



**FARKLI KLİNİK IŞIKLARI ALTINDA KAYDEDİLEN
DENTAL FOTOĞRAFLARA AİT DİŞ RENKLERİNİN
YAPAY ZEKÂ TEKNİKLERİ KULLANILARAK
TESPİTİ**

Esra EFİTLİ

**Danışman: Dr. Öğr. Üyesi Abdullah Ammar KARCIOĞLU
Yüksek Lisans Tezi
Yazılım Mühendisliği Ana Bilim Dalı
2025**

(Her hakkı saklıdır.)

T.C.
ATATÜRK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
YAZILIM MÜHENDİSLİĞİ ANA BİLİM DALI

**FARKLI KLİNİK IŞIKLARI ALTINDA KAYDEDİLEN DENTAL FOTOĞRAFLARA
AİT DİŞ RENKLERİNİN YAPAY ZEKÂ TEKNİKLERİ KULLANILARAK TESPİTİ**

(Detection of Tooth Colors of Dental Photographs Recorded Under Different Clinic Lights
Using Artificial Intelligence Techniques)

YÜKSEK LİSANS TEZİ

Esra EFİTLİ

Danışman: Dr. Öğr. Üyesi Abdullah Ammar KARCIOĞLU

Erzurum
Haziran, 2025



FEN BİLİMLERİ ENSTİTÜSÜ

Graduate School of Natural and
Applied Sciences

T.C.
ATATÜRK ÜNİVERSİTESİ
Fen Bilimleri Enstitüsü Müdürlüğü
TEZ KABUL VE ONAY TUTANAĞI

FARKLI KLİNİK IŞIKLARI ALTINDA KAYDEDİLEN DENTAL FOTOĞRAFLARA AIT DIŞ RENKLERİNİN YAPAY ZEKÂ TEKNİKLERİ KULLANILARAK TESPİTİ

Dr. Öğr. Üyesi Abdullah Ammar KARCIOĞLU danışmanlığında, Esra EFİTLİ tarafından hazırlanan bu çalışma, 20/06/2025 tarihinde aşağıdaki jüri tarafından Yazılım Mühendisliği Anabilim Dalı Yazılım Mühendisliği Bilim Dalı'nda Yüksek Lisans tezi olarak **oybirliği** ile kabul edilmiştir.

Jüri Başkanı: Prof. Dr. Rabia Meryem YILMAZ

Atatürk Üniversitesi

Aslı ıslak imzalıdır

Danışman: Dr. Öğr. Üyesi Abdullah Ammar
KARCIOĞLU

Atatürk Üniversitesi

Aslı ıslak imzalıdır

Jüri Üyesi: Dr. Öğr. Üyesi Merve YILDIRIM

Karadeniz Teknik Üniversitesi

Aslı ıslak imzalıdır

Enstitü Yönetim
Kurulunun .../.../.... tarih
ve sayılı kararı.

Bu tezin Atatürk Üniversitesi Lisansüstü Eğitim ve Öğretim Yönetmeliği'nin ilgili maddelerinde belirtilen şartları yerine getirdiğini onaylarım.

Aslı ıslak imzalıdır

Prof.Dr. Alper NUHOĞLU

Enstitü Müdürü

Bu çalışma TÜBİTAK 1001 Hızlı Destek Programı projeleri kapsamında desteklenmiştir.
Proje No: 123E597

Not: Bu tezde kullanılan özgün ve başka kaynaklardan yapılan bildiriş, çizelge, şekil ve fotoğrafların kaynak olarak kullanımı, 5846 sayılı Fikir ve Sanat Eserleri Kanunundaki hükümlere tabidir.



FEN BİLİMLERİ ENSTİTÜSÜ
Graduate School of Natural and
Applied Sciences

T.C.
ATATÜRK ÜNİVERSİTESİ REKTÖRLÜĞÜ
FEN BİLİMLERİ ENSTİTÜSÜ MÜDÜRLÜĞÜ

ETİK BİLDİRİM VE İNTİHAL BEYAN FORMU

Yüksek Lisans Tezi olarak Dr. Öğr. Üyesi Abdullah Ammar KARCIOĞLU danışmanlığında sunulan “Farklı Klinik Işıkları Altında Kaydedilen Dental Fotoğraflara Ait Diş Renklerinin Yapay Zekâ Teknikleri Kullanılarak Tespiti” başlıklı çalışmanın tarafımızdan bilimsel etik ilkelere uyularak yazıldığını, yararlanılan eserlerin kaynakçada gösterildiğini, Fen Bilimleri Enstitüsü tarafından belirlenmiş olan Turnitin Programı benzerlik oranlarının aşılmadığını ve aşağıdaki oranlarda olduğunu beyan ederiz.

Tez Bölümleri	Tezin Benzerlik Oranı (%)	Maksimum Oran (%)
Giriş	%0	30
Kuramsal Temeller	%4	30
Materyal ve Metot	%3	35
Araştırma Bulguları ve Tartışma	%0	20
Sonuçlar ve Öneriler	%0	20
Tezin Geneli	%4	25

Not: Yedi kelimeye kadar benzerlikler ile Başlık, Kaynakça, İçindekiler, Teşekkür, Dizin ve Ekler kısımları tarama dışı bırakılabilir. Yukarıdaki azami benzerlik oranları yanında tek bir kaynaktan olan benzerlik oranlarının %5'den büyük olmaması gerekir.

Sunulan bilgilerin doğru olduğunu, aksi halde doğacak hukuki sorumlulukları kabul ettiğimizi beyan ederiz.

Tez Yazarı (Öğrenci)	Tez Danışmanı
Esra EFİTLİ	Dr. Öğr. Üyesi Abdullah Ammar KARCIOĞLU
20.6.2025	20.6.2025
İmza: Aslı ısalık imzalıdır	İmza: Aslı ıslak imzalıdır

* Tez ile ilgili YÖKTEZ’de yayınlamasına ilişkin bir engelleme var ise aşağıdaki alanı doldurunuz.

Tezle ilgili patent başvurusu yapılması / patent alma sürecinin devam etmesi sebebiyle Enstitü Yönetim Kurulunun .../.../... tarih ve sayılı kararı ile teze erişim 2 (iki) yıl süreyle engellenmiştir.

Enstitü Yönetim Kurulunun .../.../... tarih ve sayılı kararı ile teze erişim 6 (altı) ay süreyle engellenmiştir.

Not: Bu form, Tezin son şekline uygun olarak bilgisayar ortamında doldurulmalı, çıktısı imzalanıp Tezin sonuna eklenmelidir.

TEŞEKKÜR

Tez çalışmam süresince bilimsel bilgi birikimi, yönlendirmeleri ve desteğiyle bana rehberlik eden değerli danışmanım Dr. Öğr. Üyesi Abdullah Ammar KARCIOĞLU'na en içten teşekkürlerimi sunarım.

Tez konusunun şekillenmesinde ve klinik uygulama süreçlerinin yürütülmesinde sunduğu deneyim ve katkılarından dolayı Doç. Dr. Alper ÖZDOĞAN'a teşekkür ederim.

Yazılım geliştirme sürecindeki teknik desteklerinden dolayı Öğr. Gör. Emrah ŞİMŞEK'e; veri toplama sürecinde desteklerinden dolayı Öğr. Gör. Furkan KARATAŞ ve Öğr. Gör. Tuba ŞENOCAK'a teşekkür ederim.

Bu tez, Türkiye Bilimsel ve Teknolojik Araştırma Kurumu (TÜBİTAK) tarafından desteklenen 123E597 numaralı 1002 - Hızlı Destek Projesi kapsamında yürütülmüştür. Destekleri dolayısıyla TÜBİTAK'a teşekkür ederim.

Bu süreçte manevi destekleriyle her zaman yanımda olan aileme sonsuz şükranlarımı sunarım.

Esra EFİTLİ

ÖZET

YÜKSEK LİSANS TEZİ

FARKLI KLİNİK IŞIKLARI ALTINDA KAYDEDİLEN DENTAL FOTOĞRAFLARA AİT DİŞ RENKLERİNİN YAPAY ZEKÂ TEKNİKLERİ KULLANILARAK TESPİTİ

Esra EFİTLİ

Danışman: Dr. Öğr. Üyesi Abdullah Ammar KARCIOĞLU

Amaç: Protetik diş tedavilerinde renk belirleme süreci ışık kaynaklarının değişkenliği, görsel değerlendirmenin öznelliği, enstrümantal ölçüm araçlarının yüksek maliyeti ve standardizasyon eksiklikleri gibi çeşitli sınırlamalarla karşı karşıyadır. Bu tezin amacı yapay zekâ yöntemleri kullanılarak, değişen ışık koşullarına rağmen tutarlı ve güvenilir diş rengi tahminlerinin yapılmasını sağlamak ve mevcut sistematik sınırlamalara alternatif bir çözüm üretmektir.

Yöntem: Bu çalışmada yöntemsel süreç, kavramsal doğrulama ve teknik yeterlilik açısından kademeli bir şekilde ilerleme sağlanmıştır. İlk aşamada, dört farklı klinik ışık kaynağında beşer kez çekilen Vita 3D Master renk skalası kullanılarak oluşturulan veri seti kullanılmıştır. Üç farklı ışık kaynağının ayrımında bulanık mantık, dört farklı ışık kaynağı altında çekilen 29 farklı diş renginin sınıflandırılmasında makine öğrenimi algoritmaları kullanılmıştır. Deneysel çalışmalarda farklı renk uzayları ve farklı görüntü işleme tekniklerinin etkileri detaylı bir şekilde analiz edilmiştir. İkinci aşamada, beş farklı klinik ışık kaynağı altında gönüllü hastaların diş görüntülerinden veri seti oluşturulmuştur. Klinik senaryoya uygun bir model geliştirmek üzere derin öğrenme modelleri kullanılarak deneysel çalışmalar gerçekleştirilmiştir. Görüntüler üzerinde YOLOv5 ile dişler otomatik tespit edilmiştir, ardından önerilen renk sınıflandırma modeli LABNet'e ön işlem den geçirilerek aktarılmıştır. Böylece renk belirleme süreci klinik uygulamalara uygun olacak şekilde standart hale getirilmiştir.

Bulgular: İlk veri setinde, klinik ışıklarının belirlenmesinde bulanık mantık %98,85 doğruluk elde etmiştir. Renk anları yöntemiyle dört farklı ışık kaynağının sınıflandırılmasında %100, ışıktan bağımsız 29 Vita renginde %85 doğruluk elde edilirken histogram yöntemiyle %97,93 doğruluk elde edilmiştir. İkinci veri setinde ise, YOLOv5 diş tespitinde mAP@50 skoru %99,5 ve önerilen renk tespiti modelinde ise eğitimde %97,54, doğrulamada %88,74 doğruluk elde edilmiştir.

Sonuç: Klinik ışık kaynaklarından bağımsız yüksek doğrulukta diş rengi tespiti yaparak protetik tedavi süreçlerinde yapay zekâ kullanımının etkinliği gösterilmiştir.

Anahtar Kelimeler: Makine öğrenmesi, derin öğrenme, bulanık mantık, görüntü işleme, diş tespiti, diş rengi belirleme.

Haziran 2025, 80 sayfa

ABSTRACT

MASTER THESIS

DETECTION OF TOOTH COLORS OF DENTAL PHOTOGRAPHS RECORDED UNDER DIFFERENT CLINIC LIGHTS USING ARTIFICIAL INTELLIGENCE TECHNIQUES

Esra EFİTLİ

Supervisor: Assist. Prof. Dr. Abdullah Ammar KARCIOĞLU

Purpose: The process of shade determination in prosthodontics faces several limitations such as variability of light sources, subjectivity of visual assessment, high cost of instrumental measurement tools and lack of standardization. The aim of this thesis to provide consistent and reliable tooth color estimation despite changing light conditions using artificial intelligence methods and to provide an alternative solution to the existing systematic limitations.

Methodology: In this study, gradual progress has been made in terms of methodological process, conceptual validation and technical adequacy. In the first stage, a dataset created using Vita 3D Master color scale, which was taken five times under four different clinical light sources, was used. Fuzzy logic was used to distinguish three different light sources, and machine learning algorithms were used to classify 29 different tooth colors taken under four different light sources. In experimental studies, the effects of different color spaces and different image processing techniques were analyzed in detail. In the second stage, a dataset was created from dental images of volunteer patients under five different clinical light sources. Experimental studies were carried out using deep learning models to develop a model suitable for the clinical scenario. Teeth were automatically detected on the images with YOLOv5, then preprocessed and transferred to the proposed color classification model LABNet. Thus, the color determination process was standardized to be suitable for clinical applications.

Findings: Using the initial dataset, fuzzy logic achieved 98.85% accuracy in predicting clinical lights. The color moments method achieved 100% accuracy in classifying four different light sources, 85% accuracy in 29 Vita colors independent of light, and 97.93% accuracy with the histogram method. Using the second dataset, the mAP@50 score for YOLOv5 tooth detection was 99.5% and the proposed color detection model achieved 97.54% accuracy in training and 88.74% accuracy in validation.

Conclusion: The effectiveness of the use of artificial intelligence in prosthetic treatment processes has been demonstrated by providing high-accuracy tooth color determination independent of clinical light sources.

Keywords: Machine learning, deep learning, fuzzy logic, image processing, tooth detection, tooth color determination.

June 2025, 80 pages

İÇİNDEKİLER TABLOSU

KABUL VE ONAY TUTANAĞI.....	i
ETİK BİLDİRİM VE İNTİHAL BEYAN FORMU	ii
TEŞEKKÜR	iii
ÖZET	iv
ABSTRACT	v
İÇİNDEKİLER TABLOSU	vi
TABLolar DİZİNİ.....	viii
ŞEKİLLER DİZİNİ	ix
KISALTMALAR VE SİMGELER DİZİNİ	xi
GİRİŞ.....	1
KURAMSAL TEMELLER.....	4
Protetik Diş Tedavisi ve Estetik Gereklilikler	4
Klinik Aydınlatma Koşullarının Renk Algısına Etkisi ve Metamerizm Fenomeni.....	4
Dental Fotoğrafçılık ve Akıllı Telefonların Klinik Renk Tespitinde Kullanımı	5
Sağlıkta Yapay Zekâ.....	5
Makine Öğrenmesi ve Derin Öğrenme Uygulamaları.....	6
Bulanık Mantık	7
Renk Uzayları	8
Literatür Taraması	8
MATERYAL VE YÖNTEM	12
Vita 3D Master ile Veri Setinin Oluşturulması	12
Vita 3D Master	13
İntraoral (Ağız İçi) Görüntüler ile Veri Setinin Oluşturulması	14
Klinik veri toplama.....	14
Veri setinin hazırlanması.....	16
Performans Değerlendirme Metrikleri.....	17
Bulanık Mantık Yöntemleri Kullanılarak Farklı Klinik Işıkların Tahmini	18
ML tabanlı bulanık C-ortalamaları	19
ANFIS	19
Renk Anları ve Makine Öğrenmesi Kullanılarak Diş Rengi Tahmini	20
Renk anları	21
Histogram ve Makine Öğrenmesi Kullanılarak Diş Rengi Tahmini	22

İntraoral Görüntülerde YOLOv5 ile Diş Tespiti	23
YOLOv5 mimarisi.....	23
YOLOv5 tabanlı modelin kurulumu ve eğitim süreci.....	24
Diş Rengi Tahmini Problemine Özgü Derin Öğrenme Model: LABNet	25
Veri seti özellikleri ve modelleme öncesi hazırlık süreci.....	25
CNN tabanlı modeller ve önerilen LABNet modeli.....	27
Ön işlem	29
Otomatik Diş Rengi Tespiti.....	30
ARAŞTIRMA BULGULARI	33
Bulanık Mantık Yönteminin Bulguları.....	33
Renk Anları ve Makine Öğrenmesi Bulguları.....	38
Histogram ve Makine Öğrenmesi Bulguları.....	40
YOLOv5 ile Diş Tespiti Bulguları	43
Diş Rengi Tahmini Bulguları	51
TARTIŞMA.....	55
SONUÇ VE ÖNERİLER	59
KAYNAKÇA	62
ÖZGEÇMİŞ.....	68

TABLULAR DİZİNİ

Tablo 1. Dijital Medya ve Yazılım Kullanılarak Yapılan Diş Rengi Belirleme Çalışmalarının Kısa Bir Literatür Özeti	9
Tablo 2. YZ'ye Dayalı Diş Rengi Belirleme Çalışmalarının Literatür Özeti.....	10
Tablo 3. Kullanılan Yazılım ve Donanım Bileşenleri	12
Tablo 4. Otomatik Diş Rengi Tespiti İçin Kullanılan Veri Setlerinin Özeti	30
Tablo 5. FCM Kümelemesinin Sonuçları	35
Tablo 6. FCM & ML Sonuçları	36
Tablo 7. ANFIS Sonuçları	37
Tablo 8. Tüm Öznitelikleri İçeren Veri Setinden Elde Edilen Sonuçlar	38
Tablo 9. RGB Veri Setinden Elde Edilen Sonuçlar	39
Tablo 10. HSV Veri Setinden Elde Edilen Sonuçlar	39
Tablo 11. LAB Veri Setinden Elde Edilen Sonuçlar	39
Tablo 12. Histogram ve ML Sonuçları	40
Tablo 13. YOLOv5 Modelinin Doğrulama Veri Seti Üzerindeki Performans Sonuçları.....	45
Tablo 14. Diş Rengi Tespiti Modellerinin Eğitim ve Doğrulama Performansları.....	52

ŞEKİLLER DİZİNİ

Şekil 1. Renk uzayları.	8
Şekil 2. Vita 3D Master.	13
Şekil 3. Vita 3D Master diş örnekleri ve bunların kırılmış görüntüleri.	14
Şekil 4. Ağız içi fotoğraflarının kaydedilme protokolünün şematik gösterimi.	15
Şekil 5. Bir hastaya ait farklı klinik ışık koşullarında çekilen görüntülerin bir örneği.	16
Şekil 6. Etiketleme örneği.	16
Şekil 7. Bir hastaya ait 12 ön grup dişinin ROI'leri ve renk değerleri.	17
Şekil 8. Karmaşıklık matrisi.	17
Şekil 9. Bulanık mantık yöntemleri kullanılarak farklı klinik ışıkların tahmini çalışmasının genel çerçevesi.	19
Şekil 10. ANFIS mimarisi.	20
Şekil 11. Renk anları ve makine öğrenmesi kullanılarak diş rengi tahmini çalışmasının genel çerçevesi.	21
Şekil 12. Öznitelik önem grafiği.	22
Şekil 13. Histogram ve ML kullanılarak yapılan diş rengi tahmini çalışmasının genel çerçevesi.	23
Şekil 14. YOLOv5 Mimarisi. Nan vd. (2023)'ten uyarlanmıştır.	24
Şekil 15. Orijinal etiket dosyası ve YOLOv5 formatına uygun etiket dosyası örneği.	25
Şekil 16. Veri setinin sınıf dağılım grafiği.	26
Şekil 17. LABNet mimarisi.	28
Şekil 18. SCCS'nin şematik gösterimi.	28
Şekil 19. DCCA'nın şematik gösterimi.	29
Şekil 20. Otomatik diş rengi tespiti çalışmasının özeti.	31
Şekil 21. Çalışmanın genel çerçevesi.	32
Şekil 22. LAB, HSV ve RGB veri kümeleri için özellik önemi (sırasıyla gösterilmiştir).	33
Şekil 23. LAB, HSV ve RGB veri kümeleri için üyelik fonksiyonlarına bir örnek (sırasıyla gösterilmiştir).	34
Şekil 24. LAB, HSV ve RGB veri kümeleri için FCM kümelemesi (sırasıyla gösterilmiştir).	34
Şekil 25. FCM için karmaşıklık matrisleri.	35
Şekil 26. FCM & ML için karmaşıklık matrisleri.	36
Şekil 27. ANFIS için karmaşıklık matrisleri.	37

Şekil 28. ANFIS modelinin doğruluk kayıp grafiği.	38
Şekil 29. Işık kaynağından bağımsız sınıflandırmanın en iyi doğruluk oranlarının karmaşıklık matrisleri.	42
Şekil 30. Işık kaynağına bağımlı sınıflandırmanın en iyi doğruluk oranlarının karmaşıklık matrisleri (test: %30).....	43
Şekil 31. Konum ve boyut özelliklerine ait ilişki grafiği.	44
Şekil 32. Dışlerin konum etiketleri.....	46
Şekil 33. Eğitim aşamasında oluşan mozaik görünüm ve gerçek etiketler.	47
Şekil 34. Doğrulama verisinin ikinci veri grubunda model tarafından yapılan tahminler.	47
Şekil 35. Eğitim sürecine ait kayıp ve doğruluk metriklerinin grafiği.	48
Şekil 36. Kesinlik güven eğrisi.	49
Şekil 37. Duyarlılık güven eğrisi.....	49
Şekil 38. F1 skor güven eğrisi.	49
Şekil 39. YOLOv5 için karmaşıklık matrisi.....	50
Şekil 40. Bağımsız bir görüntü üzerinde YOLOv5 modelinin nesne tespiti.....	51
Şekil 41. LABNet modelinin doğruluk kayıp grafiği.....	52
Şekil 42. LABNet modeline ait sınıflara göre performans grafiği.....	53
Şekil 43. LABNet modelinin karmaşıklık matrisi.....	54

KISALTMALAR VE SİMGELER DİZİNİ

ANFIS	: Adaptive Neuro-Fuzzy Inference System
CIELAB	: Commission Internationale de l'Éclairage - L^* , a^* , b^* renk uzayı
DCCA	: Dinamik Kanal Dikkati
DL	: Derin Öğrenme
DT	: Decision Tree (Karar Ağacı)
FCM	: Bulanık C-Ortalamalar
FN	: False Negative – Yanlış negatif sınıflandırılan örnek
FL	: Fuzzy Logic (Bulanık Mantık)
FP	: False Positive – Yanlış pozitif sınıflandırılan örnek
HLS	: Hue, Lightness, Saturation – Ton, Parlaklık, Doygunluk
HSV	: Hue, Saturation, Value (Ton, Doygunluk, Parlaklık)
KNN	: K-Nearest Neighbors (K-En Yakın Komşu)
LAB	: L^* (aydınlık), a^* (yeşil-kırmızı), b^* (mavi-sarı) bileşenlerine dayalı renk uzayı
LR	: Lojistik Regresyon
ML	: Makine Öğrenmesi
NN	: Neural Network (Yapay Sinir Ağı)
RF	: Random Forest (Rastgele Orman)
RGB	: Red, Green, Blue (Kırmızı, Yeşil, Mavi) renk uzayı
ROI	: Region of Interest (İlgili bölge)
SCCS	: Statik Renk Kanal Ölçekleme
SVC	: Support Vector Classifier (Doğrusal Olmayan Destek Vektör Sınıflandırıcısı)
SVM	: Support Vector Machine (Destek Vektör Makineleri)
SVR	: Support Vector Regression (Destek Vektör Regresyonu)
TN	: True Positive – Doğru pozitif sınıflandırılan örnek
TP	: True Negative – Doğru negatif sınıflandırılan örnek
XGBOOST	: Extreme Gradient Boosting (Aşırı Gradyan Artırmalı Sınıflandırma)
XYZ	: CIE 1931 renk uzayı bileşenleri
VIA	: VGG Image Annotator
YCBCR	: Luminance (Y) ve chrominance (Cb ve Cr) bileşenlerinden oluşan renk uzayı
YZ	: Yapay Zekâ

GİRİŞ

Protetik diş tedavisi, kaybolan veya hasar görmüş dişlerin yerine yapay dişlerin yerleştirildiği diş hekimliği alanıdır. Bu tedavi, dişlerin fonksiyonunu ve estetiğini geri kazandırmak amacıyla protezler, köprüler ve diş implantları gibi uygulamaları içermektedir (Zitzmann vd., 2007). Protetik diş tedavisinde renk tespiti, kaybolan ya da hasar görmüş dişlerin yerine yapılan yapay dişlerin estetik uyumunu sağlamak için önemli bir adımdır. Bu işlem, genellikle dişin doğal rengine en yakın protez dişin seçilmesini hedeflemektedir. Protez oluşturma süreci oldukça karmaşık ve zordur. Bu sürecin başarısı diş hekimliğiyle ilgili renk bilimi ve optik özellikler konusunda iyi bir bilgiye bağlıdır (Della Bona, 2020). Dişin rengi farklı ton aralığına sahip beyaz renk olduğundan dış koşullardan olumsuz etkilenmektedir ve bir süre sonra aynı renk olarak algılanmaktadır (Karcioglu vd., 2025). Restorasyonun son rengi hastanın beklentilerini karşılamazsa, yeniden çalışma gerektirir ve bu da ek zaman ve maliyet gerektirmektedir (Chen vd., 2023). Rengi anlamak, diş rengi uyumsuzluğuyla ilgili estetik sorunları çözmek için önemlidir. Rengin karmaşıklığı klinik uygulamasını sınırlamaktadır (Pecho vd., 2016). Işık kaynağı, renk seçim işlemini doğrudan etkilemektedir ve renklerin farklı ışık koşulları altında algılanmasında belirsizlikler ve değişimler oluşmaktadır (Kim vd., 2007; Joiner, 2004).

Diş hekimliğinde renk belirleme yöntemleri görsel ve enstrümental yöntemler olmak üzere 2 ana başlık şeklinde incelenmektedir (Abraham vd., 2023). Görsel teknik olan renk seçim kılavuzları ile görsel olarak renkleri eşleştirme, günümüzde halen sıklıkla tercih edilen bir renk seçim yöntemidir. Bu yöntemde protetik restorasyonların yapılacağı porselen tozlarına ait renk örneklerinin bulunduğu skalalar ile hastanın mevcut dişleri arasında renk eşleştirmesi yapılmaktadır. Hastanın mevcut diş veya restorasyonuna en yakın renk bulununcaya kadar deneme yanılma yöntemi ile skaladaki örnek renkler sırası ile denenmektedir. Oldukça subjektif olan bu yöntem hastanın yaşı, cinsiyeti, klinisyenin tecrübesi, göz yorgunluğu ve kliniğin ışığı gibi faktörlerden etkilenebildiği için yerini farklı arayışlara bırakmıştır (Hardan vd., 2022). Enstrümental yöntemler farklı renk parametreleri ile sayısal olarak ifade edilen renk değerlerini; rengin öznel analizinden nesnel analizine geçişini sağlamıştır (Moussa, 2021). Spektrofotometreler, kolorimetreler, tarayıcılar, dijital kameralar ve akıllı telefonlar enstrümental renk tespit yöntemleridir (Jouhar vd., 2022; Öngül vd., 2012). Bu dijital cihazlardan spektrofotometreler ve kolorimetreler günümüzde dental kliniklerde kullanım alanı

bulmaktadır. Spektrofotometreler spektral yansıma miktarını ölçen cihazlar olup, dalga boyuna göre yoğunluğunu ölçen fotometrelerdir (Mohammed vd., 2022). Spektrofotometrelerde renk seçimi tekrar edilebilir ve güvenilir olduğu için altın standart olarak kabul edilir (Moussa, 2021). Kolorimetreler rengi; ton, chroma ve değer olarak kaydeder. Yalnızca sabit aydınlatma koşullarında rengi ölçebilirler (Mohammed vd., 2022). Spektrofotometre ve kolorimetrelerin görüş alanlarının küçük olması, konveks olmayan bir yüzeyde daha doğru bir ölçüm yapıyor olmaları, cihazların maliyetlerinin yüksek oluşu ve teknik hassasiyet gerektirmeleri gibi sebeplerden dolayı günümüzde daha farklı teknolojilere ihtiyaç duyulmaktadır (Mohammadi vd., 2021). Geçmiş çalışmalar dijital görüntülerin değerlendirme açısından uygun olduğunu ve geleneksel görsel yöntemlerden daha başarılı olduğunu göstermiştir (Bernauer vd., 2021). Bunun yanı sıra renk seçiminde dijital kameraların ve akıllı telefonların kullanımı sabit bir ışık kaynağının olmaması nedeniyle engellenmektedir (Sampaio vd., 2019). Renk eşleştirme yapılırken birtakım faktörler göz önünde bulundurulmalıdır. Bu faktörler arasında ışık kaynağı, gözlemlenen nesne ve gözlemci yer alır (Joiner, 2004).

Çalışmanın temel amacı dental renk seçim işlemini yapay zekâ (YZ) teknolojileri ile ortam aydınlatmasından bağımsız, objektif ve kolay erişilebilir bir standardizasyona ulaştırmaktır. Renk eşleştirme subjektif bir prosedür olarak kabul edildiğinden, doğru renk seçimi genellikle dişlerin doğal görünümünü yakalamanın en zahmetli aşamasıdır. Ayrıca hastalar arasında da estetik kavramının öneminin artması ve restorasyonların estetik görünümünün farkındalığının artması renk seçimi işleminin kusursuz olmasını gerektirmektedir. Restorasyonların renginin laboratuvar aşamasında yer alan dental teknisyenlere de doğru olarak iletilebilmesi yapılacak restorasyonların estetik başarısı için kilit noktalardan birisidir. Mevcut renk seçim yöntemleri için en uygun zaman gün ortasındaki doğal güneş ışığı; en ideal olarak kabul edilmektedir. Çünkü bu zaman dilimi kırmızımsı ve sarı dalga boyları açısından daha zengin olan sabah ve akşam pozlamalarına kıyasla ışığın tüm dalga boylarının neredeyse eşit bir karışımını içermektedir. Güneş ışığına uygun erişimi olmayan kliniklerde ise güneş ışığını simüle etmek ve uygun aydınlatma sağlayabilmek için yapay ışık kaynaklarına ihtiyaç duyulmaktadır. Günümüzde kabul görmüş renk seçim tekniklerinin hepsinin doğası gereği tüm bu farklı aydınlatma koşullarını ekarte etmek için yeterli görülmemektedir. Renk seçim işleminin YZ entegrasyonu ve akabinde farklı işletim sistemleri ile uyumlu olan akıllı uygulama ile geleneksel renk seçim yöntemlerinin dezavantajları göz önünde bulundurularak tekrarlanabilir, güvenilirliği kabul görmüş, etkin, hızlı ve maliyeti düşük bir yöntem tasarlanmış olacaktır. Bu amaç doğrultusunda çalışmanın hedefleri aşağıda listelenmiştir:

1. Diş renk seçimini yapabilen YZ modellerinin geliştirmek ve güncel teknolojik standartlar seviyesine getirmek.
2. Renk seçim işlemi esnasında olabilecek insan kaynaklı hataların minimuma indirmek,
3. Farklı bir ekipman gerektirmeden sadece akıllı telefonlar ile kolay ve hatasız bir şekilde renk seçiminin gerçekleştirmek,
4. Dişin yüzey topografisinden kaynaklanabilecek hataları ekarte etmek,
5. Farklı klinik aydınlatmalarının renk seçimi üzerindeki etkisinin ortadan kaldırılarak metamerizmi ortadan kaldırmak,
6. Laboratuvara daha doğru bir renk iletimi ile restorasyonun hatasız yapılması ve maliyeti düşürmek.



KURAMSAL TEMELLER

Protetik Diş Tedavisi ve Estetik Gereklilikler

İdeal bir restorasyonun fonksiyon, fonetik ve estetik yeterlilikleri karşılaması gerekir. Estetik faktörlerin başında da protetik restorasyonun rengi gelmektedir. Protetik bir restorasyonun başarısında diş hekimi ve diş teknisyeni arasındaki koordinasyonun sağlıklı olması önem arz etmektedir. Karşılıklı kooperasyon ve doğru iletişim yapılacak restorasyonun minimal hata ile tamamlanmasını sağlayacaktır. Günümüz iletişiminin temel taşı olan akıllı telefonlar ve fotoğraf, video gibi görsel verileri hızlı bir şekilde iletme olanak sağlayan online platformlar koordinasyonun daha kaliteli olmasına imkân tanımaktadır. Bu sayede diş hekimi kolay erişebileceği bu imkanları kliniğinde etkili bir şekilde kullanarak restorasyonun renk, şekil, okluzyon (çeneler arası kapanış ilişkisi) gibi parametrelerini farklı merkezdeki diş teknisyeni ile değerlendirilebilmektedir. Estetik parametrelerin başında gelen renkleri doğru bir şekilde belirlemek ve laboratuvara aktarmak oldukça hassastır (Abraham vd., 2023). Klinik olarak renk seçim işlemi ışık kaynağı, nesne ve gözlemci gibi faktörlerden etkilenen öznel bir prosedürdür (Hardan vd., 2022).

Klinik Aydınlatma Koşullarının Renk Algısına Etkisi ve Metamerizm Fenomeni

Dental kliniklerde kullanılan üç ışık kaynağı mevcuttur: Değişken olan doğal gün ışığı, doğal güneş ışığına kıyasla görünür spektrumun kırmızı bölgesine doğru eğimli bir diş ünitesinin ameliyat ışığı ve son olarak belirtilen renk sıcaklığına bağlı olarak çeşitli renksel geriverim özelliklerine sahip olan floresan tavan lambalarıdır (Sampaio vd., 2018). Diş rengi seçimi ve eşleştirmesi için en uygun koşullar, renk sıcaklığı 5.500 K ile 6.500 K arasında olan ve Renk Geriverim İndeksi (CRI) 90'dan büyük olan bir ışık tarafından sağlanır. Protetik tedavilerde dişlerin renk seçimleri değerlendirilirken yalnızca bir ışık kaynağının varlığında seçim yapılması gerektiği bildirilmektedir, çünkü farklı kaynaklardan üst üste gelen aydınlatma metamerizme yol açabilir (Sampaio vd., 2018). Renk algısı nesne, ışık ve gözlemci arasındaki etkileşimi sonucu ortaya çıkar. Bu üç faktörün çeşitli nedenlerle farklı yorumlanması metamerizmi doğurur (Wee, 2006). Metamerizm, bir cismin renginin farklı ışık kaynakları altında farklı algılanmasıdır. Belirli aydınlatma koşulları arasında benzer görünen ancak spektral yansıması farklı olan iki renge metamer, bu fenomene metamerizm denir. Metamerizm, laboratuvar ve dental klinik arasındaki aydınlatma farklılıklarından da kaynaklanabilecek bir fenomendir (Wee, 2006).

Dental Fotoğrafçılık ve Akıllı Telefonların Klinik Renk Tespitinde Kullanımı

Diş renginin doğru olarak kaydedilmesi ideal estetik için tek parametre değildir. Diş teknisyeninin farklı bir merkezde olması halinde, daha doğru ve optimum estetik özelliklere sahip bir restorasyon için hasta fotoğraflarının da görülmesi gerekebilmektedir. Restorasyonun çenedeki konumu, pozisyonu, komşu ve karşı dişlerin görünüşleri, dişlerin rengi; bütün bu gerçek faktörlerin diş teknisyeni tarafından da görsel olarak bilinmesi gerekir. Bu durumun gerçekleşebilmesi için de hasta fotoğraflarından da sıklıkla faydalanılmaktadır.

Dijital dental fotoğrafçılık dental kliniklerde rutin olarak uygulanan bir işlem olmakla birlikte, lisansüstü eğitimlerde ders olarak da işlenmektedir. Dental fotoğrafçılık ile çekilen yüksek kalitedeki görüntüler hastalara sunulan tedavi seçenekleri ile hasta iletişimi arttırılmakta, motivasyon geliştirilmekte, hekimler arasında iş birliği oluşturarak multidisipliner bir tedavi yaklaşımı sağlanmakta, laboratuvar ile iletişim daha anlaşılır bir şekilde gerçekleştirilmekte ve vaka dökümantasyonu oluşturulmaktadır. Tüm bunların yanında hekimin kendini yasal olarak korumasına da katkıda bulunmaktadır (Kalpana vd., 2018). Tüm bu avantajlarına rağmen özellikle klinik içi stüdyo gerektirmesi, paraflaş, flaş setleri, fon perdesi gibi çok sayıda ve pahalı ekipman ihtiyacı, hastanın dental ünitte stüdyoya transferi, uzun zaman alan çekim işlemleri, profesyonel kamera ile çekilen fotoğrafların iletilebilmesi için bilgisayar ortamına aktarılma zorunluluğu gibi sorunları bulunmaktadır.

Hayatımızın ve günlük yaşantımızın ayrılmaz bir parçası haline gelen akıllı telefonlar diş hekimliği klinik uygulamalarında da kendilerine yer bulmuşlardır. Akıllı telefonların ek bilgi işlem kapasitelerine sahip olmaları, işlevselliklerinin gün geçtikçe artması, artan yazılım uygulamaları, cihaza heran rahatlıkla ulaşıyor olması ve yüksek çözünürlüklü fotoğraf çekebilme yetenekleri ile diş hekimliğinde kullanım alanı hızla artmaktadır (Abraham vd., 2023). Diş hekimliğinde özellikle sosyal medya platformlarında vaka paylaşımı gibi durumlarda dental fotoğraflardan faydalandığı düşünülse de dental uygulamaları kolaylaştıran birçok uygulama mevcuttur. Kullanılan akıllı telefonun kamerasının kalitesi ve görüntüyü işleme tekniği renk ölçümünün kesinliğini ve doğruluğunu etkileyen en önemli faktördür (Jouhar vd., 2022). Akıllı telefonların kullanımı ile birlikte daha düşük maliyetli ve daha hızlı fotoğraf çekimi sayesinde klinik işleyiş daha da kolaylaşmıştır (Mohammadi vd., 2021). Ayrıca diş hekimleri ile diş laboratuvarları arasındaki iletişimi de etkin ve hızlı bir hale getirmiştir.

Sağlıkta Yapay Zekâ

YZ insanlar gibi düşünerek görevleri yerine getirebilen makinelerdir (Schwendicke vd., 2020). İnsan müdahalesini minimuma indirerek karmaşık problemleri çözme potansiyeline

sahiptir. Sağlık hizmetlerinde iki tür kullanılmaktadır: fiziksel olan robotlar ve sanal olan klinik karar destek algoritmaları (Shan vd., 2021). YZ, sağlık hizmetlerinde hizmet süreçlerinin kalitesini artırmakta, yönetsel ve klinik maliyetleri düşürmektedir. Teşhis, tanı ve tedavi gibi klinik süreçleri hızlandırırken, insan etkileşimini azaltarak insan kaynaklı hataların önüne geçmektedir (Ceylan ve Emir, 2023). Diş hekimlerinin iş koşullarını ve performanslarını iyileştirmek adına YZ'den faydalanılmaktadır (Grischke vd., 2020). Diş hekimliği uygulamalarında YZ daha çok en iyi tedavileri ortaya çıkaracak olan doğru teşhis sürecini verimli hale getirebilmek için kullanılmakla birlikte (Khanagar et vd., 2021) YZ teknolojilerinin diş hekimliğine entegrasyonu farklı disiplinlerdeki klinik uygulamalarda kendini göstermektedir. Diş hekimliği, YZ gelişmelerinden doğrudan etkilenmediği düşünülse de otomatik hastalık tespiti, tanı destek sistemleri, radyografik görüntüler üzerinden diş, çürük ve restorasyon tespiti (Tuzoff vd., 2019), diş hareketlerinin tespiti (Sağlam vd., 2021) ve implant uygulamalarında kemiklerin korunması, dental implantların sınıflandırılması (Lee vd., 2020), oral yapıların otomatik analizi için görüntü segmentasyonu ve diş hekimliği ile ilgili görüntü tabanlı çalışmalarda ilerleme kaydedilmiştir (Hung vd., 2019; Lee vd., 2018; Scrobotă vd., 2017; Tian vd., 2019).

Makine Öğrenmesi ve Derin Öğrenme Uygulamaları

YZ'nin hızla gelişmesiyle birlikte makine öğrenmesi (ML), karmaşık veri ilişkileriyle başa çıkmada önemli avantajlar sağlamaktadır (Li vd., 2024). ML, bir veri kümesine dayalı olarak sonuçları tahmin etmek için algoritmalara dayanır ve YZ'nin bir alt alanıdır (Khanagar vd., 2021). Son zamanlarda ML birden fazla değişkeni etkili bir şekilde dikkate alarak renk eşleşmesini analiz etmek için bir araç olarak ortaya çıkmıştır. Klinik durumların değişkenliği, çeşitli arka plan renkleri ve piyasada bulunan renk kılavuzları göz önüne alındığında, klinik karar alma belirli bir ölçüde teknik hassasiyete sahiptir. Geleneksel deneyime dayalı karar almaya kıyasla, ML modellerinin kullanımı doğru renk eşleştirmesini kolaylaştırarak klinik karar almayı geliştirebilir ve klinik geçerlilik gösterebilir (Yang vd., 2024). ML modelinin deneyimli diş hekimlerinin yerini almaktan ziyade zaman kazandıran bir karar destek aracı olarak tasarlandığını kabul etmek çok önemlidir ve yüksek doğruluğu önemli olmakla birlikte yorumlanabilirliği de hayati öneme sahiptir (Kamal vd., 2020; Yang vd., 2024). ML teknikleri, diş hekimliğinde problem çözme ve renk bilimlerinde gelecekteki gelişmelere katkı sağlarken, algoritmalar ve dijital işleme yöntemleri öznel hataları ortadan kaldırarak daha kesin sonuçlar sunabileceği düşünülmektedir (Shishira vd., 2024).

Bu gelişmelere paralel olarak, ML'nin bir alt dalı olan derin öğrenme (DL) ise daha karmaşık veri yapılarını çözümlenebilirlik kapasitesiyle dikkat çekmektedir. Geleneksel ML'den


farklı olarak, özellik mühendisliğine olan ihtiyacı en aza indirir ve verinin kendisinden temsil öğrenme yeteneği sayesinde özellikle yüksek boyutlu ve yapısal verilerle başarılı sonuçlar elde eder (Goodfellow vd., 2016). Çok katmanlı yapay sinir ağlarına dayanan bu yöntemler, özellikle büyük veri setlerinden yüksek düzeyde soyutlama yapabilme becerisi sayesinde tıbbi görüntüleme, teşhis sistemleri ve klinik karar destek sistemlerinde etkili sonuçlar üretmektedir. Diş hekimliğinde de DL tabanlı sistemler, geleneksel klinik uygulamaların dijital dönüşümünü hızlandırmaktadır. Artan hasta yoğunluğu ve zaman baskısı altında, teşhis doğruluğunu ve klinik verimliliği artırmak amacıyla geliştirilen DL'ye dayalı klinik karar destek sistemleri, hastalıkların tanısında, tedavi planları ve hastalığın değerlendirilmesinde önemli katkılar sağlamaktadır. Bu sistemler, insan uzmanlığını destekleyici yapılarıyla hem hasta memnuniyetini hem de klinik sonuçların güvenilirliğini artırma potansiyeline sahiptir (Singh vd., 2025).

Bulanık Mantık

Bulanık mantık (FL), kliniklerde kullanılan yapay zeka uygulamalarından biridir. FL, hem esnek hem de kolayca uygulanabilir bir ML yöntemidir (Babu vd., 2021). Karmaşık karar ağaçlarının ve kural tabanlı programlama tekniklerinin entegrasyonunu sağlayarak YZ uygulamaları için önemli bir temel işlevi yerine getirir (Cara vd., 2013). Bu, FL'nin daha gelişmiş ve karmaşık karar alma süreçlerini etkili bir şekilde yönetebileceğini gösterir. FL, belirsiz ve karmaşık problemlerde insan düşüncesine benzer bir yaklaşım sunar. Özellikle kesin sınırlarla tanımlanamayan durumlarda kullanılabilir (Carrillo-Perez vd., 2022). FL'nin en önemli avantajı, verilerdeki belirsizliklerle başa çıkabilme yeteneğidir (Roy vd., 2021; Tandon vd., 2020; Thukral ve Bal, 2019; Zadeh, 1965). Bulanık sistemler, YZ'de olduğu gibi bilgileri insanmış gibi işlemeyi mümkün kılar. Bir ögenin bir kümeye üyelik değeri 0 ile 1 arasında olabilir (Thukral ve Bal, 2019). Bu şekilde, belirsiz verilere dayanarak karmaşık kararlar alınabilir (Carrillo-Perez vd., 2022). FL tamamen bulanık "eğer-o zaman" kurallarına dayanmaktadır. Ayrıca, YZ'nin diğer uygulama alanları gibi kesin sonuçlar üretmeye odaklanmaz. Örneğin, bir renk için "siyah" ve "beyaz" gibi kesin ifadeler yapmak yerine, "açık beyaz" veya "orta beyaz" gibi daha incelikli kararlar alınmasını sağlar. Tıbbi alandaki ortaya çıkan ihtiyaçları karşılamak için, FL'nin tıp sektörünün her alanında katkısı hızla artmaktadır (Thukral ve Bal, 2019). Benzer şekilde, diş hekimliğinde FL, protez planlaması, teşhis ve tedavideki belirsizliklerin yönetilmesinde önemli avantajlar sunmaktadır. Diş hekimlerine zaman kazandırır ve onlara akıcı bir iş akışı sunar. Hassasiyeti artırır ve daha doğru kararlar alınmasını sağlar. Bu şekilde, klinik süreçlerde yardımcı görevi görebilir (Roy vd., 2021).

Renk Uzayları

RGB, LAB ve HSV renk uzayları, görüntü işleme ve renk analizinde yaygın olarak kullanılan temel renk uzaylarıdır. Görüntü işlemede okunan görüntü RGB renk uzayındadır ve bu uzay ile yapılan çalışmalar işleme gereksinimini azaltır (Minaee vd., 2021). RGB uzayı kırmızı, yeşil ve mavi renk bileşenlerine dayanır ve özellikle dijital görüntüleme sistemlerinde tercih edilir. Ancak RGB renk uzayı, cihaz tabanlı olup renk algısını tam olarak modelleyemediği için farklı uygulamalar için uygun olmayabilir. HSV renk uzayı, renkleri ton, doygunluk ve değer bileşenlerine ayırarak renk analizi için daha esnek bir yapı sunar. Görüntü işlemede yaygın olarak kullanılan renk uzaylarından biridir ve renk tonlarının belirlenmesinde avantaj sağlar. Özellikle insan algısına yakın bir renk ayrımı sağlar (Justiawan vd., 2019). Bu nedenle, nesne algılama ve renk tabanlı segmentasyon gibi işlemlerde sıklıkla tercih edildiği gözlemlenmiştir. LAB renk uzayı ise, Uluslararası Aydınlatma Komisyonu (CIE) tarafından tanımlanmış, insan görsel algısına en yakın temsili sunan sistemdir. Diş kliniklerinde kullanılan renk ölçüm cihazlarında yaygın olarak tercih edilen bir renk uzayıdır ve renk farklılıklarını daha doğru bir şekilde temsil eder (Wang vd., 2014). Bu renk uzayı, insan gözünün renk algısına yakın bir yapıya sahiptir. Renk uzayları ile yapılan çalışmalarda elde edilen sonuçlar arasında değişiklik olduğu görülmektedir. Hangi uzayın en iyi sonucu vereceği, çalışmanın yöntemine ve uygulama bağlamına bağlı olduğu sonucuna varılmıştır. Bu nedenle, bu çalışmaya üç renk uzayı da dâhil edilmiştir. Renk uzaylarının temsili Şekil 1’de gösterilmiştir.



Şekil 1. Renk uzayları.

Literatür Taraması

Bernauer vd. (2021) protetik diş tedavisinde YZ kullanımının bireysel protokoller gerektiren kompleks teşhis ve tedavi planlamaları içermesi sebebiyle hala yetersiz olduğu sonucuna varmıştır. Jarad vd. (2005) yaptıkları çalışmada geleneksel yöntem ve bilgisayarlı renk eşleştirmesinin kıyaslarken Tam ve Lee (2012) dijital kameralar kullanarak renk eşleşmesi işlemini değerlendirmiştir. Bu çalışmalar diş kliniğinde dijital renk eşleştirmenin geleneksel yöntemden iyi olduğunu göstermiştir.

Tam ve Lee (2017) ile Wanna vd. (2022) akıllı telefon ile çekilen görüntülerin kullanıldığı çalışmalarında telefonun diş kliniğinde renk ölçüm aracı olarak kullanılabilceğini göstermişlerdir. Bununla birlikte YZ kullanan çalışmalar incelendiğinde görüntü kaynağı olarak renk skalalarının temel alındığı görülmüştür (Liu vd., 2013; Sigit ve Arief, 2017; Justiawan vd., 2019; Fayed vd., 2022). Farklı renk sayıları ile sunulan skalaların renk değerlerinin sınırlı olması veri sayısını kısıtlamaktadır. Bu yüzden bazı çalışmalarda veri çoğaltma için birden çok kamera kullanıldığı ya da aynı renk sekmesinin birden fazla tekrarlar çekildiği görülmektedir (Kim vd., 2018; Fayed vd., 2022).

Wanna vd. (2022) çalışmasında renk skalasından referans olarak seçilen renk değerin, değeri bulunması istenilen hedef diş ile birlikte çekilmesi gerekmektedir. Çalışmaların ortak eksikliği, renk değişimini önlemeye yönelik olarak, çeşitli klinik ışıklarıyla model eğitiminin yapılmamış olmasıdır. Aksine genelde sabit ışık şartları kullanılmaya çalışıldığı gözlemlenmiştir. Özellikle, klinik ışıklar diş renginin nasıl yorumlandığını etkiler (Hardan vd., 2022). Bir çalışma, ışık koşullarının etkisinin teknoloji ile azaltılmasının mümkün olduğunu belirtmiştir (Hu vd., 2016). Bu noktada, sabit olmayan ışık kaynaklarının renk eşleştirme üzerindeki etkilerini ortadan kaldıracak alternatif yaklaşımlar değerlendirilmelidir. Ayrıca YZ tabanlı diş rengi eşleştirmesi üzerine yapılan çalışmalar nispeten azdır ve genellikle Vita renk skalası kullanımına dayanmaktadır. Renk eşleştirmesi için hazır yazılımlar ve uzman görüşleri kullanan ve renk eşleşmesi süreçlerinin incelendiği çalışmaların özeti Tablo 1’de gösterilmiştir. Renk eşleştirmesi (sınıflandırma) konusunda teknoloji odaklı ve YZ tabanlı çalışmaların özeti Tablo 2’de gösterilmiştir.

Tablo 1. Dijital Medya ve Yazılım Kullanılarak Yapılan Diş Rengi Belirleme Çalışmalarının Kısa Bir Literatür Özeti

Referans	Renk Uzayı	Veri	Sonuçlar
(Wang vd., 2014)	CIELAB	Vita 3D Master	$\Delta E < 2,69$ kabul edilebilir; $\Delta E < 1,6$ mükemmel renk eşleşmesi olarak değerlendirilir.
(Oh vd., 2010)	-	Vita kılavuzu, Hastaların diş görüntüleri	Vita kılavuzu: %88 doğru eşleşme; hasta diş görüntüleri: %75 doğru eşleşme elde edilmiştir.
Tam ve Lee (2012)	RGB, HSV, XYZ, $L^*a^*b^*$	Vita 3D Master	Dijital kameraların renk eşleştirmede kullanımı desteklenmiştir. Sab: %87 doğruluk göstermiştir.
(Jarad vd., 2005)	CIELAB	Vita Lumin	Dijital kamera, klinikte renk ölçüm aracı olarak kullanılmıştır. Bilgisayarlı eşleştirme geleneksel yöntemden daha iyi bulunmuştur.
(Schropp, 2009)	CIE, $L^*c^*h^*$	Vita 3D Master	Bilgisayar yazılımı %67 doğru eşleşme sağlamıştır; klinik %32, görüntü ise %28 doğru eşleşme sağlamıştır.

Tablo 1. (Devamı)

(Cal vd., 2004)	RGB, L değeri	3 renk kılavuzu	Renk sekmelerinin doğruluğunun yeniden değerlendirilmesi gerektiği sonucuna varılmıştır. Gün ışığında çekilen fotoğraflar, stüdyo ortamında çekilenlerle önemli farklılıklar göstermiştir.
(Beneducci vd., 2022)	RGB, CIELAB	Vita Classic, Hastaların diş görüntüleri	Ağırlıklı kappa sonuçları, uzman ile sistem sonuçlarının benzer olduğunu göstermiştir.

Tablo 2. YZ'ye Dayalı Diş Rengi Belirleme Çalışmalarının Literatür Özeti

Referans	Renk Uzayı	Veri	Model	Veri Boyutu	Doğruluk(%)
(Fayed vd., 2022)	HSV, LAB, RGB	Vitapan 3D Master	KNN	1300	70
(Lin vd., 2019)	YCBCR, CIELAB	Vita 3D Master	FL	26	92,31
(Liu vd., 2013)	HIS	Vita 3D Master	KNN	29*2 (tekrar), 3(sınıf)*20	90
(Justiawan vd., 2019)	RGB, HSV, LAB	Vitapan Classical, Hastaların diş görüntüleri	KNN, NN, DT	640	KNN:97,5, NN:76,8, DT:85,63
(Tam ve Lee, 2017)	RGB, HSV, XYZ, LAB	Vita 3D Master	SVM	300	Group1:86-98, Group2: 97 – 100
(Wanna vd. 2022)	-	Vita Classic	RF, SVM, XGBOOST	15.360	RF: 97.1
(Sigit ve Arief, 2017)	RGB, HSV, LAB	Vita Classic	KNN	Eğitim: 576, Test: 64	RGB:97,8, HSV:65, LAB:94,8
(Kim vd., 2018)	CIELAB	Vita 3D Master, hastaların diş görüntüleri	SVM, LR, RF, KNN	Eğitim:(26*5 kamera), Test: (26*3)	SVM:96,9, LR:77,2, RF:89,3, KNN:96,1
(Ueki vd., 2020)	HSV, RGB	Vita, hastaların diş görüntüleri	NN	816	68
(Chen vd., 2023)	HLS, LAB	Vita Classic	XGBoost, YOLOv8	450	XGBoost: 77,5 YOLOv8: 0,995 (mAP50)

Tablo 2 de yer alan diş rengi sınıflandırması alanında yapılmış bazı önceki çalışmaların çoğunda RGB, LAB ve HSV gibi yaygın renk uzayları tercih edildiği; sınıflandırma algoritmaları olarak çok k-en yakın komşu (KNN), destek vektör makineleri (SVM), rastgele ormanlar (RF) ve XGBoost gibi denetimli öğrenme yöntemleri kullanıldığı görülmektedir. Kullanılan veri setlerinin boyutları çalışmalara göre önemli ölçüde değişiklik göstermekte olup hem yapay (skala temelli) hem de gerçek klinik görüntülere dayalı veri kaynakları kullanılmıştır. Klasik makine öğrenimi yöntemlerine ek olarak son dönem çalışmalarda DL

temelli yaklaşımların da kullanılmaya başlandığı gözlemlenmektedir. Yer alan önceki çalışmaların çoğu ya yalnızca kontrollü laboratuvar koşullarında elde edilen görüntüler üzerinden sınıflandırma yapmış ya da sınırlı ışık koşullarında tekil yöntemlerle modelleme gerçekleştirmiştir. Buna karşın, bu çalışma klinik gerçekliğe daha yakın bir yaklaşımla hem kontrollü hem de doğal klinik koşullarda elde edilen iki ayrı veri seti üzerinden kapsamlı bir yöntemsel yapı sunmaktadır. Ayrıca, ışık farklılıklarının etkisini azaltmak amacıyla bulanık mantıkla ışık kaynağı ayırımı yapılmış; ardından hem geleneksel ML hem de ileri düzey DL teknikleri ardışık olarak uygulanmıştır. Dış bölgesinin tespiti için modern nesne tanıma algoritması olan YOLOv5'in entegrasyonu ve bu çalışmaya özgü geliştirilen LABNet modelinin kullanılması, sürecin tam otomatik, hızlı ve klinik olarak uygulanabilir bir hale gelmesini sağlamıştır. Böylece çalışma, sadece sınıflandırma doğruluğunu değil, aynı zamanda süreç otomasyonunu ve klinik uyumu da önceleyerek literatüre çok yönlü bir katkı sunmaktadır.

MATERYAL VE YÖNTEM

Bu çalışmada, klinik ortamlarda diş rengi belirleme sürecinin otomatikleştirilmesine yönelik bütüncül bir yöntemsel yaklaşım benimsenmiştir. Yöntemsel süreç; kavramsal doğrulama, teknik yeterlilik ve klinik geçerlilik açısından kademeli olarak yapılandırılmıştır. İlk aşamada, farklı klinik ışık koşulları altında elde edilen verilerle oluşturulan kontrollü bir referans veri seti üzerinden, ışık kaynaklarının ayrımı için bulanık mantık; renk sınıflandırması için ise çeşitli ML algoritmaları kullanılmıştır. Bu kapsamda, Vita 3D Master kullanılarak veri seti oluşturulmuş, farklı renk uzayları ve görüntü işleme tekniklerinin sınıflandırma üzerindeki etkileri deneysel olarak analiz edilmiştir. İkinci aşamada ise, gerçek klinik senaryolara uygun bir yapı hedeflenerek, beş farklı klinik ışık koşulunda gönüllü hastalardan toplanan diş görüntüleri ile bir veri seti hazırlanmış ve DL tabanlı bir yaklaşım benimsenmiştir. Bu süreçte, dişlerin görüntüden otomatik olarak tespiti YOLOv5 algoritmasıyla gerçekleştirilmiş, ardından bu çalışmada özgün olarak önerilen DL modeli LABNet'e ön işlem adımlarından geçirilerek aktarılmıştır. Böylece, diş rengi belirleme süreci klinik uygulamalarla uyumlu şekilde tam otomatik bir yapıya kavuşturulmuştur. Çalışma sürecinde kullanılan yazılım ve donanım bileşenleri Tablo 3'te özetlenmiştir.

Tablo 3. Kullanılan Yazılım ve Donanım Bileşenleri


Kategori	Bileşen	Açıklama
Donanım	İşlemci (CPU)	Intel Core i7-13700H
	Bellek (RAM)	16 GB
	Grafik Kartı (GPU)	NVIDIA GeForce RTX 4060
	CUDA / cuDNN	CUDA 11.3, cuDNN 8.2
Yazılım Ortamı	Çalışma Ortamı	Anaconda, Jupyter Notebook
	Programlama Dili	Python 3.8, Python 3.9
Yazılım Bileşenleri	DL Kütüphaneleri	TensorFlow 2.6, PyTorch 2.7
	Görüntü İşleme	OpenCV
	Nesne Tespiti	YOLOv5
	Renk sınıflandırma	Önerilen model: LABNet
	Veri Etiketleme Aracı	VGG Image Annotator

Vita 3D Master ile Veri Setinin Oluşturulması

Bu çalışmada, diş rengi tespiti amacıyla görüntüleme işlemleri için akıllı telefon kamerası kullanılmıştır. Görüntüler, iPhone 13 Pro Max cihazı kullanılarak fotoğraf modunda çekilmiştir. Her görüntü alınmadan önce odaklama ayarlanmış ve cihaz ilgili dişe sabitlenmiştir.

Vita 3D Master

Diş rengi belirleme sürecinde genellikle renk kılavuzları kullanılarak görsel eşleştirme yöntemi tercih edilmektedir. Diş hekimliğinde en yaygın kullanılan renk kılavuzları arasında Vita Classical ve Vita 3D Master yer almaktadır. Vita 3D Master, rengin üç boyutunu temsil eden Munsell renk sistemine benzer bir yapıya sahiptir (Basavanna vd., 2013). Bu çalışmada, daha geniş renk aralığına sahip olması nedeniyle görüntü kaynağı olarak Vita 3D Master renk skalası tercih edilmiştir. Vita 3D Master, diğer skalalara göre daha geniş bir renk aralığı (29 renk) sunmaktadır. Bu renkler 5M3, 5M2, 5M1, 3R2.5, 3R1.5, 3M3, 3M2, 3M1, 3L2.5, 3L1.5, 4R2.5, 4R1.5, 4M3, 4M2, 4M1, 4L2.5, 4L1.5, 2R2.5, 2R1.5, 2M3, 2M2, 2M1, 2L2.5, 2L1.5, 1M2, 1M1, 0M3, 0M2, 0M1'dir. Bu skala Şekil 2'de gösterilmiştir.




Şekil 2. Vita 3D Master.

Vita 3D Master skalasındaki her bir renk sekmesi, dört farklı klinik ışık koşulunda ve her koşul için beş tekrar olacak şekilde, gri bir arka plan önünde çekilmiştir. Kullanılan klinik ışık kaynakları şu şekildedir:

1. Flaş desteği olmayan doğal ışık (doğal),
2. Doğal ışık altında kullanılan flaş ışığı (flaş),
3. Flaşsız diş ünitesine ait beyaz ışık (beyaz),
4. Flaşsız diş ünitesine ait sarı ışık (sarı).

Gri arka plan kullanımı, renklerin çevresel etkilerden arındırılarak daha nötr ve standart bir görüntüleme ortamı sağlamak amacıyla tercih edilmiştir. Toplamda 580 görüntü elde edilmiştir. Elde edilen her görüntü, boyuttan bağımsız olarak diş renginin en belirgin olduğu ekvator bölgesinden kırılmış ve böylece işlenmeye hazır bir veri kümesi oluşturulmuştur. Oluşturulan bu veri kümesinde, her bir görüntü dosyasının adı ilgili renk değerini, bulunduğu klasör ise görüntünün hangi klinik ışık koşulunda çekildiğini temsil etmektedir. Tüm renk değerleri ve ışık bilgileri, görüntüler işlendikten sonra sayısal veri kümesine entegre edilmiştir.

Vita 3D Master örneklerine ait görüntüler ve kırılmış görüntülerin örneği Şekil 3'te gösterilmiştir.



Şekil 3. Vita 3D Master diş örnekleri ve bunların kırılmış görüntüleri.

İntraoral (Ağız İçi) Görüntüler ile Veri Setinin Oluşturulması

Klinik veri toplama


250 kadın, 250 erkek olmak üzere toplam 500 gönüllünün katılımı ile mevcut çalışma gerçekleştirildi. Gönüllülerin çalışmaya dahil edilme kriterleri şu şekildedir:

1. 18-40 yaş arasındaki bireyler,
2. Alt ve üst ön grup dişlerinde eksik dişi olmayan bireyler,
3. Alt ve üst ön grup dişlerinde protetik veya konservatif restorasyonu olmayan bireyler,
4. Alt ve üst ön grup dişlerinde içsel ve dışsal renklenme olmayan bireyler,
5. Ağız hijyeni iyi düzeyde olan bireyler,
6. Ön grup dişlerinde anomali, pozisyon eğriliği veya morfolojik bozukluk olmayan bireyler.

Dahil edilme kriterlerine uygun olarak belirlenen gönüllülere tedavi protokolü anlatılıp, rızaları alınıp, onam formu imzalatıldıktan sonra, ağız içi fotoğrafları alınmadan önce dişlerin yüzeyinde mevcut olan plak ve birikintileri gidermek için polisaj patı (Detartrine; Septodent) ile yüzeysel bir polisaj işlemi uygulandı ve ağız çalkalama suyu (Listerine; Johnson&Johnson) ile 1 dakika boyunca çalkatılarak ağız içi temizlik sağlanmıştır. Dişlerle ilgili hazırlık tamamlandıktan sonra ağız içi fotoğrafların çekimine geçilmiştir. Standardizasyonu sağlamak amacıyla tüm dental fotoğraflar bir araştırmacı tarafından tek bir akıllı telefon ile (Iphone 13 Pro Max; Apple) ×3 yakınlaştırma ile fotoğraf modunda çekilmiştir. Fotoğraflar sabit bir mesafeden (akıllı telefon kamerası ile gönüllünün başı arasındaki mesafe 20 cm olacak şekilde), yer düzlemine göre gönüllünün başı dik oklüzal düzlemi ise paralel olacak şekilde kaydedilmiştir. Fotoğrafların kaydı esnasında yanak dudak gibi çevre yumuşak dokuların

görüntüyü engellemesi için yanak ekartörleri (Osung) kullanılmıştır ve gönüllülerin sadece alt ve üst ön grup 12 dişini içine alacak şekilde pozlama yapılmıştır. Ağız içi fotoğrafların kaydı sırasında, alt ve üst ön grup dişlerin klinik kuronlarının tamamen görünmesi ve üst ön grup dişlerin, alt ön grup dişlerin insizal üçlülerini örtmemesi için; gönüllüler, çeneler arası yaklaşık 2 mm açıklık olacak şekilde ve baş başa pozisyonlandırılmıştır. Farklı klinik aydınlatma koşullarını simüle edebilmek amacıyla her bir gönüllüden 5 farklı aydınlatma koşulu altında birer adet fotoğraf alınarak o gönüllüye ait 5 fotoğraf kaydedilmiştir. Aydınlatma ortamlarını sağlayabilmek ve sabit mesafeden kayıt yapabilmek amacıyla tüm fotoğraflar LED aydınlatma sistemi ile donatılmış ve akıllı telefon sabitleyicisi olan bir tripod düzeneği (Ring Light; Ringo) kullanılmıştır. Görüntülerin kaydedilme protokolünün şematik gösterimi Şekil 4'te gösterilmektedir. Çalışmada kullanılan tripod ışık kaynağı dental reflektör ve dental klinik aydınlatma ışıklarını simüle edebilecek ışık kapasitesine (2700-6500 K), toplam 84 watt güce, 11.300 lümen ışık çıkışına, 96 CRI değerine ve 480 LED'e sahiptir. Çalışmada kullanılan 5 farklı aydınlatma ortamı şu şekildedir:

1. Doğal ışık kaynağı altında flaş desteksiz
2. Doğal ışık kaynağı altında flaş destekli
3. Dental ünit reflektörünün sarı ışığını simüle edecek şekilde flaş desteksiz (2700 K)
4. Dental ünit reflektörünün gün ışığını simüle edecek şekilde flaş desteksiz (4600 K)
5. Dental ünit reflektörünün gün ışığını simüle edecek şekilde flaş desteksiz (6500 K)



Şekil 4. Ağız içi fotoğraflarının kaydedilme protokolünün şematik gösterimi.

Ağız içi fotoğrafların çekimini takiben her bir dişin Vita 3D renk değeri bir dijital spektrofotometre (Vita Easyshade V; Vita Zahnfabrik) yardımıyla tek diş modunda belirlenerek kaydedilmiştir. Gönüllülerden alınan her bir fotoğraf tek tek incelenmiş, projeye uygun olmayan görüntüler silinerek süreç tekrarlanmıştır. Her bir gönüllüye ait (hasta bilgileri gizli kalacak şekilde) yalnızca numaralandırma yöntemi kullanılarak dijital klasörler

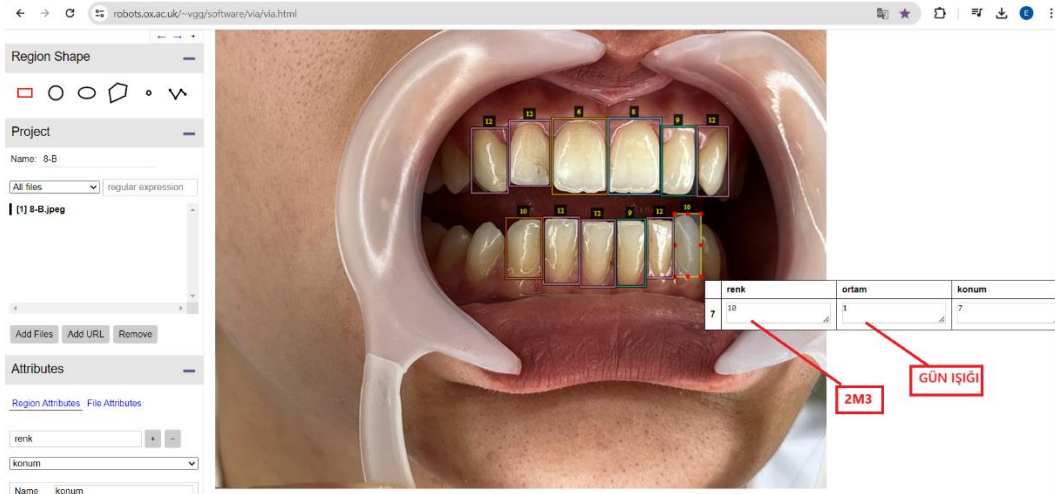
oluşturulmuştur. Sayısal olarak adlandırılmış dijital klasörlere, hastaya ait fotoğraflar ve renk değerlerini içeren dijital kartela eklenmiştir. Elde edilen görüntüler, bilgisayar ortamında gruplandırılıp numaralandırılarak .jpeg formatında kaydedilmiştir. Bir hasta için beş klinik ışıkta çekilen görüntülerin bir örneği Şekil 5'te gösterilmiştir.



Şekil 5. Bir hastaya ait farklı klinik ışık koşullarında çekilen görüntülerin bir örneği.

Veri setinin hazırlanması

Klinik aşamada toplanan görüntülerin yazılıma uygun olanları seçilmiştir. Eğitimler için 200 hasta ele alınmıştır. Görüntüler, açık kaynaklı VGG Image Annotator (VIA) yazılımı kullanılarak işaretlenmiştir (Dutta ve Zisserman, 2019). Her görüntüde 12 ön grup dişi için ayrıntılı etiketleme ve işaretleme yapılmıştır. Bu işlem sonucunda, her görüntüye ait dosya adı, dosya boyutu, dosya özellikleri, bölge sayısı, bölge kimliği, bölge şekil koordinatları ve bölge etiketleri gibi bilgiler .csv uzantılı, görüntüyle aynı ada sahip dosyalara kaydedilmiştir. Bölge etiketleri konum, renk ve ortamdır. Konum, numaralandırılmış dişleri belirtmektedir. Renk, klinikte ölçülen değerdir. Ortam, görüntünün hangi klinik ışık koşulunda çekildiğini belirten etikettir. Şekil 6'te VIA ile etiketleme örneği gösterilmiştir.



Şekil 6. Etiketleme örneği.

Görüntülerin renk sınıflandırma eğitim sürecine uygun hale getirilmesi için, her dişin bireysel olarak ayrıştırılması gerekmektedir. Etiket dosyalarındaki koordinatlar kullanılarak her bir diş için maskeleye yapılmıştır. Diş tespiti için doğrudan bu koordinatlar ve konum etiketi kullanılmıştır. Dişin kenarları ve kök kısmı, ışık etkileri nedeniyle renk açısından güvenilir değildir. Bu yüzden, her dişin merkezinden %30 oranında kırpma yapılarak ilgi alan (ROI)

oluşturulmuş ve renk sınıflandırma modellerinin bu bölge kullanılarak eğitilmesi hedeflenmiştir. Bir hastaya ait diş ROI'lerinin, 5 farklı klinik ışığı ve 12 dişin konumuna bağlı olarak rengindeki değişimlerin net bir şekilde görüldüğü örnek veri Şekil 7'de gösterilmiştir.




Şekil 7. Bir hastaya ait 12 ön grup dişinin ROI'leri ve renk değerleri.

Veri setinde toplam 23 farklı diş rengi tespit edilmiştir. Bu renkler: 2M3, 3M2, 2R2.5, 2M2, 1M2, 4R1.5, 2R1.5, 3R1.5, 2L1.5, 1M1, 2M1, 3M3, 2L2.5, 4M3, 3M1, 0M3, 4M2, 3L1.5, 3R2.5, 3L2.5, 4L1.5, 4M1 ve 4R2.5'tir.

Performans Değerlendirme Metrikleri

Sınıflandırma modellerinin performansını değerlendirmek amacıyla kullanılan karmaşıklık matrisi (confusion matrix), tahmin edilen değerler ile gerçek değerlerin karşılaştırılmasına olanak tanıyan bir tablodur. Bu matris, modelin doğru sınıflandırma yapabilme yetisini görselleştirmeye yardımcı olur. Karmaşıklık matrisi dört temel bileşenden oluşmaktadır: True Positive (TP), doğru şekilde pozitif olarak sınıflandırılan örnekleri; True Negative (TN), doğru şekilde negatif olarak sınıflandırılan örnekleri; False Positive (FP), yanlış şekilde pozitif olarak sınıflandırılan örnekleri; False Negative (FN) ise yanlış şekilde negatif olarak sınıflandırılan örnekleri ifade eder (Efitli vd., 2025). Karmaşıklık matrisinin genel yapısı Şekil 8'de gösterilmiştir.



Şekil 8. Karmaşıklık matrisi.

Bu matris kullanılarak modelin doğruluk (accuracy), kesinlik (precision), duyarlılık (recall) ve F1 skor (F1 score) gibi performans metrikleri hesaplanmaktadır. Doğruluk, doğru tahmin edilen örneklerin toplam tahmin sayısına oranıdır ve Eşitlik 1’de verilmiştir. Kesinlik, pozitif olarak tahmin edilen örneklerin ne kadarının gerçekten pozitif olduğunu gösterir ve Eşitlik 2’de sunulmuştur. Duyarlılık, gerçekten pozitif olan örneklerin ne kadarının doğru tahmin edildiğini ölçer ve Eşitlik 3’te gösterilmiştir. F1 skoru ise kesinlik ve duyarlılığın harmonik ortalamasıdır ve Eşitlik 4’te tanımlanmıştır.

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

$$\text{Kesinlik} = TP/(TP + FP) \quad (2)$$

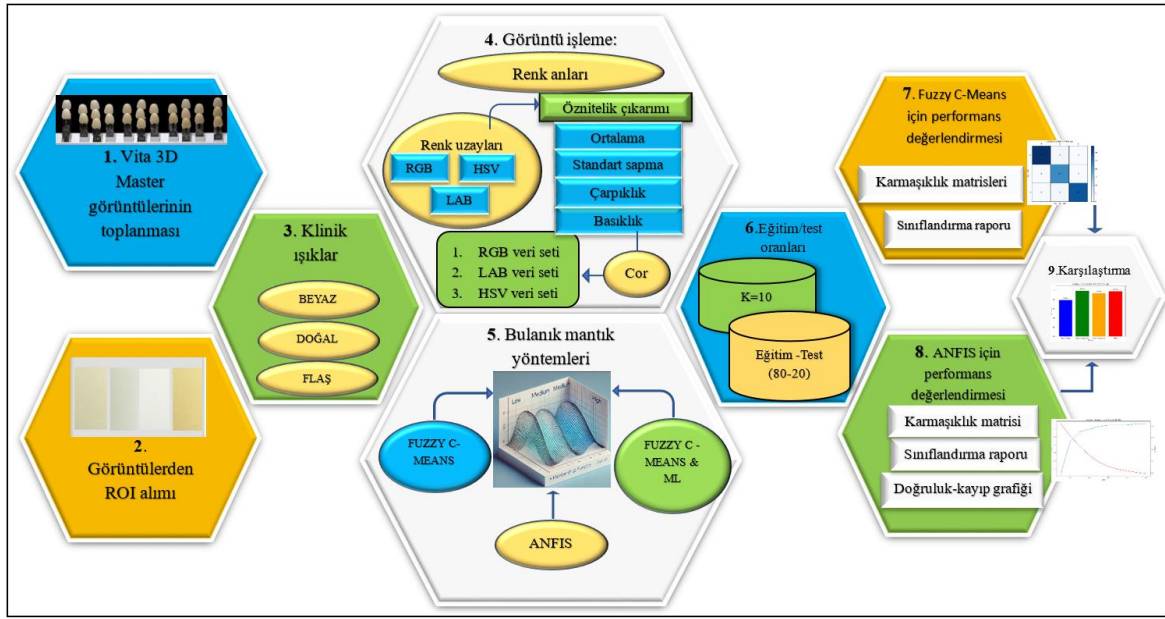
$$\text{Duyarlılık} = TP/(TP + FN) \quad (3)$$

$$\text{F1 skor} = 2 * (\text{Precision} * \text{Recall})/(\text{Precision} + \text{Recall}) \quad (4)$$

Performans değerlendirmesinde kullanılan bir diğer önemli araç ise doğruluk ve kayıp (loss) grafikleridir. Doğruluk grafiği, modelin zamanla doğru sınıflandırma oranındaki değişimi ve doğruluk oranının artışı gösterirken; kayıp grafiği, modelin hata oranındaki azalma veya artışı yansıtır. Eğitim süreci boyunca doğruluk grafiği, modelin tahmin başarısındaki artışı; kayıp grafiği ise kayıp fonksiyonundaki düşüşü izlemek için kullanılır. Eğitim sürecindeki ilerlemeyi gözlemlemek için karmaşıklık matrisleri, doğruluk ve kayıp grafiklerinden yararlanılmıştır.

Bulanık Mantık Yöntemleri Kullanılarak Farklı Klinik Işıkların Tahmini

Bu çalışmada, diş kliniklerindeki farklı ışık kaynaklarının tahmini için Vita 3D Master renk skalası ile oluşturulan veri seti kullanılmıştır. Görüntülerin işlenmesi için renk anları kullanılmıştır. Veri kümeleri RGB, HSV, LAB renk uzaylarına göre oluşturulmuştur. ANFIS ve Bulanık C-Ortalamalar (FCM) yöntemlerinden yararlanılmıştır. Aynı zamanda, önerilen hibrit yaklaşımda performans iyileştirmeleri için ML sınıflandırıcılarından KNN ve RF kullanılmıştır. Çalışmanın genel çerçevesi Şekil 9’da gösterilmiştir.



Şekil 9. Bulanık mantık yöntemleri kullanılarak farklı klinik ışıkların tahmini çalışmasının genel çerçevesi.

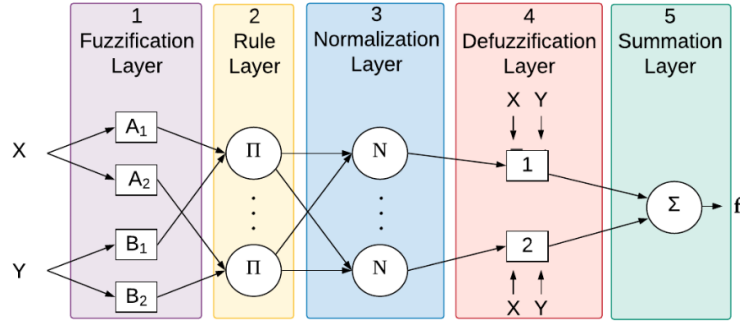
ML tabanlı bulanık C-ortalamları

Bulanık C-Ortalamları (FCM), belirsiz verilerle başa çıkabilen küme analizi için bir yöntem olarak geliştirilmiştir. FCM, veri noktalarının birden fazla kümeye ait olabileceğini kabul ederek verilerin içsel belirsizliğini modellemeye olanak tanır (Askari, 2021). Bu bağlamda, her veri noktasına her kümeye ait olma derecesi olarak bilinen üyelik dereceleri atanır. Bu değerler 0 ile 1 arasında değişir; 0 noktanın o kümeye ait olmadığını, 1 ise kesinlikle o kümeye ait olduğunu gösterir. FCM, görüntü işleme, veri madenciliği ve tıbbi görüntüleme yaygın olarak kullanılmıştır (Hung ve Yang, 2001). Algoritmanın temel adımları, üyelik hesaplamasını ve başlangıçta rastgele belirlenen merkezlerin merkez güncellemesini içerir. Bazı durumlarda, FCM sonuç doğruluğunu artırmak için diğer ML algoritmalarıyla entegre edilir. Bu tür hibrit yaklaşımlar, FCM'nin bulanık üyelik modellemesinin güçlü yanlarını diğer sınıflandırıcıların yetenekleriyle birlikte kullanarak üstün performans sağlar (Yang vd., 2015). Bu çalışmada, hibrit FCM hem FCM hem de ML algoritmalarını birleştirerek kullanılmıştır.

ANFIS

Uyarlanabilir Nöro-Bulanık Çıkarım Sistemi (ANFIS), yapay sinir ağları ve bulanık mantığı birleştiren, bulanık mantığın hem öğrenme kapasitesini hem de esnekliğini sunan bir hibrit modeldir. İlk olarak 1993 yılında Jang tarafından geliştirilmiştir (Karaboga ve Kaya, 2019). ANFIS, verilerden öğrenerek girdi-çıkı ilişkilerini belirler ve süreçte bulanık kuralları otomatik olarak günceller. Eğitim aşamasında, geri yayılım algoritması ve en küçük kareler yöntemi genellikle birlikte kullanılır. Bu şekilde, sistem önce giriş verilerine göre kuralları belirler ve ardından bu kuralları optimize eder. (Hosseini ve Zekri, 2012). ANFIS mimarisi

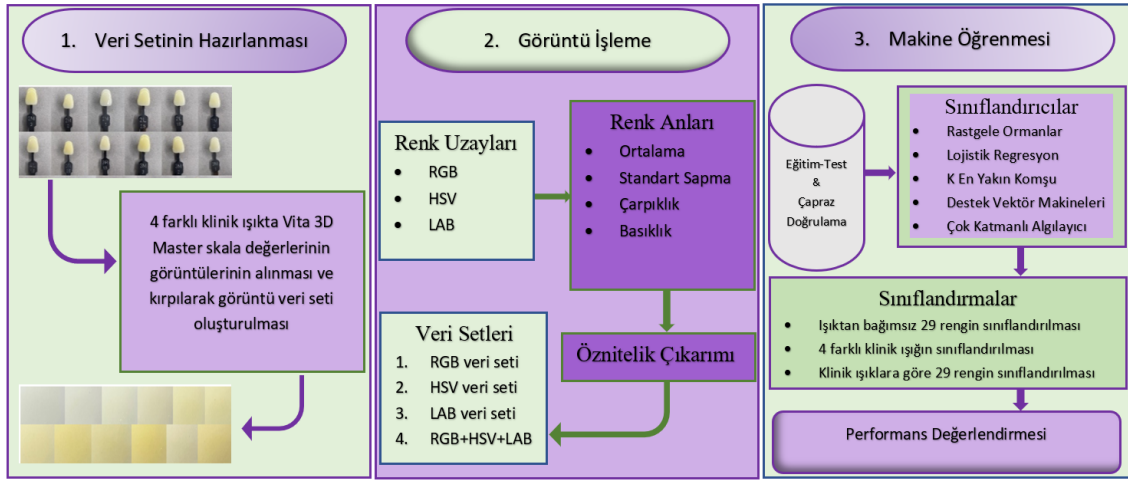
Şekil 10'da gösterilmiştir (Guerra vd., 2024). Bu çalışmada ışık koşullarını tahmin etmek için manuel kural çıkarma zordur. Çok sayıda kuralın manuel olarak belirlenmesi sistem karmaşıklığına ve tutarsızlıklara yol açar. Kurallar arasında çelişkilerin oluşması hatalı durumlara neden olur. Bu tür sorunların üstesinden gelmek için bu çalışmada ANFIS yöntemi tercih edilmiştir.



Şekil 10. ANFIS mimarisi (Guerra vd., 2024).

Renk Anları ve Makine Öğrenmesi Kullanılarak Diş Rengi Tahmini

Bu çalışmada farklı klinik ışıklarında doğru rengi tespit etmek için Vita 3D Master renk skalası ile oluşturulan veri seti kullanılmıştır. Renk anları ve ML tabanlı diş rengi değerlendirmesi yapılmıştır. Lojistik regresyon (LR), çok katmanlı algılayıcı (MLP), KNN, SVM, RF bu çalışmada kullanılan sınıflandırıcılardır. LR ikili veya çok sınıflı sınıflandırma problemlerinde kullanılan istatistiksel bir yöntemdir. Olasılık tahmini yaparak verilerin belirli bir sınıfa ait olma ihtimalini belirlemektedir. RF karar ağaçlarının bir topluluğu olarak çalışıp her bir ağaçtan alınan sonuçları birleştirerek tahmin yapmaktadır. SVM verileri farklı sınıflara ayıran en uygun hiper düzlemi bulmayı amaçlamaktadır. MLP yapay sinir ağları temelli bir yöntemdir. KNN bir veri noktasının sınıfını belirlemek için en yakın komşularını analiz eden basit ama güçlü bir algoritmadır (Mahesh, 2020). Çalışmanın genel çerçevesi Şekil 11'de gösterilmiştir.




Şekil 11. Renk anları ve makine öğrenmesi kullanılarak diş rengi tahmini çalışmasının genel çerçevesi.

Renk anları

Renk anları, görüntü işleme ve renk analizi çalışmalarında, bir görüntünün renk dağılımını sayısal olarak özetleyen istatistiksel değerlerdir (Mutlag ve ark., 2020). Bunlar ortalama (mean), standart sapma (standard deviation), çarpıklık (skewness) ve basıklık (kurtosis) değerleridir (Justiawan ve ark., 2019). Ortalama, görüntü piksellerinin ortalama değeridir. Standart sapma renk dağılımının varyansının karekökü alınarak elde edilmektedir. Bazı kaynaklarda varyans renk anı olarak kullanılmıştır (Mutlag ve ark., 2020). Çarpıklık, Renk dağılımının ne kadar asimetrik olduğu hakkında bilgi vermektedir. Basıklık renk dağılımı hakkında bilgi vermektedir. Bu değerler hesaplanırken görüntü pikselleri üzerinde işlem gerçekleştirilmektedir. Bu dört bileşen birlikte kullanıldığında, bir görüntünün renk özellikleri hakkında kapsamlı bilgi sağlamaktadır. Ortalama ve sapma, renklerin genel dağılımını tanımlarken, çarpıklık ve basıklık renk dağılımının daha detaylı analizini mümkün kılar. Renk anları genellikle bir görüntünün belirli bir renk uzayında hesaplanmaktadır. Bu hesaplamalar genellikle her kanal için ayrı yapılır (örneğin, LAB uzayında L, A, B için). Bu kanalların her biri için istatistiksel anlar hesaplanır. Klinik uygulamaların renk farkı analizinde renk anları tercih edilen bir yaklaşımdır (Sigit ve Arief, 2017).

Bu çalışmada görüntüler buldukları renk uzaylarına göre renk kanallarına ayrılmıştır. Böylece her bir renk uzayı için 12’şer öznitelik çıkarılmıştır. Örneğin HSV renk uzayı için OrtalamaH, OrtalamaS, OrtalamaV, StdSapmaH, StdSapmaS, StdSapmaV, ÇarpıklıkH, ÇarpıklıkS, ÇarpıklıkV, BasıklıkH, BasıklıkS, BasıklıkV öznitelikleri çıkarılmıştır. Ayrıca, çıkarılan özniteliklere görüntülerdeki dişin rengi ve çekildiği klinik ışığı da eklenmiştir. Bu sayede, her veri seti için 14’er öznitelik elde edilmiştir. Tüm özniteliklerin renye göre önem grafiği Şekil 12’de gösterilmiştir.



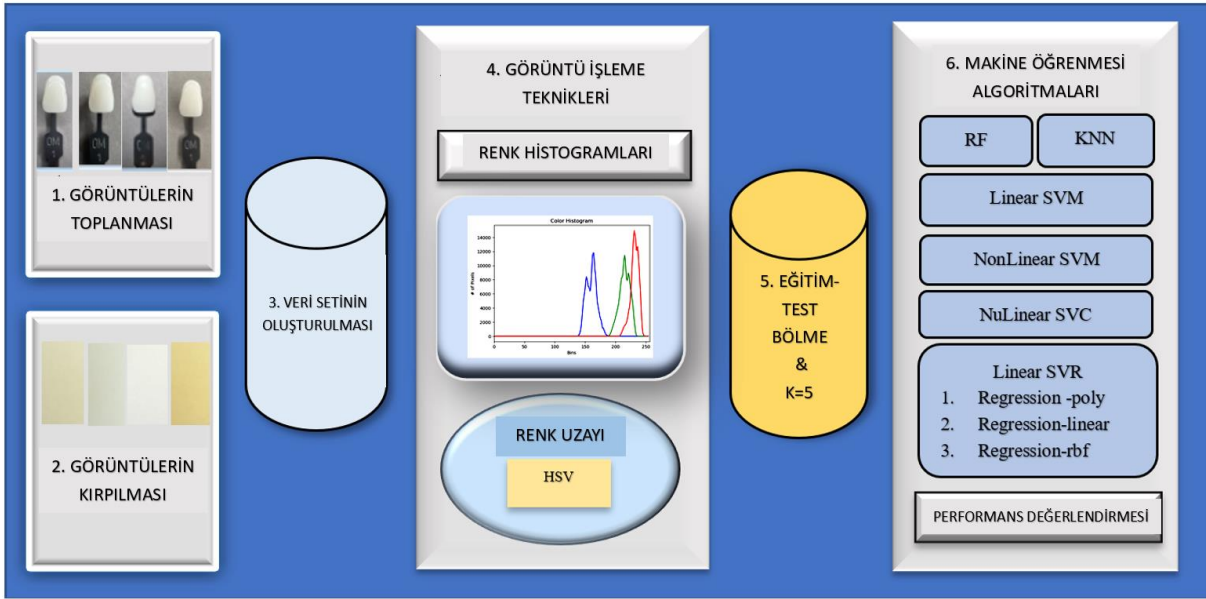
Şekil 12. Öznitelik önem grafiği.

Histogram ve Makine Öğrenmesi Kullanılarak Diş Rengi Tahmini

Bu çalışmada, Vita 3D Master renk skalası ile oluşturulan veri seti kullanılmıştır. HSV renk uzayı, renk histogramları ve ML algoritmaları kullanılmıştır. Renk histogramları, görüntülerdeki piksel değerlerinin hangi aralıklarda ve ne sıklıkla gözlemlendiğini göstermektedir. Görüntü piksellerinin dağılımını sayısal olarak temsil edebilmek amacıyla, her bir renk kanalında 64 aralık olacak şekilde toplam 64x64x64 boyutlarında histogram bölmeleri (“bin” yapısı) kullanılmıştır. Altı farklı sınıflandırma senaryosu için doğruluk sonuçları elde edilmiştir:

1. Dört farklı klinik ışık koşulu,
2. Işık kaynaklarından bağımsız 29 farklı renk,
3. Beyaz ışık altında 29 renk,
4. Doğal ışık altında 29 renk,
5. Sarı ışık altında 29 renk,
6. Flaş ışığı altında 29 renk.

SVM, Destek Vektör Regresyonu (SVR), Doğrusal Olmayan Destek Vektör Makinesi (Nonlinear SVM), Doğrusal Olmayan Destek Vektör Sınıflandırıcısı (SVC), KNN ve RF bu çalışmada kullanılan ML algoritmalarıdır. Bu çalışmanın genel çerçevesi Şekil 13’te gösterilmiştir.



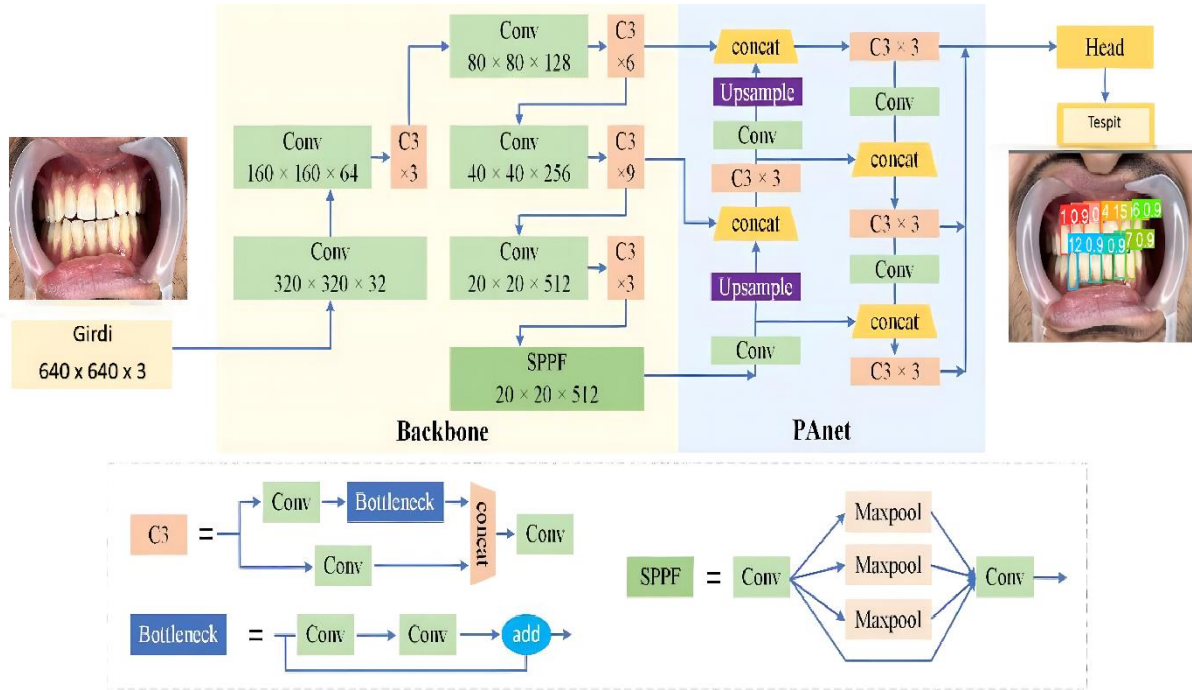
Şekil 13. Histogram ve ML kullanılarak yapılan dış rengi tahmini çalışmasının genel çerçevesi.

İntraoral Görüntülerde YOLOv5 ile Diş Tespiti

YOLOv5 mimarisi

YOLO (You Only Look Once), nesne tanıma işlemini görüntüler üzerinde tek bir geçişle gerçekleştiren ve sınıflandırma ile konum tahminini aynı anda yapabilen uçtan uca bir DL algoritmasıdır (Khanam ve Hussain, 2024). YOLO mimarisi, evrişimli sinir ağları (CNN) aracılığıyla görüntülerdeki nesnelerin sınıflarını ve koordinatlarını doğrudan tahmin ederek yüksek hızda nesne algılama imkânı sunmaktadır. YOLOv5, önceki sürüm olan YOLOv4'e kıyasla Focus yapısı, C3 modülü, Mosaic veri artırımı ve adaptif anchor kutusu hesaplaması gibi çeşitli yapısal iyileştirmelerle hem doğruluk hem de hız açısından önemli gelişmeler sunmuştur. Model karmaşıklığına göre YOLOv5, s (small), m (medium), l (large) ve x (extra-large) gibi farklı versiyonlara ayrılmıştır. Model karmaşıklığı arttıkça doğruluk artmakta, ancak model boyutu ve işlem süresi uzamaktadır. YOLOv5 mimarisi üç ana bölümden oluşur: C3 blokları, SPPF (Spatial Pyramid Pooling - Fast) modülü ve PANet tabanlı neck yapısı. Backbone'da yer alan CSPNet, ağır farklı aşamaları arasında bilgi akışını optimize ederek hem parametre sayısını azaltır hem de bilgi kaybını minimize eder (Nan vd., 2023). SPPF, geniş alansal bağlam bilgisi sağlayarak çok ölçekli özellik birleştirmesini hızlandırır. Ağır neck kısmı, alt düzey özelliklerin daha üst düzey katmanlara etkili biçimde aktarımını sağlayan PANet yapısı ile gerçekleştirilirken; head kısmı ise üç farklı ölçekte çıktı üreten YOLOv3/YOLOv4 benzeri bir yapıdır. Bu modüller ve esnek yapı sayesinde YOLOv5, farklı görevlerde kolayca uyarlanabilir ve hız-doğruluk dengesi açısından üstün bir performans

sergilemektedir (Li vd., 2022). Nan vd., (2023) çalışmalarında sundukları YOLOv5 mimarisinin çalışmamıza uyarlanmış hali Şekil 14’te gösterilmiştir.



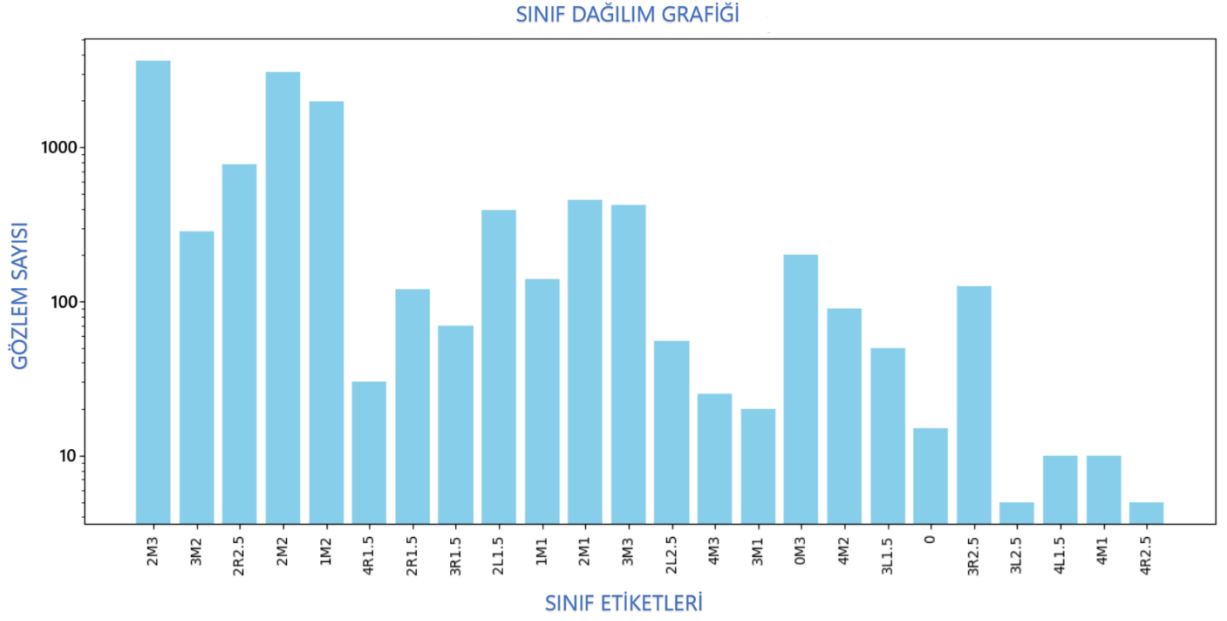
Şekil 14. YOLOv5 Mimarisi. Nan vd. (2023)’ten uyarlanmıştır.

YOLOv5’in nesne tespiti başarımı, yalnızca mimari düzeydeki iyileştirmelerle değil, aynı zamanda etkili eğitim stratejileriyle de desteklenmektedir. Modelin eğitim sürecinde kullanılan veri artırma (data augmentation) teknikleri, gerçek dünya görüntülerindeki çeşitliliğe karşı modelin genelleme yeteneğini artırmak amacıyla geniş bir dönüşüm yelpazesi sunar. Özellikle Mosaic artırma yöntemi, dört farklı görüntüyü tek bir eğitim örneğinde birleştirerek küçük nesnelerin tespitinde önemli avantajlar sağlar. Bunun yanı sıra, *kayıp* fonksiyonu (loss function) bileşenleri arasında yer alan GIoU, sınıflandırma ve nesne varlık (objectness) kayıpları, modelin ortalama doğruluk oranı (mAP) optimizasyonuna doğrudan katkı sunar. YOLO mimarisinin PyTorch framework’üne taşınması, daha hızlı geliştirme döngüsü, kolay hata ayıklama ve yeni yöntemlerin entegrasyonunda esneklik sağlamıştır. Ayrıca, anchor box boyutlarının veri kümesine özel olarak genetik algoritmalar ve k-means kümeleme ile optimize edilmesi, modelin farklı nesne ölçeklerine uyumunu artırmıştır. Bu yönleriyle YOLOv5, yalnızca mimari değil, eğitimsel ve operasyonel düzeyde de ileri seviye bir nesne tespit çözümü olarak öne çıkmaktadır (Khanam ve Hussain, 2024).

YOLOv5 tabanlı modelin kurulumu ve eğitim süreci

Bu çalışmada dış tespiti amacıyla YOLOv5 mimarisi tercih edilmiştir. Modelin eğitimi için öncelikle YOLOv5’in resmi GitHub deposundan temin edilerek çalışma ortamına entegre edilmiştir (Ultralytics, 2025). Veri setindeki etiketler başlangıçta .csv formatında bulunmakta

görmektedir ve veri setinin doğasına, problemin karmaşıklığına, modelin yapısına bağlı olarak farklılık gösterebilmektedir.



Şekil 16. Veri setinin sınıf dağılım grafiği.

Bu çalışma kapsamında kullanılan veri setinde, bazı sınıfların örnek sayısı istatistiksel olarak yeterli sayının altında kalmıştır. Örnek sayıları DL modellerinin öğrenmesi için yeterli miktar, 5 farklı ışıkta çekilmiş olmaları ve sınıf dağılımına göre farkı azaltma kriterleri benimsenerek belirlenmiştir. Böylece eğitimde kullanılan veri setinden örnek sayısı 300'ün altında kalan sınıflar çıkarılmıştır. Sonuç olarak 6 renk sınıfı kalmıştır. Bunlar: 2R2.5, 2M2, 2M3, 1M2, 2L1.5, 2M1'dir. Bu yaklaşım, DL sınıflandırma çalışmalarında sıkça benimsenen bir yöntem olup, yeterli örnekleme sahip olmayan sınıfların modele dahil edilmemesiyle performans artışı sağlayabilir (Johnson ve Khoshgoftaar, 2019). Veri setindeki her sınıfın istatistiksel olarak anlamlı sayıda örnek içerdiğinden emin olmak, modelin güvenilirliği ve başarısı açısından önemlidir.

Gerçek dünyadaki dış renklerinin dağılımı da benzer şekilde asimetric olduğundan, bu gözlem veri setinin tutarlılığını desteklemekle birlikte, sınıf dengesizliği problemi gibi yapay öğrenme süreçlerinde ele alınması gereken önemli bir zorluk doğurmaktadır. Bu tür dengesizlikler, YZ modellerinde yüksek frekanslı sınıfların aşırı öğrenilmesine, düşük frekanslı sınıflarda ise sınıflandırma başarımının düşmesine yol açabilmektedir ya da eğitim sürecinde modelin öğrenmesini kısıtlamaktadır. Veri seti dengesini sağlamak için farklı yöntemler bulunmaktadır. Bu çalışmada sınıflandırma renk bilgisine dayalı olarak yapılmaktadır. Ancak, sınıflar arası ayırım çoğunlukla benzer tonlar üzerinden gerçekleştiğinden, renk geçişleri oldukça hassas ve sınıf temsili açısından kritiktir. Ayrıca, görüntüler farklı ışık kaynakları

altında elde edildiği için, veri seti doğal ışık varyasyonu da içermektedir. Bu bağlamda, renk ve doku bütünlüğünün korunması kritik rol oynar. Sentetik örnekleme temelli klasik dengeleme yöntemleri (örneğin SMOTE), bu bütünlüğü bozarak sınıf temsil gücünü zayıflatma riski taşımaktadır (Blagus ve Lusa, 2013). Özellikle ince ton farklarının belirleyici olduğu dış rengi sınıflandırması gibi bir problemde, yapay veri üretimi modelin genelleme yetisini olumsuz etkileyebilmektedir. Bu nedenle, bu çalışmada sınıf dengesizliğiyle başa çıkmak için SMOTE ve benzeri yöntemler kullanılmamıştır.

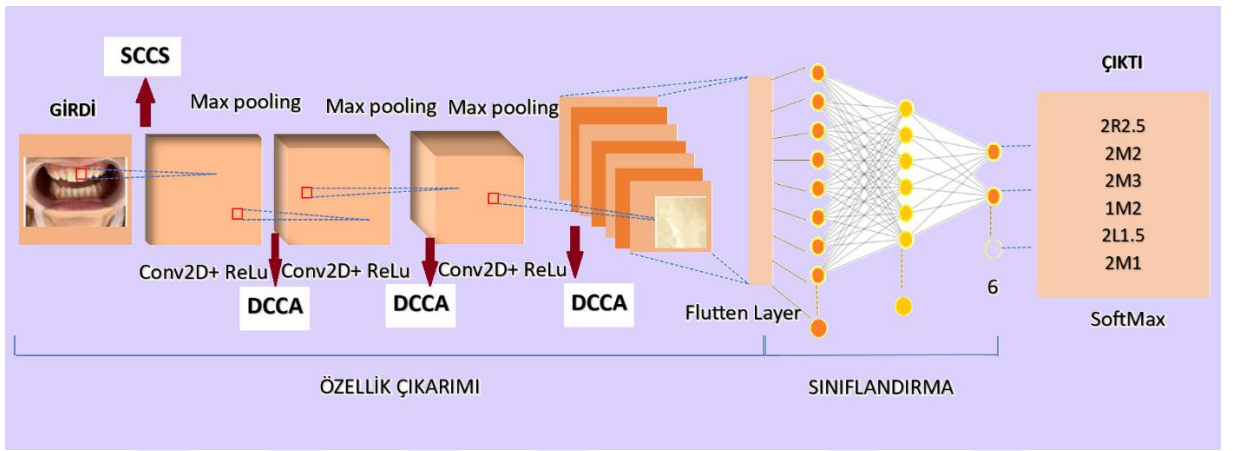
Bu çalışma için dengeleme amaçlı artırma yöntemleri kullanılması düşünülmüştür fakat artırma sürecinde tercih edilen teknikler, ROI yapısının hassasiyetine uygun olarak dikkatle belirlenmelidir. Zoom (yakınlaştırma) ve crop (kırpma) gibi bölgesel dönüşümler, ROI'lerin sınırlı alanlar olması nedeniyle kullanılmamıştır. Çünkü bu tür işlemler, dışın merkezinde yer alan ve sınıf ayrımında belirleyici olan renk ve doku bilgilerinin kaybına neden olabilir. Benzer şekilde, renk ve ışık değişimlerine dayalı artırımlar (örneğin parlaklık ayarı, kontrast değişimi, renk jittering) da benzer tonlardaki renklerin ayrımında yapay değişikliklere sebep olur ve sınıflar arası sınırları bulanıklaştırarak sınıflandırma performansını olumsuz etkileyebilir.

Sonuç olarak, bu çalışmada sınıf dengesizliği problemi, veri setinin yapısal özelliklerine uygun şekilde, dikkatli ve kontrollü bir dengeleme stratejisiyle ele alınmıştır. Az gözleme sahip sınıflarda yalnızca yatay ve dikey çevirme gibi sınırlı görüntü artırma işlemleri uygulanmıştır. Ardından, sınıflar arası temsil eşitsizliğini gidermek amacıyla örnekleme tabanlı bir dengeleme süreci yürütülmüş; her sınıfın örnek sayısı, en yüksek frekansa sahip sınıfla eşitlenecek biçimde yeniden örneklenmiştir.

CNN tabanlı modeller ve önerilen LABNet modeli

DL, çok katmanlı yapay sinir ağları kullanarak verilerden anlamlı özellikler çıkartmayı ve karmaşık ilişkileri modellemeyi amaçlamaktadır (LeCun vd., 2015). CNN, DL'de insan nöron yapısından uyarlanmış olan yapay sinir ağı modelidir. Özellikle görsel verilerin analizinde etkin olarak kullanılmaktadır. Bu çalışmada CNN temelli diğer önceden eğitilmiş DL modelleri olan ResNet50, VGG16, VGG19 ve EfficientNetB0 kullanılmıştır. ResNet50, VGG16, VGG19 ve EfficientNetB0 modelleri temel olarak CNN prensiplerine dayansa da bazıları daha sofistike yapılar kullanarak farklılaşmıştır. CNN, temel yapı taşlarını öğrenme yeteneği sayesinde verimli sonuçlar verirken, ResNet50 gibi derin ağlar, katmanlar arasındaki bağlantıları optimize ederek daha hassas özellikler öğrenmektedir. VGG16 ve VGG19, derin ağ mimarilerinin klasik örnekleri olup, özellikle düşük çözünürlükteki görüntülerde etkili performans sergilerken, EfficientNetB0 ise model verimliliğini artırarak daha hızlı ve doğru sonuçlar elde edilmesini sağlamaktadır (Reka vd., 2023).

Önceden eğitilmiş DL modellerine ek olarak, bu çalışmada daha yalın ama probleme özgü bir çözüm sunmak amacıyla LABNet adlı özel bir CNN tabanlı renk sınıflandırma mimarisi önerilmektedir. LABNet, klasik CNN yapısını temel alırken, LAB renk uzayını kullanan statik renk kanal ölçekleme (SCCS-Static Color Channel Scaling) ve örneğe duyarlı dinamik kanal dikkati (DCCA-Dynamic Color Channel Attention) gibi dikkat mekanizmalarıyla modelin renk varyasyonlarına karşı duyarlılığını artırmak ve genelleme yeteneğini artırmak üzere tasarlanmıştır. Parametre sayısı ve yapısal karmaşıklığı önceden eğitilmiş modellere kıyasla çok daha düşük olmasına rağmen, LABNet özellikle LAB renk uzayındaki ton benzerlikleri altında sınıflar arası ayrımı başarıyla gerçekleştirebilmesi ve daha tutarlı temsiller öğrenebilmesi hedeflenmiştir. LABNet mimarisi Şekil 17’de gösterilmiştir.



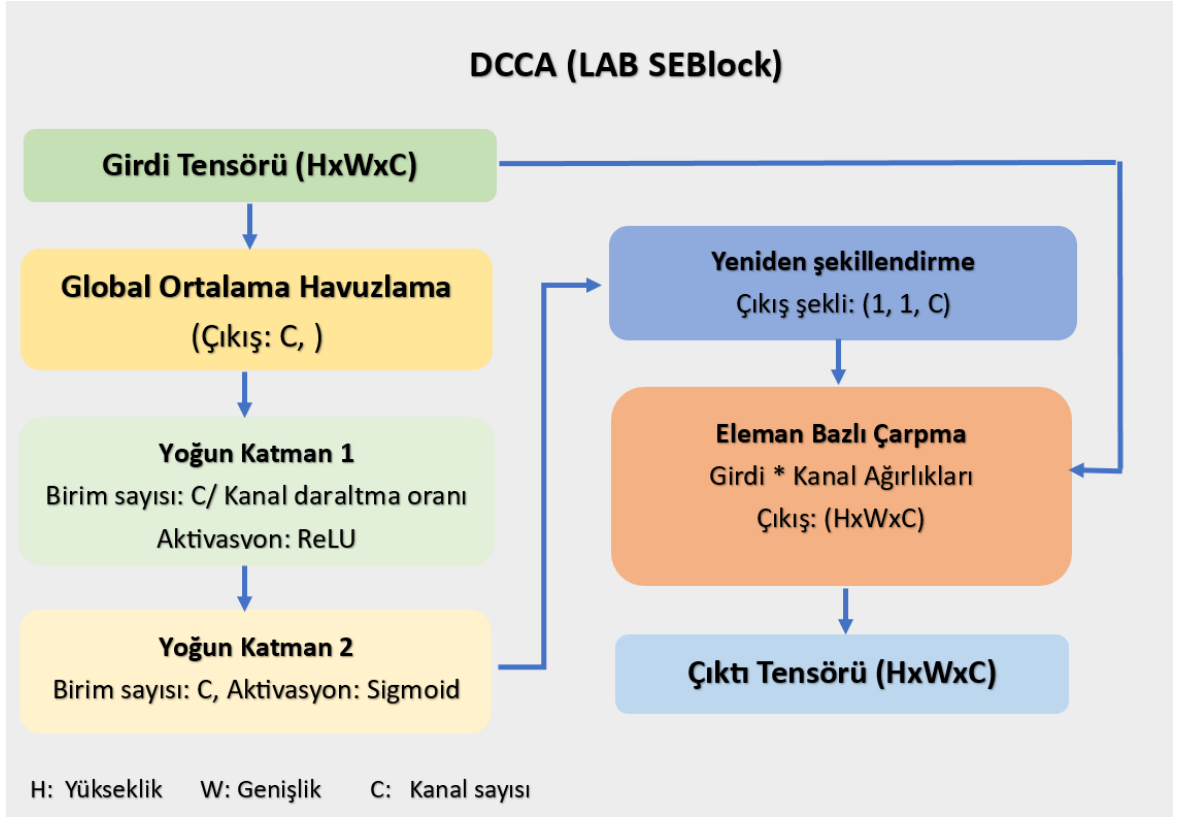
Şekil 17. LABNet mimarisi.

İlk olarak, giriş görüntüsüne uygulanan SCCS katmanı ile L, a, b kanallarının genel önem dereceleri öğrenilerek sabit bir kanal ölçekleme gerçekleştirilir. SCCS katmanının şematik gösterimi Şekil 18’de gösterilmektedir.



Şekil 18. SCCS'nin şematik gösterimi.

DCCA yapısı ise sıkıştırma ve uyarma (Squeeze-and-Excitation, SE) blok mimarisi ile her örnek için kanal düzeyinde uyarlanabilir dikkat uygular. Bu yapı, global ortalama havuzlama ve sıkıştır-genişlet işlemleri yoluyla girişteki renk ve ışık varyasyonlarını dikkate alarak, daha kararlı ve genellenebilir temsiller üretmektedir. DCCA'nın şematik gösterimi Şekil 19'da gösterilmektedir.



Şekil 19. DCCA'nın şematik gösterimi.

Bu çalışmada, dış rengi sınıflandırması için kullanılan modellerin her biri aynı hiperparametreler ve eğitim ayarları ile optimize edilmiştir. Model eğitimlerinde karmaşık ve büyük veri setlerinde daha iyi genelleme performansı sunduğu için Adam (Adaptive Moment Estimation) optimizasyon algoritması kullanılmıştır. Sparse Categorical Crossentropy kayıp fonksiyonu sınıfların bir tamsayı (integer) olarak kodlandığı çok sınıflı sınıflandırma problemlerinde bellek açısından verimli ve hesaplama yükü açısından optimize bir yaklaşım sunmaktadır. Çalışmamızda renk etiketleri sayısal etiketlerle eşleştirildiğinden bu kayıp fonksiyonu kullanılmıştır.

Ön işlem

Giriş olarak hazırlanan görüntüler için ön işlem gerçekleştirilmiştir. Öncelikle görüntüler (ROI'ler) LAB renk uzayına dönüştürülmüştür. LAB renk uzayı, insan gözünün renk algısına dayanan ve renkleri daha objektif bir şekilde tanımlamak için geliştirilen bir renk uzayı modelidir (Ganesan vd., 2010). İlk bileşen olan L (Luminance), bir görüntüdeki ışık seviyelerini

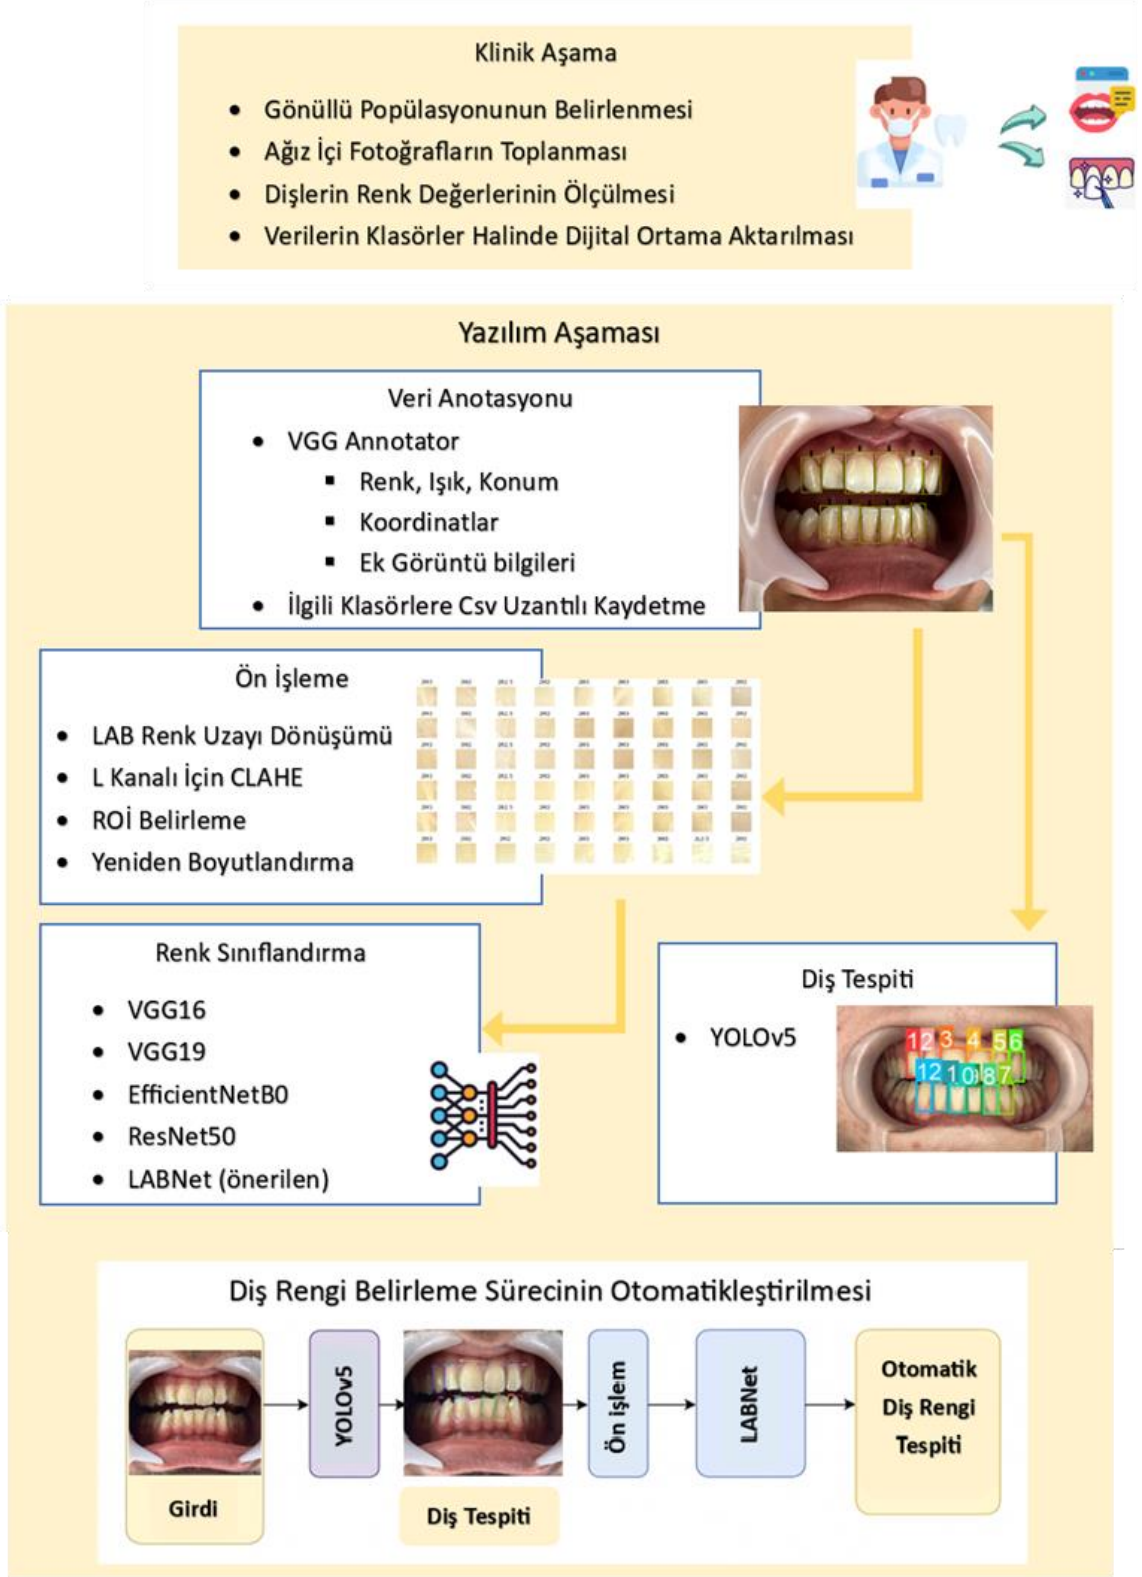
temsil eder ve parlaklık düzeyini belirler. İkinci bileşen A (Green-Red), renklerin yeşil ile kırmızı arasındaki farkını gösterir. Son olarak, B (Blue-Yellow) kanalı, mavi ile sarı arasındaki farkı temsil eder. Bu üç bileşen, renklerin daha doğru ve insana yakın bir şekilde modellenmesine olanak sağlar, özellikle renk analizi ve düzenlemelerinde oldukça kullanışlıdır. Ayrıca diş hekimleri ve protez uzmanları, doğal dişlerin renk tonları ile uyumlu protezler oluşturmak için LAB renk uzayından faydalanmaktadır. Diş görüntülerinde parlama, dişin doğal yapısındaki ışık yansımaları, kullanılan ışık kaynağının konumu, pozlama ayarları ve yüzey özelliklerinden kaynaklanabilir. Bu parlamalar, görüntüde doğru renk ve doku analizini zorlaştırarak, doğru tanımlama yapılmasını engellemektedir. Bu yüzden LAB uzayındaki görüntülerdeki parlamayı azaltmak için L kanalına CLAHE (Contrast Limited Adaptive Histogram Equalization) uygulanmıştır. Böylece yalnızca parlaklık değerlerini iyileştirilip renk bilgisine (A ve B kanalları renk bilgisini tutar) dokunulmaması sağlanmıştır.

Otomatik Diş Rengi Tespiti

Otomatik diş rengi belirleme sürecinde, diş tespit modeli ile renk sınıflandırma modeli birleştirilerek bütüncül bir yapı oluşturulmuştur. Bu sayede, gelen görüntülerdeki dişler tespit edilip her biri ayrı ayrı alınarak ön işleme tabi tutulmuş ve ardından sınıflandırma modeline renk tahmini için yönlendirilmiştir. Böylece sistem, görüntüdeki her bir diş için renk tahminini otomatik olarak gerçekleştirebilmesi hedeflenmiştir. Tespit ve sınıflandırma modellerinin parametreleri ve veri kümesi, model gereksinimlerine göre farklı şekilde yapılandırılmıştır. Renk sınıflandırma modelinin doğrulama performansı otomatik diş rengi tespitinin performansını göstermektedir. Otomatik diş rengi tespitinin özeti Şekil 20’de, ilgili eğitimler için kullanılan veri kümesi özellikleri ise Tablo 4’te gösterildiği gibidir.

Tablo 4. Otomatik Diş Rengi Tespiti İçin Kullanılan Veri Setlerinin Özeti

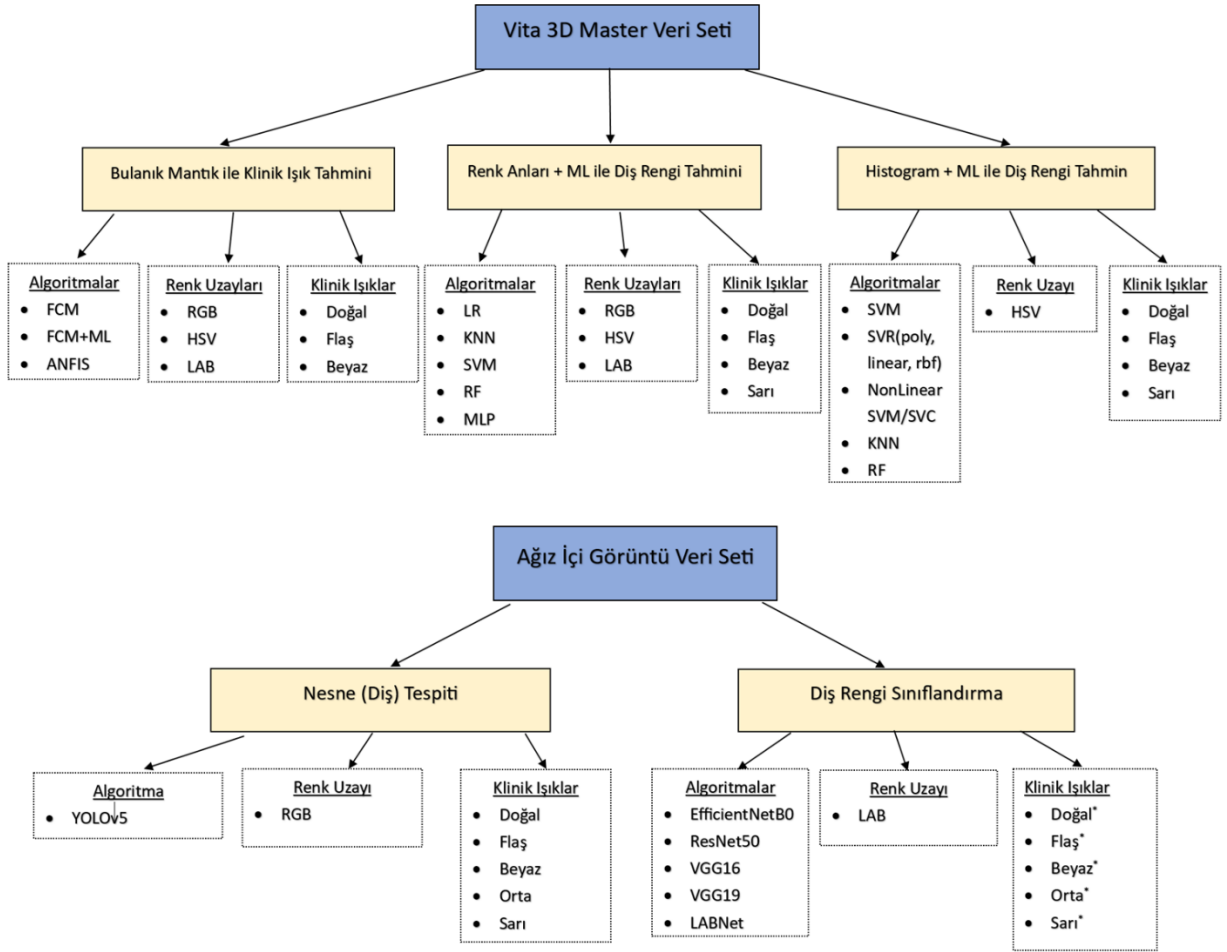
Özellik	Diş Tespiti	Renk Sınıflandırma
Toplam görüntü sayısı	1000	15.810
Eğitim verisi (%)	90%	80%
Doğrulama verisi (%)	10%	20%
Model	YOLOv5	LABNet
Görüntünün girdi boyutu	640x640px	128 x128px
Kırılma faktörü	-	0.3
Kullanılan renk uzayı	RGB	LAB
Veri artırımı	Varsayılan	Yatay ve dikey çevirme - Dengeleme
Ön işlem	Varsayılan	L kanalına CHALE uygulanması
Verideki klinik ışık sayısı	5	5
Sınıf sayısı	12 diş	6 renk
Tekrar (Epoch)	50	30
Toplu işlem boyutu (Batchsize)	16	32



Şekil 20. Otomatik diş rengi tespiti çalışmasının özeti.

Bu tez kapsamında yapılan tüm çalışmaların genel çerçevesi Şekil 21’de gösterilmiştir.

FARKLI KLİNİK IŞIKLARI ALTINDA KAYDEDİLEN DENTAL FOTOĞRAFLARA AİT DİŞ RENKLERİNİN YAPAY ZEKÂ TEKNİKLERİ KULLANILARAK TESPİTİ



- Doğal* : Doğal ışık kaynağı altında flaş desteksiz
 Flaş* : Doğal ışık kaynağı altında flaş destekli
 Beyaz* : Dental ünit reflektörünün sarı ışığını simüle edecek şekilde flaş desteksiz (2700 K)
 Orta* : Dental ünit reflektörünün gün ışığını simüle edecek şekilde flaş desteksiz (4600 K)
 Sarı* : Dental ünit reflektörünün gün ışığını simüle edecek şekilde flaş desteksiz (6500 K)


Şekil 21. Çalışmanın genel çerçevesi.

ARAŞTIRMA BULGULARI

Bu bölümde, geliştirilen ve uygulanan yöntemsel adımların çıktıklarına dair bulgular ayrıntılı biçimde sunulmaktadır. Bulgular, ön işleme süreciyle birlikte geleneksel YZ yaklaşımlarına dayalı ML tekniklerinden başlayarak, DL tabanlı yöntemlere doğru ilerleyen bütüncül bir analiz yapısı içerisinde sunulmuştur. Her bir alt bölümde, kullanılan yöntemlerin performansı değerlendirilmiş, elde edilen sonuçlar görsel ve sayısal biçimde açıklanmış ve ilgili metriklerle desteklenmiştir.

Bulanık Mantık Yönteminin Bulguları


Bu çalışmada renk anları yöntemi ile görüntüler sayısal kümelere dönüştürülmüştür. RGB, LAB ve HSV renk uzayları kullanıldığından her renk uzayı için ayrı bir veri seti oluşturulmuştur. Veri setindeki özniteliklerin önemini belirlemek için FL sisteminde doğru kuralların oluşturulması ve karar alma sürecini etkilemektedir. Doğru özniteliklerin seçilmesi, FL üyelik fonksiyonlarının daha iyi tanımlanmasına yol açar. Bu nedenle veri setleri için öznitelik önemleri çıkarılmıştır. Her veri seti için ilk dört öznitelik belirlenmiş ve FL yöntemleri uygulanmıştır. Veri setleri için klinik ışıklara göre öznitelik önemlerinin grafikleri Şekil 22'de gösterilmiştir.



Şekil 22. LAB, HSV ve RGB veri kümeleri için özellik önemi (sırasıyla gösterilmiştir).


Verilerin bulanık kümeleme analizi FCM algoritması kullanılarak gerçekleştirilmiştir. Özellik önemine göre belirlenen özellik (örneğin LAB veri kümesi için MeanA, MeanL, StdL, Skewb) kümeleme işlemine tabi tutulmuş ve her bir veri noktasının üyelik dereceleri hesaplanmıştır. Bu çalışmada klinik ışıklarına ilişkin üç farklı tahmin olacağından, bulanık kümeleme işlemi de üçe bölünmüştür. Üyelik fonksiyonları Gauss dağılımı ile tanımlanmıştır. Verilerin bulanık kümelere atanması sürecinde, her veri noktası için düşük ve yüksek üyelik fonksiyonları oluşturulmuştur. Bu fonksiyonlar her özellik için çıkarılmıştır. Veri kümelerinde ışıkla en yüksek korelasyona sahip özelliklerin üyelik fonksiyon grafikleri Şekil 23'te

gösterilmektedir. Grafiklere göre, bazı değerlerde sapmalar olduğu gözlemlenmektedir. Bu sapmalar, verilerin doğal yapısından kaynaklanmaktadır. Bu tür anomaliler nispeten küçük veri kümelerinde daha sık görülür. Bu sapmaların modelin genel eğilimi üzerinde önemli bir olumsuz etkisi olmadığı düşünülmüştür. Aykırı değerlerin çıkarılması modelin doğruluğunu artırsa da, mevcut veri kümesinin sınırlı olması nedeniyle her veri kümesini korumak daha yararlı olacağı düşünülmüştür. Bu nedenle, aykırı değerlere müdahale edilmemiş ve üyelik fonksiyonları grafiklerde olduğu gibi bırakılmıştır.



Şekil 23. LAB, HSV ve RGB veri kümeleri için üyelik fonksiyonlarına bir örnek (sırasıyla gösterilmiştir).

Ayrıca, FCM tarafından kümelere ayrılan verilerin kümeler arasındaki dağılımı, Şekil 24'te iki boyutlu grafikler aracılığıyla gösterilmektedir. Grafik dağılımı, seçilen özelliklere göre şekillenir. Bu grafikler, FCM algoritmasının verileri farklı kümelere nasıl dağıttığını açıkça gösterir. FCM'nin temel özelliği olan üyelik derecelerine dayalı bulanık kümeler sayesinde, her veri noktası kesin olarak tek bir kümeyle atanmaz, bunun yerine birden fazla kümeyle ait olma olasılığı üzerinden değerlendirilir. Bu, özellikle verilerin birbirine yakın olduğu bölgelerdeki geçişleri açıklamaktadır.



Şekil 24. LAB, HSV ve RGB veri kümeleri için FCM kümelemesi (sırasıyla gösterilmiştir).


Kümeleme sonuçları daha sonra ışık etiketleriyle eşleştirilerek her bir kümenin hangi ışık kaynağıyla ilişkili olduğu belirlenmiştir. İlk olarak, kümelere ait veriler için en yaygın ışık etiketi tespit edilmiş ve bu bilgi, küme-ışık kaynağı eşleşmesi olarak kaydedilmiştir. Ardından, her bir veri için tahmin edilen ışık etiketi, küme üyeliğine göre belirlenmiştir. FCM algoritması, verileri etiketler olmadan kümelere ayıran denetimsiz bir öğrenme yöntemi olarak kullanılmaktadır. Ancak bu çalışmada, FCM ile elde edilen kümeler, bir sınıflandırma yapısı oluşturmak amacıyla ışık etiketleriyle eşleştirilmiştir. Bu şekilde, tahmin edilen ışıkların gerçek

ışıklar karşılaştırılarak doğruluk, duyarlılık, kesinlik ve F1 skor gibi sınıflandırma performans ölçütleri hesaplanabilmiştir. FCM kümeleme sonuçları Tablo 5’te gösterilmiştir.

Tablo 5. FCM Kümelemesinin Sonuçları

Veri setleri	Sınıflar	Kesinlik(%)	Duyarlılık(%)	F1-Skor(%)	Doğruluk(%)
LAB	Beyaz	67	81	73	79
	Doğal	76	60	67	
	Flaş	96	96	96	
HSV	Beyaz	47	51	49	62
	Doğal	53	54	54	
	Flaş	93	81	86	
RGB	Beyaz	57	54	56	52
	Doğal	39	51	44	
	Flaş	66	50	57	

Tablo 5’te görüldüğü gibi, LAB renk uzayı, %79 doğruluk oranıyla en yüksek performansı göstermiştir. HSV renk uzayı, %62 doğruluk oranıyla orta düzeyde bir başarı sağlamıştır. RGB renk uzayı ise %52 doğruluk oranıyla daha düşük bir performans sergilemiştir. Flaş ışığının, diğer ışık kaynaklarına kıyasla daha keskin bir ayırım yarattığı gözlemlenmiştir. Bu nedenle, metamerizm üzerindeki etkisinin daha belirgin olduğu sonucuna varılmıştır. Doğal ve beyaz ışık koşullarında ise bu ayırım daha az belirginleşmiştir ve metamerizm etkisi daha düşük seviyede kalmıştır. Buna göre, farklı renkler beyaz ve doğal ışık altında benzer görüldüğü için yanlış seçimlere neden olabileceği değerlendirilmiştir. Benzer şekilde, ışık farkının yüksek olduğu flaş ışığında aynı renk farklı ışıkta çok farklı görünebilir; ancak ışık kaynaklarının ayırım performansı arttıkça bu durumların tolere edilebileceği anlaşılmıştır. Çünkü görüntünün hangi ışıkta çekildiği doğru şekilde ayırt edildiğinde, bir sonraki adım olan görüntü renginin belirlenmesi daha kolay hale gelmektedir.



Şekil 25. FCM için karmaşıklık matrisleri.


Şekil 25, FCM algoritması ile elde edilen sonuçların karmaşıklık matrisini göstermektedir. Örneğin, LAB veri setinde flaş ışığı altında 138 doğru tahmin ve 6 yanlış tahmin yapılmıştır. Doğal ışıkta ise 58 görüntü hatalı şekilde beyaz ışık olarak sınıflandırılmıştır. HSV veri setinde, beyaz ve doğal ışığın sıklıkla karıştırıldığı

gözlemlenmiştir; çünkü doğru ve yanlış sınıflamalar birbirine oldukça yakındır. RGB veri seti ise diğerlerine kıyasla daha düşük doğrulukla tahmin yapmış ve ışık kaynaklarının birbirine karıştırıldığı tespit edilmiştir.

FCM'den elde edilen doğruluk oranlarını artırmak amacıyla, FCM yöntemi ML algoritmalarıyla (LAB için KNN, HSV için KNN, RGB için RF sınıflandırıcıları) birleştirilerek hibrit bir model oluşturulmuştur. Seçilen sınıflandırıcılar, veri setleri için en iyi hibrit modeli oluşturacak şekilde belirlenmiştir. Veri setleri çapraz doğrulama (K=10) ve eğitim %80-test %20 olacak şekilde bölünerek eğitilmiştir. Hibrit modelin uygulanması sonucunda, LAB için doğruluk oranı %79'dan %99'a, HSV için %62'den %93'e ve RGB için %52'den %95'e yükselmiştir. Bu sonuçlar, hibrit yaklaşımın tüm renk uzaylarında önemli bir performans artışı sağladığını göstermektedir. Sınıflandırma sonuçlarının ayrıntıları Tablo 6'da verilmiştir. Şekil 26 bu modelin karmaşıklık matrisini göstermektedir.

Tablo 6. FCM & ML Sonuçları

Veri seti	Sınıflar	FCM & ML sonuçları (K=10)(%)				FCM & ML sonuçları (eğitim: %80-test: %20)(%)			
		Kesinlik	Duyarlılık	F1-skor	Doğruluk	Kesinlik	Duyarlılık	F1-Skor	Doğruluk
LAB	Beyaz	88	95	91	93	100	97	99	99
	Doğal	91	88	90		97	100	98	
	Flaş	100	97	98		100	100	100	
HSV	Beyaz	83	85	84	88	97	88	92	93
	Doğal	88	87	87		90	93	92	
	Flaş	94	92	93		92	100	96	
RGB	Beyaz	86	79	82	89	97	91	94	95
	Doğal	84	89	86		90	97	93	
	Flaş	95	98	97		100	100	100	



Şekil 26. FCM & ML için karmaşıklık matrisleri.


ANFIS yönteminde de öznitelik önemine göre 4 öznitelik belirlenerek girdi olarak kullanılmıştır. Ayrıca ANFIS modelinde tüm veri kümeleri için tekrar sayısı 100 alınırken kural sayısı veri kümelerine göre değişmektedir. Veri kümelerinin kural sayısına göre performansları değerlendirilmiş ve optimum kural sayısı belirlenerek eğitim tamamlanmıştır. FL ve yapay sinir

ağlarının birleştiren ANFIS modeli ışık koşullarını tahmin etmede yüksek doğruluk oranlarına ulaşmıştır. Tablo 7'de sınıflandırma sonuçlarının detayları gösterilmektedir.

Tablo 7. ANFIS Sonuçları


Veri seti	Sınıf	Kesinlik(%)	Duyarlılık(%)	F1-Skor(%)	Doğruluk (%)	Kayıp
LAB	Beyaz	100	97	99	98	0,1259
	Doğal	92	100	96		
	Flaş	100	97	98		
HSV	Beyaz	94	86	90	92	0,1420
	Doğal	96	100	98		
	Flaş	88	93	90		
RGB	Beyaz	91	89	90	92	0,1420
	Doğal	100	100	100		
	Flaş	87	90	89		

LAB renk uzayında, ANFIS modeli %98 doğrulukla en yüksek performansı göstermiştir. Bu sonuç, LAB renk uzayının renk doğruluğu açısından klinik uygulamalar için daha uygun olduğunu desteklemekte ve bu modelle metamerizm etkisinin büyük ölçüde en aza indirildiğini göstermektedir. LAB uzayı, ışık kaynakları arasında en tutarlı sınıflandırmayı sağlayarak ışık koşullarının etkilerinin doğru bir şekilde modellenebileceğini göstermektedir. HSV ve RGB renk uzaylarında elde edilen sonuçlar da her iki uzayda da %92 doğrulukla oldukça iyidir. Şekil 27'de sunulan karmaşıklık matrisleri, ANFIS modelinin ışık kaynaklarını başarılı bir şekilde ayırt ettiğini göstermektedir. LAB renk uzayında, beyaz ve flaş ışığı her biri bir yanlış sınıflandırma ile sınıflandırılırken, özellikle doğal ışık %100 doğrulukla tahmin edilmektedir.



Şekil 27. ANFIS için karmaşıklık matrisleri.

ANFIS ile elde edilen kayıp değerleri LAB için 0.1259, HSV ve RGB için 0.1420 olarak hesaplanmıştır. Doğruluk kayıp grafiği Şekil 28'de gösterilmiştir. Kayıp düşük ve sıfıra yakın olduğunda performansın yüksek olduğunu göstermektedir. Doğruluk ne kadar yüksekse performans da o kadar iyidir. Model 100 tekrar için eğitilmiş ve her 10 tekrarda bir kayıp ve doğruluk değerleri kaydedilerek grafikler çizilmiştir.



Şekil 28. ANFIS modelinin doğruluk kayıp grafiği.

Renk Anları ve Makine Öğrenmesi Bulguları

Bu çalışmada üç renk uzayı da kullanılmıştır. Dört farklı veri seti oluşturulmuştur. Her veri seti için 5 farklı ML algoritması uygulanmıştır. Dört klinik ışığın sınıflandırılması ve ışık kaynaklarından bağımsız (hangi klinik ışığı altında çekilmiş olursa olsun) 29 rengin sınıflandırılması yapılmıştır. Ayrıca beyaz ışık, doğal ışık, sarı ışık ve flaş ışığı kaynaklarında da 29 rengin sınıflandırılması yapılmıştır. Bu kapsamlı yönüyle ve farklı klinik ışıklarla birlikte çalışıp metamerizmi ele almasıyla diğer çalışmalardan ayrılmaktadır. Renk anlarıyla elde edilen özniteliklerin, renk uzayından bağımsız şekilde birleştirilmesiyle oluşturulan veri setine ait sonuçlar Tablo 8’de, RGB veri setinin sonuçları Tablo 9’da, HSV veri setinin sonuçları Tablo 10’da ve LAB veri setinin sonuçları ise Tablo 11’de sunulmuştur.

Tablo 8. Tüm Öznitelikleri İçeren Veri Setinden Elde Edilen Sonuçlar

Bölme oranı	Işık kaynağına bağımlılık	Sınıflandırma	Algoritmalar ve doğrulukları				
			LR	KNN	SVM	RF	MLP
Eğitim: %70 Test: %30	Bağımsız	4 farklı klinik ışık	0,99	0,98	0,99	0,98	0,99
		29 farklı Vita rengi	0,54	0,83	0,80	0,85	0,55
	Bağımlı	Beyaz ışıkta 29 renk	0,98	0,95	0,95	0,98	0,89
		Doğal ışıkta 29 renk	0,84	0,91	0,91	0,89	0,68
		Flaşlı ışıkta 29 renk	0,59	0,54	0,61	0,84	0,50
K:5	Bağımsız	4 farklı klinik ışık	0,90	0,87	0,91	0,85	0,91
		29 farklı Vita rengi	0,41	0,75	0,67	0,76	0,46
	Bağımlı	Beyaz ışıkta 29 renk	0,97	0,96	0,97	0,97	0,91
		Doğal ışıkta 29 renk	0,90	0,92	0,93	0,97	0,84
		Flaşlı ışıkta 29 renk	0,78	0,76	0,85	0,92	0,67
		Sarı ışıkta 29 renk	0,94	0,88	0,91	0,93	0,86

Tablo 9. RGB Veri Setinden Elde Edilen Sonuçlar

Bölme oranı	Işık kaynağına bağımlılık	Sınıflandırma	Algoritmalar ve doğrulukları				
			LR	KNN	SVM	RF	MLP
Eğitim: %70 Test: %30	Bağımsız	4 farklı klinik ışık	0,96	0,95	0,98	0,94	0,98
		29 farklı Vita rengi	0,41	0,77	0,73	0,81	0,57
	Bağımlı	Beyaz ışıkta 29 renk	0,90	0,95	0,93	0,93	0,89
		Doğal ışıkta 29 renk	0,89	0,86	0,95	0,89	0,77
		Flaşlı ışıkta 29 renk	0,57	0,59	0,63	0,68	0,66
	Sarı ışıkta 29 renk	0,75	0,75	0,82	0,80	0,66	
K:5	Bağımsız	4 farklı klinik ışık	0,90	0,82	0,87	0,82	0,90
		29 farklı Vita rengi	0,30	0,69	0,53	0,65	0,49
	Bağımlı	Beyaz ışıkta 29 renk	0,94	0,94	0,93	0,90	0,86
		Doğal ışıkta 29 renk	0,90	0,92	0,95	0,89	0,72
		Flaşlı ışıkta 29 renk	0,72	0,76	0,82	0,82	0,43
	Sarı ışıkta 29 renk	0,88	0,83	0,89	0,89	0,82	

Tablo 10. HSV Veri Setinden Elde Edilen Sonuçlar

Bölme oranı	Işık kaynağına bağımlılık	Sınıflandırma	Algoritmalar ve doğrulukları				
			LR	KNN	SVM	RF	MLP
Eğitim: %70 Test: %30	Bağımsız	4 farklı klinik ışık	0,94	0,97	0,97	0,95	0,98
		29 farklı Vita rengi	0,46	0,80	0,71	0,85	0,69
	Bağımlı	Beyaz ışıkta 29 renk	0,91	1,00	0,98	0,95	0,80
		Doğal ışıkta 29 renk	0,82	0,93	0,93	0,93	0,66
		Flaşlı ışıkta 29 renk	0,40	0,61	0,55	0,71	0,45
	Sarı ışıkta 29 renk	0,82	0,78	0,76	0,93	0,71	
K:5	Bağımsız	4 farklı klinik ışık	0,87	0,85	0,89	0,84	0,89
		29 farklı Vita rengi	0,35	0,73	0,56	0,71	0,48
	Bağımlı	Beyaz ışıkta 29 renk	0,98	0,98	0,97	0,97	0,73
		Doğal ışıkta 29 renk	0,90	0,90	0,92	0,94	0,80
		Flaşlı ışıkta 29 renk	0,60	0,70	0,74	0,88	0,45
	Sarı ışıkta 29 renk	0,91	0,87	0,90	0,91	0,85	

Tablo 11. LAB Veri Setinden Elde Edilen Sonuçlar

Bölme oranı	Işık kaynağına bağımlılık	Sınıflandırma	Algoritmalar ve doğrulukları				
			LR	KNN	SVM	RF	MLP
Eğitim: %70 Test: %30	Bağımsız	4 farklı klinik ışık	0,95	1,00	0,98	0,98	0,99
		29 farklı Vita rengi	0,37	0,74	0,72	0,84	0,54
	Bağımlı	Beyaz ışıkta 29 renk	0,86	0,98	0,95	0,95	0,82
		Doğal ışıkta 29 renk	0,84	0,89	0,91	0,93	0,75
		Flaşlı ışıkta 29 renk	0,59	0,64	0,70	0,84	0,62
	Sarı ışıkta 29 renk	0,80	0,82	0,84	0,91	0,64	
K:5	Bağımsız	4 farklı klinik ışık	0,89	0,85	0,88	0,86	0,89
		29 farklı Vita rengi	0,30	0,68	0,64	0,74	0,46
	Bağımlı	Beyaz ışıkta 29 renk	0,94	0,94	0,95	0,95	0,74
		Doğal ışıkta 29 renk	0,90	0,91	0,95	0,95	0,81
		Flaşlı ışıkta 29 renk	0,74	0,75	0,78	0,90	0,63
	Sarı ışıkta 29 renk	0,88	0,88	0,90	0,94	0,85	

Elde edilen bulgular en yüksek doğruluk değerlerinin sınıflandırıcı, bölme oranı ve veri setine bağlı olarak değiştiğini göstermektedir. Problemin hem veri seti hem algoritma hem de bölme oranı çeşitliliğiyle ele alınması, daha güvenilir ve uygun bir modelin geliştirilmesine olanak sağlamıştır. Farklı sınıflandırma yöntemleriyle elde edilen ve %85-%100 arasında değişen doğruluk değerleri, geleneksel renk değerlendirme yöntemlerinin ML teknikleriyle uygulanabileceğini göstermiştir. Bu çalışmada kullanılan farklı sınıflandırma yöntemleri diğer klinik durumlar (örneğin, en uygun klinik ışığın belirlenmesi) için de sonuç üretme potansiyeli taşımaktadır. Bu durum ML yöntemlerinin çeşitli alanlardaki problemlere birden fazla yenilikçi çözüm sunma potansiyelini de göstermektedir.

Histogram ve Makine Öğrenmesi Bulguları

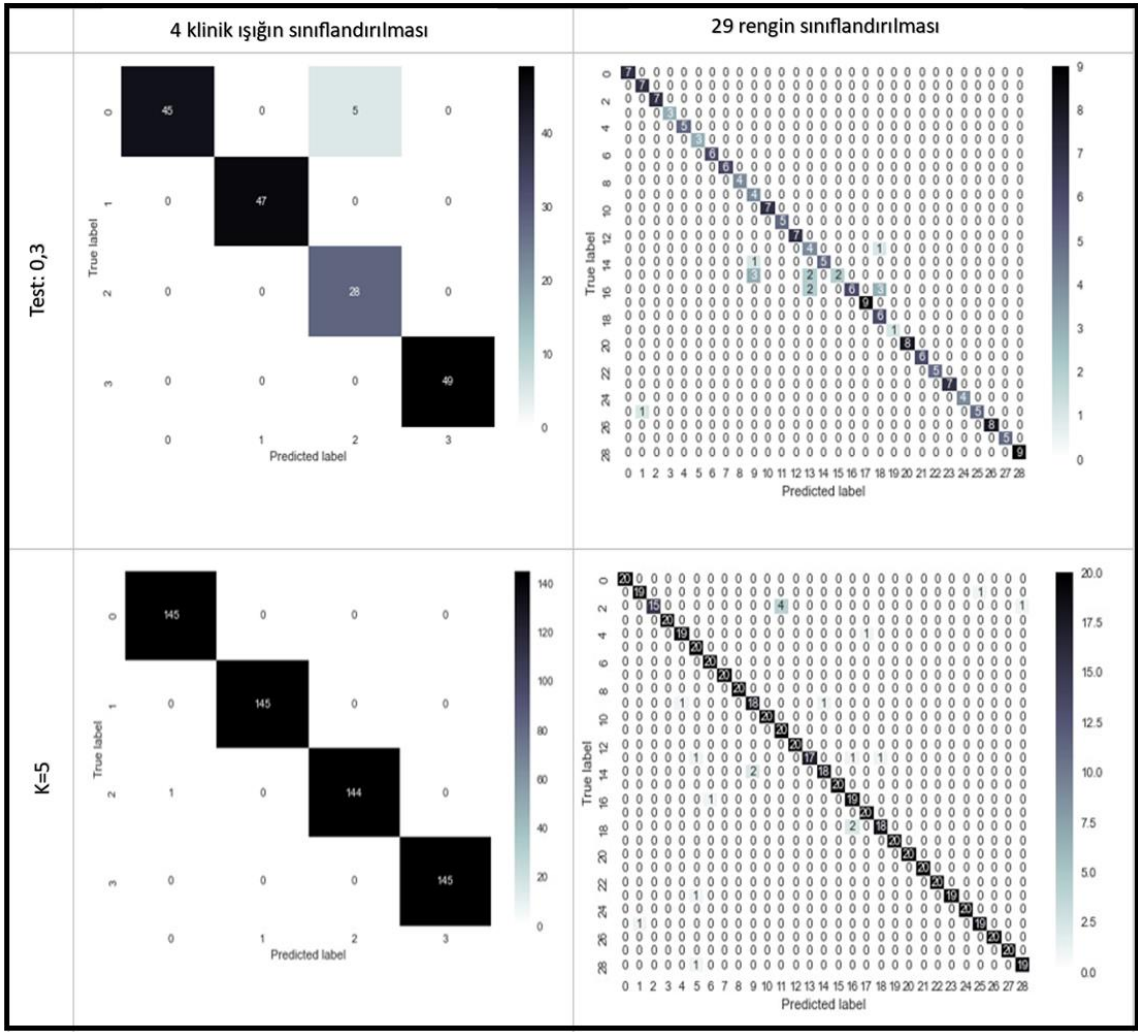
Tablo 12’de görüldüğü üzere, görüntünün hangi ışık kaynağı altında çekildiğinden bağımsız olarak, renk tanımada yüksek doğruluk elde edilmiştir. Eğitim/test veri kümesi %70/%30 oranında bölündüğünde dikkate değer başarılar gözlemlenmiştir. Özellikle, dört farklı klinik ışık koşulunun sınıflandırılmasında en yüksek doğruluk oranı %97,13 ile Nonlinear SVC algoritmasında elde edilmiştir. Aynı şekilde, 29 renk sınıfının sınıflandırılmasında da en yüksek doğruluk oranı %92,53 ile yine Nonlinear SVC algoritmasına aittir.

Tablo 12. Histogram ve ML Sonuçları

Bölme oranı	Işık kaynağına bağımlılık ve sınıflandırma	Algoritmalar ve doğrulukları (%)									
		SVM	SVR (Reg-poly)	SVR (Reg-linear)	SVR (Reg-rbf)	NonL inear SVM	NonLi near SVC	KNN	RF		
Eğitim: %70 Test: %30	Bağımsız	4 farklı klinik ışık	94,83	87,91	84,85	87,53	79,31	97,13	93,68	90,23	
		29 farklı Vita rengi	87,36	69,55	73,06	87,13	62,07	92,53	82,76	78,16	
	Bağımlı	Beyaz ışıkta 29 renk	95,45	97,54	97,59	98,19	86,36	100,0	88,64	86,36	
		Doğal ışıkta 29 renk	97,73	96,51	96,97	97,05	65,91	97,73	88,64	97,73	
		Flaşlı ışıkta 29 renk	97,73	92,53	95,32	94,64	72,73	97,73	86,36	86,36	
		Sarı ışıkta 29 renk	86,36	53,88	79,42	84,50	75,00	97,73	72,73	86,36	
	CV:5	Bağımsız	4 farklı klinik ışık	98,62	95,07	93,20	94,94	87,07	99,83	98,10	95,86
			29 farklı Vita rengi	96,03	81,23	73,86	89,08	75,00	97,93	94,31	89,66
Bağımlı		Beyaz ışıkta 29 renk	99,31	98,39	97,76	98,65	99,31	100,0	100,0	99,31	
		Doğal ışıkta 29 renk	99,31	97,35	97,92	97,91	99,31	99,31	99,31	99,31	
		Flaşlı ışıkta 29 renk	95,86	92,66	90,06	92,64	94,48	96,55	95,17	95,17	
		Sarı ışıkta 29 renk	96,55	61,25	75,54	81,73	96,55	95,86	95,86	93,10	

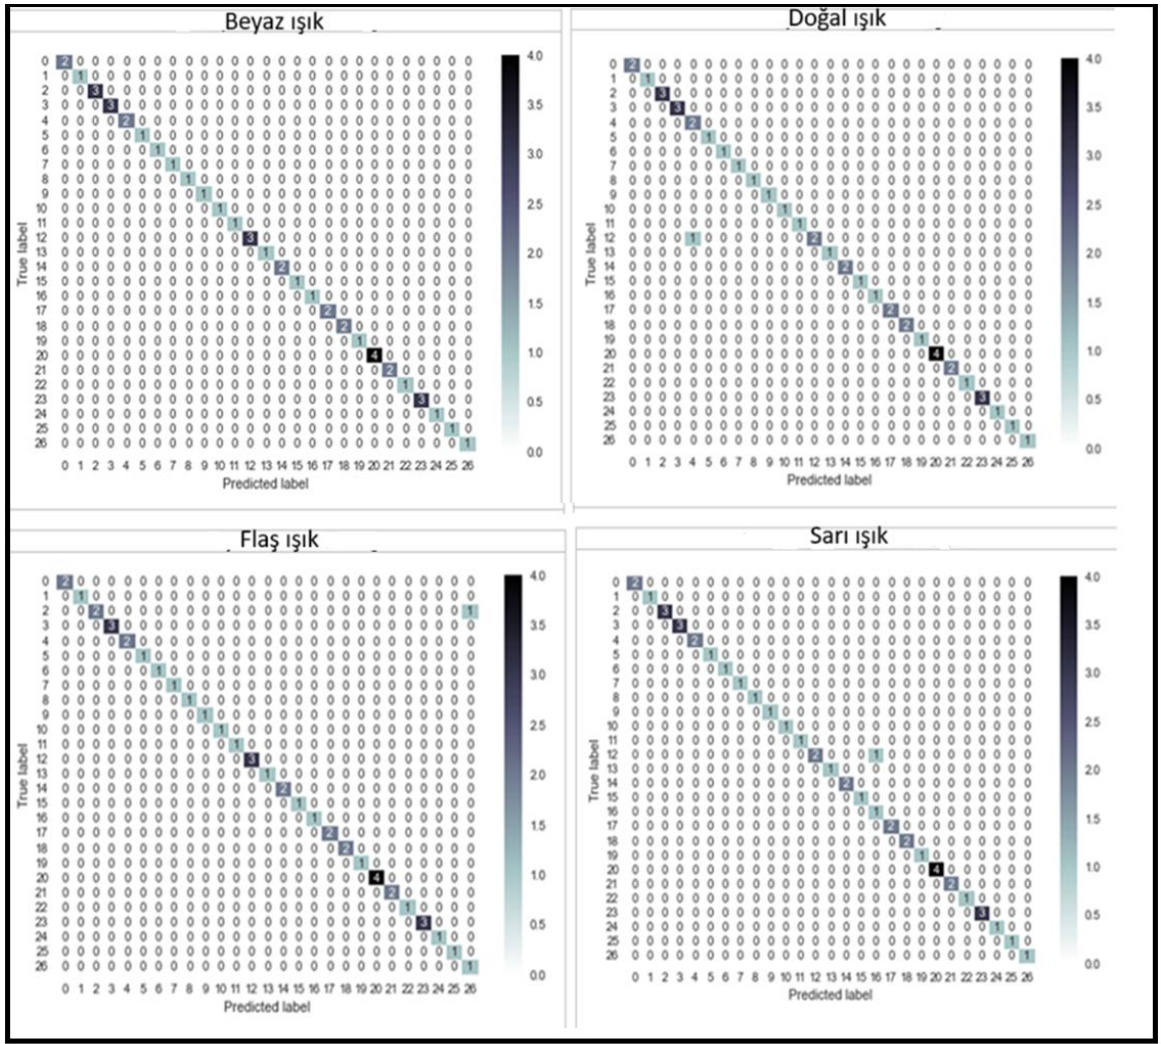
Dikkat çekici bir bulgu ise, beyaz ışık altında çekilen görüntülerde 29 renk için sınıflandırmanın %100 doğrulukla gerçekleştirilmiş olmasıdır; bu durum yöntemin kontrollü aydınlatma altında ne denli başarılı olduğunu göstermektedir. Ayrıca, Nonlinear SVC ile doğal, flaş ve sarı ışık koşullarında yapılan 29 renk sınıflandırmasında doğruluk oranı %97,73 gibi yüksek bir seviyede kalmıştır. Çapraz doğrulama sonuçları da renk histogramının etkinliğini bir kez daha doğrulamaktadır. Tablo 12’de yer alan bu sonuçlara göre, dört farklı klinik ışığın sınıflandırılmasında en yüksek doğruluk oranı %99,83 ile Nonlinear SVC tarafından elde edilmiştir. Aynı algoritma ile 29 renk sınıfında %97,93 doğruluğa ulaşılmıştır. Özellikle beyaz ışık altında, sınıflandırma doğruluğu %100 olarak gözlenmiş ve bu durum, yönteminin güçlü aydınlatma koşulları altında ne kadar tutarlı olduğunu vurgulamıştır. Doğal ışık senaryosunda da Nonlinear SVC ile %99,31 doğruluk oranı elde edilmiştir. Flaş ve sarı ışık koşullarında ise doğruluk oranlarında küçük farklılıklar gözlemlenmiş; Nonlinear SVC ve Nonlinear SVM algoritmaları sırasıyla %96,55 doğruluk ile yüksek performanslarını sürdürmüştür. Genel olarak, Nonlinear SVC algoritmasıyla en yüksek başarı elde edilmiştir. Sonuçlar, tüm yaklaşımların yüksek doğruluk seviyeleriyle tutarlı sınıflandırma gerçekleştirdiğini göstermektedir. Bu bulgular, YZ temelli yöntemlerin metamerizm kaynaklı görsel belirsizlikleri azaltmada etkili bir çözüm sunduğunu ortaya koymaktadır.

Elde edilen en yüksek doğruluk değerlerine karşılık gelen karmaşıklık matrisleri Şekil 29 ve Şekil 30 gösterilmiştir.



Şekil 29. Işık kaynağından bağımsız sınıflandırmanın en iyi doğruluk oranlarının karmaşıklık matrisleri.


Özellikle, klinik ışıkların sınıflandırılmasında yalnızca beş test veri noktası yanlış tahmin edilmiştir. Ancak aynı sınıflandırma için K=5 olarak seçildiğinde, karmaşıklık matrisi yalnızca bir yanlış tahmini ortaya koymuş ve neredeyse mükemmel bir sonuç göstermiştir. Benzer şekilde, 29 rengin sınıflandırılmasında da K=5 için gelişmiş sonuçlar gözlemlenmiştir. Her bir klinik ışık sınıflandırması 145 görüntüden oluşmaktadır. K=5 için her alt kümede yer alan örnek sayısının sınırlı olması nedeniyle, bu sınıflandırmalara ilişkin karmaşıklık matrisleri %30'luk bir test kümesi boyutuyla eğitilen modele dayalı olarak sunulmuştur. Ayrıca, veri kıtlığı nedeniyle test verilerinin 29 sınıfın tamamını içermemesi olasılığı göz önünde bulundurularak, karmaşıklık matrisleri test verilerinde yer alan sınıf sayısına göre gösterilmiştir. Şekil 30 görüldüğü üzere, beyaz klinik ışık altında çekilen görüntüler için yapılan tüm tahminlerin doğru olduğu gözlemlenmiştir. Benzer şekilde



Şekil 30. Işık kaynağına bağımlı sınıflandırmanın en iyi doğruluk oranlarının karmaşıklık matrisleri (test: %30).

YOLOv5 ile Diş Tespiti Bulguları

Bu çalışmada kullanılan veri setinde 12 diş sınıfı bulunmakta ve her biri eşit sayıda gözlem içermektedir. İlişki grafiği (correlogram), her gözlemde ölçülen özellikler (x, y, w, h) arasındaki korelasyonları görsel olarak sunan bir grafik türüdür. Genellikle matris biçiminde düzenlenen bu grafiklerde her hücre, iki özellik arasındaki korelasyon katsayısını temsil eder. Grafik renk tonları, pozitif ve negatif korelasyonları belirtir; koyu tonlar güçlü, açık tonlar ise zayıf korelasyonları gösterir. Bu sayede, çok özellikli veri setlerinde hangi özelliklerin birbirleriyle güçlü ilişkide olduğu, hangilerinin ise bağımsız kaldığı hızlıca tespit edilebilir. Konum ve boyut özelliklerine ait ilişki grafiği Şekil 31 'de gösterilmiştir.



Şekil 31. Konum ve boyut özelliklerine ait ilişki grafiği.

Şekil 31'e bakıldığında, üst kısımda yer alan histogramlar, x eksenindeki dağılımın ortalama yaklaşık 0.5 civarında ve simetrik olduğunu ortaya koymaktadır; bu durum, nesnelerin yatay düzlemde ağız içerisinde ortalandığını göstermektedir. Y eksenindeki dağılım ise hafifçe ortalamasının üzerinde yoğunlaşma sergilemekte olup, nesnelerin konumlarının ağızın orta-üst bölgesine denk geldiğini düşündürmektedir. Dağılım noktaları incelendiğinde, x ve y koordinatları arasında dikeyde merkezileşmiş bir dağılım gözlemlenmektedir; bu da verinin çene yapısına paralel bir yayılım gösterdiğine işaret etmektedir. Genişlik (Width) ile yükseklik (height) özellikleri arasında pozitif yönlü bir korelasyon bulunmakta, daha geniş nesnelerin genellikle daha yüksek olduğu anlaşılmaktadır. Bu durum, farklı diş türlerinin boyutsal tutarlılığını destekler niteliktedir. Buna karşın, width-x ve height-y grafiklerinde belirgin bir örüntü bulunmamakta; konum ile boyut arasında sistematik bir ilişkinin olmadığı gözlemlenmektedir. Bu durum ise anatomik olarak beklenen bir sonucu yansıtmaktadır. Genel olarak, etiket dağılımının hem konumsal hem de boyutsal açıdan düzenli ve tutarlı bir biçimde gerçekleştirildiği anlaşılmaktadır. Veri setinde belirgin bir boşluk ya da dengesizlik bulunmaması, modelin eğitim sürecini ve genelleme performansını olumlu yönde etkilemektedir. Width-height arasındaki pozitif korelasyon, anatomik yapıların doğru ve tutarlı biçimde temsil edildiğine dair güçlü bir kanıt sunmaktadır.

Çalışmada YOLOv5 modeli varsayılan hiperparametre değerleriyle eğitilmiştir. Bu parametreler; öğrenme oranı, momentum ve ağırlık cezası gibi optimizasyon süreciyle ilgili ayarların yanı sıra, renk uzayı dönüşümleri, görüntü çevirme ve mozaikleme gibi çeşitli veri


artırma tekniklerini de kapsamaktadır. Model mimarisi toplamda 368 katmandan ve yaklaşık 46.1 milyon öğrenilebilir parametreden oluşmaktadır. Eğitim süreci yaklaşık 5 saat sürmüş olup, 50 tekrar boyunca öğrenme gerçekleştirilmiştir. Optimizasyon işlemi SGD algoritmasıyla yürütülmüş ve öğrenme oranı 0.01 olarak belirlenmiştir. Model 640×640 piksel çözünürlüğündeki görüntüler kullanılarak eğitilmiştir. Anchor (çapa) kutuları, eğitim verisindeki nesne boyutlarına göre otomatik olarak optimize edilip böylece modelin, her bir ızgara hücresinde farklı oranlardaki nesnelere tahmin etmesi kolaylaştırmıştır. Bu sayede model, farklı boyutlardaki dış yapılarının (örneğin küçük azı dişleri ile geniş ön dişler gibi) tespitinde daha hassas sonuçlar elde etmiştir. Veri ayrımı kapsamında, veri setinin %90'ı model eğitimi (train.py) için, %10'u ise doğrulama (val.py) amacıyla kullanılmıştır. Modelin başarımı yalnızca doğrulama verisi üzerinden değil; aynı zamanda eğitim ve doğrulama aşamalarına dahil edilmemiş, bağımsız görüntüler üzerinde yapılan testler (detect.py) ile de değerlendirilmiştir. Tablo 13'te YOLOv5 modelinin doğrulama verisi üzerindeki sınıf bazlı performans sonuçları sunulmuştur.

Tablo 13. YOLOv5 Modelinin Doğrulama Veri Seti Üzerindeki Performans Sonuçları

Sınıf (Diş)	Görüntü Sayısı	Kesinlik	Duyarlılık	mAP@50	mAP@50-95
Tümü	1200	0,998	0,999	0,995	0,893
1	100	0,999	1,000	0,995	0,887
2	100	0,998	1,000	0,995	0,904
3	100	0,998	1,000	0,995	0,947
4	100	0,998	1,000	0,995	0,931
5	100	1,000	0,988	0,995	0,881
6	100	1,000	1,000	0,995	0,870
7	100	1,000	1,000	0,995	0,855
8	100	0,999	1,000	0,995	0,878
9	100	0,993	1,000	0,995	0,893
10	100	0,998	1,000	0,995	0,899
11	100	0,998	1,000	0,995	0,896
12	100	0,998	1,000	0,995	0,882


Tablo 13'e göre tüm sınıflar genelinde model, yüksek kesinlik ve duyarlılık göstermiştir. Kesinlik ve duyarlılık değerlerinin büyük çoğunlukla 0.99 ve üzerinde olması, modelin hem doğru pozitif oranının yüksek olduğunu hem de tespit edilmesi gereken nesnelere neredeyse hiç kaçırmadığını göstermektedir. Özellikle mAP@50 değerlerinin tüm sınıflarda 0.995 düzeyinde olması, modelin farklı diş sınıflarını yüksek doğrulukla tespit edebildiğini ortaya koymaktadır. mAP@50-95 metriği, daha ayrıntılı ve zorlayıcı bir değerlendirme sağladığından sınıflar arasında belirli varyasyonlar gözlemlenmiştir (0.855–0.947 aralığında). Ancak bu metrikte de genel performansın yüksek olduğu söylenebilir. Bu başarılı sonuçlar, eğitim verisinin yeterli çeşitliliğe sahip olması ve anchor kutularının otomatik olarak optimize edilmesinin, modelin farklı boyut ve şekillerdeki dış yapılarını etkili biçimde ayırt etmesini sağladığını

düşündürmektedir. Sınıf bazında yapılan değerlendirmede, 7 numaralı diş sınıfında $mAP@50-95$ değeri 0.855 ile en düşük seviyededir. Bu durum, modelin bu dişi ayırt etmede diğer sınıflara göre daha fazla zorlandığını göstermektedir. Benzer şekilde 6, 5 ve 12 numaralı sınıflarda da $mAP@50-95$ değerlerinin nispeten düşük olduğu görülmektedir. Bu zorlukların, ilgili dişlerin köşede kalmasından, görsel özelliklerinin bazı diğer sınıflarla benzerlik göstermesinden veya görüntüleme sırasında yeterli ayırt edici özelliklerin sunulmamasından kaynaklandığı düşünülmektedir. Dişlerin konum (bu modelde sınıf olarak ele alınmıştır) etiketlenme sırası Şekil 32’de gösterilmiştir.




Şekil 32. Dişlerin konum etiketleri.

Modelin eğitim sürecinde ikinci veri grubunda (batch) elde edilen örnek görseller Şekil 33’te, doğrulama verisi üzerinde gerçekleştirilen tahmin sonuçları ise Şekil 34’te sunulmuştur.

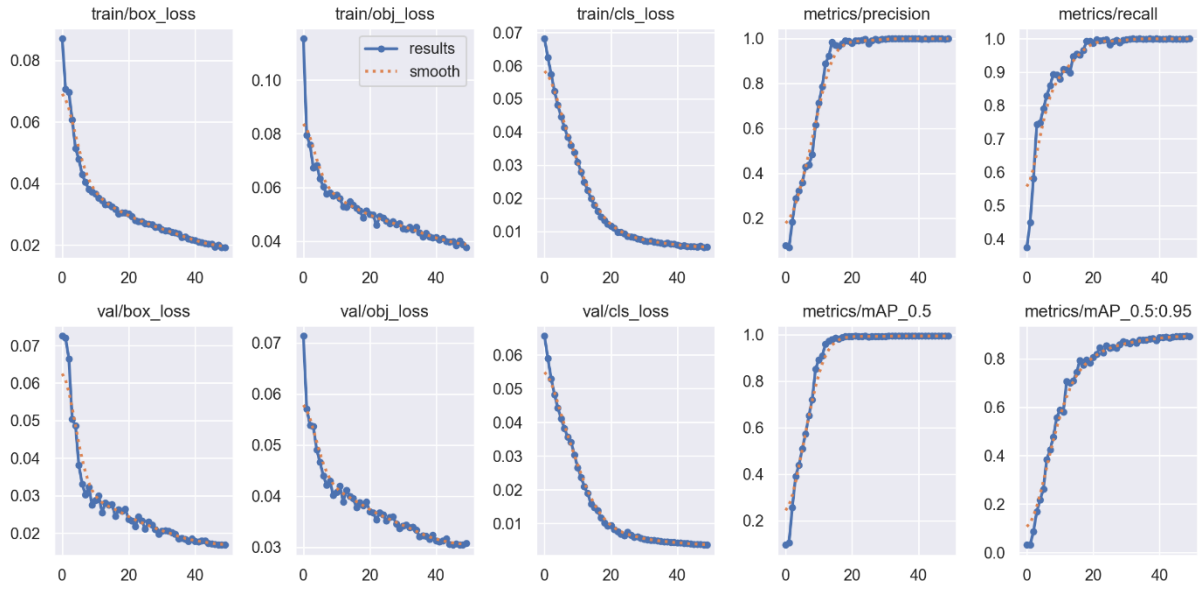


Şekil 33. Eğitim aşamasında oluşan mozaik görünüm ve gerçek etiketler.



Şekil 34. Doğrulama verisinin ikinci veri grubunda model tarafından yapılan tahminler.


Modelin eğitim süreci boyunca izlenen kayıp (loss) ve başarı (metric) grafiklerine ait sonuçlar Şekil 35’te sunulmuştur.




Şekil 35. Eğitim sürecine ait kayıp ve doğruluk metriklerinin grafiği.

Şekil 35’e bakıldığında eğitim setine ait kayıp değerleri, modelin her öğrenme tekrarında hatalarını giderek azalttığını göstermektedir. Aynı eğilim doğrulama setindeki kayıp grafiklerinde de gözlemlenmekte olup, eğitim ve doğrulama eğrilerinin paralel seyretmesi modelin aşırı öğrenmeden (overfitting) kaçındığını göstermektedir. Özellikle kutu kayıpları değerinin yaklaşık 0.08’den 0.02 seviyelerine kadar düşmesi, modelin nesne konumlarını başarılı biçimde öğrenebildiğine işaret etmektedir. Benzer şekilde, sınıf kayıpları değerinin 0.06’dan 0.01’in altına inmesi, modelin sınıflandırma başarısında kayda değer bir artış olduğunu ortaya koymaktadır. Modelin doğruluk metrikleri incelendiğinde; kesinlik ve duyarlılık değerlerinin sırasıyla 0.98 ve 0.95 seviyelerinde kararlı bir düzeye ulaştığı gözlemlenmektedir. Bu durum, modelin hem sahte pozitifleri minimize ettiğini, hem de gerçek nesnelere başarıyla tespit edebildiğini göstermektedir. Ortalama doğruluk metrikleri olan mAP@0.5 ve mAP@0.5:0.95 değerleri sırasıyla 0.99 ve 0.88 seviyelerinde olup, modelin hem düşük hem yüksek eşik değerlerinde yüksek genel performans sergilediğini ifade etmektedir. Tüm bu göstergeler, modelin eğitim sürecinin dengeli ve etkili biçimde ilerlediğini; hem sınıf tanıma hem de konum tahmini görevlerinde başarılı sonuçlar elde ettiğini ortaya koymaktadır.


Şekil 36, Şekil 37 ve Şekil 38’de sırasıyla modelin kesinlik, duyarlılık ve F1 skor değerlerine ilişkin güven eğrileri (confidence curves) gösterilmektedir. Bu eğriler, modelin farklı güven eşik değerleri altında sınıflandırma performansında nasıl değişim gösterdiğini ortaya koymaktadır. Böylelikle, modelin yalnızca yüksek güvenli çıktılar üretip üretmediği değil, aynı zamanda düşük güven düzeylerinde nasıl davrandığı da değerlendirilebilmektedir.



Şekil 36. Kesinlik güven eğrisi.




Şekil 37. Duyarlılık güven eğrisi.



Şekil 38. F1 skor güven eğrisi.

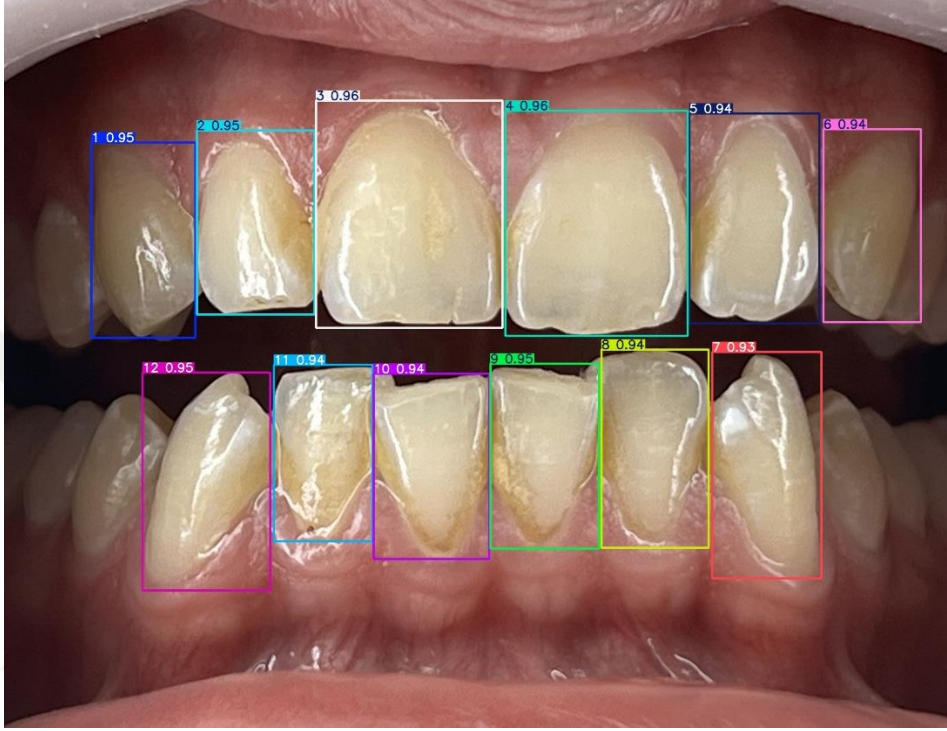
Şekil 39’da sunulan karmaşıklık matrisi, modelin farklı dış sınıflarını ne derece doğru sınıflandırabildiğini göstermektedir. Matrisin ana köşegenindeki yüksek doğruluk değerleri, modelin genel başarısını ortaya koymaktadır. En düşük doğru sınıflandırma oranı bile %97 ile 6. dış sınıfta görülmüştür. Bu değerler, modelin sınıflar arasında net ayrımlar yapabildiğini ve karışıklığın oldukça az olduğunu göstermektedir. Örnek olarak 5. dış sınıfı incelendiğinde, ana köşegende %99 doğruluk oranı yer almaktadır; bu, modelin bu sınıfı başarıyla tanıdığını göstermektedir. Ancak aynı satırda, 5. dışın yanlışlıkla yaklaşık %1 oranında 4. dış ve yaklaşık %2 oranında 7. dış olarak sınıflandırıldığı gözlemlenmiştir. Karmaşıklık matrisinde ana köşegen dışındaki diğer düşük değerler, modelin benzer dış sınıfları arasında nadiren karışıklık yaşadığını göstermektedir. Ayrıca, arka plan (background) ile olan düşük kesişim oranları, modelin gereksiz pozitif tahminlerden kaçındığını ve doğru nesne algılamada başarılı olduğunu desteklemektedir. Genel olarak, karmaşıklık matrisi sonuçları modelin yüksek doğrulukla sınıf tahmini yaptığını ve sınıflar arası karışıklığın minimum seviyede olduğunu göstermektedir. Bu da modelin dış sınıflandırma performansının güvenilir ve tutarlı olduğunu doğrulamaktadır.



Şekil 39. YOLOv5 için karmaşıklık matrisi.

Şekil 40, modelin eğitim veri seti dışındaki bağımsız bir görüntü üzerinde gerçekleştirdiği dış tespiti sonuçlarını gösterilmektedir. Görselde, tespit edilen dışların

konumlarını belirten sınırlayıcı kutular (bounding box) ile bu tahminlerin güven skorları gösterilmiştir. Görüntü üzerinde tespit edilen tüm dişlerin tahmin skorlarının %90'ın üzerinde olması, modelin yeni ve daha önce görmediği verilere karşı da yüksek doğruluk ve güvenle sınıflandırma yapabildiğini göstermektedir. Bu sonuç, modelin genelleme yeteneğinin güçlü olduğunu ve eğitim verisinden farklı örneklerde bile doğru konum ve sınıf tahminleri yapabildiğini desteklemektedir.



Şekil 40. Bağımsız bir görüntü üzerinde YOLOv5 modelinin nesne tespiti.

Diş Rengi Tahmini Bulguları


Diş rengi tespiti için kullanılan modellerin eğitim ve doğrulama süreçlerine ait doğruluk ve kayıp değerlerini içeren bulgular Tablo 14'te gösterilmektedir. Diş rengi tespiti probleminde kullanılan verinin sınıflar arası dağılım açısından dengesiz bir yapıya sahip olması bu durumun modellerin doğrulama performanslarını doğrudan etkilediğini ortaya koymaktadır. Yapılan ön işlemler sonrasında sınıf sayısı altıya indirgenmiş olsa da, örnek sayıları arasındaki farklar belirgin kalmış ve verilere dengeleme ve artırma uygulanması her ne kadar eğitim performansını artırsa da bu durum doğrulama aşamasında performans düşüşlerine neden olmuştur. Özellikle bazı modellerin eğitim sırasında yüksek doğruluk göstermesine karşın doğrulama aşamasında kayda değer düşüşler yaşaması, sınıf dengesizliği ile birlikte modelin genelleme kapasitesinin sınırlı kaldığını göstermektedir. Ayrıca, diş rengi sınıflarının görsel olarak birbirine oldukça yakın tonlardan oluşması, bu problemi yalnızca sınıf sayısı değil, aynı zamanda ayırım gücü açısından da zorlayıcı hâle getirmiştir. Tüm bu koşullar altında, probleme özgü olarak yapılandırılmış olan LABNet modelinin, hem doğruluk hem de kayıp değerleri

bakımından en başarılı sonuçları vermesi, bu tür yapısal hassasiyetlerin dikkate alınmasının model başarısı üzerinde belirleyici olduğunu göstermektedir.

Tablo 14. Diş Rengi Tespiti Modellerinin Eğitim ve Doğrulama Performansları

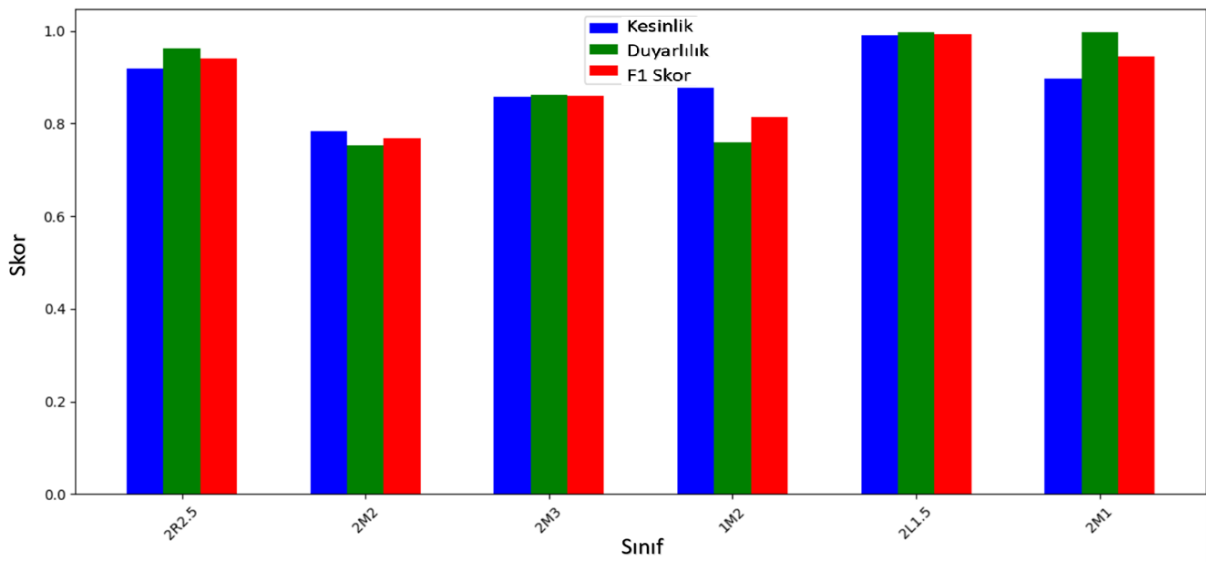
Modeller	Eğitim		Doğrulama	
	Doğruluk	Kayıp	Doğruluk	Kayıp
EfficientNetB0	%67	0,8409	%63	0,9873
ResNet50	%95	0,1398	%84	0,9960
VGG16	%82	0,4787	%73	0,9728
VGG19	%85	0,4067	%77	0,8603
LABNet	%97	0,3226	%89	0,6737

Tablo 14'e göre; EfficientNetB0 modeli, doğruluk açısından diğer modellere göre düşük performans göstermiştir. Ancak bu modelde eğitim ve doğrulama doğrulukları arasında yalnızca düşük fark olması, modelin veriye aşırı uyum göstermediğini ve daha istikrarlı bir öğrenme süreci izlediğini göstermektedir. Bu duruma rağmen yüksek kayıp değerleri, modelin çıktılarında belirsizliklerin fazla olduğunu, dolayısıyla doğru tahminlerde dahi kararlarının zayıf güvenle alındığını işaret etmektedir. ResNet50 modeli eğitimde yüksek doğruluk yakalamasına rağmen doğrulama sürecinde bu oran düşmektedir. Bu düşüş, modelin eğitim verisine fazla adapte olduğuna ve yeni verilerde genelleme yapmada zorlandığına işaret etmektedir. Doğrulama kaybı kararsız çıktılar ürettiğini göstermektedir. VGG16 ve VGG19 modelleri benzer yapılar sunmakla birlikte, doğrulama performansları eğitim aşamasına göre daha düşük kalmıştır. Bu çalışma kapsamında önerilen LABNet modeli, eğitim ve doğrulama aşamalarında sırasıyla %97 ve %89 doğruluk oranlarına ulaşarak diğer modellerle karşılaştırıldığında en yüksek performansı göstermiştir. Ayrıca, modelin eğitim ve doğrulama kayıp değerlerinin sırasıyla 0,3226 ve 0,6737 gibi görece düşük seviyelerde gerçekleşmesi, tahminlerinin yalnızca isabetli değil, aynı zamanda yüksek güven düzeyine sahip çıktılar üretebildiğini ortaya koymaktadır. LABNet'e ait doğruluk kayıp grafiği Şekil 41'de gösterilmiştir.




Şekil 41. LABNet modelinin doğruluk kayıp grafiği.

Şekil 42’de, LABNet modelinin doğrulama verisi üzerinde her bir sınıf için elde ettiği kesinlik, duyarlılık ve F1 skorları sunulmaktadır. Genel olarak tüm metriklerde yüksek performans elde edilmiş olup, modelin altı sınıf arasında dengeli ve istikrarlı bir sınıflandırma başarımı gösterdiği görülmektedir. Özellikle 2L1.5 ve 2M1 sınıflarında %99’a ulaşan F1 skorları, modelin bu sınıfları hem doğru hem de kararlı biçimde tanıyabildiğini göstermektedir. Diğer sınıflarda da skorlar %77 ile %94 arasında değişmekte olup, bu durum modelin sınıflar arası ayırım yapabilme becerisinin güçlü olduğunu ortaya koymaktadır. Ancak bazı sınıflarda (örneğin 1M2 ve 2M2) duyarlılık ve kesinlik değerlerinde nispeten düşüşler gözlemlenmiştir. Bu durum, bu sınıfların görsel benzerlikleri nedeniyle modelin ayırt edici performansını sınırlayabildiğini göstermektedir.



Şekil 42. LABNet modeline ait sınıflara göre performans grafiği.

Şekil 43’te sunulan karmaşıklık matrisi ise modelin tahmin performansını sınıflar arası düzeyde detaylı biçimde görselleştirmektedir. Matris üzerindeki diyagonal değerlerin yüksekliği, doğru sınıflandırmaların yoğunlaştığını gösterirken, diyagonal dışı değerler modelin hangi sınıfları karıştırma eğiliminde olduğunu ortaya koymaktadır. Özellikle renk tonları birbirine yakın olan sınıflar arasında sınırlı ölçüde karışma gözlemlenmiş, ancak genel olarak modelin sınıflar arasında anlamlı ayrımlar yapabildiği görülmüştür.



Şekil 43. LABNet modelinin karmaşıklık matrisi.

Şekil 43'te yer alan karmaşıklık matrisine göre, 2L1.5 ve 2M1 sınıflarında doğru sınıflandırma sayıları sırasıyla 494 ve 541 olup, bu sınıfların büyük çoğunluğunun doğru tahmin edildiği görülmektedir. Buna karşılık, 2M2 ve 1M2 sınıflarında doğru sınıflandırma sayıları daha düşük olup, bu sınıfların örneklerinin önemli bir kısmı benzer sınıflar olan 2M3 ve 2M2 gibi diğer sınıflara yanlış atanmıştır. 2M3 sınıfında da benzer şekilde, bazı örneklerin 2M2 ve 1M2 sınıflarına karıştığı gözlenmiştir. Bu durum, renk tonlarının birbirine yakın olduğu sınıflar arasında modelin ayırım yapmada zorlandığını göstermektedir. Ancak genel olarak matristeki yüksek diyagonal değerler ve görece düşük yanlış sınıflandırma oranları, LABNet modelinin renk temelli dış sınıflandırma problemini başarılı şekilde çözdüğünü ortaya koymaktadır.

TARTIŞMA

Bu çalışmada hem in vitro (Vita 3D Master kılavuzu ile elde edilen skala görüntüleri) hem de in vivo (gerçek hasta verilerinden elde edilen klinik görüntüler) senaryolar değerlendirilmiştir. İn vitro ortamda elde edilen kontrollü veriler, modelin öğrenme sürecine yüksek doğruluk elde ederken; in vivo görüntüler, modelin işlevselliğini sürdürdüğünü ortaya koymuştur. Fayed vd. (2022), Lin vd. (2019) ve Liu vd. (2013) çalışmalarında yalnızca in vitro koşullar temel alınmış ve klinik doğrulama süreci göz ardı edilmiştir. Bu yönüyle bu çalışma, önceki araştırmalardan ayrılarak sonuçlarının hem laboratuvar hem de klinik düzeyde güvenilirliğini ortaya koymaktadır.

Çalışmada kullanılan hem in vitro ve hem in vivo veri setleri hedeflenen sonuçları elde etmiştir. Özellikle ışık kaynağı çeşitliliği, modelin genellenebilirliğini artırmış ve metamerizmin etkilerini en aza indirmiştir. Bu anlamda model, farklı klinik ışık koşullarına karşı robust (dayanıklı) bir sınıflandırma yeteneği geliştirmiştir. Elde edilen doğruluk oranları, çalışmanın başlangıcında hedeflenen ışık koşullarından bağımsız ve otomatik diş rengi tahmini vizyonuna büyük ölçüde ulaşılmış olduğunu göstermektedir. Yöntemsel olarak hipotez belirlenmemiş olsa da, amaçlar doğrultusunda ulaşılan sonuçlar hedeflerle yüksek oranda örtüşmektedir. Başka bir ifadeyle, çalışmanın temel hedefi olan klinik ışık çeşitliliğine rağmen güvenilir renk tahmini başarıyla gerçekleştirilmiştir.

Mevcut çalışmada kullanılan YOLOv5 tabanlı diş tespit sistemi, mAP@50 metriği ile %99,5 doğruluk sergilemiştir. Bu oran, Chen vd. (2023)'nin YOLOv8 tabanlı çalışmasında elde ettiği %99,5 ile benzer düzeyde olup, modelin nesne tespit başarısının güncel sistemlerle rekabet edebilecek seviyede olduğunu göstermektedir. Buna karşın Chen vd. (2023) yalnızca Vita Classic kullanırken, bu çalışmada gerçek klinik görüntüler kullanılmıştır ki bu, çalışmanın özgün bir yönüdür. Ayrıca bir ağız içi görüntüsünde 12 diş aynı anda tespit edilmektedir. YOLOv5 modelinin gerçek zamanlı çalışabilmesi, küçük nesnelere algılamadaki başarısı ve dental renk uyumu üzerine yapılan son dönem çalışmalarında kullanılarak diş tespitinde başarısı göstermesi (Chen vd., 2023) bu çalışma için seçilmesinde etkili olmuştur. Thanh vd. (2022) ağız içi görüntülerden çürük lezyonlarının otomatik tespiti amacıyla farklı derin öğrenme mimarileri kullanmış ve en iyi sonucu RetinaNet ile elde ederek doğruluk oranını %83 olarak raporlamışlardır. Mevcut çalışmada ise ağız içi görüntülerden dişlerin otomatik olarak tespiti için YOLOv5 mimarisi tercih edilmiş ve mAP@50 metriğine göre %99,5 düzeyinde

yüksek doğruluk elde edilmiştir. Bu sonuç tespit modellerinin ağız içi görüntü analizinde yüksek performans potansiyelini bir kez daha ortaya koymuştur.

Diş rengi sınıflandırmasında önerilen DL tabanlı LABNet modeli eğitim aşamasında %97,54 doğruluk sergilemiştir. Sigit ve Arief (2017), ML tabanlı ve LAB renk uzayında %94,8 doğruluk raporlamış; Liu vd. (2013) %90 oranında başarı bildirmiştir. Ancak bu çalışmalar sadece skala temelli verilerle sınırlı kalmış, farklı ışık senaryolarına entegre olmamıştır. Çalışmamız ise doğrudan hasta görüntülerinden elde edilen verilerle eğitilmiştir ve farklı klinik ışıklara bağlı kalmadan renk tahmin edilmiştir. Bu açıdan literatürde benzeri olmayan bir uygulamaya sahiptir. Wang ve ark. (2014), Beneducci ve ark. (2022) ile Kim ve ark. (2018) tarafından yürütülen çalışmalarda, LAB renk uzayının dental renk analizinde güvenilir bir temsil sunduğu vurgulanmıştır. Bu doğrultuda, yürütülen çalışmamız da benzer şekilde LAB uzayının doğruluğunu ve tutarlılığını destekleyen bulgular ortaya koymuştur. Ayrıca bu çalışmada RGB, LAB ve HSV renk uzayları kullanılarak, her bir uzayın kendine özgü avantajından yararlanılmıştır. Çeşitli çalışmalarda (Lin vd. 2019, Beneducci vd. 2022) tek renk uzayı kullanılırken, çoklu renk uzayı kullanımı doğruluk ve dayanıklılık açısından model değerlendirmesini artırmıştır. Tam ve Lee (2017) yaptıkları çalışmada RGB modelinin stabil ışık koşullarında daha doğru sonuçlar verdiğini, ancak değişken koşullarda performansının düştüğünü rapor etmişlerdir. Bu çalışma, LAB uzayının kullanımıyla bu sınırlamaları aşarak, farklı aydınlatma ortamlarında güvenilir sonuçlar elde etti.

Tam ve Lee (2017) ile Wanna vd. (2022) çalışmalarında, akıllı telefon kameralarının diş kliniklerinde renk ölçümünde bir araç olabileceğini belirtilmiştir. Bu çalışmada da akıllı telefon kullanılarak benzer sonuçlar elde edilmiş ve bu cihazların renk tespiti için bir araç olarak kullanılabilmesi doğrulanmıştır.

Shan vd. (2021), diş hekimliğinde yapay zekanın görüntü analizi ve tanı destek sistemlerindeki potansiyelini inceleyerek renk analizinde standardize veri toplamanın önemini vurgulamışlardır; bu bağlamda, bu çalışmanın standardize edilmiş veri toplama protokolü literatürle uyumludur. Literatürde, veri seti büyüklüğü ve çeşitliliğinin yapay zekâ modellerinin başarısındaki rolü sıkça tartışılmaktadır. Shetty vd. (2024), bazı çalışmaların sınırlı veri setleriyle çalıştığını ve bu durumun genelleme kapasitesini kısıtladığını ifade etmişlerdir. Buna karşılık, bu çalışmada yeterli örnek sağlanmıştır ve geniş bir veri seti oluşturulmuştur. Bu durum, Lin vd. (2019) ile Chen vd. (2023) tarafından önerilen veri çeşitliliğinin doğruluğu artırma potansiyelini desteklemektedir.

Chaware vd. (2023) çalışmalarında spektrofotometre ile yapılan enstrümental renk seçimi ile Android tabanlı mobil uygulama üzerinden gerçekleştirilen renk seçimini

karşılaştırmış ve bu iki yöntem arasında klinik olarak anlamlı bir fark bulunmadığını rapor etmişlerdir. Ayrıca, farklı ışık modellerinin renk algısı üzerinde etkili olduğu da çalışmalarıyla doğrulanmıştır. Bu bulgular, bu çalışmada farklı klinik aydınlatma koşullarının dikkate alınmasını ve mobil tabanlı renk tespit sisteminin önerilmesini destekleyen niteliktedir.

Çalışmada geliştirilen yapay zekâ destekli renk belirleme süreci, yalnızca deneysel başarı değil, klinik uygulamalar açısından da çeşitli avantajlar sunduğu gözlemlenmiştir. Bu bağlamda elde edilen kazanımlar aşağıdaki şekilde özetlenebilir:

1. Geleneksel renk belirleme süreci, renk kılavuzlarının tek tek dişe tutulması, hekim ve teknisyenin ortak kararı ile pozlama tekrarları gibi işlemler nedeniyle zaman alırken, bu sistem bir seferde otomatik olarak 12 dişi tespit edip renklerini eşleştirdiği için, klinikte renk tayini süresini dakikalardan saniyelere indirerek zamandan tasarruf sağlar.
2. Uyum sağlamayan restorasyonların yeniden yapılması hem zaman kaybı hem de maliyet doğururken, sistem renk uyumsuzluğu nedeniyle tekrarlanan restorasyon oranını düşürerek yeniden yapım riskini azaltır.
3. Spektrofotometre ve kolorimetre gibi yüksek maliyetli cihazların her klinikte bulunmaması sebebiyle maliyetler yükselirken, bu sistem yalnızca akıllı telefon kullanarak yüksek maliyetli donanımlara ihtiyaç duymadan renk tespiti yapabildiği için maliyetleri düşürür.
4. Renk seçimi sürecinde hekimin ve teknisyenin aynı ışık koşullarında değerlendirme yapması gerekmesi nedeniyle koordinasyon hataları yaşanabilir; sistem ise renk bilgisini dijital olarak ileterek kişiden ve ortamdan bağımsız değerlendirir.
5. Görsel olarak yapılan renk iletimi klinikten laboratuvara geçerken bozulabileceği için, sistem her dişin rengini spesifik renk etiketiyle vererek renk bilgisinin eksiksiz ve yorumdan bağımsız aktarılmasını standartlaştırır.
6. Sabit olmayan ışık koşullarında bile doğru renk tespiti yapabildiği için klinik ışık koşullarına duyarsız çalışır.
7. Renk seçimi sırasında hekimin göz yorgunluğu, tecrübesi ve ışık duyarlılığı gibi etkenler sonucu etkileyebileceği için, sistem süreci otomatikleştirerek manuel göz yorgunluğunu ve subjektifliği azaltır.
8. Sabit klinik altyapısına ihtiyaç olmadan renk tayini yapılabilmesini sağlayan sistem, evde bakım, mobil klinik veya kırsal bölgelerde erişilebilirlik sağlar.
9. Klinik karar verme sürecinde, özellikle uzman hekimlerin öneri ve onay süreçlerinde belgelendirilebilir, ölçülebilir ve tekrar edilebilir objektif raporlama imkânı sağlar.

Bu çalışmada elde edilen bulgular, dental renk tespiti açısından önemli katkılar sunmakla birlikte, belirli yönleriyle bazı sınırlamalar ve geliştirmeye açık alanlar da barındırmaktadır. Örneğin Örneklem grubunun 18–40 yaş aralığıyla sınırlı tutulmuş olması, modelin farklı yaş gruplarındaki bireyler için de benzer başarıyı gösterip göstermeyeceğine dair kesin bir çıkarım yapılmasını zorlaştırabilir. Bu nedenle, gelecekte farklı yaş gruplarını kapsayan veri setleriyle yapılan çalışmalar, modelin genellenebilirliğini artırabilir. Ayrıca, geliştirilen LABNet modeli sınıflandırma performansına odaklanmış olup, ileride regresyon tabanlı renk farkı (ΔE) tahminlerinin de entegre edilmesi yöntemin kapsamını genişletebilir. Görüntülerin tek bir cihazla elde edilmiş olması, modelin farklı cihazlarla kaydedilen görüntülerde benzer başarıyı gösterip göstermeyeceği konusunda bazı belirsizlikler yaratabilir; ileride çok kaynaklı veri setleriyle çalışılması, sistemin farklı donanım koşullarında da geçerliliğini artırabilir ve daha esnek hale getirilmesini mümkün kılabilir. Veri setinde bazı renk değerlerinin daha nadir görülmesi, doğal şekilde temsil edilmemiş olabileceğine işaret edebilir; bu nedenle, her rengin dengeli biçimde yer aldığı bir veri toplama stratejisinin geliştirilmesi, modelin performansını olumlu yönde etkileyebilir. Ek olarak, klinik ışık kaynaklarının spektral özelliklerinin detaylı biçimde analiz edilmesi, modelin ışık farklılıklarına karşı gösterdiği toleransı daha iyi anlamaya katkı sağlayabilir. Son olarak, sistemin mobil uygulama ortamına entegre edilmesi, klinik pratikte erişilebilirliği ve kullanıcı dostu yapıyı güçlendirecek bir adım olabilir.

SONUÇ VE ÖNERİLER

Bu tez kapsamında gerçekleştirilen çalışmalar, farklı klinik ışık koşullarında diş rengi sınıflandırmasının doğruluğunu artırmaya yönelik çeşitli ML, FL ve DL tabanlı yaklaşımların etkinliğini ortaya koymaktadır. Klinik ortamlarda karşılaşılan zorlukları ve metamerizm etkisini en aza indirmek amacıyla hem yapay hem de gerçek diş görüntülerinden oluşturulmuş veri setleri üzerinde çalışılmış, sınıflandırma performansı farklı renk uzayları ve çeşitli algoritmalar ile karşılaştırılmalı olarak değerlendirilmiştir.

Bu çalışma genelinde LAB renk uzayının, özellikle metamerizm etkisini tolere etme ve ortam ışığından bağımsız renk tahmini yapma konusunda diğer renk uzaylarına kıyasla daha başarılı olduğu gözlemlenmiştir. LAB uzayında hem geleneksel ML algoritmaları hem FL destekli yöntemlerle hem de DL ile yüksek doğruluk oranları elde edilmiştir ve bu durum bu renk uzayının klinik uygulamalarda kullanılabileceğini göstermiştir. Gerçek hasta verilerini kullanan aşamada LAB renk uzayı tercih edilmiş, L kanalına CLAHE ile parlaklık düzeltmesi uygulanmış ve bu sayede ışık koşullarından kaynaklanan değişkenliğe karşı daha dayanıklı bir sistem geliştirilmiştir. Bu yaklaşım, LAB uzayının insan algısına daha yakın olması nedeniyle literatürde savunulan görüşleri destekler niteliktedir.

Farklı ışık kaynakları altında toplanan görüntülerle yapılan sınıflandırmalarda, ışıkların yüksek derecede ayrıştırılabilir olduğu gözlemlenmiştir. Beyaz ışık altında yapılan sınıflandırmalar, sentetik verilerle %100'e yakın doğrulukla gerçekleştirilmiş, bu da beyaz ışığın klinik diş rengi değerlendirmesi için ideal olduğunu doğrulamıştır. Doğal ve sarı ışık altında renk ayırımının daha zorlaştığı; ancak flaş ışığın yüksek spektral fark yaratması nedeniyle bazı durumlarda ışık olarak ayırt ediciliği artırdığı anlaşılmıştır. Fakat bu durum aynı zamanda rengin farklı görünmesine de sebep olmaktadır.

Bu çalışma literatürdeki diş rengi belirlemeye yönelik yapay zekâ uygulamalarını hem metodolojik kapsam hem de klinik uygulanabilirlik açısından önemli ölçüde ileriye taşımaktadır. Öncelikle, diğer çalışmaların sınırlı sayıda örnek ya da sentetik veri setleriyle gerçekleştirilmesine karşın bu çalışmada gerçek hasta verilerinden oluşan geniş ve dengelenmiş bir veri seti kullanılmıştır; bu durum, modelin genelleme ve klinik senaryoya uygunluk kapasitesini artırmıştır. Ayrıca, literatürde yaygın olarak kullanılan görsel ve enstrümental yöntemlerin öznelliği ve maliyeti sıklıkla eleştirilmişken, mevcut çalışma akıllı telefon tabanlı bir yapay zekâ çözümüyle bu sorunlara erişilebilir ve düşük maliyetli bir alternatif sunmuştur.

Gerçek diş görüntülerinden elde edilen veri seti ile yapılan analizler, yaklaşımın yalnızca yapay örneklerde değil, klinik gerçekliğe daha yakın koşullarda da geçerli olduğunu göstermiştir. Bununla birlikte, yaş, diş tipi ve renk dengesizliği gibi biyolojik ve örnekleme temelli sınırlamaların performans üzerindeki etkisi de vurgulanmıştır. DL aşamasında elde edilen bulgular, geliştirilen sistemin klinik koşullarda otomatik ve güvenilir şekilde çalışabileceğini göstermiştir. Dişlerin tespiti için kullanılan YOLOv5 modelinin mAP@50 skorunda %99,5 gibi oldukça yüksek bir başarı elde etmesi, görüntü işleme sürecinin otomatik hale getirilebileceğini ortaya koymuştur. Böylece hastadan alınan tek bir görüntü ile 12 diş için de renk değerlendirmesi yapılmasına olanak sağlayacaktır. Bu çalışmaya özgü önerdiğimiz CNN tabanlı renk tahmin modeli olan LABNet; VGG16, VGG19, ResNet50 ve EfficientNetB0 gibi yerleşik DL modelleriyle karşılaştırıldığında daha dengeli ve klinik senaryolara daha uygun sonuçlar üretmesi, bu modelin özelleştirilmiş yapısının hedef probleme ne derece uyumlu olduğunu kanıtlamaktadır. Böylece, geleneksel yöntemlerle elde edilen yüksek sınıflandırma başarılarının, DL ile otomatikleştirilen süreçlerde de sürdürülebilir olduğu ve bu sistemin gelecekte gerçek zamanlı, kullanıcıdan bağımsız çalışan klinik uygulamalar için güçlü bir temel sunduğu anlaşılmıştır. Bu çalışma klinik açıdan aşağıdaki somut çıktıları sağlamaktadır:

1. Farklı klinik ışık koşullarından bağımsız çalışabilen yapay zekâ temelli bir renk tahmin sistemi geliştirilmiştir.
2. Sadece akıllı telefonla çekilen dental fotoğraflar kullanılarak otomatik renk tespiti başarıyla gerçekleştirilmiştir.
3. Klinik ve laboratuvar arasındaki renk iletişimi, dijital ve standart hale getirilerek subjektifliğin azaltılması sağlanmıştır.
4. Işık kaynaklarının neden olduğu metamerizma etkisi, sistem tarafından tanımlanarak kontrol altına alınmıştır.
5. Manuel renk eşleştirmeye kıyasla daha nesnel bir sistem sunularak hekimden bağımsız, tekrarlanabilir ölçüm imkânı sunulmuştur.
6. Renk uyumsuzluklarına bağlı tekrar işlemler azaltılmış, bu sayede zaman ve maliyet açısından verimlilik sağlanmıştır.
7. Yüksek maliyetli cihazlara alternatif olarak erişilebilir ve pratik bir çözüm önerilmiştir.

Sonuç olarak, YZ yöntemlerinin renk uzayı seçimiyle birlikte optimize edilmesi sayesinde, klinik diř rengi sınıflandırmasında hem ışık koşullarına duyarlı hem de ışık koşullarından bağımsız başarılı tahminler yapılabileceđi gösterilmiştir. Bu yaklaşım, metamerizmin oluşturduđu belirsizlikleri azaltarak daha standart, hızlı ve düşük maliyetli bir renk belirleme sürecine olanak tanımaktadır. Gelecekte bu yöntemin mevcut veri sınırları aşıldığında mobil uygulamalarla entegre edilerek doğrudan klinik kullanıma sunulması mümkün olabileceđi düşünülmektedir.



KAYNAKÇA

- Abraham, G., Kurian, N., Wadhwa, S., & Varghese, K. G. (2023). A smartphone application with a gray card for clinical shade selection: A technique. *The Journal of Prosthetic Dentistry*. <https://doi.org/10.1016/j.prosdent.2023.01.016>
- Askari, S. (2021). Fuzzy C-Means clustering algorithm for data with unequal cluster sizes and contaminated with noise and outliers: Review and development. *Expert Systems with Applications*, 165, 113856. <https://doi.org/10.1016/j.eswa.2020.113856>
- Babu, A., Onesimu, J. A., & Sagayam, K. M. (2021). Artificial intelligence in dentistry: concepts, applications and research challenges. *E3S Web of Conferences*, 297, 01074. EDP Sciences. <https://doi.org/10.1051/e3sconf/202129701074>
- Basavanna, R. S., Gohil, C., & Shivanna, V. (2013). Shade selection. *International Journal of Oral Health Sciences*, 3(1), 26-31. <https://doi.org/10.4103/2231-6027.122097>
- Beneducci, W. P., Teixeira, M. L., & Pedrini, H. (2022). Dental shade matching assisted by computer vision techniques. *Computer Methods in Biomechanics and Biomedical Engineering: Imaging & Visualization*, 1-19. <https://doi.org/10.1080/21681163.2022.2130824>
- Bernauer, S. A., Zitzmann, N. U., & Joda, T. (2021). The use and performance of artificial intelligence in prosthodontics: a systematic review. *Sensors*, 21(19), 6628. <https://doi.org/10.3390/s21196628>
- Blagus, R., & Lusa, L. (2013). SMOTE for high-dimensional class-imbalanced data. *BMC bioinformatics*, 14, 1-16.
- Cal E, Sonugelen M, Guneri P, Kesercioglu A, Kose T. Application of a digital technique in evaluating the reliability of shade guides. *J Oral Rehabil*. 2004 May;31(5):483-91. <https://doi.org/10.1111/j.1365-2842.2004.01197.x>
- Cara, A. B., Herrera, L. J., Pomares, H., & Rojas, I. (2013). New online self-evolving neuro fuzzy controller based on the TaSe-NF model. *Information Sciences*, 220, 226-243. <https://doi.org/10.1016/j.ins.2012.02.041>
- Carrillo-Perez, F., Pecho, O. E., Morales, J. C., Paravina, R. D., Della Bona, A., Ghinea, R., ... & Herrera, L. J. (2022). Applications of artificial intelligence in dentistry: A comprehensive review. *Journal of Esthetic and Restorative Dentistry*, 34(1), 259-280. <https://doi.org/10.1111/jerd.12844>
- CEYLAN, G., & EMİR, F. (2023). Estetik ve Protetik Yapay Zekâ Uygulamalarında Güncel ve Gelecek Vadeden Yaklaşımlar. *Türkiye Klinikleri Oral and Maxillofacial Radiology-Special Topics*, 9(1), 38-44.
- Chaware, S. H., Borse, S. V., Kakatkar, V., & Darekar, A. (2023). Clinical performance of newly developed android mobile digital application on tooth shade reproduction: A multicenter randomized controlled clinical trial. *Contemporary Clinical Dentistry*, 14(1), 3-10. https://doi.org/10.4103/ccd.ccd_522_21
- Chen, Y. J., Hsu, P. T., & Liu, C. Y. (2023, December). Clinical Tooth Color Recognition System Based on Deep Learning. In *2023 International Conference on Next Generation Electronics (NEleX)* (pp. 1-4). IEEE. <https://doi.org/10.1109/NEleX59773.2023.10420915>

- Della Bona, A. (Ed.). (2020). *Color and appearance in dentistry* (Vol. 1). Switzerland: Springer.
- Dutta, A., & Zisserman, A. (2019, October). The VIA annotation software for images, audio and video. In *Proceedings of the 27th ACM international conference on multimedia* (pp. 2276-2279). <https://doi.org/10.1145/3343031.3350535>
- Efitli, E., Karcioğlu, A. A., Şimşek, E., Özdoğan, A., Karataş, F., & Şenocak, T. (2025). Machine Learning-Based Tooth Color Assessment Using Color Moments to Prevent Metamerism in Different Clinical Lights. *Journal of the Institute of Science and Technology*, 15(1), 71-82. <https://doi.org/10.21597/jist.1594829>
- Fayed, A. E. M., Mohamed, H. A., & Othman, H. I. (2022). A Comparison between visual shade matching and digital shade analysis system using K-NN algorithm. *Al-Azhar Journal of Dental Science*, 25(2), 133-141. <https://doi.org/10.21608/ajdsm.2021.85035.1211>
- Ganesan, P., Rajini, V., & Rajkumar, R. I. (2010). Segmentation and edge detection of color images using CIELAB color space and edge detectors. *INTERACT-2010*, 393-397. <https://doi.org/10.1109/INTERACT.2010.5706186>
- Guerra, M. I., de Araújo, F. M., de Carvalho Neto, J. T., & Vieira, R. G. (2024). Survey on adaptative neural fuzzy inference system (ANFIS) architecture applied to photovoltaic systems. *Energy Systems*, 15(2), 505-541. <https://doi.org/10.1007/s12667-022-00513-8>
- Goodfellow, I., Bengio, Y., Courville, A., & Bengio, Y. (2016). *Deep learning* (Vol. 1, No. 2). Cambridge: MIT press.
- Grischke, J., Johannsmeier, L., Eich, L., Griga, L., & Haddadin, S. (2020). Dentronics: Towards robotics and artificial intelligence in dentistry. *Dental Materials*, 36(6), 765-778. <https://doi.org/10.1016/j.dental.2020.03.021>
- Hardan, L., Bourgi, R., Cuevas-Suárez, C. E., Lukomska-Szymanska, M., Monjarás-Ávila, A. J., Zarow, M., ... & Haikel, Y. (2022). Novel trends in dental color match using different shade selection methods: a systematic review and meta-analysis. *Materials*, 15(2), 468. <https://doi.org/10.3390/ma15020468>
- Hosseini, M. S., & Zekri, M. (2012). Review of medical image classification using the adaptive neuro-fuzzy inference system. *Journal of Medical Signals & Sensors*, 2(1), 49-60.
- Hu, J. C., Wang, C. H., & Kuhns, D. (2016). New Algorithm in Shade Matching. *Journal of Cosmetic Dentistry*, 32(1).
- Hung, M. C., & Yang, D. L. (2001, November). An efficient fuzzy c-means clustering algorithm. In *Proceedings 2001 IEEE international conference on data mining* (pp. 225-232). IEEE. <https://doi.org/10.1109/ICDM.2001.989523>
- Hung, M., Voss, M. W., Rosales, M. N., Li, W., Su, W., Xu, J., ... & Licari, F. W. (2019). Application of machine learning for diagnostic prediction of root caries. *Gerodontology*, 36(4), 395-404. <https://doi.org/10.1111/ger.12432>
- Jarad, F. D., Russell, M. D., & Moss, B. W. (2005). The use of digital imaging for colour matching and communication in restorative dentistry. *British Dental Journal*, 199(1), 43-49. <https://doi.org/10.1038/sj.bdj.4812559>
- Johnson, J. M., & Khoshgoftaar, T. M. (2019). Survey on deep learning with class imbalance. *Journal of big data*, 6(1), 1-54.
- Jouhar, R., Ahmed, M. A., & Khurshid, Z. (2022). An overview of shade selection in clinical dentistry. *Applied Sciences*, 12(14), 6841. <https://doi.org/10.3390/app12146841>

- Joiner, A. (2004). Tooth colour: a review of the literature. *Journal of dentistry*, 32, 3-12. <https://doi.org/10.1016/j.jdent.2003.10.013>
- Justiawan, Wahjuningrum, D. A., Hadi, R. P., Nurhayati, A. P., Prayogo, K., Sigit, R., & Arief, Z. (2019). Comparative analysis of color matching system for teeth recognition using color moment. *Medical Devices: Evidence and Research*, 497-504. <https://doi.org/10.2147/MDER.S224280>
- Kalpana, D., Rao, S. J., Joseph, J. K., Kurapati, S. K. R. 2018. "Digital dental photography", *Indian Journal of Dental Research*, 29: 507-512.
- Kamal, S. A., Yin, C., Qian, B., & Zhang, P. (2020). An interpretable risk prediction model for healthcare with pattern attention. *BMC Medical Informatics and Decision Making*, 20, 1-10. <https://doi.org/10.1186/s12911-020-01331-7>
- Karaboga, D., & Kaya, E. (2019). Adaptive network based fuzzy inference system (ANFIS) training approaches: a comprehensive survey. *Artificial Intelligence Review*, 52, 2263-2293. <https://doi.org/10.1007/s10462-017-9610-2>
- Karcioglu, A. A., Efitli, E., Simsek, E., Ozdogan, A., Karatas, F., & Senocak, T. (2025). ML-based tooth shade assessment to prevent metamerism in different clinic lights. *Lasers in medical science*, 40(1), 39. <https://doi.org/10.1007/s10103-025-04297-y>
- Khanagar, S. B., Al-Ehaideb, A., Maganur, P. C., Vishwanathaiah, S., Patil, S., Baeshen, H. A., ... & Bhandi, S. (2021). Developments, application, and performance of artificial intelligence in dentistry—A systematic review. *Journal of dental sciences*, 16(1), 508-522. <https://doi.org/10.1016/j.jds.2020.06.019>
- Khanam, R., & Hussain, M. (2024). What is YOLOv5: A deep look into the internal features of the popular object detector. *arXiv preprint arXiv:2407.20892*.
- Kim, M., Kim, B., Park, B., Lee, M., Won, Y., Kim, C. Y., & Lee, S. (2018). A digital shade-matching device for dental color determination using the support vector machine algorithm. *Sensors*, 18(9), 3051. <https://doi.org/10.3390/s18093051>
- Kim, S. H., Lee, Y. K., Lim, B. S., Rhee, S. H., & Yang, H. C. (2007). Metameric effect between dental porcelain and porcelain repairing resin composite. *Dental materials*, 23(3), 374-379. <https://doi.org/10.1016/j.dental.2006.01.027>
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *nature*, 521(7553), 436-444.
- Lee, J. H., Kim, D. H., Jeong, S. N., & Choi, S. H. (2018). Detection and diagnosis of dental caries using a deep learning-based convolutional neural network algorithm. *Journal of dentistry*, 77, 106-111. <https://doi.org/10.1016/j.jdent.2018.07.015>
- Li, G., Fu, L., Gao, C., Fang, W., Zhao, G., Shi, F., ... & Cui, Y. (2022). Multi-class detection of kiwifruit flower and its distribution identification in orchard based on YOLOv5l and Euclidean distance. *Computers and Electronics in Agriculture*, 201, 107342.
- Li, Q., Chen, D., Wang, H., & Shen, J. (2024). A machine learning based approach to standardizing tooth color and shade recommendations. *The Journal of Prosthetic Dentistry*. <https://doi.org/10.1016/j.prosdent.2024.09.010>
- Lin, T. L., Chuang, C. H., Chen, S. L., Lin, N. H., Miaou, S. G., Lin, S. Y., ... & Villaverde, J. F. (2019). An efficient image processing methodology based on fuzzy decision for dental shade matching. *Journal of Intelligent & Fuzzy Systems*, 36(2), 1133-1142. <https://doi.org/10.3233/JIFS-169887>
- Liu, J., Zhao, N., & He, R. (2013, October). Study of color matching system for porcelain teeth. In *2013 IEEE International Conference on Medical Imaging Physics and Engineering* (pp. 310-314). <https://doi.org/10.1109/ICMIPE.2013.6864558>

- Mahesh, B. (2020). Machine learning algorithms-a review. *International Journal of Science and Research (IJSR)*. [Internet], 9(1), 381-386. <https://doi.org/10.21275/ART20203995>
- Minaee, S., Boykov, Y., Porikli, F., Plaza, A., Kehtarnavaz, N., & Terzopoulos, D. (2021). Image segmentation using deep learning: A survey. *IEEE transactions on pattern analysis and machine intelligence*, 44(7), 3523-3542. <https://doi.org/10.1109/TPAMI.2021.3059968>
- Moussa, R. (2021). Dental Shade Matching: Recent Technologies and Future Smart Applications. *J. Dent. Health Oral Res*, 2, 1-10. <http://dx.doi.org/10.46889/JDHOR.2021.2103>
- Mohammed, A. O., Mohammed, G. S., Mathew, M., Alzarea, B., Bandela, V. 2022. "Shade selection in esthetic dentistry: A review", *Cureus*, 14.
- Mohammadi, A., Bakhtiari, Z., Mighani, F., & Bakhtiari, F. (2021). Validity and reliability of tooth color selection by smartphone photography and software applications. *The Journal of the Indian Prosthodontic Society*, 21(3), 281. https://doi.org/10.4103/jips.jips_193_21
- Mutlag, W. K., Ali, S. K., Aydam, Z. M., & Taher, B. H. (2020, July). Feature extraction methods: A review. In *Journal of Physics: Conference Series* (Vol. 1591, No. 1, p. 012028). IOP Publishing. <https://doi.org/10.1088/1742-6596/1591/1/012028>
- Nan, Y., Zhang, H., Zeng, Y., Zheng, J., & Ge, Y. (2023). Faster and accurate green pepper detection using NSGA-II-based pruned YOLOv5l in the field environment. *Computers and Electronics in Agriculture*, 205, 107563.
- Oh, W. S., Pogoncheff, J., & O'Brien, W. J. (2010). Digital computer matching of tooth color. *Materials*, 3(6), 3694-3699. <https://doi.org/10.3390/ma3063694>
- Öngül, D., Şermet, B., & Balkaya, M. C. (2012). Visual and instrumental evaluation of color match ability of 2 shade guides on a ceramic system. *The Journal of prosthetic dentistry*, 108(1), 9-14. [https://doi.org/10.1016/S0022-3913\(12\)60102-4](https://doi.org/10.1016/S0022-3913(12)60102-4)
- Pecho, O. E., Pérez, M. M., Ghinea, R., & Della Bona, A. (2016). Lightness, chroma and hue differences on visual shade matching. *Dental materials*, 32(11), 1362-1373. <https://doi.org/10.1016/j.dental.2016.08.218>
- Reka, S. S., Murthy Voona, V. D., Sai Nithish, P. V., Paavan Kumar, D. S., Venugopal, P., & Ravi, V. (2023). Performance Analysis of Deep Convolutional Network Architectures for Classification of Over-Volume Vehicles. *Applied Sciences*, 13(4), 2549. <https://doi.org/10.3390/app13042549>
- Roy, P., Vivekananda, L., & Singh, G. P. (2021). Artificial intelligence in dentistry and its future. *GSC Advanced Research and Reviews*, 7(1), 82-86. <https://doi.org/10.30574/gscarr.2021.7.1.0078>
- Sağlam, H., Tuğba, A., Bayrakdar, İ. Ş., Bilgir, E., Uğurlu, M., Çelik, Ö., Orhan, K. 2021. "Diş hekimliğinde yapay zeka: Artificial intelligence in dentistry", *Sağlık Bilimlerinde Yapay Zeka Dergisi*, 1, 26-33.
- Sampaio, C. S., Gurrea, J., Gurrea, M., Bruguera, A., Atria, P. J., Janal, M., ... & Hirata, R. (2018). Dental Shade Guide Variability for Hues B, C, and D Using Cross-Polarized Photography. *International Journal of Periodontics & Restorative Dentistry*. <https://doi.org/10.11607/prd.3270>
- Sampaio, C. S., Atria, P. J., Hirata, R., Jorquera, G. 2019. "Variability of color matching with different digital photography techniques and a gray reference card", *The Journal of Prosthetic Dentistry*, 121, 333-339.

- Schropp, L. (2009). Shade matching assisted by digital photography and computer software. *Journal of Prosthodontics: Implant, Esthetic and Reconstructive Dentistry*, 18(3), 235-241. <https://doi.org/10.1111/j.1532-849X.2008.00409.x>
- Scrobotă, I., Băciuț, G., Filip, A. G., Todor, B., Blaga, F., & Băciuț, M. F. (2017). Application of fuzzy logic in oral cancer risk assessment. *Iranian journal of public health*, 46(5), 612.
- Shan, T., Tay, F. R., & Gu, L. (2021). Application of artificial intelligence in dentistry. *Journal of dental research*, 100(3), 232-244. <https://doi.org/10.1177/0022034520969115>
- Shetty, S., Gali, S., Augustine, D., & Sv, S. (2024). Artificial intelligence systems in dental shade-matching: A systematic review. *Journal of Prosthodontics*, 33(6), 519-532. <https://doi.org/10.1111/jopr.13805>
- Shishira, R., Nayak, S. D., Suma, M. N., & Mishra, G. (2024). Dental shade matching using machine learning models. In *Internet of Things enabled Machine Learning for Biomedical Applications* (pp. 131-144). CRC Press
- Sigit, R., & Arief, Z. (2017). Tooth shade assessment using PCA and KNN classifier algorithm based on color moment. *EMITTER International Journal of Engineering Technology*, 5(1), 139-153. <https://doi.org/10.24003/emitter.v5i1.171>
- Singh, V., Singh, K., Sehrawat, R., Singh, A. P., Augustine, J., & Verma, M. (2025, February). Deep Learning Techniques For Dental Caries Detection And Prosthodontics: A Systematic Review. In *2025 2nd International Conference on Computational Intelligence, Communication Technology and Networking (CICTN)* (pp. 651-655). IEEE.
- Tam, W. K., & Lee, H. J. (2012). Dental shade matching using a digital camera. *Journal of dentistry*, 40, e3-e10. <https://doi.org/10.1016/j.jdent.2012.06.004>
- Tam, W. K., & Lee, H. J. (2017). Accurate shade image matching by using a smartphone camera. *Journal of Prosthodontic Research*, 61(2), 168-176. <https://doi.org/10.1016/j.jpor.2016.07.004>
- Tandon, D., Rajawat, J., & Banerjee, M. (2020). Present and future of artificial intelligence in dentistry. *Journal of Oral Biology and Craniofacial Research*, 10(4), 391-396. <https://doi.org/10.1016/j.jobcr.2020.07.015>
- Tian, S., Dai, N., Zhang, B., Yuan, F., Yu, Q., & Cheng, X. (2019). Automatic classification and segmentation of teeth on 3D dental model using hierarchical deep learning networks. *Ieee Access*, 7, 84817-84828. <https://doi.org/10.1109/ACCESS.2019.2924262>
- Thanh MTG, Van Toan N, Ngoc VTN, Tra NT, Giap CN, Nguyen DM. Deep Learning Application in Dental Caries Detection Using Intraoral Photos Taken by Smartphones. *Applied Sciences* 2022, Vol 12, Page 5504. 2022;12(11):5504.
- Thukral, S., & Bal, J. S. (2019). Medical applications on fuzzy logic inference system: a review. *International Journal of Advanced Networking and Applications*, 10(4), 3944-3950.
- Tuzoff, D. V., Tuzova, L. N., Bornstein, M. M., Krasnov, A. S., Kharchenko, M. A., Nikolenko, S. I., ... & Bednenko, G. B. (2019). Tooth detection and numbering in panoramic radiographs using convolutional neural networks. *Dentomaxillofacial Radiology*, 48(4), 20180051. <https://doi.org/10.1259/dmfr.20180051>
- Yang, S., Choi, J., Bae, S., & Chung, M. (2015). A hybrid prediction model integrating FCM clustering algorithm with supervised learning. In *Advances in Computer Science and*

- Ubiquitous Computing: CSA & CUTE (pp. 619-629). Springer Singapore.
https://doi.org/10.1007/978-981-10-0281-6_88
- Yang, J., Hao, Z., Xu, J., Wang, J., & Jiang, X. (2024). Fusion machine learning model predicts CAD-CAM ceramic colors and the corresponding minimal thicknesses over various clinical backgrounds. *Dental Materials*, 40(2), 285-296.
<https://doi.org/10.1016/j.dental.2023.11.013>
- Wang, J., Lin, J., Gil, M., Seliger, A., Da Silva, J. D., & Ishikawa-Nagai, S. (2014). Assessing the accuracy of computer color matching with a new dental porcelain shade system. *The Journal of prosthetic dentistry*, 111(3), 247-253.
<https://doi.org/10.1016/j.prosdent.2013.07.008>
- Wanna, Y., Wiratchawa, K., Leenaracharongruang, R., Sittiwong, W., Panpisut, P., & Intharah, T. (2022, July). DentShadeAI: a Framework for Automatic Dental Shade Matching through Mobile Phone Camera. In 2022 37th International Technical Conference on Circuits/Systems, Computers and Communications (ITC-CSCC) (pp. 282-285). IEEE. <https://doi.org/10.1109/ITC-CSCC55581.2022.9894968>
- Wee, A. G. 2006. "Description of color, color replication process and esthetics, Pages:710-712", *Contemporary Fixed Prosthodontics*. Editors: Rosenstiel, S. F., Land, M. F., Fujimoto, J. St Louis: Mosby.
- Ueki, K., Wakamatsu, H., & Hagiwara, Y. (2020, October). Evaluation of dental prosthesis colors using a neural network. In 2020 IEEE 5th International Conference on Signal and Image Processing (ICSIP) (pp. 210-214). IEEE.
<https://doi.org/10.1109/ICSIP49896.2020.9339381>
- Ultralytics. (2025). YOLOv5 repository. GitHub. <https://github.com/ultralytics/yolov5>
- Zadeh, L. A. (1965). Fuzzy sets. *Information and Control*, 8(3), 338-353.
[https://doi.org/10.1016/S0019-9958\(65\)90241-X](https://doi.org/10.1016/S0019-9958(65)90241-X)
- Zitzmann, N. U., Haggmann, E., & Weiger, R. (2007). What is the prevalence of various types of prosthetic dental restorations in Europe?. *Clinical oral implants research*, 18, 20-33.
<https://doi.org/10.1111/j.1600-0501.2007.01435.x>

ÖZGEÇMİŞ

Kişisel Bilgiler	
Adı Soyadı:	Esra EFİTLİ
Uyruğu:	
E-mail:	
Eğitim	
Lise:	Ilıca İMKB Yavuz Selim Anadolu Öğretmen Lisesi (2016)
Lisans:	Atatürk Üniversitesi, Bilgisayar Mühendisliği (2020)
Yüksek lisans:	Atatürk Üniversitesi, Yazılım Mühendisliği
Yabancı Dil Bilgisi	
Tezden Üretilmiş Yayınlar	
<ol style="list-style-type: none">1. TÜBİTAK 123E597 numaralı 1002 - Hızlı Destek Projesi ile desteklenmiştir.2. Karcıođlu, A. A., Efitli, E., Simsek, E., Ozdogan, A., Karatas, F., & Senocak, T. (2025). ML-based tooth shade assessment to prevent metamerism in different clinic lights. <i>Lasers in medical science</i>, 40(1), 39.3. Efitli, E., Karcıođlu, A. A., ŐimŐek, E., Özdođan, A., KarataŐ, F., & Őenocak, T. (2025). Machine Learning-Based Tooth Color Assessment Using Color Moments to Prevent Metamerism in Different Clinical Lights. <i>Journal of the Institute of Science and Technology</i>, 15(1), 71-82.	