DIRECTORY,
    validation_split=0.2,
    subset="validation",
    seed=123,
    image_size=(IMG_SIZE, IMG_SIZE),
    batch_size=batch_size)

#class names
class_names = train_ds.class_names
print(class_names)
```

```

#9 images from the training dataset
import matplotlib.pyplot as plt

plt.figure(figsize=(7,7))
for images, labels in train_ds.take(1):
    for i in range(9):
        ax = plt.subplot(3, 3, i + 1)
        plt.imshow(images[i].numpy().astype("uint8"))
        plt.title(class_names[labels[i]])
        plt.axis("off")

#Configuring the dataset for performance:
AUTOTUNE = tf.data.experimental.AUTOTUNE

train_ds = train_ds.cache().shuffle(1000).prefetch(buffer_size=AUTOTUNE)
val_ds = val_ds.cache().prefetch(buffer_size=AUTOTUNE)

#applying augmentation to reduce overfitting
data_augmentation = keras.Sequential([
    layers.experimental.preprocessing.RandomFlip("horizontal_and_vertical", input_shape=(IMG_SIZE, IMG_SIZE, 3)),
    layers.experimental.preprocessing.RandomRotation(0.05),
    layers.experimental.preprocessing.RandomZoom(0.02)])

#augmented image display
plt.figure(figsize=(7,7))
for images, _ in train_ds.take(1):
    for i in range(9):
        augmented_images = data_augmentation(images)
        ax = plt.subplot(3, 3, i + 1)
        plt.imshow(augmented_images[0].numpy().astype("uint8"))
        plt.axis("off")

#MODEL
model = Sequential([
    data_augmentation,
    layers.experimental.preprocessing.Rescaling(1./255),
    layers.Conv2D(16, 3, padding='same', activation='relu'),
    layers.MaxPooling2D(),
    layers.Conv2D(32, 3, padding='same', activation='relu'),
    layers.MaxPooling2D(),
    layers.Conv2D(64, 3, padding='same', activation='relu'),
    layers.MaxPooling2D(),
    layers.Dropout(0.25),
    layers.Flatten(),
    layers.Dense(128, activation='relu'),
    layers.Dense(5, activation='softmax')
])

```

```

#COMPILE
model.compile(optimizer='adam',
              loss=tf.keras.losses.SparseCategoricalCrossentropy(from_logits=True),
              metrics=['accuracy'])

model.summary()

#TRAINING
epochs = 25

history = model.fit(
    train_ds,
    validation_data=val_ds,
    epochs = epochs)

#Visualizing training results
acc = history.history['accuracy']
val_acc = history.history['val_accuracy']

loss=history.history['loss']
val_loss=history.history['val_loss']

epochs_range = range(epochs)

plt.figure(figsize=(8, 8))
plt.subplot(1, 2, 1)
plt.plot(epochs_range, acc, label='Training Accuracy')
plt.plot(epochs_range, val_acc, label='Validation Accuracy')
plt.legend(loc='lower right')
plt.title('Training and Validation Accuracy')

plt.subplot(1, 2, 2)
plt.plot(epochs_range, loss, label='Training Loss')
plt.plot(epochs_range, val_loss, label='Validation Loss')
plt.legend(loc='upper right')
plt.title('Training and Validation Loss')
plt.show()

#TEST STEP
from google.colab import files
from keras.preprocessing import image
import numpy as np

uploaded = files.upload()

```

```

result_dict = {"tid":[], "class":[], "conf":[]}

for fn in uploaded.keys():
    path = fn
    img = image.load_img(path, target_size=(IMG_SIZE, IMG_SIZE))

    img_array = image.img_to_array(img)
    img_array = np.expand_dims(img_array, axis = 0)

    predictions = model.predict(img_array)
    print("tooth id:{}, class:{}, conf:%{:.2f}".format(fn[:-4], np.argmax(predictions), 100 * np.max(predictions)))

    result_dict["tid"].append(fn[:-4])
    result_dict["class"].append(np.argmax(predictions))
    result_dict["conf"].append(100 * np.max(predictions))
    np.savetxt("/content/gdrive/MyDrive/Colab Notebooks/TEZ (Kodlar)/predictions.csv", predictions, delimiter=",")

#write results to csv
import pandas as pd
result_df = pd.DataFrame.from_dict(result_dict)
result_df.to_csv("/content/gdrive/MyDrive/Colab Notebooks/TEZ (Kodlar)/testing_results.csv")

```

#2-DATAFRAME OPERATIONS

```

from google.colab import drive
drive.mount("/content/gdrive")
import pandas as pd
import random
import itertools
from itertools import combinations

df = pd.read_csv("/content/gdrive/MyDrive/Colab Notebooks/TEZ (Yazılacak Belge)/1-DataVector.csv", header=None)

dflist=df.values.tolist()#verileri listeye dönüştürme

#random sayı tanımlayan fonksiyon, modu verdiği uzunluğa göre alıyor
def randfunc(lenght):
    return random.randint(0,lenght-1)

df1 = [1]# aynı sonuçlar için 1 ekleme
df0 = [0]# aynı sonuçlar için 0 ekleme
duplicates = []#tekrarlayan id'leri tutacak
temp=[]#verileri geçiçi tutmak için. aynı olan id'leri bulup bir arada tuttuk

```

```

for i in range(0,len(dflist)-1):
    k=1
    alist = []

    for j in range(i+1,len(dflist)):
        if dflist[i][0] == dflist[j][0]:
            k+=1
    if k>1:
        for a in range(i,i+k):
            temp.append(a)#aynı idleri kümele
        duplicates.append(temp)
        temp = []

temp=[]#geçici veriler için
for i in (range(len(duplicates))):
    if len(duplicates[i])>1:
        temp.append(list(combinations(duplicates[i], 2)))

teeth = []
for i in range(len(temp)):
    for j in range(len(temp[i])):
        if ([temp[i][j]] not in teeth and temp[i][j] not in teeth):
            teeth.append(temp[i][j])

dfnew = []
for i in range(len(teeth)):
    dfnew.append(dflist[teeth[i][0]]+ dflist[teeth[i][1]]+ df1)
    for j in range(0,3):
        rnd=randfunc(len(dflist))
        while((dflist[rnd][0]==dflist[teeth[i][0]][0] or dflist[teeth[i][1]][0]==dflist[rnd][0])):
            rnd=randfunc(len(dflist))

    dfnew.append(dflist[teeth[i][0]]+ dflist[rnd]+ df0)

```

```

dfToCsv = pd.DataFrame(dfnew)
dfToCsv.to_csv("/content/gdrive/MyDrive/Colab Notebooks/TEZ (Yazılacak Belge)/2-
DfOpsResults.csv", index=None, header=None)

```

#3-DISTANCE METRICS

```

from google.colab import drive
drive.mount("/content/gdrive")
import pandas as pd

```

```

import numpy as np

df = pd.read_csv("/content/gdrive/MyDrive/Colab Notebooks/TEZ (Yazılacak Belge)/2-
DfOpsResults.csv", header=None)

from sklearn.metrics import pairwise_distances

dist_jaccard = []
dist_euclidean = []
dist_hamming = []
dist_cosine = []

for i in range(len(df)):
    X=np.asarray(df.iloc[i:i+1,2:34])
    Y=np.asarray(df.iloc[i:i+1,36:68])

    dist_jaccard.append(pairwise_distances(X,Y,metric='jaccard')[0][0])
    dist_euclidean.append(pairwise_distances(X,Y,metric='euclidean')[0][0])
    dist_hamming.append(pairwise_distances(X,Y,metric='hamming')[0][0])
    dist_cosine.append(pairwise_distances(X,Y,metric='cosine')[0][0])

jaccard_df=pd.DataFrame(data= dist_jaccard,index=None)
euclid_df=pd.DataFrame(data= dist_euclidean,index=None)
hamming_df=pd.DataFrame(data= dist_hamming,index=None)
cosine_df=pd.DataFrame(data= dist_cosine,index=None)

df["jaccard"]=dist_jaccard
df["euclidean"]=dist_euclidean
df["hamming"]=dist_hamming
df["cosine"]=dist_cosine

jaccard_score = df[[0,1,34, 35,'jaccard']]
jaccard_score.to_csv('/content/gdrive/MyDrive/Colab Notebooks/TEZ (Yazılacak Belge)/3-
jaccard_score.csv',header=None, index=False)

euclidean_score = df[[0,1,34, 35,'euclidean']]
euclidean_score.to_csv('/content/gdrive/MyDrive/Colab Notebooks/TEZ (Yazılacak Belge)/4-
euclidean_score.csv',header=None, index=False)

hamming_score = df[[0,1,34, 35,'hamming']]
hamming_score.to_csv('/content/gdrive/MyDrive/Colab Notebooks/TEZ (Yazılacak Belge)/5-
hamming_score.csv',header=None, index=False)

cosine_score = df[[0,1,34, 35,'cosine']]

```

```
cosine_score.to_csv('/content/gdrive/MyDrive/Colab Notebooks/TEZ (Yazılacak Belge)/6-  
cosine_score.csv',header=None, index=False)
```

KAYNAKÇA

- A~lberg, J.V., Goodwin, M.: Automated dental identification with lowest cost path-based teeth and jaw separation. *Scandinavian Journal of Forensic Science* 22(2), 44 - 56 (2016)
- Abdel-Mottaleb, M., Nomir, O., Nassar, D., Fahmy, G., Ammar, H.: Challenges of developing an automated dental identification system. In: *IEEE 46th Midwest Symposium on Circuits and Systems*, vol. 1, pp. 411-414 (2003)
- Ajaz, A., Kathirvelu, D.: Dental biometrics: Computer aided human identification system using the dental panoramic radiographs. In: *IEEE International Conference on Communications and Signal Processing*, pp. 717-721 (2013)
- Atheeswaran, A., R.Karunya, Amir, A.: Human identification using dental biometrics. *International Journal of Applied Engineering Research* 9, 4428–4433 (2014)
- Banday, M., Mir, A.H.: Dental biometric identification system using ar model. In: *TENCON*, pp. 2363-2369 (2019)
- Barboza, E., Marana, A., Tostes Oliveira, D.: Semiautomatic dental recognition using a graph-based segmentation algorithm and teeth shapes features. pp. 348-353 (2012). DOI 10.1109/ICB.2012.6199831
- Boser, B. E. , Guyon, I. M., Vapnik, V. N.: A training algorithm for optimal margin classifiers. In: *COLT92: 5th Annual Workshop on Computational Learning Theory*, pp. 144-152 (1992)
- Classification and Regression Trees, 1984, Breiman vd. (CART)
- Convolutional Networks for Images, Speech, and Time-Series (1995) (Yann Lecun, Bengio)
- Cui, Z., Li, C., Wang, W.: Toothnet: Automatic tooth instance segmentation and identification from cone beam ct images. In: *2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 6361-6370 (2019)
- Dental Biometric Features: A Comparative Study for Human Identification (???)
- Fahmy, G., Nassar, D., Haj-Said, E., Chen, H., Nomir, O., Zhou, J., Howell, R., Ammar, H.H., Abdel-Mottaleb, M., Jain, A.K.: Towards an automated dental identification system. *Journal of Electronic Imaging* 14(4), 43018–43018 (2005)

- Fan, F., Ke, W., Wu, W., Tian, X., Lyu, T., Liu, Y., Liao, P., Dai, X., Chen, H., Deng, Z.: Automatic human identification from panoramic dental radiographs using the convolutional neural network. *Forensic Science International* 314, 110416 (2020)
- Fan, Y., Beare, R., Matthews, H., Schneider, P., Kilpatrick, N., Clement, J., Claes, P., Penington, A., Adamson, C.: Marker-based watershed transform method for fully automatic mandibular segmentation from cbct images. *Dentomaxillofacial Radiology* 48, 20180261 (2018). DOI 10.1259/dmfr.20180261
- Fejlichowski, D., Czapiewski, P.: An Application of the Curvature Scale Space Shape Descriptor for Forensic Human Identification Based on Orthopantomograms, vol. 8104, pp. 67{76 (2013). DOI 10.1007/978-3-642-40925-77
- Frejlichowski, D., Wanat, R.: Extraction of teeth shapes from orthopantomograms for forensic human identification. In: *Computer Analysis of Images and Patterns, Lecture Notes in Computer Science*, vol. 6855, pp. 65{72. Springer Berlin Heidelberg (2011)
- H, A., Zoroo , R., Shirani, G.: Rapid automatic segmentation and visualization of teeth in ct-scan data. *Journal of Applied Sciences*, vol 9 (2009). DOI 10.3923/jas.2009.2031.2044
- He, K., Gkioxari, G., Dollar, P., Girshick, R.: *Proceedings of the IEEE International Conference on Computer Vision (ICCV)*, 2017, pp. 2961-2969
- Heinrich, A., Güttler, F., Schenkl, S., Wagner, R., Teichgräber, U.: Automatic human identification based on dental X-ray radiographs using computer vision. *Scientific reports* 10(1), 3801 (2020)
- Hofer, M., Marana, A.N.: Dental biometrics: Human identification based on dental work information. In: *SIBGRAPI*, pp. 281-286 (2007)
- Human Identification with Dental Panoramic Images Based on Deep Learning (Wu vd, 2021)
- Hwang, J.J., Jung, Y.H., Cho, B.H., Heo, M.S.: An overview of deep learning in the field of dentistry. *Imaging Science in Dentistry* 49, 1 (2019). DOI 10.5624/isd.2019.49.1.1
- Jader, G., Fontineli, J., Ruiz, M., Lima, K., Pithon, M., Oliveira, L.: Deep instance segmentation of teeth in panoramic x-ray images. pp. 400-407 (2018)

- Jader, G., Oliveira, L., Pithon, M.: Automatic segmenting teeth in X-ray images: Trends, a novel data set, benchmarking and future perspectives. *Expert Systems with Applications* 107 (2018). DOI 10.1016/j.eswa.2018.04.001
- Jain, A., Chen, H.: Matching of dental x-ray images for human identification. *Pattern Recognition* 37(7), 1519 - 1532 (2004)
- Joseph, L.J., George, L.B., Shabna GU, Susmi I, Santhi, N.: Teeth feature extraction and matching for human identification using morphological skeleton transform. In: 2016 International Conference on Energy Efficient Technologies for Sustainability (ICEETS), pp. 802{807 (2016)
- Lai, Y., Fan, F., Wu, Q., Ke, W., Liao, P., Deng, Z., Chen, H., Zhang, Y.: Lcanet: Learnable connected attention network for human identification using dental images. *IEEE Transactions on Medical Imaging* (2020). DOI 10.1109/TMI.2020.3041452
- LeCun, Y., Bengio, Y., Hinton, G.: Deep Learning. In: *Nature* 521(7553):436-44 (2015). DOI:10.1038/nature14539
- Lee, C., Lim, S.H., Huh, K.H., Han, S.S., Kim, J.E., Heo, M.S., Yi, W.J., Lee, S.S., Choi, S.C.: Performance of dental pattern analysis system with treatment chronology on panoramic radiography. *Forensic Science International* 299, 229 – 234 (2019)
- Lee, J.H., Han, S.S., Kim, Y., Lee, C., Kim, I.: Application of a fully deep convolutional neural network to the automation of tooth segmentation on panoramic radiographs. *Oral Surgery, Oral Medicine, Oral Pathology and Oral Radiology* (2019). DOI 10.1016/j.oooo.2019.11.007
- Lin, P., Lai, Y., Huang, P.: An effective classification and numbering system for dental bitewing radiographs using teeth region and contour information. *Pattern Recognition* 43(4), 1380 { 1392 (2010)
- Lin, P.L., Lai, Y.H., Huang, P.W.: Dental biometrics: Human identification based on teeth and dental works in bitewing radiographs. *Pattern Recognition* 45(3), 934 – 946 (2012)
- Lorton, L., Rethman, M., Friedman, R.: Computer-assisted postmortem identification (CAPMI) system: A computer-based identification program. *Journal of Forensic Sciences* 50 33, 977–984 (1988)

- McCarthy, J., Minsky, M.L., Rochester, N., Shannon, C.: A Proposal for the Dartmouth Summer Research Project on Artificial Intelligence. In: AI Magazine 27 (4): 12-14 (2006)
- McCulloch, W., Pitts, W., A Logical Calculus of the Ideas Immanent in Nervous Activity. Bulletin of Mathematical Biophysics 5, 115–133 (1943). DOI 10.1007/BF02478259
- Miki, Y., Muramatsu, C., Hayashi, T., Zhou, X., Hara, T., Katsumata, A., Fujita, H.: Tooth labeling in cone-beam ct using deep convolutional neural network for forensic identification. p. 101343E (2017). DOI 10.1117/12.2254332
- Nomir, O., Abdel-Mottaleb, M.: Human identification from dental x-ray images based on the shape and appearance of the teeth. Information Forensics and Security, IEEE Transactions on 2, 188 { 197 (2007). DOI 10.1109/TIFS.2007.897245
- Oktay, A. B., Gurses, A.: Tooth Restoration and Dental Work Detection on Panoramic Dental Images via CNN. 2020 Medical Technologies Congress (TIPTEKNO), 2020, pp. 1-4, DOI: 10.1109/TIPTEKNO50054.2020.9299272.
- Oktay, A.B.: Human identification with dental panoramic radiographic images. IET Biometrics 7(4), 349{355 (2017)
- Oktay, Akhtar ve Gurses, Dental Biometric Features: A Comparative Study for Human Identification, (in press)
- Petju, M., Suteerayongprasert, A., Thongpud, R., Hassiri, K.: Importance of dental records for victim identification following the indian ocean tsunami disaster in thailand. Public 59 Health 121(4), 251 – 257 (2007)
- Programs for Machine Learning, (Quinlan 1993) (C4.5)
- Quinlan, J.R.: Induction of decision trees. Mach Learn 1, 81–106 (1986). DOI 10.1007/BF00116251
- Random Forests (Breiman, 2001)
- Reesu, G.V., Woodsend, B., M~ Açnica, S., Revie, G.F., Brown, N.L., Mossey, P.A.: automated identification from dental data (autoidd): A new development in digital forensics. Forensic Science International 309, 110218 (2020)
- Schwendicke, F., Samek W., Krois J.: Artificial Intelligence in Dentistry: Chances and Challenges. J Dent Res; 99(7):769-774. doi: 10.1177/0022034520915714 (2020).

- Sequential Minimal Optimization: A Fast Algorithm for Training Support Vector Machines (Platt, 1998)
- Shah, N., Bansal, N., Logani, A.: Recent advances in imaging technologies in dentistry. *World journal of radiology* 6, 794–807 (2014). DOI 10.4329/wjr.v6.i10.794
- Shannon, C.E., A Mathematical Theory of Communication. In: *Bell System Technical Journal*, pp. 379-423 (1948)
- Solomonoff, R.J.: *An Inductive Inference Machine* (1957)
- Some Studies in Machine Learning Using the Game of Checkers (Samuel, A.L., 1959)
- The perceptron: a probabilistic model for information storage and organization in the brain (1958) F. Rosenblatt
- Tuzoff, D., Tuzova, L., Bornstein, M., Krasnov, A., Kharchenko, M., Nikolenko, S., Sveshnikov, M., Bednenko, G.: Tooth detection and numbering in panoramic radiographs using convolutional neural networks. *Dentomaxillofacial Radiology* 48, 20180051 (2019)
- Utsuno, D.: Victim identification in large-scale disasters using dental findings. *IATSS Research* 43 (2019). DOI 10.1016/j.iatssr.2019.06.005
- Variability and Mutability (Corrado Gini, 1912)
- Vijayakumari, B., Kirubalini, R.R., Manisha, C.R.: Cadaver identification with dental radiographs using isoperimetric and nodal graph approach. *IET Biometrics* 9(1), 38{45 (2019)
- Wang, Y.J., Liu, S., Wang, G., Liu, Y.: Accurate tooth segmentation with improved hybrid active contour model. *Physics in Medicine and Biology* 64 (2018). DOI 10.1088/1361- 6560/aaf441
- WEB 1, <http://www.winid.com>
- WEB 2, <https://tinyurl.com/5vzr52ts>
- WEB 3, <https://tinyurl.com/44jnn4ww>
- WEB 4, <https://cs231n.github.io/convolutional-networks/>
- WEB 5, <https://tinyurl.com/asr4bhbc>
- WEB 6, <https://tinyurl.com/u75kuv6>
- WEB 7, <https://tinyurl.com/m49sh7fp>

- WEB 8, <https://tinyurl.com/ckhsbmst>
- WEB 9, https://keras.io/api/models/model_training_apis/
- WEB 10, <https://tinyurl.com/9drh8dcf>
- WEB 11, <https://tinyurl.com/4aj82xrt>
- WEB 12, <https://tinyurl.com/4yxsp6>
- WEB 13, <https://github.com/tensorflow/tensorflow>
- WEB 14, <https://keras.io/about/>
- WEB 15, <https://tinyurl.com/n8sa24ny>
- Zhang, Z., Ong, S.H., Zhong, X., Foong, K.W.: Efficient 3d dental identification via signed feature histogram and learning keypoint detection. Pattern Recognition 60, 189 { 204 (2016)
- Zhong, X., Yu, D., Wong, Y.S., Sim, T., Lu, W.F., Foong, K.W.C., Cheng, H.L.: 3d dental biometrics: Alignment and matching of dental casts for human identification. Computers in Industry 64(9), 1355 { 1370 (2013). Special Issue: 3D Imaging in Industry