



TÜRKİYE CUMHURİYETİ
ANKARA ÜNİVERSİTESİ
SAĞLIK BİLİMLERİ ENSTİTÜSÜ



İNTRAKORONAL BEYAZLATMA SONUÇLARININ YAPAY ZEKA İLE TAHMİNİ

Suna Elçin YENER

ENDODONTİ ANABİLİM DALI
DOKTORA TEZİ

DANIŞMAN
Prof. Dr. Meltem ÖZTAN

ANKARA
2026

TÜRKİYE CUMHURİYETİ
ANKARA ÜNİVERSİTESİ
SAĞLIK BİLİMLERİ ENSTİTÜSÜ

İNTRAKORONAL BEYAZLATMA SONUÇLARININ YAPAY ZEKA İLE TAHMİNİ

Suna Elçin YENER

ENDODONTİ ANABİLİM DALI
DOKTORA TEZİ

DANIŞMAN
Prof. Dr. Meltem ÖZTAN

ANKARA
2026

ETİK BEYAN

Ankara Üniversitesi
Sağlık Bilimleri Enstitüsü Müdürlüğü'ne,

Doktora tezi olarak hazırlayıp sunduğum “İntrakoronal Beyazlatma Sonuçlarının Yapay Zeka ile Tahmini” başlıklı tez, bilimsel ahlak ve değerlere uygun olarak tarafımdan yazılmıştır. Tezimin fikir/hipotezi tümüyle tez danışmanım ve bana aittir. Tezde yer alan deneysel çalışma/araştırma tarafımdan yapılmış olup, tüm cümleler, yorumlar bana aittir. Yukarıda belirtilen hususların doğruluğunu beyan ederim.

Öğrencinin Adı Soyadı: Suna Elçin YENER
Tarih:
İmza:

KABUL VE ONAY

Ankara Üniversitesi Sağlık Bilimleri Enstitüsü

Endodonti Anabilim Dalında

Suna Elçin YENER tarafından hazırlanan

“İntrakoronal Beyazlatma Sonuçlarının Yapay Zeka ile Tahmini” adlı
tez çalışması aşağıdaki jüri tarafından DOKTORA TEZİ olarak OY BİRLİĞİ ile kabul
edilmiştir.

Tez Savunma Tarihi: 07/01/2026

Prof. Dr. Bade SONAT

Ankara Üniversitesi Diş Hekimliği Fakültesi

Endodonti Anabilim Dalı

Jüri Başkanı

Prof. Dr. Zeliha YILMAZ

Hacettepe Üniversitesi Diş Hekimliği Fakültesi

Endodonti Anabilim Dalı

Raportör

Prof. Dr. Meltem ÖZTAN

Ankara Üniversitesi Diş Hekimliği Fakültesi

Endodonti Anabilim Dalı

Üye

Prof. Dr. Aylin KALAYCI

Ankara Üniversitesi Diş Hekimliği Fakültesi

Endodonti Anabilim Dalı

Üye

Prof. Dr. Kamran GÜLŞAHI

Başkent Üniversitesi Diş Hekimliği Fakültesi

Endodonti Anabilim Dalı

Üye

Tez hakkında alınan jüri kararı, Ankara Üniversitesi Sağlık Bilimleri Enstitüsü Yönetim
Kurulu tarafından onaylanmıştır.

Prof. Dr. Fügen AKTAN

Sağlık Bilimleri Enstitüsü Müdürü

ÖZET

İntrakoronal Beyazlatma Sonuçlarının Yapay Zeka ile Tahmini

Bu çalışmanın amacı intrakoronal beyazlatma tedavisi sonrası meydana gelen renk değişimlerinin başlangıçtaki L^* , a^* , b^* değerlerinden yola çıkarak farklı yapay zeka modelleriyle tahmin edilmesi ve elde edilen tahminlerin klinik karşılığının Vita 3D-Master renk skalası üzerinden değerlendirilmesidir. Çalışmamızda 261 maksiller anterior diştten elde edilen toplam 783 girdi kullanılmıştır. Her girdinin beyazlatma öncesi ve sonrası renk ölçümleri Vita Easyshade V (VITA Zahnfabrik, Bad Säckingen, Germany) spektrofotometre ile üçer kez alınarak ortalamaları hesaplanmıştır. Girdi olarak beyazlatma öncesi L^* , a^* , b^* değerleri ve bu değerlerden elde edilen doygunluk ve ton değerleri kullanılmış, çıktı olarak da beyazlatma sonrası L^* , a^* , b^* değerleri tahmin edilmiştir. Model olarak XGBoost, DNN, LSTM ve BiLSTM algoritmaları oluşturulmuştur. Modeller LOOCV doğrulama yöntemi ile eğitilmiş, performans değerlendirmesinde MAE, RMSE, R^2 , Pearson Korelasyon Katsayısı, ortalama ΔE_{00} ve Top-2 Vita doğruluk oranı kullanılmıştır. Tahmin edilen LAB_1 değerleri ± 1 tolerans aralığında 5x5x5 ızgara oluşturularak Vita 3D-Master skalasındaki referans renkleriyle ΔE_{00} formülü üzerinden eşleştirilmiştir. En yüksek doğruluk oranı XGBoost modelinde elde edilmiştir (MAE: 1.36, RMSE:1.70, R^2 : 0.65, Pearson: 0.80, ortalama ΔE_{00} : 2.33, Top-2 Vita Doğruluk: %83.6). DNN modeli de benzer şekilde düşük hata değerleri göstermiştir. LSTM ve BiLSTM modelleri ise daha düşük başarı kriterleriyle birbirine yakın sonuçlar vermiştir.

Anahtar Sözcükler: BiLSTM, DNN, İntrakoronal Beyazlatma, LSTM, XGBoost, Yapay Zeka

SUMMARY

Prediction of Intracoronary Bleaching Outcomes Using Artificial Intelligence

The aim of this study was to predict the color changes that occur after intracoronary bleaching based on the initial L*, a*, b* values using various artificial intelligence models, and to evaluate the clinical relevance of these predictions through the Vita 3D-Master shade guide. A total of 783 inputs obtained from 261 maxillary anterior teeth were used in the study. For each input, pre- and post-bleaching color measurements were taken three times using a Vita Easyshade V (VITA Zahnfabrik, Bad Säckingen, Germany) spectrophotometer, and the averages were calculated. As input features, the pre-bleaching L*, a*, b* values and their derived chroma (C*) and hue (h°) values were used, while the output variables were the post-bleaching L*, a*, b* values. The models developed were XGBoost, DNN, LSTM, and BiLSTM. All models were trained using the Leave-One-Out Cross-Validation (LOOCV) method. Model performance was evaluated using MAE, RMSE, R², Pearson correlation coefficient, mean ΔE_{00} , and Top-2 Vita accuracy. Predicted LAB₁ values were evaluated within a ± 1 tolerance range by constructing a 5×5×5 cube and matched with the Vita 3D-Master reference shades using the CIEDE2000 formula. The highest performance was achieved by the XGBoost model (MAE: 1.36, RMSE: 1.70, R²: 0.65, Pearson: 0.80, mean ΔE_{00} : 2.33, Top-2 Vita accuracy: 83.6%). The DNN model also demonstrated low error values, while the LSTM and BiLSTM models produced similar results with slightly lower performance.

Keywords: Artificial Intelligence, BiLSTM, DNN, Intracoronary bleaching, LSTM, XGBoost

İÇİNDEKİLER

Etik Beyan	ii
Kabul ve Onay	iii
Özet	iv
Summary	v
İçindekiler	vi
Önsöz	viii
Simgeler ve Kısaltmalar	ix
Şekiller	x
Çizelgeler	xi
1.GİRİŞ	1
1.1 Renk Tanımı	2
1.2 Renk Analiz Sistemleri	3
1.2.1. Görsel Değerlendirmede Kullanılan Renk Sistemleri	3
1.2.1.1 Munsell Renk Sistemi:	3
1.2.2. Dijital Cihazlarla Kullanılan Renk Sistemleri	5
1.2.2.1 CIE (Comission Internationale D'Eclairage) L*a*b Renk Sistemi	5
1.2.2.2. RGB Renk Sistemi:	6
1.3. Dış Hekimliğinde Renk Ölçüm Yöntemleri	7
1.3.1. Geleneksel Renk Ölçüm Yöntemleri	7
1.3.2. Dijital Renk Ölçüm Yöntemleri	7
1.3.2.1. Kolorimetreler	7
1.3.2.2. Spektrofotometreler	9
1.3.2.3. Spektroradyometreler	10
1.3.2.4. Görüntü Sistemleri ve Dijital Kameralar	10
1.4 Dış Renklenmeleri	11
1.4.2 Dış Kaynaklı Renklenmeler	11
1.4.1.1 Metalik Renklenmeler	11
1.4.1.2 Metalik Olmayan Renklenmeler	11
1.5 İç Renklenmeler	12
1.5.1 Kanal Tedavisi Esnasındaki Prosedürlere Bağlı Renklenmeler	12
1.5.2 Endodontik Tedavi Sonrası Restoratif İşlemlere Bağlı Renklenmeler	14
1.6 Beyazlatmanın Tarihçesi	15
1.7 Beyazlatmanın Mekanizması	15
1.8 Beyazlatma Tedavisinde Kullanılan Materyaller	15
1.8.1 Hidrojen Peroksit	16
1.8.2 Karbamid Peroksit (CH ₆ N ₂ O ₃)	17
1.8.3. Sodyum Perborat	17
1.9 İntrakoronal Beyazlatma Yöntemleri	18
1.9.1 Walking Bleach Yöntemi	19
1.9.2 Termokatalitik Yöntem	19
1.10 Yapay Zeka	19
1.10.1 Yapay Zekanın Tarihçesi	19
1.10.2 Yapay Zekanın ve Alt Dalları	20
1.10.2.1 Makine Öğrenmesi	20

1.10.2.1.1 XGBoost	21
1.10.2.2 Derin Öğrenme	22
1.10.2.2.1. Yapay Sinir Ağları (Artificial Neural Network – ANN)	22
1.10.2.2.2. Derin Sinir Ağları (Deep Neural Network – DNN)	23
1.10.2.2.3. Evrişimli Sinir Ağları (Concolutional Neural Networks – CNN)	25
1.10.2.2.4. Yinelenen Sinir Ağları (Recurrent Neural Network – RNN)	25
1.10.2.2.5 Sıralı Modeller: Uzun Kısa Süreli Bellek (LSTM) ve Çift Yönlü LSTM (BiLSTM)	25
1.10.3 Endodontide Yapay Zeka	26
1.10.3.1 Periapikal Lezyonların Tespiti	26
1.10.3.2. Vertikal Kök Kırıklarının (VKK) Tespiti	27
1.10.3.3. Kök Kanal Morfolojisinin Tespiti	27
1.10.3.4. Çalışma Boyunun Tespiti	28
1.10.3.5 Kanal Tedavisi Yenilemesinde Prognoz Tahminleri	28
1.10.3.6 Post Operatif Ağrının Tahmini	29
1.10.3.7 Diş Rengi Tahmini	29
1.11 Çalışmanın Amacı	30
2. GEREÇ ve YÖNTEM	31
2.1. Çalışmaya Dahil Edilen Dişlerin Seçimi	31
2.2 Örneklerin Hazırlanması	31
2.3 Dişlerin Renklendirilmesi	32
2.4 Beyazlatma Prosedürü	33
2.5 Yapay Zeka Modelinin Geliştirilmesi	35
2.6 İstatiksel Analiz	38
3. BULGULAR	40
4. TARTIŞMA	41
5. SONUÇ ve ÖNERİLER	49
KAYNAKLAR	50
EKLER	58
Ek-1 Etik Onay Raporu	58
ÖZGEÇMİŞ	62

ÖNSÖZ

Doktora eğitimim süresince ve tez çalışmamın her aşamasında büyük bir sabır ve özenle bana yardımcı olan, bilgi ve tecrübelerini paylaşan, yol gösteren, öğrencisi olmaktan gurur duyduğum değerli danışman hocam Prof. Dr. Meltem DARTAR ÖZTAN'a,

Tez çalışmamın deneysel sürecinde bilgi ve tecrübeleriyle katkı sağlayan hocam Dr. Öğr. Üyesi Koray AÇICI'ya

Doktora eğitimim süresince bilimsel ve mesleki tecrübelerinden yararlandığım Ankara Üniversitesi Diş Hekimliği Fakültesi Endodonti Anabilim Dalı öğretim üyelerine,

Çocukluk yıllarımdan bu yana her daim yanımda olan ilk arkadaşlarım Bilgenur KAPUSUZUOĞLU, Başak BAYTEKİN ve Ezgi AKÇAY'a,

Lise günlerimizden bu yana hiç ayrılmadığımız değerli arkadaşlarım Özenay ARSLAN, Esra CANBOLAT, Zeynep KAZAK ve Elif Selcen PUSAT'a,

Üniversite sıralarını birlikte paylaştığım biricik arkadaşlarım Dt. Beril Olgaç, Uzm. Dt. Deniz SAVAŞ ÇANKAYA, Uzm. Dt. Yasemin YAMAN ÇALIŞKAN ve Uzm. Dt. Merve Öge'ye ,

Doktora eğitimim boyunca bilgi paylaşımı, desteği ve dostluklarıyla bu süreci daha anlamlı ve verimli kılan Dt. İpek GÜÇLÜOL, Dr. Dt. Damla GÖÇMEN ve Uzm. Dt. Gülseren ANAR'a,

Hayatım boyunca benden desteklerini esirgemeyen, bugünlere gelmeme vesile olan ailem Hamdi Tuna YENER, Ezgi YILMAZ YENER, Sevil YENER ve Hüseyin YENER'e,

Doktora eğitimim süresince burs desteği aldığım TÜBİTAK Türkiye Bilim İnsanı Destek Programları Başkanlığı (BİDEB) 2211-Yurt İçi Lisansüstü Burs Programı'na sağladıkları katkı ve destek için,

Bilim ve akıl yolunda bizlere örnek olan, çağdaş Türkiye'nin mimarı Gazi Mustafa Kemal ATATÜRK'e sonsuz teşekkürler...

SİMGELER ve KISALTMALAR

%	Yüzde
°C	Santigrad Derece
ΔE	CIE Lab* sistemine göre renk farkı
ΔE_{00}	CIEDE2000 sistemine göre renk farkı
L^*	Parlaklık değeri
a^*	Kırmızı – yeşil renk bileşeni
b^*	Sarı – mavi renk bileşeni
C^*	Chroma (doygunluk) değeri
h°	Hue (ton) değeri
pH	Hidrojen iyonu derişimi
H_2O_2	Hidrojen Peroksit
OH^-	Hidroksil iyonu
HO_2	Hidroperoksil
nm	Nanometre
vd.	Ve diğerleri
ANN	Yapay Sinir Ağları
BiLSTM	Çift Yönlü LSTM
$CH_6N_2O_3$	Karbamid Peroksit
CIE	Comission International D'Eclairage (Uluslararası Aydınlatma Komisyonu)
CNN	Evrişimli Sinir Ağları
DNN	Derin Sinir Ağları
KIBT	Konik ışınlı bilgisayarlı tomografi
LOOCV	Leave-One-Out Cross-Validation
LSTM	Uzun Kısa Süreli Bellek
MAE	Mean Absolute Error (Ortalama Mutlak Hata)
MTA	Mineral Trioksit Agregat
MTAD	Mixture of Tetracyclin, Acid and Detergent
NaOCl	Sodyum Hipoklorit
PCA	Parakloroanilin
R^2	Determinasyon katsayısı
RMSE	Root Mean Swuare Error (Ortalama Karekök Sapması)
RNN	Yinelenen Sinir Ağları
YZ	Yapay Zeka

ŞEKİLLER

Şekil 1.1. Işığın dalga boyları	2
Şekil 1.2. Dairesel renk diyagramı (Sikri, 2010)	3
Şekil 1.3. Munsell renk sistemi	4
Şekil 1.4. CIEDE Renk Sisteminde renk farkı hesaplama formülü	5
Şekil 1.5. RGB renk sistemi	6
Şekil 1.6. Kolorimetre (Minolta CR 321, Konica Minolta, Tokyo, Japan)	8
Şekil 1.7. Vita EasyShade V (Vita Zahnfabrik, Bad Sackingen, Almanya)	9
Şekil 1.8. Asidik pH'daki hidrojen peroksidin iyonizasyonu (Çalışkan, 2023)	16
Şekil 1.9. Tamponlanmış hidrojen peroksidin (pH 9,8-10,8) iyonizasyonu (Çalışkan, 2023)	17
Şekil 1.10. Karbamiit peroksitin ayrışması (Çalışkan, 2023)	17
Şekil 1.11. Sodyum perboratın ayrışması (Attin vd., 2003)	18
Şekil 1.12. Optimizasyon formülü	21
Şekil 1.13. Düzenleştirme formülü	21
Şekil 1.14. Biyolojik sinir hücresi ve yapay sinir ağı (Maltarollo vd., 2013)	22
Şekil 1.15. Biyolojik sinir sistemi elemanları ve yapay sinir sisteminde karşılıkları (Öztürk ve Şahin, 2018)	23
Şekil 1.16. Çok katmanlı sinir ağı fonksiyon bileşimi	23
Şekil 1.17. Katman düzeyinde hesaplama fonksiyonu	24
Şekil 1.18. Derin öğrenme optimizasyon problemi	24
Şekil 1.19. DNN düzenleştirme terimi	24
Şekil 2.1. Santrifüj Cihazı Mikro 22 (Hettich Zentrifugen, Almanya)	32
Şekil 2.2. Santrifüje edilen örnekler	33
Şekil 2.3. Renklendirilmiş diş örnekleri	33
Şekil 2.4. Opalescence Endo (Ultradent, ABD)	34
Şekil 2.5. VİTA 3D-Master Renk Skalası	34

ÇİZELGELER

Çizelge 2.1. XGBoost hiperparametreleri ve anlamları	36
Çizelge 2.2. DNN hiperparametreleri ve anlamları	37
Çizelge 2.3. LSTM ve BiLSTM hiperparametreleri ve anlamları	38
Çizelge 2.4. Yapay Zeka model performans metrikleri ve açıklamaları	39
Çizelge 3.1. Modellerin performansları	40



1. GİRİŞ

Günümüzde diş estetiğinin önemi her geçen gün artmaktadır. Estetik diş hekimliğinin amacı dişlerin renk, şekil ve boyut olarak dişeti, dudaklar ve yüz ile uyumlu olacak şekilde restore edilmesidir. Estetik görüntünün iyileştirilmesi için birçok farklı tedavi yöntemi geliştirilmiştir. Mekanik abrazyon, kompozit restorasyonlar, porselen lamina ve veneerler, tam seramik kronlar ve diş beyazlatma teknikleri bu amaçla kullanılan başlıca yöntemler arasında yer almaktadır (Arens, 1989). Beyazlatma tedavileri; kolay uygulanması, konservatif olması ve diğer tedavilere göre daha ekonomik olması gibi avantajları ile ilginin ve talebin arttığı bir tedavi seçeneği olarak karşımıza çıkmaktadır.

Diş renklenmeleri birçok sebebe bağlı ortaya çıkabilir. Geliştiği bölgeye ve etiyojisine göre içsel veya dışsal renklenmeler olarak sınıflandırılabilir. Pulpa nekrozu, pulpal hemorajiler, endodontik tedavi sonrasında kalan pulpa artıkları, kanal dolgu patları, kanal içi medikamentler, endodontik materyaller içsel renklenmelere örnektir ve bu tür renklenmelerin giderilmesinde kanal tedavisi sonrası intrakoronal beyazlatma tedavisi uygulanabilir.

Intrakoronal beyazlatma tedavilerinde sıklıkla farklı konsantrasyonlarda hidrojen peroksit, karbamid peroksit ve sodyum perborat kullanılmaktadır (Frysh vd., 1995). Hidrojen peroksit preparatları dişlerin beyazlatılma tedavisinde %5 ile %35 arasındaki oranlarda kullanılabilir. Buna alternatif olarak karbamid peroksit veya sodyum perborat ile karıştırılarak da uygulanabilir. İntrakoronal beyazlatma tedavisi için ise genellikle %30-%35'lik konsantrasyonlarda kullanımı daha etkili bulunmuştur (Plotino vd., 2008).

Intrakoronal beyazlatma için başlıca iki yöntem kullanılmaktadır. Bunlar "Termokatalitik" ve "Walking Bleach" teknikleridir. Walking Bleach tekniğinin basit ve ucuz olması, hasta başında geçirilen zamanı kısaltması ve nispeten daha güvenilir olması sebepleriyle en sık kullanılan beyazlatma tekniklerinden biri olmuştur (Kaneko vd., 2000).

Beyazlatmanın etkinliğini ölçebilmek için renkleri ayırt etmede görerek veya cihazlarla ölçüm yapılmaktadır. Klinikte sıklıkla kişinin dişini renk skalaları kullanarak standart renklerle göz ile ayırt etme yöntemi kullanılmaktadır. Fakat bu yöntem sübjektiftir ve güvenilirliği tartışmalıdır. Göz yanılgılarını minimuma indirebilmek için renk ölçüm


cihazları geliştirilmiştir. Sıklıkla; kolorimetreler, sprektoradyometreler, spektrofotometreler ve dijital kameralar kullanılır. Bu cihazların çoğu renk değişimlerini tanımlamak için CIELAB renk sistemini kullanır (Todorović vd., 2013).

Yapay zeka teknolojilerinin diş hekimliğinde kullanımı hızla yaygınlaşmaktadır. Endodonti alanında ise yapay zeka uygulamaları başlıca teşhis ve tahmin başlıkları altında toplanmıştır. Apikal lezyonların tespiti, vertikal kök kırıklarının tespiti, çalışma boyu tespiti, kök kanal tedavisi yenilemelerinde prognoz tahmini, rejenerasyon tedavilerinde kök hücre canlılığı tahmini ile ilgili çalışmalar örnek olarak gösterilebilir.

1.1 Renk Tanımı

Renk, çeşitli dalga boylarındaki ışığın gözdeki retina tabakasına ulaşarak algılanmasına denir. Işık cisimlere çarptığında bir kısmı soğurulur bir kısmı yansır. Algıda oluşan bu farklılığa renk tonu denmektedir (Strenk vd., 2005; Wee, 2006).


Işığın olmadığı ortamda renk de algılanamaz. Kırmızı, yeşil ve mavi renkler ana renklerdir. Tüm dalga boylarının aynı anda göze ulaşması durumunda beyaz, hiç ulaşmaması durumunda ise siyah olarak algılanmaktadır. İnsan gözü görünür ışık olarak adlandırılan elektromanyetik spektrumunun 380-780 nm aralığını algılayabilmektedir (Brewer vd., 2004; McPhee, 1985) (Şekil 1.1).



Şekil 1. 1. Işığın dalga boyları

1.2 Renk Analiz Sistemleri

1666 yılında Newton tarafından tasarlanan ilk dairesel renk diyagramı üzerinde yıllar içerisinde çeşitli düzenlemeler yapılmıştır ve günümüzdeki versiyonu 12 renkten oluşmaktadır (Şekil 1.2). Bu diyagramdaki birincil renkleri mavi, sarı ve kırmızıdır. Birincil renklerin ikili gruplar halinde karıştırılmasıyla ikincil renkler olan yeşil, turuncu ve mor renkleri elde edilmektedir. Birincil ve ikincil gruplar karıştırılarak elde edilen üçüncül grupta ise altı adet renk bulunmaktadır (Sikri, 2010).




Şekil 1. 2. Dairesel renk diyagramı (Sikri, 2010)

Renk sistemleri sayesinde renklerin uzaydaki konumları üç boyutlu olarak tespit edilebilmektedir. Bu sayede renk tanımlanabilir. Renk sistemlerine örnek olarak Munsell, CIE ve RGB sistemleri örnek gösterilebilir (Chu, 2004; Paravina ve Powers, 2004; Sproull, 1973).

1.2.1. Görsel Değerlendirmede Kullanılan Renk Sistemleri

1.2.1.1 Munsell Renk Sistemi:

1905 yılında Albert H. Munsell tarafından geliştirilen Munsell renk sistemi en eski renk sistemidir (Wee, 2006). Bu sistemde ton (hue), parlaklık (value) ve doygunluk (chrome) olmak üzere üç değişken mevcuttur (Şekil 1.3).



Şekil 1. 3. Munsell renk sistemi

Parlaklık dik ekseninde silindirik şekilde gösterilir. Bu silindirin çevresinde bulunan halkanın üzerine ton yerleşir ve bu halkada beş ana beş ara renk bulunur. Doygunluk ise yatay ekseninde yerleşir ve merkezden dışarıya doğru gidildikçe yoğunluk artar (Phillips).

Ton , cismin ana rengi olarak tanımlanır. Bir rengi diğerinden ayırmaya yarayan değer olarak ifade edilmiştir (Munsell, 1919). VITA Classical renk skalasında A turuncu, B sarı, C sarı/gri ve D turuncu/gri renkleri ile gösterilir (Fondriest, 2003).

Parlaklık siyah – beyaz bir skaladır. Bu skalada 0 siyahı, 10 ise beyazı gösterir. Diş hekimliğinde renk seçiminde parlaklık en önemli renk parametresidir (Wee, 2006). Doğal dişteki parlaklık değeri 4-8 arasındadır (Hammad ve Stein, 1991). Yapılan restorasyonlarda parlaklık değeri arttıkça daha yapay görüntüye, azaldıkça daha cansız bir görüntüye sebep olur (Rosenstiel vd., 2001).

Doygunluk, ana rengin pigment yoğunluğunu ifade eder. Parlaklık değeri ile ters orantılıdır. VITA skalasında numaralar ile ifade edilir (Fondriest, 2003). 15 ayrı değerde tanımlanmıştır. En düşük yoğunluk değeri merkezde bulunur, dairenin dışına gidildikçe bu değer artar (Kuehni, 2002).

1.2.2. Dijital Cihazlarla Kullanılan Renk Sistemleri

1.2.2.1 CIE (Comission Internationale D'Eclairage) L*a*b Renk Sistemi

1976 yılında Comission Internationale de L'Eclairage (Uluslararası Aydınlanma Komisyonu) (CIE) tarafından tanımlanan renk sistemidir. Bu sistemde, L* - a* - b* olmak üzere 3 farklı parametre kullanılmaktadır. L* değeri Munsell sistemindeki parlaklık değeri gibi rengin parlaklık ve açıklık-koyuluk değeriyle ilişkilidir. 100 L* değeri beyazı, 0 L* değeri ise siyahı ifade eder. a* koordinatı yatay ekseninde rengin kırmızı (+a) ve yeşil (-a) doygunluğunu gösterirken b* koordinatı ise diğ ekseninde rengin sarı (+b) ve mavi (-b) doygunluğunu göstermektedir.

Bu üç ayrı koordinatın kesiştiği yer ise renk değerini gösterir. Bu sistemde tek bir değer üzerinden renk değişimi tanımlanır. CIE sisteminin en önemli avantajı nesnelerin zamanla gösterdiği renk değişiminin hesaplanabilmesidir. Renkteki farklılığı göstermek için ΔE değeri kullanılır. ΔE değeri renk değişiminin büyüklüğünü gösterir fakat bu değişimin yönü ile ilgili fikir vermez. ΔE değeri şu şekilde hesaplanır:

$$\Delta E = [(\Delta L^*)^2 + (\Delta a^*)^2 + (\Delta b^*)^2]^{1/2}$$

$$\Delta L = L_2^* - L_1^* \quad (\Delta L = \text{Parlaklık değerindeki fark})$$

$$\Delta a = a_2^* - a_1^* \quad (\Delta a = \text{Kırmızı-yeşil skalasında bulunan fark})$$

$$\Delta b = b_2^* - b_1^* \quad (\Delta b = \text{Yeşil-sarı skalasında bulunan fark})$$

CIEDE 2000 bu sistemdeki diğer renk değişim formülüdür. CIE L*a*b* formülü düzenlenerek oluşturulmuştur. CIE L*a*b* sisteminde bütün renk parametreleri eşit olarak değerlendirilirken CIEDE 2000 sisteminde gözlerin algısında baskın olan parametrenin katsayısı dikkate alınarak hesaplamalar yapılmaktadır. Bu şekilde renklerin algılanabilirliği daha doğru şekilde belirlenir. Bu sebepten ötürü son zamanlarda CIEDE renk analiz sistemi daha fazla tercih edilmektedir. CIEDE Renk Sisteminde iki cisim arasındaki renk farkının hesaplama yöntemi şu formülle ifade edilmiştir:


$$\Delta E_{00} = \sqrt{\left(\frac{\Delta L'}{k_{LSL}}\right)^2 + \left(\frac{\Delta C'}{k_{CSC}}\right)^2 + \left(\frac{\Delta H'}{k_{HSH}}\right)^2 + RT \frac{\Delta C'}{k_{CSC}} \frac{\Delta H'}{k_{HSH}}}$$

Şekil 1.4. CIEDE Renk Sisteminde renk farkı hesaplama formülü

Bu sistemin formülündeki $\Delta L'$, $\Delta C'$, $\Delta H'$, örneklerin işlemden önceki ve sonraki renk açıklığı, doygunluğu ve renk ölçümlerini ifade eder. Rotasyon Fonksiyonu (RT) ise mavi bölgedeki doygunluk ve ton arasındaki etkileşimi belirtir. SH, SC, SL; L, a ve b koordinatları üzerindeki toplamda renk farkının ayarlanmasında kullanılır. KL, KC, KH parametreleri ise deneysel izleme koşullarına bağlı hesapsal düzeltme terimleridir (Arai vd., 2021).

1.2.2.2. RGB Renk Sistemi:

RGB sistemi, cisimlerin renklerini değerlendirmek için kullanılan bir sistemdir. RGB ismi, üç ana renk olan kırmızı-yeşil-mavi renklerin baş harflerinden gelmektedir. Kırmızı ve yeşil renklerin birleşmesi sonucu sarı, mavi ve yeşil renklerin birleşimi ile turkuaz, mavi ve kırmızı renklerinin birleşmesi ile magenta rengi elde edilmektedir. 3 ana rengin eşit şekilde karıştırılması sonucunda da saf beyaz renk elde edilir. Sistemdeki ana renklerin kullanılarak farklı renkler elde edilmesine eklemeli renk karışımı (additive color) denir. Televizyon ve bilgisayar ekranlarında kullanılan bu sistemde her ana renk için 0 ile 255 arasında değişen farklı parlaklık ve doygunluk değerleri bulunmaktadır (Chu, 2004).



Şekil 1. 5. RGB renk sistemi

1.3. Diş Hekimliğinde Renk Ölçüm Yöntemleri

1.3.1. Geleneksel Renk Ölçüm Yöntemleri

Rengin algılanması; bireyden bireye değişebilen, tekrarlandığı durumlarda göz yorgunluğuna bağlı olarak tutarsızlıklar gözlenebilen bir durumdur (Chu, 2004). Görsel renk ölçüm yöntemi; ortamdaki ışığın spektral özellikleri ve şiddeti, ölçümü yapan kişinin yaşı, tecrübesi, göz yorgunluğu, psikolojik durumu, kişinin kullandığı skaladaki renklerin yeterliliği, cismin, cismi aydınlatan ışık kaynağının ve kişinin konumu gibi birçok farklı faktöre bağlıdır (Sproull, 1973).

Renk skalaları renk belirlenmesi amacıyla kullanılan maliyeti az, geleneksel renk ölçüm yöntemidir. En sık kullanılan skalalara Vita Classic (Vita, Bad Sackingen, Almanya) ve Vita 3D-Master (Vita, Bad Sackingen, Almanya) örnek gösterilebilir.

1.3.2. Dijital Renk Ölçüm Yöntemleri

Geleneksel renk ölçüm yöntemleri ile yapılan analizde sayısal değerler bulunmaz, bu yüzden de objektif sonuçlar elde edilemez. Objektif sonuçlar elde etmek için dijital renk ölçüm cihazları üretilmiştir. Bu sayede renk ölçümleri tekrarlanabilir ve daha güvenilirdir. Ayrıca daha detaylı sonuçlar vermektedir. Günümüzde hekimler tarafından sıklıkla tercih edilen ölçüm cihazları kolorimetreler, spektrofotometreler, spektoradyometreler ve dijital fotoğraf makineleridir.

Bu ölçüm cihazları genellikle; bir dedektör, bir sinyal düzenleyici ve gelen sinyali uygulayıcının elde edeceği verilere dönüştürebilen bir yazılım programından oluşur (Ivan ve Rade, 2009). Bu sistemlerin sayısal sonuçlar vermesi ve tekrarlanabilir ölçümler yapılabilmesi gibi avantajları bulunmasına rağmen maliyetlerinin fazla olması ve kalibrasyon hataları gibi dezavantajları da bulunmaktadır (Chu, 2004)

1.3.2.1. Kolorimetreler

Kolorimetreler, herhangi bir sayısal işlem kullanmadan X-Y-Z veya L*a*b* koordinatlarıyla uygulayıcıya verir. Cisimlerden yansıyan ışınların gözdeki renk reseptörlerini taklit eden filtrelerden geçmesiyle renk belirlenir.

CIE L*a*b* Sistemi kullanan ölçüm cihazları renk tespiti yaparken cisme sabit açılarla ışınlar gönderip geri yansıyan ışınlar üzerinden ölçümler yapar.

Kolorimetrelerin kullanımı spektrofotometrelere nazaran daha kolaydır ve daha az maliyetlidir. Fakat kolorimetrelerin filtrelerinin zamanla eskiyerek ölçümlerin tutarlılığında ve sürekliliğinde düşüşler olması ve bu sebeple CIE L*a*b sistemiyle uyumlu sonuçlar verme olasılığının azalması en önemli dezavantajıdır.

Translüsente olan nesnelerin ölçümü yapılırken ışık kırılıp dağıldığı için kolorimetreler bu nesnelerde etkili ölçüm yapamazlar. Bunu önlemek için renk ölçümü esnasında standart bir arka plan kullanılmalıdır (Ahmad, 2008).

Kolorimetreler düz olmayan yüzeylerin ölçümünde daha az başarılıdır. Bu sebeple dış yüzeylerinin ölçümünde hataların olma ihtimali daha fazladır. Ayrıca nesnelerin üzerinden yansıyan ışığın kolorimetreye ulaşamaması sonucunda “edge loss” denilen hatalar da oluşmaktadır. Bu sebepler nedeniyle renk stabilitesini değerlendirilmek amacıyla kolorimetrelerin kullanılması tercih edilmemektedir (Tung vd., 2002).

1980’li yıllarda ilk kolorimetre olan “Chromoscan” (Sterngold-Stamford-Conn) üretilmiştir. Ardından “ShadeEye Natural Color Concept, Chrome Meter” (Shofu Dental), Minolta Chromameter (Minolta CR-321, Osaka, Japonya)” gibi çeşitli markalara ait cihazlar üretilmiştir.



Şekil 1. 6. Kolorimetre (Minolta CR 321, Konica Minolta, Tokyo, Japan).

1.3.2.2. Spektrofotometreler

Spektrofotometreler, nesne üzerinden yansıyan ışık ile beyaz yüzeyden yansıyan ışığı oranlayarak ölçüm yaparlar ve nesne üzerinden yansıyan ya da nesneden geçen görülebilir radyant enerjiyi ölçerler. Dedektör, ışık kaynağı ve monokromatörden oluşmaktadır (Wee vd., 2000).

Bu cihazlar çoklu dalga boylarında ölçüm yapabilir ve renkleri algılamakta insan gözlerinden çok daha hassastır (Chu, 2004). Kompozit rezinlerin, protetik restorasyonların, renk skalalarının, dental materyallerin renklerinin ölçümünde ve iki farklı cisim arasındaki renk farklılıklarının belirlenmesinde kullanılmaktadır (Aladağ vd., 2009).

Spektrofotometrelerle yapılan ölçümler konvansiyonel ve görsel yöntemlere göre %33 daha başarılı bulunmuşlardır. Yapılan çalışmalarda spektrofotometreler ile yapılan ölçümlerin %93 oranında doğru sonuçlar verdiği tespit edilmiştir (Paul vd., 2002). Yapılan ölçümlerin tekrar edilebilirliği, ayrıntılı ve güvenilir olması diş hekimliğinde tercih edilmesinin ana nedenlerindendir. Standardizasyon sağlandığında çok başarılı sonuçlar veren bu cihazların dezavantajları olarak standardizasyonunu sağlamada güçlükler yaşanması, pahalı olması ve klinik kullanımda uygulanmasının zor olması gösterilebilir. Düz yüzeylerde daha başarılı sonuçlar vermesi ise kolorimetrelere tercih edilmesini sağlamıştır (Chu, 2004).

Piyasada bulunan spektrofotometre cihazlarına Crystaleye (Olympus, Tokyo, Japonya), SpectroShade Micro (MHT Optic Research, Niederhasli, İsviçre) ve Vita EasyShade V (Vita Zahnfabrik, Bad Sackingen, Almanya) örnek gösterilebilir.



Şekil 1. 7. Vita EasyShade V (Vita Zahnfabrik, Bad Sackingen, Almanya)

1.3.2.3. Spektoradyometreler

Bu cihazların çalışma prensibi elektromanyetik alanda kendine özgü yansımalar yapıp bu değerin ölçülmesi şeklindedir. Dedektör, okuyucu, toplayıcı optikler ve monokromatörden oluşmaktadır. Cisimden yansıyan ışığı, rengi ve transparanlığı projektör aracılığıyla beyaz bir ekrana taşıyıp renk ölçümü yapar.

Spektoradyometrelerin kolorimetrelere karşı avantajı; ışık kaynağı, cihaz ve cisim arasında açıklık olmadığı için kolorimetrelerdeki “edge loss” sorunu ortadan kalkmaktadır. Spektrofotometrelere göre avantajı ise sabit ışık kaynağının olmaması ve spektoradyometrelerle temassız ölçüm yapılabilmesidir. Dış yüzeyleri düz olmadığı ve translusent olduğu için ölçümlerinde spektoradyometreler tercih edilebilirler fakat ölçüm esnasında cihazın pozisyonundaki herhangi bir değişiklik ölçüm sonuçlarını etkileyebileceği için ölçüm sırasında son derece dikkatli ve özenli olunması gerekmektedir. Aynı zamanda maliyetlerinin çok yüksek olması da dezavantajlarındanır.

Piyasada CS-1000A (Konica, Minolta, Amerika), SC 1000S (Konica, Minolta, Amerika), SpektraScan PR 670 (Jadak, Amerika) ve Spektra Duo PR 680 (Jadak, Amerika) gibi spektoradyometre modelleri bulunmaktadır.

1.3.2.4. Görüntü Sistemleri ve Dijital Kameralar

Son dönemlerde çok popüler hale gelen bu sistemlerin en önemli avantajları nesnenin rengini tek bir noktadan değil bir bütün imaj haline getirmesidir (Chu, 2004). Bu sistemlerde kameralar ile objenin fotoğrafı çekildikten sonra görüntüsü bilgisayar ortamına aktarılır ve CIE L*a*b sistemiyle renk belirlenir. Bu sistemde; dijital kamera, bu kameraya bağlı bilgisayar, görüntüyü yakalayan bir sürücü, renk sensörü ve bilgisayar bulunmaktadır (Wee vd., 2006).

Fotoğrafın görüntü kalitesi doğru bir renk analizi için çok önemlidir. Kamera tipi, kamera ayarları, fotoğrafın çekildiği ortamın aydınlatma koşulları, çekilen görüntünün boyutu, fotoğrafı çekilen dışın konumu gibi birçok faktör görüntü kalitesini etkilemektedir. Koşullar ne kadar uygun olursa sistem de o kadar doğru sonuca yaklaşır (Karamouzos vd., 2007).

Dijital kameralar ve renk skalaları birlikte kullanılarak elde edilen fotoğraflar hekim ve teknisyenin daha uyumlu çalışabilmesini sağlamaktadır. Bu yöntemler teknisyen dişin opasitesi, translüsensi gibi özellikleri hakkında bilgi elde edebilir. Fakat yine de sadece dijital kameralarla yapılan renk analizi kusursuz bir renk uyumu için tek başına yeterli değildir (Sarıkaya ve Güler, 2009).

Bu sistemlere örnek olarak ClearMatch (Smart Technology, Hood River, Utah) yazılımı örnek verilebilir.

1.4 Dış Renklenmeleri

Herhangi bir sebepten ötürü dişlerin doğal renklerinin bozularak farklı bir renk almasına “dış renklenmeleri” denir. Etkili beyazlatma tedavisi için renklenmelerin etiyolojisinin belirlenmesi ve ona göre bir tedavi planı oluşturulması çok önemlidir. (Watts ve Addy, 2001). Dış renklenmeleri iç kaynaklı veya dış kaynaklı olmak üzere ikiye ayrılırlar.

1.4.2 Dış Kaynaklı Renklenmeler

Dış renklenmeler, renklenmelerin kaynağına göre metalik ve metalik olmayan renklenmeler olarak sınıflandırılmışlardır (Gorlin ve Goldman, 1970).

1.4.1.1 Metalik Renklenmeler

Bazı sistemik ya da çevresel faktörler dişlerde belirgin renk değişimlerine yol açabilmektedir. Örneğin, demir preparatlarının uzun süreli kullanımı ya da demir döküm işçilerinin maruziyeti sonucu metalik koyu renklenmeler oluşabilir (Nordbo vd., 1982). Bakır tuzları içerikli ağız gargaraları diş yüzeyinde yeşil renklenmeler yapar (Waerhaug vd., 1984). Potasyum permanganat içeren gargaralar kullanıldığında mordan siyaha doğru farklı renklenmeler yapabilir (Watts ve Addy, 2001). Dış hekimliğinde kullanılan gümüş nitrat dişlerde gri renklenmeler yapar (Dayan vd., 1983). Benzer şekilde stanöz floridin kullanımı da sarı-kahverengi renklenmeler yapar (Ellingsen vd., 1982).

1.4.1.2 Metalik Olmayan Renklenmeler

Metalik olmayan dış kaynaklı renklenmeler, genellikle diş yüzeyine tutunmuş plak ve benzeri birikimlerden oluşur. Bu tür renk değişimlerinin olası etyolojik etkenleri

iecekler, beslenme, ağız gargaraları, tütün ve diğerk medikamanlardır. ocuklarda bunlara ek olarak kromojenik bakterilerden de söz edilebilir (Theilade vd., 1973).

Klorheksidin ieren ağız gargaralarının uzun süre kullanımı ve ağız gargaralarında quarterner amonyum bileşiklerinin kullanılması ile oluşan renklenmeler de diř hekimliğinde önemli bir yere sahiptir.

Diř kökenli renklenmeler iki ana grupta incelenmektedir. Bunlardan ilki bileşikler pelikıl üzerine bağlanır (direk boyanma) ve kendi temel renklerinin sonucu olarak renklenme oluřtururlar. Tütün renklenmesi, ay, kahve gibi ieceklere bağı olan renklenmeler bu tür renklenmeye örnek gösterilebilir. İkinci kategoride ise diř yüzeyinde kimyasal etkileşimler sonucu renklenme (indirekt boyanma) oluřur (Watts ve Addy, 2001).

1.5 İ Renklenmeler

Diř sert dokularının yapılarında ve kalınlıklarında gelişim esnasında meydana gelen herhangi bir değıřim sonucu diř dokularının ışığı geirme özellikleri değıřir ve i renklenmeler meydana gelir.

İ kökenli renklenmeler lokal ve sistemik nedenlerle oluşan renklenmeler olarak iki farklı grupta incelenirler.

Sistemik nedenlerle oluşan i renklenmeler alkaptonuri, konjenital eritropoetik porfiria, konjenital hiperbillurubinemi, amelogenezis imperfekta, dentinogenezis imperfekta, dentin displazileri, tetkrasiklin boyanması, florozis, mine hipoplazisi ve yařlanmadır.

Lokal nedenlerle oluşan i kökenli renklenmeler ise pulpa kaynaklı renklenmeler, servikal kök rezorpsiyonu, dental tedavilere bağı renklenmeler ve endodontik tedavi sonrası oluşan renklenmeler olarak sınıflara ayrılırlar (Plotino vd., 2008).

1.5.1 Kanal Tedavisi Esnasındaki Prosedürlere Bağı Renklenmeler

Kanal tedavisi esnasında yapıla giriş kavitesi preparasyonu, kemomekanik enstrümentasyon, irrigasyon esnasında kullanılan solüsyonlar, kanal iine uygulanan

medikamanlar ve kök kanal boşluğunun doldurulması dişlerde renklenmelere sebep olabilir (Ahmed ve Abbott, 2012).

Giriş kavitesinin yetersiz açılması veya şeklinin ideal olmaması nedeniyle pulpa odasında kalan pulpa dokusunun artıklarının parçalanmasına bağlı olarak açığa çıkan maddeler renklenmelere sebep olur (Ahmed ve Abbott, 2012).

Kök kanalında en sık kullanılan irrigasyon solüsyonu sodyum hipoklorittir. Bazı durumlarda sodyum hipokloritin etkinliğini arttırmak, kostik etkisini azaltmak ve smear tabakasını kaldırmaya yardım etmek için başka irrigasyon solüsyonları ile kombine kullanımı bildirilmiştir (Haapasalo ve Qian, 2008).

Sodyum hipoklorit, klorheksidin jel ile birlikte kullanıldığında parakloranilin (PCA) içeren kahverengi bir çökelti oluşturur. PCA hem karsinogeniktir hem de bu çökelti dentinde renklenmelere sebep olur.

Bir başka irrigasyon solüsyonu olan MTAD (Dentsply Tulsa Dental, Tulsa, OK, USA) bir tetrasiklin izomeri, deterjan ve asitten oluşmaktadır. Bu solüsyon NaOCl'den sonra kullanıldığında mavi renklenme yapmaktadır. Bunun sebebi MTAD içeriğindeki tetrasiklin izomeri olan doksisisiklinin NaOCl ile etkileşime girmesidir (Torabinejad vd., 2003).

NaOCl'den sonra son irrigasyon solüsyonu olarak BioPure MTAD'nin kullanılmasının sarı bir çökelti oluşturduğu bildirilmiştir (Tay vd., 2006). Ayrıca %1.3 NaOCl ile irrigasyon sonrasında MTAD ile irrigate edilip ışıktaki bekletilen kök kanal tedavili dişlerde kırmızı-mor renklenmeler gözlenmiştir. Bunların dışında NaOCl ve sitrik asitin de kimyasal etkileşime girerek beyaz bir çökelti oluşturduğu bildirilmiştir (Ahmed ve Abbott, 2012).

Endodontide kanal içi medikamanların çok geniş bir kullanımı vardır. Travmalı dişlerin tedavilerinde, geniş periapikal lezyonlara sahip dişlerde, kök rezorpsiyonu olan dişlerde, kök ucu gelişimi tamamlamamış dişlerde apeksifikasyon ve rejenerasyon tedavilerinde yaygın şekilde bu medikamanlar kullanılmaktadır (Banchs ve Trope, 2004; Jung vd., 2008; Mohammadi ve Abbott, 2009). Bunlara ek olarak bazı materyaller süt dişlerinin kök kanal tedavilerinde kanal dolgu materyali olarak da kullanılmaktadır (Kupietzky vd., 2003). Endodontik tedavilerdeki avantajlarının yanı sıra kanal içi

medikamanlar dişte uzun sürelerde bekletildiğinde diş kronunda renklenmeye sebep olabilir (Ahmed ve Abbott, 2012). Üçlü antibiyotik patı ve Ledermix patı giriş kavitesinden düzgün şekilde uzaklaştırılmadığında en çok renklenmeye sebep olan kanal içi medikamanlardır (Kim vd., 2010; Kim vd., 2000). Ayrıca iyodoform ve formokrezol bazlı medikamanların da renklenmelere sebep olduğu bildirilmiştir (Kupietzky vd., 2003).

Kök kanal tedavisinde kullanılan kanal dolgu materyalleri özellikle mine-sement sınırının koronalinde bırakıldığında renklenmeye sebep olur. Bu renklenmeler çoğunlukla servikal üçlüde gözlenirler çünkü bu bölgede mine ince, renksiz ve translusent yapıdadır (Parsons vd., 2001). Örneğin gümüş konlar kök kanal dolgusunda kullanıldığında korozyona uğrar ve bu korozyon ürünleri diş ve çevre dokularda renklenmelere sebep olur (Brady ve del Rio, 1975). Dünya çapında kök kanal tedavisinde kanal dolgu materyali olarak en sık kullanılan materyal guta perkadır, fakat kök kanal tedavisi sonunda mine-sement seviyesinin altına kadar indirilmezse kronunda renklenmeye sebep olabilir (van der Burgt ve Plasschaert, 1985).

Kök kanal patlarının da renklenmelere sebep olduğu bildirilmiştir (Ahmed ve Abbott, 2012). Genellikle patların içeriğindeki reaksiyona girmemiş bileşikler, nem çeken bazı komponentlerin korozyona uğraması veya dentinle girdiği kimyasal reaksiyon sonucunda renklenmeye sebep olur (Parsons vd., 2001).

Son yıllarda kullanımı gittikçe yaygınlaşmakta olan MTA da dişlerde ve çevre dokularında renklenmelere sebep olmaktadır. Estetik bölgelerde kullanılmak üzere demir oksit içermeyen bir MTA formülü de geliştirilmiştir fakat bunun da muhtemelen içeriğindeki bazı materyallerin oksidasyonu sebebiyle renklenmelere sebep olduğu bildirilmiştir (Asgary vd., 2005; Kogan vd., 2006).

1.5.2 Endodontik Tedavi Sonrası Restoratif İşlemlere Bağlı Renklenmeler

Endodontik tedavi sonrası dişlerin restorasyonlarında kullanılan amalgam, pinler ve metalik postlar koronal renklenmelere sebep olmaktadır. Ayrıca daimi restorasyonların uygulanması sırasında diş yüzeylerinin uygun hazırlanmaması, yanlış uygulama şekilleri ve materyallerin kısıtlılıkları sebebiyle bakteriyel penetrasyon ve çürük gelişebilmektedir. Bu da marjinal renklenmeye sebep olmaktadır (Plotino vd., 2008).

1.6 Beyazlatmanın Tarihçesi

Diş hekimliğinde beyazlatma ile ilgili ilk çalışma 1799 yılında Macintosh'un klorid içerikli beyazlatma ajanı üzerine yaptığı çalışmadır. Devital dişlerin beyazlatılmasıyla ilgili ilk çalışmalara 19. yüzyılın ortalarında başlanmış, hidrojen peroksitin ilk defa kullanılması ise 1884 yılında Harlan tarafından önerilmiştir. 1958 yılında Pearson, cansız dişlere dışarıdan pirozon ile beyazlatma yaparken pulpa odasına da %35'lik hidrojen peroksitin yerleştirilmesini önermiştir (Fasanaro, 1992). Günümüzde en sık kullanılan devital beyazlatma yöntemlerinden biri olan "Walking bleach" yöntemi ise ilk olarak 1961 yılında Spasser tarafından bahsedilmiştir. Araştırmacı kanal tedavisi görmüş dişlerde pulpa odasının içerisinde sodyum perborat ile distile su karışımını bekletip birkaç gün aralıklarla bu karışımın değiştirilmesini önermiştir (Spasser, 1961).

1.7 Beyazlatmanın Mekanizması

Beyazlatma için kullanılan ajanlar okside edici ajanlardır. Oksidoredüksiyon reaksiyonu ile çalışırlar. Bu reaksiyonda, beyazlatma için kullanılan ajan okside edici ajandır. Çiftleşmemiş elektronlara sahip serbest radikallerdeki elektronları vererek indirgenir. Beyazlatılacak olan madde ise indirgeyici ajandır, okside edici ajandan elektronları alarak okside olur (McEvoy, 1989).

Hidrojen peroksitten açığa çıkan serbest radikaller hidrofilik ve kararsız moleküllerdir. Bu radikaller diş sert dokularında renklenmeye neden olan organik moleküllerle reaksiyona girerek organik moleküllerin soğurma enerjisini değiştirir. Bu sayede ışığı daha az yansıtan basit moleküller oluşur. Bu reaksiyonlar diş tamamen beyazlayana kadar devam eder. Ortamda sadece hidrofilik renksiz yapıların bulunduğu doyum noktasına ulaşıldığında beyazlatma işlemine son verilmelidir. Beyazlatma işlemine devam edilirse mine dokusunda yıkım olur. (Frysh vd., 1995)

1.8 Beyazlatma Tedavisinde Kullanılan Materyaller

Günümüzde klinikte en sık kullanılan beyazlatma ajanları hidrojen peroksit, karbamid peroksit ve sodyum perborattır.

1.8.1 Hidrojen Peroksit



İlk kez Harlan tarafından 1884 yılında devital dişlerin beyazlatılması için kullanılan hidrojen peroksit, günümüzde en sık kullanılan beyazlatma ajanları arasındadır (Harlan, 1885).

Hidrojen peroksit intrakoronal beyazlatma tedavilerinde %30-35 arasında değişen yüksek konsantrasyonlarda kullanılır (Seghi ve Denry, 1992; Zappala ve Caprioglio, 1993).

Hidrojen peroksitin eterdeki %25'lik solüsyonu 'pyrozen' olarak adlandırılır. Pyrozen içeriğindeki eter daha düşük yüzey gerilimine sahip olmasını sağlar böylelikle dentin tübüllerine daha çok penetre olarak daha etkili olur. Fakat kostik etkisi ve ağız yumuşak dokularına zarar verme riski fazla olduğu için kullanımı az tercih edilir. (Çalışkan, 2023).



Hidrojen peroksitin distile sudaki %30'luk çözeltileri 'süperoksol' olarak adlandırılır. Işıkla teması halinde etkinliği azalacağı için koyu renkli şişelerde ve buzdolabında saklanmalıdır (Hardman vd., 1985). Kostik etkisi fazla olduğundan kullanırken çevre yumuşak dokuları korumak için önlemler alınmalıdır (Walsh, 2000).

Hidrojen peroksit perhidroksil, hidroksil ve serbest oksijen gibi radikallere parçalanarak etkisini bu radikallerle gösterir. Hidrojen peroksidin saf sulu formu büyük oranda zayıf bir serbest radikal olan oksijeni oluşturur (Walsh, 2000).



Şekil 1. 8. Asidik pH'daki hidrojen peroksidin iyonizasyonu (Çalışkan, 2023).

Perhidroksil ise daha güçlü bir serbest radikaldir. Bu radikalin üretiminin daha yüksek düzeyde olabilmesi için hidrojen peroksidin pH 'ı optimum 9,5-10,8 arasında olmalıdır. Bu pH oranlarında tamponlanmış hidrojen peroksidin daha fazla beyazlatma etkinliği vardır (Frysh vd., 1993).



Şekil 1. 9. Tamponlanmış hidrojen peroksidin (pH 9,8-10,8) iyonizasyonu (Çalışkan, 2023).

1.8.2 Karbamid Peroksit ($\text{CH}_6\text{N}_2\text{O}_3$)

Karbamid peroksit ($\text{CH}_6\text{N}_2\text{O}_3$), üre ve hidrojen peroksitten oluşan bir bileşiktir. Üre peroksit olarak da bilinir. Diş hekimliğinde beyazlatma işlemleri için %10 ile %35 arasında değişen konsantrasyonları kullanılır (King, 2005).

%10 karbamid peroksit çözeltisi, %3 hidrojen peroksit ve %6 üreye ayrışır (Fasanaro, 1992). Açığa çıkan hidrojen peroksit beyazlatmada görev alan oksijen radikallerini üretir (Çalışkan, 2023). Üre, amonyak ve karbondioksit olarak ayrışarak çözeltinin pH'nı artırır ve en az iki saat bazik bir ortam oluşmasını sağlar (BUDAVARI, 1989; Dahl ve Pallesen, 2016; Haywood, 1991).



Şekil 1. 10. Karbamid peroksitin ayrışması (Çalışkan, 2023)

Karbamid peroksit ürünleri genellikle karbopol veya gliserin de içermektedir (Çalışkan, 2023). Gliserin içerenler diş sert dokuları ile karşılaştığında 1-2 saat oksijen salınımı yaparken karbopol içeren ürünlerde bu süre 8 saate kadar uzar (VB, 1990). Karbopol, hidrojen peroksit salınımını yavaşlatarak materyalin daha uzun süre etkili olmasını sağlar (Matis, 2000).


Karbamid peroksitin ayrışması sırasında gerçekleşen reaksiyonlar sonucu ortam pH'sı nötrleşir. Böylelikle karbamid peroksitle yapılan beyazlatma işlemleri hem diş sert dokuları hem de ağız mukozası için daha güvenli hale gelir (Çalışkan, 2023).

1.8.3. Sodyum Perborat

En yaygın olarak kullanılan beyazlatma ajanlarından birisi olan sodyum perborat kokusuz, beyaz kristal bir tozdur. Kristalizasyonundaki su içeriğine bağlı olarak sodyum

perborat monohidrat, trihidrat ve tetrahidrat gibi çeşitli formları mevcuttur. Bu formların, su veya hidrojen peroksit ile karıştırılarak hazırlanan preparatlarının beyazlatma etkinlikleri arasında fark olmadığı bildirilmiştir (Arı ve Üngör, 2002).

Sodyum perborat kuru ortamlarda stabildir. Asit, sıcak hava ve nem varlığında hidrojen peroksit ve serbest oksijen formuna parçalanır (Rotstein ve Friedman, 1991). Açığa çıkan hidrojen peroksit pH değerine, ışığa, ortamın sıcaklığına ve katalizör varlığına bağlı olarak farklı radikallere parçalanır (Ra, 1991). Hidrojen peroksitin parçalanması sonucunda oluşan bu radikaller, hidrojen peroksitin beyazlatma etkinliğinden sorumludur (Attin vd., 2003).



Şekil 1. 11. Sodyum perboratın ayrışması (Attin vd. , 2003)

Sodyum perboratın beyazlatma etkisi %30'luk hidrojen peroksit (süperoksol) oranla daha yavaştır ve bu etki daha uzun sürede ortaya çıkar. Yumuşak dokular üzerindeki iritan etkisi ise süperoksole göre daha düşüktür (Ho ve Goerig, 1989).

1.9 İntrakoronal Beyazlatma Yöntemleri

Vital olmayan dişlerdeki renklenmeler intrakoronal beyazlatma yöntemleri ile tedavi edilebilir. Beyazlatma tedavisinin başarılı olabilmesi için renklenmenin etiyolojisinin doğru tespit edilerek bu etiyolojiye yönelik doğru beyazlatma yönteminin seçilmesi çok önemlidir (Rotstein ve Li, 2008).

İntrakoronal beyazlatma walking bleach veya termokatalitik teknik ile uygulanabilir. Her iki teknik ile de benzer sonuçlar elde edilmesine rağmen, walking bleach, termokatalitik

yöntemle kıyaslandığında daha güvenli olduğu ve klinikte daha az zaman aldığı için en sık tercih edilen yöntemdir.(Freccia ve Peters, 1982; Jiménez-Rubio ve Segura, 1998)

1.9.1 Walking Bleach Yöntemi

Bu tekniğe walking bleach denilmesinin sebebi, pulpa odasına yerleştirilen beyazlatma ajanı sayesinde hastanın klinik dışında günlük hayatına devam ederken beyazlatma işleminin de devam edebiliyor olmasıdır (Ho ve Goerig, 1989; Madison ve Walton, 1990).

1.9.2 Termokatalitik Yöntem

Termokatalitik yöntem ilk kez Stewart tarafından tanıtılmıştır. Bu yöntemde beyazlatıcı ajan pamuk pelet yardımıyla pulpa odasına yerleştirilir ve sıcak aletlerle ısı uygulanarak hidrojen peroksitin beyazlatma etkinliği artırılır (Stewart, 1965). Bu işlemde sıcaklık 50-60 °C arasında olmalıdır. Isı kaynağı beş dakikadan fazla uygulanmamalıdır. Gerekli görülürse istenilen beyazlık elde edilene kadar işlem 4-6 kez yenilenebilir.

Bu yöntemde en sık karşılaşılan komplikasyon servikal kök rezorpsiyonudur. Bunun sebebi okside edici ajanın ısı ile kombine edilmesi sonucunda sement ve periodontal ligamentin zarar görmesidir (Rotstein ve Friedman, 1991). Bu komplikasyon riski göz önüne alındığında intrakoronal beyazlatma yönteminde yüksek konsantrasyonlarda hidrojen peroksit kullanılması ve ısı uygulanarak etkinliğinin artırılması tartışmalıdır ve rutin olarak uygulanmaması önerilmiştir (Rotstein ve Li, 2008).

1.10 Yapay Zeka

Yapay Zeka (YZ) akıllı davranışı, eleştirel düşünmeyi ve insanlara benzer karar vermeyi simüle etmek için bilgisayar teknolojisini kullanan uygulamalı bilgisayar biliminin bir dalıdır. “Dördüncü sanayi devrimi” olarak da tanımlanmıştır (Shan vd., 2021).

1.10.1 Yapay Zekanın Tarihçesi

Yapay Zekanın ilk olarak tanınması 1950 yılında ünlü bilim adamı Alan Turing’in Computing Machinery and Intelligence dergisinde yayınlanan makalesinde “Makineler

düşünebilir mi?” sorusuna cevap aramasıyla başlamıştır. Kendi isminin verildiği Turing Testi’nin ilk kez tanımlandığı bu makalede, bir seri halinde tekrarlanan testler sonucunda sorgulayıcı tutarlı bir şekilde insan – bilgisayar ayrımını saptayamadığı takdirde bilgisayarın birey kadar zeki olduğunun kabul edilmesi gerektiğine dair düşüncelerini ortaya atmıştır (Turing, 1950).

Yapay Zeka teriminin ilk kez ortaya çıkması ise 1956 yılında New Hampshire’daki Dartmouth College’da yapılan bir konferansta gerçekleşmiştir. Bu terimin yaratıcı olan McCarthy, yapay zekayı “İnsan benzeri zeki bilgisayar programları yapma bilimi ve mühendisliği” olarak tanımlamıştır (Amisha vd., 2019).

1997 yılında IBM tarafından üretilen “Deep Blue” isimli program dünya satranç şampiyonu Garry Kasparov’u yenmiştir. Bu olay bilgisayarların insanlardan daha iyi olabileceğini göstererek yapay zekanın popülerliğinin artmasından çok önemli bir gelişme olmuştur.

2000’li yıllarda birçok elektronik cihazda yapay zeka uygulamaları kullanılmaya başlanmıştır. Günlük hayatımızda her geçen gün daha çok yer edinmeye başlayan yapay zeka aynı zamanda sağlık alanında da yer edinmeye başlamıştır.

Sağlık alanında 2 tip yapay zeka kullanım alanı vardır. Sanal tip yapay zekanın; diagnoz, prognoz takibi (Huang vd., 2020), görüntüleme ve osteoporoz teşhisi (L. Gao vd., 2021), randevu düzenleme (Samorani ve Blount, 2020), ilaç dozlarının ayarlanması (Romm ve Tsigelny, 2020), ilaç etkileşimlerinin gösterilmesi (Shtar vd., 2019), elektronik sağlık kayıtlarının tutulması (Hamet ve Tremblay, 2017) gibi kullanım alanları vardır. Robotik veya fiziksel tip yapay zekanın ise, cerrahi ameliyatlara yardım (Bhandari vd., 2020), telebulunma (telepresence) (Moyle vd., 2017) , rehabilitasyon (Barry, 2018), yaşlı ve engellilere yardımcı robotlar (Abdi vd., 2018) gibi kullanım alanları vardır.

1.10.2 Yapay Zekanın ve Alt Dalları

1.10.2.1 Makine Öğrenmesi

Makine öğrenmesi, yüklenen veriler ile ilişkileri istatistiksel yöntemler ile öğrenerek yeni örnekler için karar üretmeyi amaçlayan yapay zekanın önemli bir alt dalıdır. Makine

öğrenme algoritmalarına ne kadar çok veri girilirse algoritma o kadar çok gelişir ve daha iyi ölçümler yaparak kişisel cevaplar vermeyi öğrenir. Denetimli öğrenme, denetimsiz öğrenme ve pekiştirmeli öğrenme olarak alt başlıklarda incelenebilir.

1.10.2.1.1 XGBoost

Makine öğrenmesinin kapsamında olan Gradyan Artırmalı Ağaçlar (Extreme Gradient Boosting - XGBoost), ağaç tabanlı gradyan artırma yönteminin hem algoritmik hem de sistem düzeyinde iyileştirmelerle geliştirilmiş, yüksek doğruluk ve yüksek ölçeklenebilirlik sunan bir versiyonudur. XGBoost modelinin başarısının sebebi karar ağaçlarını ardışık biçimde kurarak hata terimlerini azaltan klasik gradient boosting yaklaşımını hem matematiksel hem de donanımsal açıdan optimize eden bir yapı ile yeniden ele almasıdır.

Modelin temel amacı modelin toplam kayıp fonksiyonunu aşağıdaki optimizasyon formülü doğrultusunda minimize etmektir:

$$\mathcal{L}^{(t)} = \sum_{i=1}^n l\left(y_i, \hat{y}_i^{(t-1)} + f_t(x_i)\right) + \Omega(f_t)$$

Şekil 1.12. Optimizasyon formülü

Bu formülde $l(y_i, \hat{y}_i)$ tahmin hatasını ölçen kayıp fonksiyonudur. $\Omega(f)$ ise ağaçların karmaşıklığını cezalandıran düzenleme terimidir ve bu fonksiyon aşağıdaki şekilde tanımlanır:

$$\Omega(f) = \gamma T + \frac{1}{2} \lambda \sum_{j=1}^T w_j^2$$

Şekil 1.13. Düzenleme formülü

Burada T ağacın yaprak sayısını, w_j her yaprağın çıktısını, γ yeni yaprak oluşturma ceza katsayısını, λ ise L2 düzenleme katsayısını temsil eder. XGBoost'un en güçlü yönlerinden biri, kayıp fonksiyonunun optimizasyonunda ikinci dereceden Taylor açılımı kullanmasıdır. Bunlara ek olarak XGBoost, paralel hesaplama, sütun ve satır alt örnekleme, eksik değerleri doğal olarak işleme, sparsity-aware (seyreklik farkındalığı) ve out-of-core


öğrenme gibi optimizasyonlarla hem küçük hem de çok büyük veri kümelerinde çok yüksek hız ve doğruluk sunar (Chen ve Guestrin, 2016; Developers, 2025; Rusdah ve Murfi, 2020).

1.10.2.2 Derin Öğrenme

Derin öğrenme, yapay sinir ağlarının kullanıldığı çoklu katmanlardan oluşan bir öğrenme yöntemidir. Giriş ve çıkış katmanları arasında gizli katmanlar yer alır. “Derin” terimi genellikle bu gizli katmanların sayısını ifade eder. Derin öğrenme modelleri onlarca hatta yüzlerce gizli katmana sahip olabilir.

1.10.2.2.1. Yapay Sinir Ağları (Artificial Neural Network – ANN)

Yapay Sinir ağları birbirine bağlı yapay nöronlardan oluşan, girişten çıkışa doğrusal olmayan bir eşleme ile öğrenen derin öğrenme modelidir. İnsan beynini oluşturan nöronların çalışma şeklini taklit ederek oluşturulan bir algoritmadır. ANN’nin temel elemanı yapay sinir hücreleridir. Bu hücrelerde işlem elemanları birçok veri girdisini alır, bu verileri toplar, bir fonksiyona aktarır ve sonuç çıkartır (Krogh, 2008).



Şekil 1. 14. Biyolojik sinir hücresi ve yapay sinir ağı (Matarollo vd., 2013)

Yapay sinir ağlarında katmanlar paralel şekilde oluşturulur. Girdi katmanı, ara katmanlar ve çıktı katmanlarından oluşur. Veri girdi katmanından girip ara katmanlarda işlenerek çıktı katmanına iletilir. Çıktı katmanında ise bu veri ağının çıktısı üretilir (Öztemel, 2006).

Yapay sinir ağıları sıklıkla tahmin, sınıflandırma, veri ilişkilendirme, veri yorumlama, veri filtreleme alanlarında kullanılır. Tıpta kanserli hücrelerin analiz edilmesinde, hastalıkların tanınmasında, kan analizlerinin sınıflandırılmasında kullanılır (Keskenler ve Keskenler, 2017).

Biyolojik Sinir Sistemi	Yapay Sinir Sistemi
Nöron	İşlemci Elemanı
Dentrit	Toplama Fonksiyonu
Hücre Gövdesi	Transfer Fonksiyonu
Aksonlar	Yapay Nöron Çıkışı
Sinapslar	Ağırlıklar

Şekil 1. 15. Biyolojik sinir sistemi elemanları ve yapay sinir sisteminde karşılıkları (Öztürk ve Şahin, 2018)

1.10.2.2.2. Derin Sinir Ağları (Deep Neural Network – DNN)

Derin Sinir Ağları (DNN), birbirine çok sayıda yapay nöron katmanından oluşan ve verilenden örüntü öğrenen bir modeldir. Bu mimaride birden fazla gizli katman kullanıldığı için derin adını alır ve bu sayede daha karmaşık ilişkileri yakalayabilir (Goodfellow vd., 2016).

Çok katmanlı yapıları sayesinde girdilerdeki doğrusal olmayan ilişkileri öğrenebilen modellerdir. Bir DNN modelinde temel olarak ardışık şekilde bağlanmış çok sayıda yapay nöron katmanından oluşur. Bu katmanlar, giriş verilerini giderek daha anlamlı ve karmaşık özellik temsillerine dönüştüren bir hesaplama zinciri oluşturur.

Bir DNN modeli, aşağıdaki şekilde iç içe geçmiş fonksiyonların birleşimi şeklinde ifade edilir:

$$f(x) = f_L \circ f_{L-1} \circ \dots \circ f_1(x)$$

Şekil 1.16. Çok Katmanlı Sinir Ağı Fonksiyon Bileşimi

Bu denklemde x giriş vektörünü, f_i her bir katmanda gerçekleştirilen doğrusal dönüşüm ve aktivasyon işlemlerini, L ise toplam katman sayısını ifade eder. Her bir katman düzeyinde gerçekleştirilen işlem aşağıdaki şekilde tanımlanabilir:

$$a^{(l)} = \sigma(W^{(l)}a^{(l-1)} + b^{(l)})$$

Şekil 1.17. Katman Düzeyinde Hesaplama Fonksiyonu

Bu denklemde ise $a^{(l)}$, L. Katmanın aktivasyon çıktısını, $W^{(l)}$ ağırlık matrisini, $b^{(l)}$ bias vektörünü, $\sigma(\cdot)$ ise doğrusal olmayan aktivasyon fonksiyonunu temsil eder. Bu yapı sayesinde derin sinir ağları, klasik doğrusal modellerin yakalayamadığı karmaşık örüntüleri başarılı şekilde öğrenebilir.

Bir DNN modelinin temel amacı, model parametrelerini optimize ederek toplam kayıp fonksiyonunu minimize etmektir. Modelin tahmini ile gerçek değer arasındaki fark çoğunlukla bir kayıp fonksiyonu ile ölçülür.

$$\mathcal{L}(W, b) = \sum_{i=1}^n \ell(y_i, f(x_i)) + \Omega(W)$$

Şekil 1.18. Derin Öğrenme Optimizasyon Problemi

Derin öğrenmenin genel öğrenme problemi yukarıdaki formül ile ifade edilir. $L[y_i, f(x_i)]$ tahmin hatasını ölçen kayıp fonksiyonunu ifade eder. $\Omega(w)$, model karmaşıklığını cezalandıran düzenleştirme terimini, n ise örnek sayısını temsil eder. Düzenleştirme terimi ise şu şekilde hesaplanır:

$$\Omega(W) = \lambda \sum_{l=1}^L \|W^{(l)}\|_2^2$$

Şekil 1.19. DNN Düzenleştirme Terimi

Bu düzenleştirme terimi, modelin aşırı öğrenmesini (overfitting) engeller ve ağırlıkların büyümesini kontrol altında tutmayı amaçlar.

DNN doğrusal olmayan ilişkileri yüksek başarı ile öğrenir. Büyük veri setlerinde ise yüksek doğruluk sunmalarına rağmen karar mekanizmaları şeffaf değildir. Çünkü girdilerinden öğrenilen özellikler birden çok katmandan oluşan bir bileşimden geçer. Modellerin iç yapıları yüksek boyutludur. Ayrıca yapılan bir tahmin onlarca katman ve

binlerce nöronun etkileşiminin sonucu olarak ortaya çıkar(Akın ve Şahin, 2024; Samek vd., 2021; Schmidhuber, 2015).

1.10.2.2.3. Evrişimli Sinir Ağları (Concolutional Neural Networks – CNN)

CNN derin öğrenmenin bir alt dalıdır. Yaygın olarak görsel bilginin analizinde kullanılır. Temelde verideki özelliklerini (örneğin görüntünün kenar, köşe veya desenleri) tanımak için tasarlanmıştır (Chauhan vd., 2018). Birden fazla görüntüyü işler ve bu görüntüleri analiz etmek için filtreleme yapar. Özellikle görüntü sınıflandırma, görüntünün anlamsal segmentasyonu ve görüntülerde nesnelerin tespiti gibi işlemler için kullanılır (Wu, 2017).

1.10.2.2.4. Yinelenen Sinir Ağları (Recurrent Neural Network – RNN)

RNN, sıralı veride her adımın bilgisini gizli durum olarak bir sonraki adıma aktararak bağlamı korumaya çalışır. Teorik olarak uzun bağımlılıkları temsil edebilse de gradyanların zaman ile zayıflaması (vanishing) veya artması (exploding) pratikte öğrenmeyi zorlaştırır. Bu sebeple uzun süreli ilişkileri yakalamada klasik RNN'ler çoğu zaman yetersiz kalır (Goodfellow vd., 2016).

1.10.2.2.5 Sıralı Modeller: Uzun Kısa Süreli Bellek (LSTM) ve Çift Yönlü LSTM (BiLSTM)

LSTM, yinelenen sinir ağlarda görülen vanishing sorununu azaltmak için tasarlanmış modellerdir. İçindeki giriş, unutma ve çıkış kapıları hücredeki bilginin ne kadar alınacağını, ne kadar tutulacağını ve ne zaman dışarı verileceğini kontrol eder. Bu şekilde uzun süreli ilişkileri daha iyi hatırlar ve kısa dizilerdeki gürültüyü azaltır (Hochreiter ve Schmidhuber, 1997).

BiLSTM, LSTM'nin hem ileri hem de adımı geri yönde okuyan iki halini birlikte kullanır. Böylelikle hem geçmiş hem de gelecek bilgiden yararlanarak bağlamı zenginleştirir (Graves ve Schmidhuber, 2005).

Bir LSTM bloğu, input gate, forget gate, output gate ve candidate input'tan oluşur. LSTM'de amaç, önceki zamana ait bilgiyi ve hücrenin durumunu kullanarak yeni zamandaki durumu hesaplayabilmektir. LSTM'nin geçit mekanizmasında, her geçit sigmoid

fonksiyonuyla çalışır ve bilginin ne kadar geçirileceğini kontrol eder. Bu yapı sayesinde LSTM, önceki hücre durumundaki bilgiyi tamamen silebilir, kısmen koruyabilir veya yeni gelen bilgi ile güncelleyebilir. Böylece model uzun zaman aralıklarında bilgi taşımaya devam eder.

BiLSTM, tek yönlü LSTM'nin aksine veriyi hem ileri yönde hem de geri yönde işler. Bu şekilde aman serisinin hem geçmiş hem de geleceğe ait bilgilerini aynı anda kullanır. İleri yönlü ve geri yönlü durumlarını birleştirerek son durum vektörünü elde eder. Bu yapı özellikle doğal dil işleme, tubbi sinyal analizi, zaman serisi sınıflandırma ve biyomedikal ölçümlerinin tahmini gibi verilerin hem geçmiş hem de gelecek değerleriyle ilişkili olduğu durumlarda klasik LSTM'ye göre performans artışı sağlar.

1.10.3 Endodontide Yapay Zeka

Endodontide yapay zeka çalışmaları her geçen gün daha da artmaktadır. Endodontik tedaviler için geliştirilen yapay zeka modelleri; periapikal lezyonların tespiti, kök kırıklarının tespiti, kök kanal morfolojilerindeki farklılıkların tespiti, çalışma boyunun belirlenmesi, kök kanal tedavisi yenilemelerinde prognoz tahmini, post operatif ağrı olasılığının değerlendirilmesi gibi birçok alanda kullanılmaktadır.

1.10.3.1 Periapikal Lezyonların Tespiti:

Özellikle CNN tabanlı yaklaşımlar, klasik radyolojik değerlendirmeye güçlü bir destek sağlar. Setzer ve arkadaşları CNN tabanlı yapay zeka modellerinin KIBT görüntüleri üzerinden periapikal lezyonu %92.8 oranında doğru teşhis edebildiğini ve bu sistemlerin diş hekimleri ile benzer başarılar gösterebildiğini raporlamışlardır (Setzer vd., 2020).

Endres ve arkadaşlarının yaptığı klinik bir çalışmada CNN modeller ile uzman diş hekimlerinin periapikal lezyonları saptamadaki başarıları kıyaslanmış ve duyarlılık, özgüllük ve eğri altında kalan alan değerlerinin CNN grubunda daha büyük olduğu sonucuna varmışlardır (Endres vd., 2020). Pauwels ve arkadaşlarının yaptığı bir başka klinik çalışmada ise derin öğrenme modelinin, panoramik radyograflar üzerindeki periapikal lezyonları tespit etmede 24 kişiden oluşan oral maksillofasiyal cerrahlarla eş değer tanı performansı sergilediğini bildirmişlerdir (Pauwels vd., 2021).

1.10.3.2. Vertikal Kök Kırıklarının (VKK) Tespiti:

Klinikte kron ve/veya kök kırıklarının tespiti son derece zordur. Yakın zamanda yapılan bir sistemik derleme ve meta-analiz KIBT görüntülemelerinin VKK tespitinde sadece %78 doğruluğa sahip olduğunu göstermiştir (PradeepKumar vd., 2021). Fukuda vd., panoramik radyograflar üzerinde YZ kullanarak VKK tespiti yapmış ve %75 duyarlılık ve %93 pozitif tahmin değerleri bildirmiştir (Fukuda vd., 2020). Aynı amaçla yapılan bir diğer çalışmada ise tek köklü premolar dişlerde hem periapikal radyograflar he de KIBT görüntüleri kullanarak yapay zeka ile %97 doğruluk, %93 duyarlılık ve %100 özgüllük değerleri elde edilmiştir (Johari vd., 2017). Devam eden çalışmalar, çok köklü dişlerde de VKK tespitine yönelik tanısal doğruluğu arttırmayı hedeflemektedir. VKK'nın tanısında yapay zekanın optimize edilmesi hem onarılamaz dişlerin gereksiz tedavisini hem de yanlış tanı sonucu sağlıklı dişlerin çekilmesini önleyebilir (Lai vd., 2023).

1.10.3.3. Kök Kanal Morfolojisinin Tespiti:

Başarılı bir kök kanal tedavisi yapabilmek için klinisyenin tedavi edilen dişin kök kanal morfolojisini bilmesi gerekmektedir. Geleneksel olarak bu amaçla periapikal radyograflar, bite-wing radyograflar ve KIBT görüntüleme kullanılmaktadır. Ancak bu görüntüleme tekniklerinin değerlendirilmesi öznel olabilir, eğitim ve tecrübe gerektirmektedir. Yapay zeka, kök kanal morfolojisini ve kanal sayısını değerlendirmede de kullanılmaktadır. Hiraiwa vd., panoramik radyograflar üzerinde YZ kullanarak mandibular birinci molar dişlerde tek veya çoklu distal kök teşhisinde %87 doğruluk oranı bildirmiştir (Hiraiwa vd., 2019). YZ ayrıca kök kanal eğimlerini ve önceki tedavilerdeki şekillendirme işlemlerinden sonra meydana gelen kök kanal morfolojisindeki üç boyutlu değişiklikleri doğru şekilde ölçmek için de kullanılmıştır (Christodoulou vd., 2018). Lahoud vd., üç boyutlu diş kesitlerini incelemiş ve YZ'nın kök kanal morfolojisini belirlemede insan değerlendiriciler kadar doğru, ancak daha verimli olduğunu bulmuştur (Lahoud vd., 2021). Halihazırda Dagnocat (LLC Diagnocat, Moskova, Rusya) gibi ticari YZ yazılımları mevcuttur. Bu yazılımlar klinisyenlerin hastalarına ait KIBT görüntüleri analiz etmede ve mevcut kök kanal morfolojisinin tipini belirlemede yardımcı olmaktadır. YZ'nın kök kanal morfolojisini tespit etmedeki gelecekteki yönelimler arasında normal dentoalveolar anatomideki daha fazla varyasyonu içerecek şekilde veri kümelerinin genişletilmesi yer almaktadır (Asiri ve Altuwalah, 2022). Buna bağlı olarak, YZ klinisyenlere kök kanal sistemini temizlemek için en uygun endodontik eğeleri seçmede yardımcı olabilir ve tedavi esnasında en az prosedürel hatayla işlemi tamamlayabilmek için

endodontik el aleti veya endodontik motor üzerindeki hız/tork değerleri otomatik ayarlama kullanılabılır (Lai vd. , 2023).

1.10.3.4. Çalışma Boyunun Tespiti:

Endodontik tedavi esnasında doğru çalışma boyunun tespiti en kritik adımlardan biridir, kök kanal sisteminin mekanik ve kimyasal olarak tam bir şekilde dezenfekte edilmesini sağlar. Ayrıca kök ucundan taşan şekillendirmelerden periodontal dokuyu koruyarak debris taşmasını önler ve tedavi sonrası ağrıyı azaltır (Ricucci ve Langeland, 1998). Günümüzde çalışma boyunun belirlenmesinde genellikle elektronik apeks bulucular ve periapikal radyograflar kombine olarak kullanılmaktadır. Ancak dijital radyografların doğru yorumlanması, görüntü kalitesine ve klinisyenin öznel değerlendirmesine büyük ölçüde bağlıdır (Tewary vd., 2011). Ayrıca şekillendirmenin sonlandırılması gereken sementodental birleşimin yeri radyografik apeksin 0.5 ila 2 mm gerisinde bulunabilir (Piasecki vd., 2016). Apeks bulucular yüksek doğruluk sağlasa da ıslak kanallarda, metalik restorasyon varlığında ve kablo/kalibrasyon arızalarında ölçüm hataları görülebilmektedir (Martins vd., 2014). Bu değişkenlerin tümü tedavi sonucunu olumsuz etkileyebilecek hatalı ölçümlere neden olabilir (Lai vd. , 2023). YZ algoritmaları, klinisyene radyograflardaki minör apikal foramenin tespitinde yardımcı olmak için geliştirilmektedir. Klinik durumu taklit etmek için kadavra modeli kullanan Saghiri vd. YZ yardımıyla çalışma boyu ölçümleri yapmış ve diş çekimi sonrası yapılan gerçek ölçümlerle karşılaştırıldığında YZ'nin kök uzunluğunu belirlemede %100 doğruluk sağladığını bildirmiştir. Ayrıca YZ'nin minör apikal forameni %96 oranında doğru şekilde tespit edebildiği sonucuna varmıştır (Saghiri vd., 2012). Bu teknolojinin daha da geliştirilmesi, YZ'nin görüntüleme tekniklerinden elde ettiği bilgilerin klinisyenin kullandığı endodontik aletlere aktarılabilmesini ve kök kanal eğelerini sementodental birleşimine minimum operatör müdahalesiyle yönlendirerek apikal daralımın korunmasını ve aşırı enstrümantasyonun önlenmesini mümkün kılabilir (Lai vd., 2023).

1.10.3.5 Kanal Tedavisi Yenilemesinde Prognoz Tahminleri:

Campo ve vd, cerrahi olmayan kök kanal tedavisi yenilemelerinin risklerini ve faydalarını dikkate alarak sonucunu tahmin etmek amacıyla vaka temelli bir çıkarım paradigması üzerinde çalışmışlardır. Bu sistem özünde kanal tedavisi yenilemesinin yapıp yapılmaması gerektiğini öngörmektedir. Sistemin güçlü yönü kanal tedavisi yenileme sonucunu doğru bir şekilde tahmin etme potansiyeline sahip olmasıdır. Ancak sınırlılığı,

sistemin doğruluğunun yalnızca kullanılan verilerin kalitesiyle sınırlı olmasıdır (Campo Nieves vd., 2016). Vaka temelli çıkarım, geçmişte benzer şekilde karşılaşılan problemlerden elde edilen deneyimlere dayanarak yeni problemlere çözüm üretme sürecidir. Ancak uygulamalardaki çeşitlilik ve farklı yaklaşımların fazlalığı, bu sistemde heterojenliğe yol açabilir (Gu vd., 2017). Bu nedenle gelecekte yapılacak çalışmaların bu insana bağlı heterojenliği göz önünde bulundurması ve örneklem büyüklüğünü arttırarak daha yüksek duyarlılık, özgüllük ve doğruluk elde etmeyi hedeflemesi önemlidir (Aminoshariae vd., 2021).

1.10.3.6 Post Operatif Ağrının Tahmini:

Kök kanal tedavisini takiben hastaların %1-58'inde semptom görülür, en sık bildirilen semptom ise post operatif ağrıdır (Sipaviciute ve Maneliene, 2014). Son yıllarda ağrının kontrolüne yönelik yöntemler gelişmiş olsa da klinisyenler genellikle deneyime dayalı öznel değerlendirmeler yapmaktadır. Bu nedenle ağrının yanlış tahmini, tedavi planlamasında hatalara ve hasta memnuniyetsizliğine yol açabilir. YZ temelli ağrı tahmin modelleri hem klinik karar desteği sağlar hem de hasta ile hekim arasındaki iletişimi güçlendirir. Gao vd.'nin yaptığı bir çalışmada kök kanal tedavisi sonrasındaki ağrının yapay sinir ağı modeliyle %95,6 doğrulukla tahmin edilebileceğini göstermiştir (X. Gao vd., 2021)

1.10.3.7 Diş Rengi Tahmini:

Diş renginin doğru şekilde belirlenmesi, estetik diş hekimliğinde tedavi başarısını doğrudan etkileyen bir faktördür. Geleneksel yöntemler; aydınlatma koşulları, göz yorgunluğu ve operatör tecrübesi gibi değişkenlere bağlı olduğu için yüksek oranda sübjektiftir. Bu limitasyonları aşabilmek için son zamanlarda YZ destekli sistemler daha yaygın kullanılmaya başlanmıştır (Shetty vd., 2024). YZ modelleri CIE Lab renk uzayında ölçülen verileri veya dijital görüntüleri analiz ederek renk farklılıklarını hesaplamakta ve gerçek diş rengine en yakın rengi tahmin etmektedir. Çeşitli algoritmaların karşılaştırıldığı sistematik derlemelerde karar ağaçları, bulanık mantık (fuzzy logic) ve destek vektör makineleri (support vector machine) diş renginin belirlenmesinde ve tahmininde en başarılı yöntemler olarak bildirilmiştir. Bu sonuçlar YZ'nin görsel yöntemlere göre daha yüksek tutarlılıkla çalıştığını göstermektedir. Bu alanda yapılan çalışmalar gelecekte beyazlatma tedavilerinin kişiselleştirilmesine olanak sağlayabilir (Carrillo-Perez vd., 2022; Shetty vd., 2024).

1.11 Çalışmanın Amacı

Bu çalışmanın amacı, intrakoronal beyazlatma uygulanan devital dişlerde başlangıçtaki L^* , a^* , b^* değerlerinden yararlanarak tedavi sonrası oluşacak renk değişimlerinin yapay zekâ temelli modellerle öngörülebilirliğini araştırmaktır. Bu doğrultuda elde edilen spektrofotometrik ölçümler analiz edilmiş, regresyon tabanlı makine öğrenmesi ve derin öğrenme modelleri geliştirilmiş ve tahminlerin doğruluğu CIEDE2000 renk farkı formülü ile değerlendirilmiştir. Çalışma, intrakoronal beyazlatma sonrası renk sonucunun işlem öncesi veriler temel alınarak objektif ve öngörülebilir biçimde tahmin edilmesine yönelik bir karar destek yaklaşımı sunmayı hedeflemektedir.



2. GEREÇ VE YÖNTEM

Bu çalışma Ankara Üniversitesi Diş Hekimliği Fakültesi Preklinik Laboratuvarı, Merkez Araştırma Laboratuvarı ve Ankara Üniversitesi Yapay Zeka Enstitüsü'nde yürütülmüştür.

Çalışma protokolü için Ankara Üniversitesi Diş Hekimliği Fakültesi Klinik Araştırmalar Etik Kurulu'ndan 15/14 Karar No'lu ve 18.12.2023 tarihli rapor ile etik kurul onayı alınmıştır.

2.1. Çalışmaya Dahil Edilen Dişlerin Seçimi

Çalışmamızda Ankara Üniversitesi Diş Hekimliği Fakültesi Ağız Diş ve Çene Cerrahisi Anabilim Dalı Polikliniği'nde periodontal ve ortodontik nedenlerle çekilmiş 261 adet çürüksüz maksiller anterior diş kullanıldı.


2.2 Örneklerin Hazırlanması

Kök yüzeylerindeki eklentiler ve yumuşak doku artıkları, periodontal küret yardımıyla temizlendikten sonra dişler %10'luk formalin solüsyonda 48 saat bekletilerek dezenfekte edildi, çalışmada kullanılabilecek kadar distile suda bekletildi. Dişlerin yüzeylerindeki renklemelerin giderilmesi amacıyla tüm dişlere polisaj pastası (Detartrine, Septodont, Fransa) ile polisaj işlemi uygulandı.


Elmas rond ve fissür frezler kullanılarak su soğutması altında aerator ile dişlere endodontik giriş kaviteleri açıldı. Çalışma boyunun belirlenmesinin ardından kanallar endomotor ve döner eğe sistemi (ProTaper Next, Dentsply Maillefer, Ballaigues, İsviçre) kullanılarak F3'e kadar genişletildi. Kanallar her eğe değişiminde %5.25'lik Sodyum Hipoklorit (Microvem Sodyum Hipoklorit, Altun Sterilizasyon ve Medikal) ve %17'lik EDTA (Cerkamed, Stalowa Wola, Polonya) solüsyonu ile yıkandı. Kanallar açılı gutta percha ve epoksi rezin kanal patı (AH Plus - Dentsply De Trey GmbH, Konstanz, Almanya) kullanılarak tek kon yöntemi ile dolduruldu. Giriş kaviteleri cam iyonomer siman ile kapatıldı, dişler nemli ortamda 37°C'de etüvde saklandı.

2.3 Dişlerin Renklendirilmesi


Yapay renklendirme işlemi insan kanıyla Freccia ve Peters tarafından önerilen yöntem ile gerçekleştirildi (Freccia ve Peters, 1982). Çalışmada kullanılan kan belirli aralıklarla araştırmacının kendisinden temin edildi. Kanlar deney aşamasına kadar -20°C’de saklandı. Dişler renklendirme işleminden önce dentin tübüllerinin açılması amacıyla %1’lik Sodyum Hipoklorit solüsyonunda 24 saat bekletildi. Sonrasında dişler, 4 ml kan içeren Eppendorf tüpleri içerisine yerleştirilip 3400 rpm’de 20 dk santrifüj edildi. Böylece plazma ve çökeltiden oluşan iki fazlı solüsyon elde edildi. Plazma uzaklaştırılarak 20 dk daha santrifüj işlemi yapıldı. Takip eden 14 gün boyunca dişlerin bulunduğu tüpler günde iki kez santrifüj edildi. 4., 7. ve 10. günlerde tüplerin içindeki kan yenilendi. Deney süresinde örnekler 37°C’de %100 nemli ortamda etüvde saklandı. Renklendirilmiş dişlerin renk ölçümleri dental spektrofotometre (VITA Easyshae V, VITA Zahnfabrik, Bad Sackingen, Almanya) kullanılarak sabit ışık kaynağı bulunan ortamda, gri arka plan üzerinde yapıldı. Her diş için ölçüm hatasını minimuma indirmek ve veri güvenilirliğini arttırmak için üçer ölçüm yapıldı, elde edilen L*, a* ve b* değerlerinin ortalamaları L0, a0 ve b0 olarak kaydedildi.



Şekil 2. 1. Santrifüj Cihazı Mikro 22 (Hettich Zentrifugen, Almanya)



Şekil 2. 2. Santrifüje edilen örnekler



Şekil 2. 3. Renklendirilmiş diş örnekleri

2.4 Beyazlatma Prosedürü

Renklendirme uygulaması ile dişlerin mine yüzeyinde meydana gelen yüzeyel renklenmeler polisaj pastası (Detartrine, Septodont, Fransa) kullanılarak uzaklaştırıldı. Giriş kavitelerine yerleştirilmiş olan cam iyonomer siman mine-sement sınırına kadar indirildi.

Pulpa odası içersine %35'lik hidrojen peroksit jeli (Opalescence Endo, Ultradent, ABD) uygulandı. Geçici dolgu maddesi (CavitTM, 3m Espe, Dental Products, Almanya) ile kapatılarak 3 gün sonra renk ölçümü yapılmak üzere etüvde saklandı.



Şekil 2. 4 Opalescence Endo (Ultradent, ABD)

3 gün sonra her diş için 3 ölçüm yapıp ortalaması alındı, elde edilen L^* , a^* ve b^* değerlerinin ortalamaları $L1$, $a1$ ve $b1$ olarak kaydedildi. Vita 3D Master Renk Skalasında bulunan her bir renk tonu da aynı şekilde ölçülerek kaydedildi.

Kullanılan dişlerin hepsi ilk renklendirme sonrası benzer koyu tonlar oluşturduğu için girdi kümesini genişletmek amacıyla ilk beyazlatma seansı uygulandı ve bu dişlerin beyazlatma öncesi ve sonrası değerleri ilk girdi kümesi olarak kabul edildi. Ardından dişlere tekrar beyazlatma ajanı uygulandı ve üç gün sonra yeni ölçümler alındı. Bu işlem toplamda 3 kez uygulanarak her diş için üç farklı “öncesi-sonrası” renk çifti üretildi. Böylece 261 diştten toplamda 783 girdi elde edilerek girdi kümesi genişletilmiş ve daha geniş bir renk değişim aralığı temsil edilmiştir.



Şekil 2. 5. VİTA 3D-Master Renk Skalası

2.5 Yapay Zeka Modelinin Geliştirilmesi

Oluşturduğumuz yapay zeka modellerinde amacımız beyazlatma öncesi $L^*a^*b^*$ değerlerinden ve bu değerlerden türettiğimiz doygunluk (Chroma – C^*) ve ton (Hue - h°) özelliklerinden yararlanarak beyazlatma sonrası Lab^* değerlerini yapay zeka modeli ile tahmin etmek, ve bu tahminlerin klinik karşılığını Vita 3D-Master skalasındaki renkler üzerinden değerlendirmektir.

Model çıktılarına klinik anlam kazandırmak için her dişin tahmin edilen $L^*a^*b^*$ değeri ± 1 tolerans ile çevrelenmiş $5 \times 5 \times 5$ ızgaraya (125 nokta) yerleştirildi. Iızgaradaki her nokta ΔE_{2000} formülü ile Vita 3D-Master skalasındaki referans renklerle eşleştirildi, en çok tekrar eden iki Vita rengi “Top-2” tahmini olarak raporlandı. Bu iki renkten birinin gerçek $L^*a^*b^*$ değerinden hesaplanan gerçeğe en yakın Vita rengi ile eşleşmesi durumunda tahmin doğru kabul edildi.

Oluşturulan senaryo XGBoost, DNN, LSTM ve BiLSTM modelleri ile test edildi. Her model için hiperparametreler random search yöntemi ile tarandı. Parametre seçimi için birincil ölçüt Top-2 Vita Doğruluğu olarak belirlendi. Hiperparametrelerin taramasının tamamlanmasının ardından, genelleme başarısını tarafsız ölçebilmek ve veri sızıntısını önleyebilmek amacıyla tüm modeller Leave-One-Out Cross-Validation (LOOCV) ile değerlendirildi. Her iterasyonda bir örnek test için ayrıldı, kalan tüm örnekler eğitim için kullanıldı ve bu işlem veri kümesindeki her örnek için tekrarlandı.

Çizelge 2. 1. XGBoost hiperparametreleri ve anlamları

Hiperparametre	Anlamı	Yorum
n_estimators	Toplam ağaç adımı sayısı.	Ağaç sayısı artarsa kapasite artar; çok yüksek değer overfitting (aşırı uyum) yapabilir.
max_depth	Her ağacın maksimum derinliği (kapasite).	Derinlik arttıkça ayırım gücü ve overfitting eğilimi artar.
learning_rate (lr)	Adım başına katkı ölçeği (shrinkage).	Küçük lr daha çok ağaç gerektirir ama genelde daha iyi genelleme verir.
subsample	Her ağaç için örneklenen eğitim verisi oranı.	1'den küçükse stokastisite (rastgelelik) artar, overfitting azalır.
colsample_bytree	Her ağaç için örneklenen özellik oranı.	Özellik alt-örnekleme genellemeyi iyileştirir; çok düşükse öğrenme zorlaşır.
min_child_weight	Bir dalın ayrılması için gereken minimum örnek ağırlığı.	Büyük değerler bölünmeyi kısıtlar; daha basit ağaçlar üretir.
reg_alpha	L1 cezası (seyreklik).	L1 cezası özellik seçimi/seyreklik sağlar; aşırıyı aşırı sade modellere iter.
reg_lambda	L2 cezası (düzenleştirme).	L2 cezası ağırlıkları küçültür; genellemeyi iyileştirir.
objective	Optimizasyon hedefi/kayıp fonksiyonu.	Hedef fonksiyon seçimi performans ve metrik yorumunu belirler.
tree_method	Ağaç kurma yöntemi (örn. hist).	'hist' büyük veride hızlı ve bellek dostudur.
random_state	Tekrarlanabilirlik için rastgelelik tohumu.	Aynı sonuçları tekrar almayı sağlar.
n_jobs	Kullanılan CPU iş parçacığı sayısı.	Daha fazla çekirdek daha hızlı eğitim demektir.

Çizelge 2. 2. DNN hiperparametreleri ve anlamları

Hiperparametre	Anlamı	Yorum
activation	Ara katman aktivasyonu; doğrusal olmayanlığı belirler.	Yakınsamayı ve gradyan akışını etkiler; ELU/ReLU genelde stabil ve hızlıdır.
hidden_layers	Gizli katman sayısı (model derinliği).	Daha fazla katman daha yüksek kapasite sağlar; overfitting riski artar.
units	Her gizli katmandaki nöron/birim sayısı (kapasite).	Daha çok nöron = daha yüksek kapasite; fazla olursa overfitting/süre artar.
dropout	Eğitimde nöron/bağlantıların rastgele kapatılma oranı.	Overfitting kontrolü için kullanılır; aşırı yüksek olursa underfitting yapabilir.
L2	L2 ağırlık cezası (düzenleştirme).	Ağırlıkları küçültüp genellemeyi iyileştirir; çok yüksekse kapasiteyi kısar.
lr	Öğrenme hızı (adım büyüklüğü).	Büyükse kararsız/taşıma; küçükse yavaş yakınsama. Orta değerler pratiktir.
batch	Mini-batch boyutu.	Büyük batch stabil; küçük batch genellemeyi iyileştirebilir.
epochs	Maksimum eğitim çevrimi.	Erken durdurma ile birlikte yeterli yakınsama için üst sınır.
patience	Erken durdurma sabrı.	İyileşme durduğunda eğitimi sonlandırmaya yarar; yüksek olursa süre uzar.

Çizelge 2. 3. LSTM ve BiLSTM hiperparametreleri ve anlamları

Hiperparametre	Anlamı	Yorum
layers	Katman sayısı (emülsiyon)	Emülsiyonda derinliği temsil eder; artarsa kapasite ve eğitim süresi artar.
units	Her gizli katmandaki nöron/birim sayısı (kapasite).	Daha çok nöron = daha yüksek kapasite; fazla olursa overfitting/süre artar.
dropout	Eğitimde nöron/bağlantıların rastgele kapatılma oranı.	Overfitting kontrolü için kullanılır; aşırı yüksek olursa underfitting yapabilir.
rec_dropout	Tekrarlayan (yinelemeli) bağlantılara uygulanan dropout.	Zaman/iç döngü bağlantılarını düzenler; fazlası öğrenmeyi zorlaştırır.
L2	L2 ağırlık cezası (düzenleştirme).	Ağırlıkları küçültüp genellemeyi iyileştirir; çok yüksekse kapasiteyi kısar.
lr	Öğrenme hızı (adım büyüklüğü).	Büyükse kararsız/taşma; küçükse yavaş yakınsama. Orta değerler pratiktir.
batch	Mini-batch boyutu.	Büyük batch stabil; küçük batch genellemeyi iyileştirebilir.
epochs	Maksimum eğitim çevrimi.	Erken durdurma ile birlikte yeterli yakınsama için üst sınır.
patience	Erken durdurma sabrı.	İyileşme durduğunda eğitimi sonlandırmaya yarar; yüksek olursa süre uzar.

2.6 İstatiksel Analiz

Yapay zeka modellerinin performansını değerlendirmek için istatiksel analiz aşamasında farklı hata ve doğruluk metrikleri kullanıldı. Modellerin tahmin ettiği L_1 ve L_2 değerleri, gerçek ölçüm değerleriyle karşılaştırılarak ortalama mutlak hata (MAE), ortalama karekök sapması (RMSE), belirleme katsayısı (R^2), Pearson korelasyon katsayısı hesaplandı. Renk farklılığının klinik olarak algılanabilirliğini değerlendirmek için ortalama ΔE_{90} değerleri raporlandı. Ayrıca tahmin edilen renklerin klinik geçerliliğini arttırmak amacıyla Top-2 Vita Doğruluğu hesaplandı. Böylece her modelin hem istatiksel hem de klinik performansı birlikte değerlendirildi.

Çizelge 2. 4. Yapay Zeka model performans metrikleri ve açıklamaları

Metrik Adı	Açıklama	Değerlendirme Kriteri
MAE (Mean Absolute Error)	Tahmin edilen ve gerçek değerler arasındaki mutlak farkların ortalamasıdır.	Değerin küçük olması, modelin genel tahmin hatasının düşük olduğunu gösterir.
RMSE (Root Mean Square Error)	Tahmin hatalarının karelerinin ortalamasının kareköküdür. Büyük hatalara karşı daha hassastır.	RMSE'nin düşük olması, modelin büyük hatalardan kaçındığını gösterir.
R^2 (Belirleme Katsayısı)	Modelin toplam varyansın ne kadarını açıkladığını gösterir. 0–1 aralığındadır.	1'e yaklaştıkça modelin açıklayıcılığı artar.
Pearson Korelasyon Katsayısı (r)	Tahmin edilen ve gerçek değerler arasındaki doğrusal ilişki gücünü gösterir.	+1'e yakın değer güçlü pozitif ilişkiyi, 0'a yakın değer ilişkisizliği gösterir.
ΔE_{∞} (CIEDE2000)	Renk farkının insan gözüyle algılanabilirliğini ifade eder.	$\Delta E_{\infty} < 1.0$ fark algılanmaz; 1.0–2.0 arası fark zor algılanır; 2.0 üzeri fark belirginleşir.
Top-2 Vita Doğruluğu	Tahmin edilen 2 en olası Vita rengi ile gerçek rengin eşleşme oranıdır.	Klinik anlamlılık göstergesidir; yüksek oran, modelin gerçek renge yakın tahmin yaptığını gösterir.

3. BULGULAR

Bu çalışmada XGBoost, DNN, LSTM ve BiLSTM modelleri kullanılarak diş rengindeki değişimlerin tahmini yapıldı. Modellerin performansları LOOCV yöntemi ile değerlendirildi. Elde edilen temel performans metrikleri Çizelge 3.1’de özetlenmiştir.

Çizelge 3.1. Modellerin performansları

Model	MAE	RMSE	R ² (Ortalama)	Pearson (Ortalama)	Ortalama ΔE_{∞}	Top-2 Vita Doğruluğu
XGBoost	1.36	1.70	0.657	0.801	2.33	0.836
DNN	1.47	1.85	0.602	0.759	2.54	0.816
LSTM	1.52	1.94	0.583	0.759	2.67	0.790
BiLSTM	1.52	1.94	0.583	0.759	2.67	0.790

En düşük MAE (1.36) ve RMSE (1.70) değerleri XGBoost modelinde gözlemlendi. Bu modelde aynı zamanda en yüksek R² (0.65) ve Pearson Korelasyon Katsayısı (0.80) değerlerine ulaşmıştır. En yüksek Top-2 Vita Doğruluk Oranına (%83.6) ise yine bu modelde en yüksek değere ulaşmıştır.

DNN modeli de benzer şekilde düşük hata değerleri (MAE:1.47, RMSE:1.85) göstermiştir. LSTM ve BiLSTM modelleri birbirlerine çok yakın sonuçlar vermiş ancak DNN ve XGBoost modellerine kıyasla daha yüksek hata oranları saptanmıştır.

Tüm modellerin ortalama ΔE_{∞} değerleri 2.3-2.7 aralığında olup bu fark klinik olarak kabul edilebilir sınırlar içinde kalmıştır. Bu değerler literatürde klinik olarak kabul edilebilir renk farkı sınırı olarak belirtilen $\Delta E_{\infty} < 3.3$ kriterini sağlamaktadır (Kim-Pusateri vd., 2009).

Vita 3D-Master Renk Skalasına göre yapılan Top-2 eşleşme analizinde en yüksek doğruluk olarak %83.6 ile XGBoost modelinde, en düşük doğruluk oranı ise %79 ile LSTM ve BiLSTM modellerinde saptanmıştır. Bu sonuç, modellerin tahmin ettiği renklerin klinik olarak kabul edilebilir bir aralıkta olduğunu göstermektedir.

4. TARTIŞMA

Diş renklenmeleri önemli bir estetik problemidir ve genellikle beyazlatma tedavisi veya protetik restorasyon gerektirir. Ekonomik ve konservatif olması sebebiyle de diş beyazlatma tedavisine talep gün geçtikçe artmaktadır (Kaneko vd. , 2000). Özellikle ön dişlerdeki renklenmeler, bireylerin sosyal yaşamını olumsuz etkileyebilmektedir. Bu nedenle diş renklenmelerinin nedenleri, tedavi yöntemleri ve renk değişimin objektif olarak değerlendirilmesi, klinik başarı açısından büyük önem taşımaktadır.

Wu vd. (1993), deneysel çalışmalardaki değişkenliği en aza indirmek için aynı grup dişlerin kullanılması gerektiğini bildirmiştir (Wu vd., 1993). Ayrıca standardizasyonu sağlayabilmek adına çürük veya restorasyonu olmayan dişlerin seçilmesi gerektiği de bildirilmiştir (Retief, 1991). Renklenmelerden kaynaklı gelişen renklenmelerin en çok anterior bölgede estetik probleme yol açması ve yüzey morfolojisinin tekrarlanabilirliğini kolaylaştırması açısından çalışmamızda anterior bölgedeki kesici dişler tercih edilmiştir.

Diş renklenmelerinin birçok nedeni bulunmaktadır. Travma sonrası oluşan pulpal hemoraji, devital diş renklenmelerinin en sık nedenlerinden biridir. Kan yıkım ürünü olan demir sülfidin dentin tübüllerine penetre olması dişlerde renklenmelere sebep olmaktadır (Attin vd., 2003). İntrakoronal beyazlatma tedavilerinin başarılarını inceleyen birçok çalışma içsel renklenmeleri taklit edebilmek için kan ile yapay renklendirme yapmıştır (Arı ve Üngör, 2002; Casey vd., 1989; Horn vd., 1998; Lim vd., 2004; Vachon vd., 1998). Bizim de çalışmamızda Freccia ve Peters (1982)'ın yöntemi modifiye edilerek renklendirme yapılmıştır (Freccia ve Peters, 1982).

İnsan dişleri kullanılarak yapılan *in vitro* çalışmalarda, çalışma öncesinde ve sırasında örneklerin saklama koşulları çalışmanın güvenilirliği için önemlidir çünkü örneklerin saklama koşulları da renk ölçümlerinin doğruluğunu etkileyen bir faktördür. Timol içeren distile su, distile su, serum fizyolojik veya formalin en sık tercih edilen saklama solüsyonlardır (Civelek vd., 2003). Bizim de çalışmamızda klinik ortamı taklit edebilmek için örnekler bu süreçte distile suda 37 °C 'de %100 nemli ortamda etüvde bekletilmiştir. Bu koşullar ağız içi termal dengeyi ve nemi taklit ederek dehidrasyon kaynaklı renk değişimlerinin önüne geçmektedir. Ancak tükürük akışı, pH değişimleri ve mekanik aşınma gibi dinamik faktörlerin *in vitro* olarak taklit edilememesi, klinik gerçekliği sınırlayan faktörler olarak değerlendirilebilir.

Diş hekimliğinde renk ölçümü subjektif veya objektif yöntemlerle yapılabilmektedir. Renk değerlendirmesinin görsel yöntemlerle yapılması; ortamın ışığı, göz yorgunluğu, gözlemcinin deneyimi ve renk algısının kişiden kişiye değişmesi gibi birçok değişkenden etkilenebilmektedir. Spektrofotometreler ise bu değişkenleri ortadan kaldırarak, subjektif hataları en aza indirir ve yüksek tekrarlanabilirlik sağlar. Her ölçüm öncesinde cihaz beyaz referans plakasıyla kalibre edilmiştir, böylelikle ölçümlerin doğruluğu artmış ve seanslar arası tutarlılık sağlanmıştır. CIE L*a*b renk uzayında sayısal ve standardize edilmiş ölçümler elde edilmesini sağlayarak daha objektif sonuçlar verir (Paul vd., 2002). Literatürde de spektrofotometre ile yapılan ölçümlerin dişlerin renklerinin değerlendirilmesinde görsel değerlendirmelere göre çok daha güvenilir sonuçlar verdiği bilinmektedir (Chu vd., 2010; Joiner, 2004). Bu avantajlarından dolayı bizim de çalışmamızda dişlerin renklerinin tespitinde spektrofotometre kullanılmıştır.

Günümüzde devital dişlerde intrakoronal beyazlatma için en yaygın kullanılan ajanlar; hidrojen peroksit, karbamid peroksit ve sodyum perborattır (Attin vd. , 2003). Yapılan birçok beyazlatma çalışmasında %30-35 hidrojen peroksit ajanının beyazlatma etkinliğinin yüksek olduğu bildirilmiştir (Arslan vd., 2015; Carey, 2014; Sulieman, 2004). Bu nedenle çalışmamızda %35'lik hidrojen peroksit içeren Opalescence Endo (Ultradent Products Inc., South Jordan, ABD) kullanılmıştır.

Çalışmamızda renk farkı değerlendirmeleri için CIEDE2000 (ΔE_{00}) formülünün tercih edilmesinin nedeni bu formülün insan gözünün renk algısına en yakın ölçümü sağlaması ve özellikle de dental materyallerdeki küçük renk farklılıklarını daha doğru yansıtmasıdır. Geleneksel CIELAB (ΔE_{ab}) formülü; lineer varsayımlara dayanması, özellikle düşük veya yüksek doygunluk değerlerinde insan algısına tam karşılık verememesi nedeniyle sınırlıdır. CIEDE2000 formülü ise parlaklık, doygunluk ve ton farklarını ayrı ayrı değerlendirerek bu algısal farklılığı düzeltmektedir (Luo vd., 2001).

Renk farkı eşik değerlerinin değerlendirilmesinde laboratuvar ortamında $\Delta E_{00} < 1.8$ olduğunda fark insan gözüyle ayırt edilemez olarak kabul edilmektedir. Klinik koşullarda ise ΔE_{00} 'nin 1.8 ile 3.3 arasında olması klinik olarak kabul edilebilir olarak sınıflandırıldığı bildirilmektedir (Khashayar vd., 2014; Kim-Pusateri vd. , 2009; Paravina vd., 2015). Bu sınır göz önüne alındığında çalışmamızda kullandığımız tüm modellerin klinik olarak kabul edilebilir sınırlar içerisinde kaldığı görülmektedir.

Paravina vd. (2015) tarafından yürütülen çok merkezli bir çalışmada, diş hekimliğinde renk farkı algılaması için %50:50 algılanabilirlik eşiği $\Delta E_{00} = 0.8$, kabul edilebilirlik eşiği $\Delta E_{00} = 1.8$ olarak bildirilmiştir. Bu değerler CIEDE2000 formülünün renk farklarını daha hassas ayırt etme kabiliyetini ve renk değerlendirmelerinde standardizasyon açısından önemini göstermektedir. Bu sebeple mevcut çalışmamızda da ΔE_{00} kullanılması, ölçümün hem algısal doğruluk hem de klinik geçerlilik açısından güncel literatür ile uyumlu olmasını sağlamaktadır.

Ayrıca ΔE_{00} formülünün kullanılması, a^* ve b^* değerlerinde görülen doğrusal olmayan renk değişimlerini daha iyi temsil edebilmiş, bu da modelin tahmin doğruluğu arttırmaya yönelik katkıda bulunmuştur.

Diş rengi ölçümlerinde hem spektrofotometreden kaynaklanabilecek ölçüm belirsizlikleri hem de gözle algılanan renk varyasyonları sebebiyle tek bir Vita rengi yerine en muhtemel iki rengin değerlendirilmesinin klinik açıdan daha gerçekçi bir yaklaşım olacağı düşünülmüştür. Chu vd. (2010) dişlerin translusent yapısı ve bölgesel renk geçişleri sebepleriyle tek bir ölçüm noktasının tüm dişi temsil etmediğini, ayrıca görsel ve spektrofotometrik ölçümler arasında belirgin farklılıklar olabileceğini bildirmiştir (Chu vd. , 2010). Bu nedenle çalışmamızda tek renk tahmini yerine Top-2 Vita rengi değerlendirilmesi kullanılmıştır. Bu şekilde hem ölçüm hataları hem de insan gözünün algısal eşiği dikkate alınarak klinik olarak kabul edilebilir renk varyasyonlarının daha doğru biçimde yansıtılması hedeflenmiştir.

Bu çalışmada yapay zekâ modellerinin performansını değerlendirmek için birden fazla istatistiksel ve algısal ölçüt birlikte kullanılmıştır. Tek bir performans metriği, modelin başarısını tam olarak yansıtamayacağı için hem sayısal hem de klinik açıdan anlamlı metriklerin bütüncül olarak değerlendirilmesi tercih edilmiştir (Shen vd., 2022). MAE ve RMSE, modelin tahmin ettiği L^* , a^* , b^* değerlerinin gerçek ölçümlerden ortalama ne kadar sapıldığını gösterirken, RMSE büyük hatalara daha duyarlı olması nedeniyle özellikle beyazlatma sonrası aşırı açıklık veya koyuluk gibi uç sapmaları belirlemede daha etkilidir. Determinasyon katsayısı ve Pearson korelasyon katsayısı ise tahminlerin yönlü ilişkisini ve modelin açıklayıcılığını göstermektedir. Ancak istatistiksel doğruluk tek başına klinik anlam taşımadığından, bu çalışmada renk farklarının değerlendirilmesinde CIEDE2000 (ΔE_{00}) formülü kullanılmıştır. Ayrıca Top-2 Vita shade doğruluğu, modelin tahmin ettiği renklerin klinik olarak hangi renk tonlarına denk geldiğini değerlendiren tamamlayıcı bir ölçüt olarak

kullanılmıştır. MAE, RMSE, R^2 ve ΔE_{∞} gibi sayısal metriklerle birlikte Top-2 doğruluk değerinin yüksek bulunması, modelin yalnızca istatistiksel olarak değil, klinik olarak da güvenilir sonuçlar ürettiğini göstermektedir. Bu yaklaşım, dış hekimliğindeki yapay zekâ araştırmalarında performans değerlendirmesinin sadece istatistiksel değil, aynı zamanda algısal ve klinik açıdan da bütüncül biçimde ele alınması gerektiğini ortaya koymaktadır (Schussler vd., 2024; Shen vd., 2022)

Çalışmamızda değerlendirilen tüm yapay zeka modelleri belirli düzeyde doğru tahminler üretse de XGBoost modelinin diğer derin öğrenme tabanlı modellere kıyasla daha yüksek doğruluk ve daha düşük hata oranları elde ettiği görülmüştür. Bu durum XGBoost algoritmasının yapısal özellikleri ve mevcut veri kümesinin karakteristikleri ile açıklanabilir.

XGBoost, gradient boosting prensibine dayalı olarak çalışır ve çok sayıda zayıf tahminleyicinin (weak learner) birleştirilmesiyle güçlü bir öngörücü model oluşturan bir yöntemdir. Bu yapı, özellikle küçük ve orta büyüklükteki veri kümelerinde daha yüksek genelleme yeteneği ve daha düşük hata oranları sağlamaktadır. Çalışmamızda kullandığımız veri kümesinde sınırlı sayıda ölçüm bulunduğu için XGBoost'un bu tür veri yapılarında aşırı uyum (overfitting) riskini azaltan düzenleme (regularization) bileşenleri (L1 ve L2) performans artışına katkı sağlamıştır.

Ayrıca XGBoost modeli kayıp fonksiyonunu optimize ederken önyargı-varyans dengesini etkin biçimde kurabilmekte ve doğrusal olmayan (non-linear) ilişkileri yakalayabilmektedir. Dış rengindeki değişim, özellikle de a^* ve b^* değerlerinde doğrusal olmayan ilişkiler gösterebildiği için bu özellik modelin üstün performansını açıklamaktadır.

Öte yandan; DNN, LSTM ve BiLSTM gibi derin öğrenme tabanlı modeller büyük veri kümelerine ihtiyaç duyan modellerdir. Bu modellerin çok katmanlı parametrelere sahip olan yapıları, örnek sayısının sınırlı olduğu durumlarda genelleme yeteneğini azaltabilmektedir. Özellikle LSTM ve BiLSTM modelleri zamana bağlı olan ardışık verilerde güçlü performans gösterirken bu çalışmamızda kullandığımız veri kümesi iki zamansal nokta içerdiği için zaman serisi özelliği taşımamaktadır. Bu durum LSTM ve BiLSTM modellerinin potansiyel avantajlarını sınırlamıştır. Fakat veri kümesi klasik anlamda bir zaman serisi yapısına sahip olmasa da 0. ve 3. gün ölçümleri arasında zaman bağlı bir renk değişimi söz konusudur, bu yüzden de bu modellerin çalışmaya dahil edilmesinin amacı sınırlı zaman noktaları arasındaki değişimin zamana bağlı öğrenilebilirliğini değerlendirmektir. Böylece literatürde en sık

kullanılan derin öğrenme mimarilerinin renk değişimi tahmininde ne ölçüde etkili olduğu karşılaştırılmalı olarak incelenmiştir. Literatürde de tam sürekliliği olmayan, düzensiz aralıklı veya sınırlı gözlem noktasına sahip boylamsal klinik verilerde dahi LSTM ve BiLSTM gibi zamana bağlı modellerin etkili biçimde kullanılabildiği bildirilmiştir (Baytas vd., 2017; Lu vd., 2022; Patharkar vd., 2024). Bu durum çalışmamızda LSTM ve BiLSTM kullanımının yönetsel olarak uygun ve literatüre uygun olduğunu desteklemektedir. Ayrıca bu yaklaşım, gelecekte yapılacak araştırmalara da metodolojik bir temel oluşturabilir. Diş rengindeki değişimlerin daha uzun vadeli ve çok noktalı ölçümlerle izlenerek gerçek zaman serileri halinde modellenmesi durumunda birden fazla seans beyazlatma yapılan dişlerdeki tahminlerin yapılmasına da olanak sağlayabilir.

Son yıllarda yapılan sistemik bir derlemede Shetty vd. (2024) dental renk eşleştirmede kullanılan yapay zeka algoritmalarının performanslarını karşılaştırmış ve ağaç tabanlı modellerin, özellikle XGBoost algoritmasının gradyan arttırılmalı yapısı sayesinde yüksek tahmin doğruluğu elde ettiği bildirilmiştir (Shetty vd. , 2024). Benzer şekilde Carrillo-Perez vd. (2022) diş hekimliğinde yapay zeka uygulamalarını kapsamlı biçimde değerlendirmiş ve karar ağacı temelli yöntemlerin özellikle renk analizi ve estetik diş hekimliği alanında yüksek doğruluk sunduğunu bildirmiştir. Bu bulgular mevcut çalışmamızda da XGBoost modelinin yüksek performansını destekler niteliktedir (Carrillo-Perez vd. , 2022).

Reyes vd. (2021) dental uygulamalarda makine öğrenmesinin avantajlarını ve ağaç temelli yöntemlerin stabilitesini vurgulamışlardır (Reyes vd., 2021). Ayrıca AbuSalim vd.'nin 2022 yılında hazırladığı bir başka derlemede de özellikle küçük veri kümeleri ve heterojen veriler üzerinde derin nöral ağların kararsızlık gösterebileceğini belirtmiş, XGBoost gibi modellerin yapılandırılmış verilerde daha avantajlı olabileceğini vurgulamıştır. Yine aynı derlemede XGBoost algoritmasının elektronik diş kayıtları gibi klinik veriler üzerinde yüksek başarı gösterdiği örnekler de yer almaktadır (AbuSalim vd., 2022). Sonuç olarak, mevcut çalışmamızda elde edilen düşük ΔE_{00} hataları ve yüksek Top-2 Vita doğruluk oranı, XGBoost'un bu yapısal avantajlarına paralel bir şekilde açıklanabilir.

Son yıllarda yapılan çalışmalar da yapay zekanın estetik diş hekimliğinde giderek daha fazla tercih edildiğini ortaya koymaktadır. Awdaljan vd. (2024), diş renginin seramik restorasyonlarda yeniden üretimi amacıyla geliştirilen yapay zeka tabanlı bir sistem tanıtarak dijital renk analizinde yapay zekanın doğruluk ve tekrarlanabilirliği arttırmadaki rolünü vurgulamıştır. Bu gelişmeler diş hekimliğindeki renk tahminlerinde yapay zeka modellerinin

sadece laboratuvar düzeyinde değil, klinik karar süreçlerinde de giderek artan bir şekilde yer bulduğunu göstermektedir (Awdaljan vd., 2024).

Herrera vd. (2010), %20 karbamid peroksit içeren ev tipi beyazlatma uygulamasını takiben meydana gelen renk değişimlerini öngörmek amacıyla bulanık mantık (fuzzy logic) temelli bir model geliştirmiştir. Araştırmacılar, beyazlatma öncesi $L^*a^*b^*$ değerlerinden yola çıkarak, tedavi sonrası renk değişimlerini hesaplayan bulanık mantık sistemi tanımlamıştır. Çalışmada eşleştirme yapmak için Vita Classical skalası kullanılmış, bu skaladaki her renk için üyelik fonksiyonu belirlenmiştir. Bu sayede model, başlangıç renginden yola çıkarak beyazlatma sonrası renk tahminini oldukça düşük hata oranlarıyla tahmin edebilmiştir. Bu çalışma, diş rengindeki doğrusal olmayan değişimleri bulanık kurallar aracılığıyla temsil ederek klinik olarak olası renk sonuçlarını önceden öngörebilme açısından önemli bir adımdır.

Mevcut çalışmamızda ise benzer bir amaç doğrultusunda yapay zeka tabanlı gradient boosting ve derin öğrenme modelleri kullanılmıştır. XGBoost algoritması, prensip olarak fuzzy logic sistemlerinin hedeflediği doğrusal olmayan ilişkileri öğrenbilme özelliğine sahiptir. Ancak bu yapıyı çok sayıda zayıf karar ağacını ardışık olarak eğiterek ve hataları kademeli olarak azaltarak gerçekleştirmektedir. Herrera vd. (2010)'nin modeli renk değişimlerini kural tabanlı bulanık çıkarımlar aracılığıyla yaparken bizim çalışmamızdaki XGBoost modeli bu ilişkileri istatistiksel olarak optimize edilen ağırlıklarla öğrenmiş ve düzenlileştirme bileşenleri sayesinde aşırı uyum riskini azaltmıştır.

Her iki yaklaşım da diş rengindeki karmaşık ve doğrusal olmayan değişimleri tanımlamada güçlüdür fakat fuzzy logic modelleri daha sınırlı sayıda kural setine ve öznel üyelik fonksiyonlarına dayanır. XGBoost ve derin öğrenme algoritmaları ise büyük veri kümelerinden otomatik özellik çıkarımı (feature learning) yapabilme avantajına sahiptir. Ayrıca mevcut çalışmamızda kullanılan modelleri yalnızca L^*a^*b değişkenleri üzerinden ΔE_{00} ve Top-2 Vita doğruluğu gibi klinik olarak anlamlı metriklerle değerlendirilmiş, bu sayede renk tahmini süreci laboratuvar düzeyinden klinik uygulamaya taşımayı amaçlamıştır (Herrera vd., 2010).

Favoreto vd. (2025) tarafından yapılan bir çalışmada, ofis tipi beyazlatma işlemi sonrası gelişen diş hassasiyetinin oluşumunu ve şiddetini öngörmek amacıyla makine öğrenimi algoritmaları kullanılmıştır. Araştırmacılar, yaş, başlangıç rengi, hidrojen peroksit konsantrasyonu, jel pH'ı, uygulama süresi ve seans sayısı gibi parametreleri modele dahil

ederek hem sınıflandırma hem de regresyon temelli algoritmalar geliştirmiştir. Mevcut tez çalışmamızda yaş, beyazlatma ajanı tipi, mine ve dentin kalınlığı gibi bireysel ve materyal temelli parametreler sınıflandırılmamış olmakla birlikte, gelecekte veri kümesinin genişletilmesiyle bu tür klinik değişkenlerin modele dahil edilerek algoritmanın tahmin gücünün ve klinik genellenebilirliğinin arttırılması hedeflenmektedir.

Favoreto vd. (2025)'nin elde edilen sonuçlara göre Gradient Boosting Clasifier en yüksek tahmin başarımı göstermiştir. Gradient Boosting Classifier, prensip olarak mevcut çalışmamızda en başarılı performans gösteren XGBoost algoritması ile aynı ardışık olarak eğitilen çok sayıda zayıf karar ağacının birleşimiyle hataları kademeli olarak azaltan gradient boosting temeline dayanmaktadır. Bu benzerlik, gradient boosting tabanlı yaklaşımların diş beyazlatma gibi sınıflı veri kümesine sahip klinik uygulamalarda güçlü tahmin performansı sağlayabildiğini göstermektedir.

Bu çalışma diş beyazlatma tedavisinde yapay zeka temelli modellerin yalnızca renk değişimini değil, tedavi sonrası gelişebilecek komplikasyonların da öngörülmesinde etkin biçimde kullanılabileceğini göstermiştir. Mevcut çalışmamızda ise benzer yaklaşımla beyazlatma sonrası renk değişiminin tahminine odaklanılmış ve sonuçlar renk skalası ile ilişkilendirilmiştir. Böylece yapay zekanın diş beyazlatma sürecinde hem estetik sonuçların hem de hasta konforuna ilişkin parametrelerin önceden öngörülmesine olarak tanıyan, klinik karar destek sistemlerinin geliştirilmesine katkı sağlayabileceğini ortaya koymuştur (Favoreto vd., 2025).

Thanathornwong vd. (2016) yaptığı bir çalışmada, vital dişlerde yapılan ofis tipi beyazlatma sonrası renk değişimini tahmin edebilmek için CIELAB renk uzayına dayalı bir karar destek sistemi (Decision Support System) geliştirmiştir. Bu çalışmada araştırmacılar beyazlatma öncesi $L^*a^*b^*$ değerlerini kullanarak multiple lineer regresyon modeli oluşturmuş ve bu modelin beyazlatma sonrası elde edilen ΔE değerini yüksek doğrulukla öngörebildiğini bildirmiştir. Çalışmada renk farkının özellikle b^* değeri ile anlamlı bir korelasyon gösterdiği ve sarı alt tonlu dişlerde beyazlatma etkinliğinin daha belirgin olduğu bildirilmiştir. Bu çalışmada klinik karar destek sistemlerinin diş beyazlatma sonuçlarını öngörmede potansiyel bir araç olabileceğini göstermektedir. Mevcut çalışmamızda XGBoost, DNN, LSTM ve BiLSTM gibi gelişmiş yapay zeka modelleri kullanılarak doğrusal olmayan ilişkilerin de hesaba katılması hedeflenmiştir. Böylelikle diş rengindeki değişimin daha yüksek doğrulukla tahmin edilmesi sağlanmıştır. Bu yönüyle Thanathornwong vd (2016)'nin çalışması yapay

zeka'nın diř beyazlatma alanındaki klinik karar destek uygulamaları için temel bir adım oluřtururken bizim alıřmamız bu yaklařımı daha da ileri dzeye tařıyarak diř rengindeki karmařık deęiřim dinamiklerini ğrenebilen geliřmiř bir modelleme yaklařımı sunmuřtur (Thanathornwong vd., 2016).

Elde edilen sonular, yapay zeka'nın diř hekimlięinde zellikle estetik planlama ve tedavi ngrs alanlarında gl bir karar destek aracı olabileceęini gstermektedir. XGBoost modelinin dřk ΔE_{00} ve yksek Top-2 Vita doęruluęu, gelecekte spektrofotometrik verilerden yola ıkarak beyazlatma sonularını nceden tahmin eden klinik uygulamaların geliřtirilebileceęine iřaret etmektedir. Byle bir sistem, hekimlerin tedavi ncesi olası renk deęiřimini hasta ile paylařmasına ve kiřiye zel tedavi planlamasına olanak tanıyabilir. Ayrıca, klinik veri sayısının artmasıyla derin ęrenme tabanlı modellerin performansının da ykselmesi beklenmektedir. Uzun vadede bu yaklařım, dijital renk eřleřtirme sistemleriyle entegre alıřan, otomatik renk tahmin modllerinin geliřtirilmesine zemin hazırlayabilir. Bylelikle, objektif ve tekrarlanabilir renk tahmini, diř hekimlięinde estetik bařarının artırılmasında nemli bir dijital ara haline gelebilir.

5. SONUÇ VE ÖNERİLER

Çalışmamızda intrakoronal beyazlatma sonrası renk değişikliklerini tahmin edebilmek amacıyla dental spektrofotometre ile elde edilen L^* , a^* ve b^* değerleri kullanılarak farklı yapay zeka modelleri geliştirilmiş ve performansları karşılaştırılmıştır. Elde edilen sonuçlarda;

- 1) Tüm modellerin beyazlatma sonrası L^* , a^* , b^* değerlerini ve bu değerlerin VİTA 3D-Master renk skalasındaki eşleştirmelerini klinik açıdan kabul edilebilir hata düzeyleri içinde tahmin ettiği tespit edilmiştir.
- 2) CIEDE2000 değerleri değerlendirildiğinde tüm modellerin klinik olarak kabul edilebilir sınırlar içinde kaldığı görülmektedir.
- 3) En düşük hata oranının ve en yüksek Top-2 Vita doğruluğunun XGBoost modelinde elde edildiği tespit edilmiştir.
- 4) Derin öğrenme tabanlı modellerin sınırlı veri kümelerinde daha düşük performans gösterdiği belirlenmiştir.
- 5) Çalışmamızın sınırları dahilinde elde edilen bulgulara dayanarak gelecekte yapılacak çalışmalarda daha büyük veri kümelerinin kullanılması model performanslarının artmasını sağlayabilir. Farklı zaman noktalarında yapılan ölçümlerin eklenmesi zaman temelli modellerin etkinliğini arttırabilir. Mine ve dentin kalınlığı, yaş, cinsiyet gibi ek klinik parametrelerin modele dahil edilmesi, farklı makine öğrenmesi ve hibrit model yaklaşımların denenmesi ileride yapılacak çalışmalara katkı sağlayabilir.

KAYNAKLAR

- Abdi, J., Al-Hindawi, A., Ng, T.&Vizcaychipi, M. P. (2018). Scoping review on the use of socially assistive robot technology in elderly care. *BMJ open*, 8(2), e018815. <https://doi.org/10.1136/bmjopen-2017-018815>
- AbuSalim, S., Zakaria, N., Islam, M. R., Kumar, G., Mokhtar, N.&Abdulkadir, S. J. (2022). Analysis of deep learning techniques for dental informatics: a systematic literature review. *Healthcare*, <https://doi.org/10.3390/healthcare10101892>
- Ahmad, I. (2008). *Protocols for predictable aesthetic dental restorations*. Hoboken, NJ: John Wiley & Sons.
- Ahmed, H. M.Abbott, P. V. (2012). Discolouration potential of endodontic procedures and materials: a review. *Int Endod J*, 45(10), 883-897. <https://doi.org/10.1111/j.1365-2591.2012.02071.x>
- Akın, E.Şahin, M. E. (2024). Derin öğrenme ve yapay sinir ağı modelleri üzerine bir inceleme. *EMO Bilimsel Dergi*, 14(1), 27-38.
- Aladağ, A., Çömlekçioğlu, E.&Yılmaz, G. (2009). Farklı renk anahtarlarının metal kronların renk uyumlarına etkisi. *Süleyman Demirel Üniv Diş Hek Fak*, 1, 8-17.
- Aminoshariae, A., Kulild, J.&Nagendrababu, V. (2021). Artificial Intelligence in Endodontics: Current Applications and Future Directions. *J Endod*, 47(9), 1352-1357. <https://doi.org/10.1016/j.joen.2021.06.003>
- Amisha, Malik, P., Pathania, M.&Rathaur, V. K. (2019). Overview of artificial intelligence in medicine. *J Family Med Prim Care*, 8(7), 2328-2331. https://doi.org/10.4103/jfmmpc.jfmmpc_440_19
- Arai, Y., Kurokawa, H., Takamizawa, T., Tsujimoto, A., Saegusa, M., Yokoyama, M.&Miyazaki, M. (2021). Evaluation of structural coloration of experimental flowable resin composites. *J Esthet Restor Dent*, 33(2), 284-293. <https://doi.org/10.1111/jerd.12674>
- Arens, D. (1989). The role of bleaching in esthetics. *Dent Clin North Am*, 33(2), 319-336. <https://www.ncbi.nlm.nih.gov/pubmed/2721797>
- Arı, H.Üngör, M. (2002). In vitro comparison of different types of sodium perborate used for intracoronary bleaching of discoloured teeth. *International endodontic journal*, 35(5), 433-436. <https://doi.org/10.1046/j.1365-2591.2002.00497.x>
- Arsalan, H., Akcay, M., Yasa, B., Hatirli, H.&Saygili, G. (2015). Bleaching effect of activation of hydrogen peroxide using photon-initiated photoacoustic streaming technique. *Clin Oral Investig*, 19(2), 253-259. <https://doi.org/10.1007/s00784-014-1255-9>
- Asgary, S., Parirokh, M., Eghbal, M. J.&Brink, F. (2005). Chemical differences between white and gray mineral trioxide aggregate. *J Endod*, 31(2), 101-103. <https://doi.org/10.1097/01.don.0000133156.85164.b2>
- Asiri, A. F.Altuwalah, A. S. (2022). The role of neural artificial intelligence for diagnosis and treatment planning in endodontics: A qualitative review. *Saudi Dent J*, 34(4), 270-281. <https://doi.org/10.1016/j.sdentj.2022.04.004>
- Attin, T., Paque, F., Ajam, F.&Lennon, A. M. (2003). Review of the current status of tooth whitening with the walking bleach technique. *Int Endod J*, 36(5), 313-329. <https://doi.org/10.1046/j.1365-2591.2003.00667.x>
- Awdaljan, M. W., Roque, J. C., Choi, J.&Rondon, L. F. (2024). Introducing a novel approach to dental color reproduction using AI technology. *J Esthet Restor Dent*, 36(12), 1623-1637. <https://doi.org/10.1111/jerd.13300>
- Banchs, F.Trope, M. (2004). Revascularization of immature permanent teeth with apical periodontitis: new treatment protocol? *J Endod*, 30(4), 196-200. <https://doi.org/10.1097/00004770-200404000-00003>
- Barry, D. T. (2018). Adaptation, Artificial Intelligence, and Physical Medicine and Rehabilitation. *PM R*, 10(9 Suppl 2), S131-S143. <https://doi.org/10.1016/j.pmrj.2018.04.013>

- Baytas, I. M., Xiao, C., Zhang, X., Wang, F., Jain, A. K. & Zhou, J. (2017). Patient subtyping via time-aware LSTM networks. Proceedings of the 23rd ACM SIGKDD international conference on knowledge discovery and data mining, <https://doi.org/10.1145/3097983.3097997>
- Bhandari, M., Zeffiro, T. & Reddiboina, M. (2020). Artificial intelligence and robotic surgery: current perspective and future directions. *Curr Opin Urol*, 30(1), 48-54. <https://doi.org/10.1097/MOU.0000000000000692>
- Brady, J. M. del Rio, C. E. (1975). Corrosion of endodontic silver cones in humans: a scanning electron microscope and X-ray microprobe study. *J Endod*, 1(6), 205-210. [https://doi.org/10.1016/S0099-2399\(75\)80198-1](https://doi.org/10.1016/S0099-2399(75)80198-1)
- Brewer, J. D., Wee, A. & Seghi, R. (2004). Advances in color matching. *Dent Clin North Am*, 48(2), v, 341-358. <https://doi.org/10.1016/j.cden.2004.01.004>
- BUDAVARI, S. (1989). An Encyclopedia of Chemicals, Drugs, and Biologicals. *The Merck Index*, 246.
- Campo Nieves, L., Aliaga, I., De Paz, J. F., García Barbero, Á. E., Bajo Pérez, J., Villarrubia González, G. & Corchado Rodríguez, J. M. (2016). Retreatment Predictions in Odontology by means of CBR Systems. <https://doi.org/10.1155/2016/7485250>
- Carey, C. M. (2014). Tooth whitening: what we now know. *J Evid Based Dent Pract*, 14 Suppl, 70-76. <https://doi.org/10.1016/j.jebdp.2014.02.006>
- Carrillo-Perez, F., Pecho, O. E., Morales, J. C., Paravina, R. D., Della Bona, A., Ghinea, R., Pulgar, R., Perez, M. D. M. & Herrera, L. J. (2022). Applications of artificial intelligence in dentistry: A comprehensive review. *J Esthet Restor Dent*, 34(1), 259-280. <https://doi.org/10.1111/jerd.12844>
- Casey, L. J., Schindler, W. G., Murata, S. M. & Burgess, J. O. (1989). The use of dentinal etching with endodontic bleaching procedures. *J Endod*, 15(11), 535-538. [https://doi.org/10.1016/S0099-2399\(89\)80196-7](https://doi.org/10.1016/S0099-2399(89)80196-7)
- Chauhan, R., Ghanshala, K. K. & Joshi, R. (2018). Convolutional neural network (CNN) for image detection and recognition. 2018 first international conference on secure cyber computing and communication (ICSCCC), <https://doi.org/10.1109/ICSCCC.2018.8703316>
- Chen, T. & Guestrin, C. (2016). Xgboost: A scalable tree boosting system. Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining,
- Christodoulou, A., Mikrogeorgis, G., Vouzara, T., Papachristou, K., Angelopoulos, C., Nikolaidis, N., Pitas, I. & Lyroutdia, K. (2018). A new methodology for the measurement of the root canal curvature and its 3D modification after instrumentation. *Acta Odontol Scand*, 76(7), 488-492. <https://doi.org/10.1080/00016357.2018.1440321>
- Chu, S. J. (2004). Fundamentals of color: shade matching and communication in esthetic dentistry. Chicago, IL: Quintessence Publishing Co.
- Chu, S. J., Trushkowsky, R. D. & Paravina, R. D. (2010). Dental color matching instruments and systems. Review of clinical and research aspects. *J Dent*, 38 Suppl 2, e2-16. <https://doi.org/10.1016/j.jdent.2010.07.001>
- Civelek, A., Ersoy, M., L'Hotelier, E., Soyman, M. & Say, E. C. (2003). Polymerization shrinkage and microleakage in Class II cavities of various resin composites. *Oper Dent*, 28(5), 635-641. <https://www.ncbi.nlm.nih.gov/pubmed/14531612>
- Çalışkan, M. K. (2023). *Endodontide Tanı ve Tedaviler*. Nobel Tıp Kitabevleri
- Dahl, J. E. & Pallesen, U. (2016). Tooth Bleaching—a Critical Review of the Biological Aspects. *Critical Reviews in Oral Biology & Medicine*, 14(4), 292-304. <https://doi.org/10.1177/154411130301400406>
- Dayan, D., Heifferman, A., Gorski, M. & Begleiter, A. (1983). Tooth discoloration--extrinsic and intrinsic factors. *Quintessence Int Dent Dig*, 14(2), 195-199. <https://www.ncbi.nlm.nih.gov/pubmed/6574548>
- Developers, X. (2025). *XGBoost Parameters — XGBoost Documentation*. Retrieved 01.10.2025 from <https://xgboost.readthedocs.io/en/stable/parameter.html>
- Ellingsen, J. E., Rolla, G. & Eriksen, H. M. (1982). Extrinsic dental stain caused by chlorhexidine and other denaturing agents. *J Clin Periodontol*, 9(4), 317-322. <https://doi.org/10.1111/j.1600-051x.1982.tb02098.x>
- Endres, M. G., Hillen, F., Salloumis, M., Sedaghat, A. R., Niehues, S. M., Quatela, O., Hanken, H., Smeets, R., Beck-Broichsitter, B., Rendenbach, C., Lakhani, K., Heiland, M. & Gaudin, R. A.

- (2020). Development of a Deep Learning Algorithm for Periapical Disease Detection in Dental Radiographs. *Diagnostics (Basel)*, 10(6), 430. <https://doi.org/10.3390/diagnostics10060430>
- Fasanaro, T. S. (1992). Bleaching teeth: history, chemicals, and methods used for common tooth discolorations. *J Esthet Dent*, 4(3), 71-78. <https://doi.org/10.1111/j.1708-8240.1992.tb00666.x>
- Favoreto, M. W., Matos, T. P., da Cruz, K. R., Ferraz, A. X., Carneiro, T. S., Reis, A., Loguercio, A. D. & de Araujo, C. M. (2025). Prediction based on machine learning of tooth sensitivity for in-office dental bleaching. *J Dent*, 153, 105517. <https://doi.org/10.1016/j.jdent.2024.105517>
- Fondriest, J. (2003). Shade matching in restorative dentistry: the science and strategies. *Int J Periodontics Restorative Dent*, 23(5), 467-479. <https://www.ncbi.nlm.nih.gov/pubmed/14620121>
- Freccia, W. F. Peters, D. D. (1982). A technique for staining extracted teeth: a research and teaching aid for bleaching. *J Endod*, 8(2), 67-69. [https://doi.org/10.1016/S0099-2399\(82\)80260-4](https://doi.org/10.1016/S0099-2399(82)80260-4)
- Frysh, H., Bowles, W., Baker, F., Rivera-Hidalgo, G. & Guillen, G. (1993). Effect of pH on bleaching efficiency. *J Dent Res*, 72(384), 2248.
- Frysh, H., Bowles, W. H., Baker, F., Rivera-Hidalgo, F. & Guillen, G. (1995). Effect of pH on hydrogen peroxide bleaching agents. *J Esthet Dent*, 7(3), 130-133. <https://doi.org/10.1111/j.1708-8240.1995.tb00730.x>
- Fukuda, M., Inamoto, K., Shibata, N., Arijji, Y., Yanashita, Y., Kutsuna, S., Nakata, K., Katsumata, A., Fujita, H. & Arijji, E. (2020). Evaluation of an artificial intelligence system for detecting vertical root fracture on panoramic radiography. *Oral Radiol*, 36(4), 337-343. <https://doi.org/10.1007/s11282-019-00409-x>
- Gao, L., Jiao, T., Feng, Q. & Wang, W. (2021). Application of artificial intelligence in diagnosis of osteoporosis using medical images: a systematic review and meta-analysis. *Osteoporos Int*, 32(7), 1279-1286. <https://doi.org/10.1007/s00198-021-05887-6>
- Gao, X., Xin, X., Li, Z. & Zhang, W. (2021). Predicting postoperative pain following root canal treatment by using artificial neural network evaluation. *Sci Rep*, 11(1), 17243. <https://doi.org/10.1038/s41598-021-96777-8>
- Goodfellow, I., Bengio, Y., Courville, A. & Bengio, Y. (2016). *Deep learning* (Vol. 1). MIT press Cambridge.
- Gorlin, R. Goldman, H. (1970). Environmental pathology of the teeth. *Thoma's oral pathology*. 6th ed. St Louis: Mosby.
- Graves, A. Schmidhuber, J. (2005). Framewise phoneme classification with bidirectional LSTM networks. Proceedings. 2005 IEEE International Joint Conference on Neural Networks, 2005., <https://doi.org/10.1109/IJCNN.2005.1556215>
- Gu, D., Liang, C. & Zhao, H. (2017). A case-based reasoning system based on weighted heterogeneous value distance metric for breast cancer diagnosis. *Artif Intell Med*, 77, 31-47. <https://doi.org/10.1016/j.artmed.2017.02.003>
- Haapasalo, M. Qian, W. (2008). Irrigants and intracanal medicaments. *Ingle's endodontics*. 6th ed. Hamilton, ON, Canada: BC Decker Inc, 992-1011.
- Hamet, P. Tremblay, J. (2017). Artificial intelligence in medicine. *metabolism*, 69S, S36-S40. <https://doi.org/10.1016/j.metabol.2017.01.011>
- Hammad, I. A. Stein, R. S. (1991). A qualitative study for the bond and color of ceramometals. Part II. *J Prosthet Dent*, 65(2), 169-179. [https://doi.org/10.1016/0022-3913\(91\)90158-s](https://doi.org/10.1016/0022-3913(91)90158-s)
- Hardman, P. K., Moore, D. & Petteway, G. (1985). Stability of hydrogen peroxide as a bleaching agent. *General dentistry*, 33(2), 121-122.
- Harlan, A. (1885). The removal of stains from the teeth caused by the administration of medicinal agents and the bleaching of pulpless teeth. *Journal of the American Medical Association*, 4(5), 123. <https://doi.org/10.1111/j.1708-8240.1991.tb00991.x>
- Herrera, L. J., Pulgar, R., Santana, J., Cardona, J. C., Guillen, A., Rojas, I. & Perez Mdel, M. (2010). Prediction of color change after tooth bleaching using fuzzy logic for Vita Classical shades identification. *Appl Opt*, 49(3), 422-429. <https://doi.org/10.1364/AO.49.000422>
- Hiraiwa, T., Arijji, Y., Fukuda, M., Kise, Y., Nakata, K., Katsumata, A., Fujita, H. & Arijji, E. (2019). A deep-learning artificial intelligence system for assessment of root morphology of the mandibular first molar on panoramic radiography. *Dentomaxillofac Radiol*, 48(3), 20180218. <https://doi.org/10.1259/dmfr.20180218>

- Ho, S.Goerig, A. C. (1989). An in vitro comparison of different bleaching agents in the discolored tooth. *J Endod*, 15(3), 106-111. [https://doi.org/10.1016/S0099-2399\(89\)80129-3](https://doi.org/10.1016/S0099-2399(89)80129-3)
- Hochreiter, S.Schmidhuber, J. (1997). Long short-term memory. *Neural Comput*, 9(8), 1735-1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- Horn, D. J., Hicks, M. L.&Bulan-Brady, J. (1998). Effect of smear layer removal on bleaching of human teeth in vitro. *J Endod*, 24(12), 791-795. [https://doi.org/10.1016/S0099-2399\(98\)80003-4](https://doi.org/10.1016/S0099-2399(98)80003-4)
- Huang, S., Yang, J., Fong, S.&Zhao, Q. (2020). Artificial intelligence in cancer diagnosis and prognosis: Opportunities and challenges. *Cancer Lett*, 471, 61-71. <https://doi.org/10.1016/j.canlet.2019.12.007>
- Ivan, R.Rade, P. (2009). COLOR MEASURING INSTRUMENTS. *Acta Stomatologica Naissi*, 25(60).
- Jiménez-Rubio, A.Segura, J. J. (1998). The effect of the bleaching agent sodium perborate on macrophage adhesion in vitro: implications in external cervical root resorption. *Journal of Endodontics*, 24(4), 229-232. [https://doi.org/10.1016/S0099-2399\(98\)80101-5](https://doi.org/10.1016/S0099-2399(98)80101-5)
- Johari, M., Esmaeili, F., Andalib, A., Garjani, S.&SaberKari, H. (2017). Detection of vertical root fractures in intact and endodontically treated premolar teeth by designing a probabilistic neural network: an ex vivo study. *Dentomaxillofac Radiol*, 46(2), 20160107. <https://doi.org/10.1259/dmfr.20160107>
- Joiner, A. (2004). Tooth colour: a review of the literature. *J Dent*, 32 Suppl 1, 3-12. <https://doi.org/10.1016/j.ident.2003.10.013>
- Jung, I. Y., Lee, S. J.&Hargreaves, K. M. (2008). Biologically based treatment of immature permanent teeth with pulpal necrosis: a case series. *J Endod*, 34(7), 876-887. <https://doi.org/10.1016/j.joen.2008.03.023>
- Kaneko, J., Inoue, S., Kawakami, S.&Sano, H. (2000). Bleaching effect of sodium percarbonate on discolored pulpless teeth in vitro. *Journal of Endodontics*, 26(1), 25-28. <https://doi.org/10.1097/00004770-200001000-00006>
- Karamouzos, A., Papadopoulos, M. A., Kolokithas, G.&Athanasίου, A. E. (2007). Precision of in vivo spectrophotometric colour evaluation of natural teeth. *J Oral Rehabil*, 34(8), 613-621. <https://doi.org/10.1111/j.1365-2842.2007.01744.x>
- Khashayar, G., Bain, P. A., Salari, S., Dozic, A., Kleverlaan, C. J.&Feilzer, A. J. (2014). Perceptibility and acceptability thresholds for colour differences in dentistry. *J Dent*, 42(6), 637-644. <https://doi.org/10.1016/j.ident.2013.11.017>
- Kim, J. H., Kim, Y., Shin, S. J., Park, J. W.&Jung, I. Y. (2010). Tooth discoloration of immature permanent incisor associated with triple antibiotic therapy: a case report. *J Endod*, 36(6), 1086-1091. <https://doi.org/10.1016/j.joen.2010.03.031>
- Kim, S. T., Abbott, P. V.&McGinley, P. (2000). The effects of Ledermix paste on discolouration of mature teeth. *Int Endod J*, 33(3), 227-232. <https://doi.org/10.1046/j.1365-2591.2000.00278.x>
- Kim-Pusateri, S., Brewer, J. D., Davis, E. L.&Wee, A. G. (2009). Reliability and accuracy of four dental shade-matching devices. *J Prosthet Dent*, 101(3), 193-199. [https://doi.org/10.1016/S0022-3913\(09\)60028-7](https://doi.org/10.1016/S0022-3913(09)60028-7)
- King, R. B. (2005). *Encyclopedia of inorganic chemistry* (Vol. 10). Wiley Online Library.
- Kogan, P., He, J., Glickman, G. N.&Watanabe, I. (2006). The effects of various additives on setting properties of MTA. *J Endod*, 32(6), 569-572. <https://doi.org/10.1016/j.joen.2005.08.006>
- Kuehni, R. G. (2002). The early development of the Munsell system. *Color Research & Application: Endorsed by Inter-Society Color Council, The Colour Group (Great Britain), Canadian Society for Color, Color Science Association of Japan, Dutch Society for the Study of Color, The Swedish Colour Centre Foundation, Colour Society of Australia, Centre Français de la Couleur*, 27(1), 20-27. <https://doi.org/10.1002/col.10002>
- Kupietzky, A., Waggoner, W. F.&Galea, J. (2003). The clinical and radiographic success of bonded resin composite strip crowns for primary incisors. *Pediatr Dent*, 25(6), 577-581. <https://www.ncbi.nlm.nih.gov/pubmed/14733473>
- Lahoud, P., EzEldeen, M., Beznik, T., Willems, H., Leite, A., Van Gerven, A.&Jacobs, R. (2021). Artificial Intelligence for Fast and Accurate 3-Dimensional Tooth Segmentation on Cone-beam Computed Tomography. *J Endod*, 47(5), 827-835. <https://doi.org/10.1016/j.joen.2020.12.020>

- Lai, G., Dunlap, C., Gluskin, A., Nehme, W. B. & Azim, A. A. (2023). Artificial intelligence in endodontics. *Journal of the California Dental Association*, 51(1), 2199933. <https://doi.org/10.1080/19424396.2023.2199933>
- Lim, M. Y., Lum, S. O., Poh, R. S., Lee, G. P. & Lim, K. C. (2004). An in vitro comparison of the bleaching efficacy of 35% carbamide peroxide with established intracoronal bleaching agents. *Int Endod J*, 37(7), 483-488. <https://doi.org/10.1111/j.1365-2591.2004.00829.x>
- Lu, J. Y., Zhu, J., Zhu, J. & Duong, T. Q. (2022). Long-short-term memory machine learning of longitudinal clinical data accurately predicts acute kidney injury onset in COVID-19: a two-center study. *Int J Infect Dis*, 122, 802-810. <https://doi.org/10.1016/j.ijid.2022.07.034>
- Luo, M. R., Cui, G. & Rigg, B. (2001). The development of the CIE 2000 colour-difference formula: CIEDE2000. *Color Research & Application: Endorsed by Inter-Society Color Council, The Colour Group (Great Britain), Canadian Society for Color, Color Science Association of Japan, Dutch Society for the Study of Color, The Swedish Colour Centre Foundation, Colour Society of Australia, Centre Français de la Couleur*, 26(5), 340-350. <https://doi.org/10.1002/col.1049>
- Madison, S. & Walton, R. (1990). Cervical root resorption following bleaching of endodontically treated teeth. *J Endod*, 16(12), 570-574. [https://doi.org/10.1016/S0099-2399\(07\)80199-3](https://doi.org/10.1016/S0099-2399(07)80199-3)
- Maltarollo, V. G., Honório, K. & Da Silva, A. (2013). Applications of artificial neural networks in chemical. *Artificial Neural Networks-Architectures and Applications*, 203-223.
- Martins, J. N., Marques, D., Mata, A. & Carames, J. (2014). Clinical efficacy of electronic apex locators: systematic review. *J Endod*, 40(6), 759-777. <https://doi.org/10.1016/j.joen.2014.03.011>
- Matis, B. A. (2000). Degradation of gel in tray whitening. *Compend Contin Educ Dent Suppl*(28), S28, S31-25; quiz S49. <https://www.ncbi.nlm.nih.gov/pubmed/11908345>
- McEvoy, S. A. (1989). Chemical agents for removing intrinsic stains from vital teeth. II. Current techniques and their clinical application. *Quintessence Int*, 20(6), 379-384. <https://www.ncbi.nlm.nih.gov/pubmed/2756093>
- McPhee, E. R. (1985). Extrinsic coloration of ceramometal restorations. *Dent Clin North Am*, 29(4), 645-666. <https://www.ncbi.nlm.nih.gov/pubmed/3908158>
- Mohammadi, Z., Abbott, P. V. (2009). Antimicrobial substantivity of root canal irrigants and medicaments: a review. *Aust Endod J*, 35(3), 131-139. <https://doi.org/10.1111/j.1747-4477.2009.00164.x>
- Moyle, W., Arnautovska, U., Ownsworth, T. & Jones, C. (2017). Potential of telepresence robots to enhance social connectedness in older adults with dementia: an integrative review of feasibility. *Int Psychogeriatr*, 29(12), 1951-1964. <https://doi.org/10.1017/S1041610217001776>
- Munsell, A. H. (1919). *A color notation*. Boston: Munsell color company.
- Nordbo, H., Eriksen, H. M., Rolla, G., Attramadal, A. & Solheim, H. (1982). Iron staining of the acquired enamel pellicle after exposure to tannic acid or chlorhexidine: preliminary report. *Scand J Dent Res*, 90(2), 117-123. <https://doi.org/10.1111/j.1600-0722.1982.tb01533.x>
- Paravina, R. D., Ghinea, R., Herrera, L. J., Bona, A. D., Igiel, C., Linninger, M., Sakai, M., Takahashi, H., Tashkandi, E. & Perez Mdel, M. (2015). Color difference thresholds in dentistry. *J Esthet Restor Dent*, 27 Suppl 1, S1-9. <https://doi.org/10.1111/jerd.12149>
- Paravina, R. D., Powers, J. M. (2004). *Esthetic color training in dentistry*. Chicago, IL: Quintessence Publishing Co..
- Parsons, J. R., Walton, R. E. & Ricks-Williamson, L. (2001). In vitro longitudinal assessment of coronal discoloration from endodontic sealers. *J Endod*, 27(11), 699-702. <https://doi.org/10.1097/00004770-200111000-00012>
- Patharkar, A., Cai, F., Al-Hindawi, F. & Wu, T. (2024). Predictive modeling of biomedical temporal data in healthcare applications: review and future directions. *Front Physiol*, 15, 1386760. <https://doi.org/10.3389/fphys.2024.1386760>
- Paul, S., Peter, A., Pietrobon, N. & Hammerle, C. H. (2002). Visual and spectrophotometric shade analysis of human teeth. *J Dent Res*, 81(8), 578-582. <https://doi.org/10.1177/154405910208100815>
- Pauwels, R., Brasil, D. M., Yamasaki, M. C., Jacobs, R., Bosmans, H., Freitas, D. Q. & Haider-Neto, F. (2021). Artificial intelligence for detection of periapical lesions on intraoral radiographs:

- Comparison between convolutional neural networks and human observers. *Oral Surg Oral Med Oral Pathol Oral Radiol*, 131(5), 610-616. <https://doi.org/10.1016/j.oooo.2021.01.018>
- Phillips, R. Skinner's Science of dental materials, WB Saunders Company Harcourt Brace Jovovich. In: Inc.
- Piasecki, L., Carneiro, E., da Silva Neto, U. X., Westphalen, V. P. D., Brandão, C. G., Gambarini, G. & Azim, A. A. (2016). The use of micro-computed tomography to determine the accuracy of 2 electronic apex locators and anatomic variations affecting their precision. *Journal of endodontics*, 42(8), 1263-1267. <https://doi.org/10.1016/j.joen.2016.04.024>
- Plotino, G., Buono, L., Grande, N. M., Pameijer, C. H. & Somma, F. (2008). Nonvital tooth bleaching: a review of the literature and clinical procedures. *J Endod*, 34(4), 394-407. <https://doi.org/10.1016/j.joen.2007.12.020>
- Pradeep Kumar, A. R., Shemesh, H., Nivedhitha, M. S., Hashir, M. M. J., Arockiam, S., Uma Maheswari, T. N. & Natanasabapathy, V. (2021). Diagnosis of Vertical Root Fractures by Cone-beam Computed Tomography in Root-filled Teeth with Confirmation by Direct Visualization: A Systematic Review and Meta-Analysis. *J Endod*, 47(8), 1198-1214. <https://doi.org/10.1016/j.joen.2021.04.022>
- Ra, F. (1991). Chemical, optical, and physiologic mechanism of bleaching products: A review. *Pract Periodontics Aesthet Dent*, 3, 32-36.
- Retief, D. H. (1991). Standardizing laboratory adhesion tests. *Am J Dent*, 4(5), 231-236. <https://www.ncbi.nlm.nih.gov/pubmed/1810333>
- Reyes, L. T., Knorst, J. K., Ortiz, F. R. & Ardenghi, T. M. (2021). Scope and challenges of machine learning-based diagnosis and prognosis in clinical dentistry: A literature review. *J Clin Transl Res*, 7(4), 523-539. <https://www.ncbi.nlm.nih.gov/pubmed/34541366>
- Ricucci Langeland. (1998). Apical limit of root canal instrumentation and obturation, part 2. A histological study. *International endodontic journal*, 31(6), 394-409.
- Romm, E. L. Tsigelny, I. F. (2020). Artificial Intelligence in Drug Treatment. *Annu Rev Pharmacol Toxicol*, 60(1), 353-369. <https://doi.org/10.1146/annurev-pharmtox-010919-023746>
- Rosenstiel, S. F., Land, M., Fujimoto, J. & Cockerill, J. (2001). Contemporary fixed prosthodontics. St. Louis. Mosby, Inc, 2001, 380-416.
- Rotstein, I. Friedman, S. (1991). pH variation among materials used for intracoronary bleaching. *J Endod*, 17(8), 376-379. [https://doi.org/10.1016/S0099-2399\(06\)81988-6](https://doi.org/10.1016/S0099-2399(06)81988-6)
- Rotstein, I. Li, Y. (2008). Tooth discoloration and bleaching. *Endodontics*, 3, 845-860.
- Rusdah, D. A. Murfi, H. (2020). XGBoost in handling missing values for life insurance risk prediction. *SN Applied Sciences*, 2(8), 1336 <https://doi.org/10.1007/s42452-020-3128-y>
- Saghiri, M. A., Garcia-Godoy, F., Gutmann, J. L., Lotfi, M. & Asgar, K. (2012). The reliability of artificial neural network in locating minor apical foramen: a cadaver study. *J Endod*, 38(8), 1130-1134. <https://doi.org/10.1016/j.joen.2012.05.004>
- Samek, W., Montavon, G., Lapuschkin, S., Anders, C. J. & Müller, K.-R. (2021). Explaining deep neural networks and beyond: A review of methods and applications. *Proceedings of the IEEE*, 109(3), 247-278. <https://doi.org/10.1109/JPROC.2021.3060483>
- Samorani, M. Blount, L. G. (2020). Machine learning and medical appointment scheduling: creating and perpetuating inequalities in access to health care. In (Vol. 110, pp. 440-441): American Public Health Association. <https://doi.org/10.2105/AJPH.2020.305570>
- Sarıkaya, I. Güler, A. U. (2009). Diş hekimliği uygulamalarında renk kavramı. *Türkiye Klinikleri Journal of Dental Sciences*, 15(2), 118-129.
- Schmidhuber, J. (2015). Deep learning in neural networks: An overview. *Neural networks*, 61, 85-117.
- Schussler, V., Kawakami, D. Y., Rocha, M. A. G., Sinhoreti, M. A. C., Rocha, M. G. & Oliveira, D. (2024). Perceptibility and Acceptability Thresholds for Color Differences in Ceramic Shade Tabs: A Comparison Between Dentists and Patients. *J Clin Exp Dent*, 16(12), e1509-e1516. <https://doi.org/10.4317/jced.62287>
- Seghi, R. R. Denry, I. (1992). Effects of external bleaching on indentation and abrasion characteristics of human enamel in vitro. *J Dent Res*, 71(6), 1340-1344. <https://doi.org/10.1177/00220345920710061201>

- Setzer, F. C., Shi, K. J., Zhang, Z., Yan, H., Yoon, H., Mupparapu, M. & Li, J. (2020). Artificial Intelligence for the Computer-aided Detection of Periapical Lesions in Cone-beam Computed Tomographic Images. *J Endod*, 46(7), 987-993. <https://doi.org/10.1016/j.joen.2020.03.025>
- Shan, T., Tay, F. R. & Gu, L. (2021). Application of Artificial Intelligence in Dentistry. *J Dent Res*, 100(3), 232-244. <https://doi.org/10.1177/0022034520969115>
- Shen, S., Yuan, X., Wang, J., Fan, L., Zhao, J. & Tao, J. (2022). Evaluation of a machine learning algorithms for predicting the dental age of adolescent based on different preprocessing methods. *Front Public Health*, 10, 1068253. <https://doi.org/10.3389/fpubh.2022.1068253>
- Shetty, S., Gali, S., Augustine, D. & Sv, S. (2024). Artificial intelligence systems in dental shade-matching: A systematic review. *J Prosthodont*, 33(6), 519-532. <https://doi.org/10.1111/jopr.13805>
- Shtar, G., Rokach, L. & Shapira, B. (2019). Detecting drug-drug interactions using artificial neural networks and classic graph similarity measures. *PloS one*, 14(8), e0219796. <https://doi.org/10.1371/journal.pone.0219796>
- Sikri, V. K. (2010). Color: Implications in dentistry. *J Conserv Dent*, 13(4), 249-255. <https://doi.org/10.4103/0972-0707.73381>
- Sipaviciute, E. & Maneliene, R. (2014). Pain and flare-up after endodontic treatment procedures. *Stomatologija*, 16(1), 25-30. <https://www.ncbi.nlm.nih.gov/pubmed/24824057>
- Spasser, H. F. (1961). A simple bleaching technique using sodium perborate. *NY State Dent. J.*, 27, 332-334.
- Sproull, R. C. (1973). Color matching in dentistry. Part I. The three-dimensional nature of color. *The Journal of prosthetic dentistry*, 29(4), 416-424.
- Stewart, G. G. (1965). Bleaching Discolored Pulpless Teeth. *J Am Dent Assoc*, 70(2), 325-328. <https://doi.org/10.14219/jada.archive.1965.0278>
- Strenk, S. A., Strenk, L. M. & Koretz, J. F. (2005). The mechanism of presbyopia. *Prog Retin Eye Res*, 24(3), 379-393. <https://doi.org/10.1016/j.preteyeres.2004.11.001>
- Suliman, M. (2004). An overview of bleaching techniques: 1. History, chemistry, safety and legal aspects. *Dental Update*, 31(10), 608-616. <https://doi.org/10.12968/denu.2004.31.10.608>
- Tay, F. R., Mazzoni, A., Pashley, D. H., Day, T. E., Ngoh, E. C. & Breschi, L. (2006). Potential iatrogenic tetracycline staining of endodontically treated teeth via NaOCl/MTAD irrigation: a preliminary report. *J Endod*, 32(4), 354-358. <https://doi.org/10.1016/j.joen.2005.11.006>
- Tewary, S., Luzzo, J. & Hartwell, G. (2011). Endodontic radiography: who is reading the digital radiograph? *J Endod*, 37(7), 919-921. <https://doi.org/10.1016/j.joen.2011.02.027>
- Thanathornwong, B., Suebnukarn, S. & Ouivirach, K. (2016). Decision support system for predicting color change after tooth whitening. *Comput Methods Programs Biomed*, 125, 88-93. <https://doi.org/10.1016/j.cmpb.2015.11.004>
- Theilade, J., Slots, J. & Fejerskov, O. (1973). The ultrastructure of black stain on human primary teeth. *Scand J Dent Res*, 81(7), 528-532. <https://doi.org/10.1111/j.1600-0722.1973.tb00360.x>
- Todorović, A., Todorović, A., Špadijer, G. A., Lazić, V., Miličić, B. & Đurišić, S. (2013). Reliability of conventional shade guides in teeth color determination. *Vojnosanitetski pregled*, 70(10), 929-934. <https://doi.org/10.2298/vsp110513019t>
- Torabinejad, M., Cho, Y., Khademi, A. A., Bakland, L. K. & Shabahang, S. (2003). The effect of various concentrations of sodium hypochlorite on the ability of MTAD to remove the smear layer. *J Endod*, 29(4), 233-239. <https://doi.org/10.1097/00004770-200304000-00001>
- Tung, F. F., Goldstein, G. R., Jang, S. & Hittelman, E. (2002). The repeatability of an intraoral dental colorimeter. *J Prosthet Dent*, 88(6), 585-590. <https://doi.org/10.1067/mpr.2002.129803>
- Turing, A. (1950). Computing machinery and intelligence. *Mind*, 59(236), 433-460.
- Vachon, C., Vanek, P. & Friedman, S. (1998). Internal bleaching with 10% carbamide peroxide in vitro. *Pract Periodontics Aesthet Dent*, 10(9), 1145-1148, 1150, 1152 passim. <https://www.ncbi.nlm.nih.gov/pubmed/10093559>
- van der Burgt, T. P. & Plasschaert, A. J. (1985). Tooth discoloration induced by dental materials. *Oral Surg Oral Med Oral Pathol*, 60(6), 666-669. [https://doi.org/10.1016/0030-4220\(85\)90373-1](https://doi.org/10.1016/0030-4220(85)90373-1)
- VB, H. (1990). Nightguard vital bleaching: current information and research. *Esthet Dent Update*, 1(2), 7-12.

- Waerhaug, M., Gjermo, P., Rolla, G. & Johansen, J. R. (1984). Comparison of the effect of chlorhexidine and CuSO₄ on plaque formation and development of gingivitis. *J Clin Periodontol*, 11(3), 176-180. <https://doi.org/10.1111/j.1600-051x.1984.tb01321.x>
- Walsh, L. J. (2000). Safety issues relating to the use of hydrogen peroxide in dentistry. *Aust Dent J*, 45(4), 257-269; quiz 289. <https://doi.org/10.1111/j.1834-7819.2000.tb00261.x>
- Watts, A. Addy, M. (2001). Tooth discolouration and staining: a review of the literature. *Br Dent J*, 190(6), 309-316. <https://doi.org/10.1038/sj.bdj.4800959>
- Wee, A. (2006). Description of color science, color replication progress and esthetics. book: *Contemporary Fixed Prosthodontics*. St. Louis: Mosby
- Wee, A. G., Kang, E. Y., Johnston, W. M. & Seghi, R. R. (2000). Evaluating porcelain color match of different porcelain shade-matching systems. *J Esthet Dent*, 12(5), 271-280. <https://doi.org/10.1111/j.1708-8240.2000.tb00234.x>
- Wee, A. G., Lindsey, D. T., Kuo, S. & Johnston, W. M. (2006). Color accuracy of commercial digital cameras for use in dentistry. *Dent Mater*, 22(6), 553-559. <https://doi.org/10.1016/j.dental.2005.05.011>
- Wu, J. (2017). Introduction to convolutional neural networks. *National Key Lab for Novel Software Technology. Nanjing University. China*, 5(23), 495.
- Wu, M. K., De Gee, A. J., Wesselink, P. R. & Moorer, W. R. (1993). Fluid transport and bacterial penetration along root canal fillings. *Int Endod J*, 26(4), 203-208. <https://doi.org/10.1111/j.1365-2591.1993.tb00560.x>
- Zappala, C. Caprioglio, D. (1993). Discromie Dentarie: Sistemi di Sbiancamento Alla Poltrona e Domiciliari. *Dental Cadmos*, 61, 13-13.

EKLER

Ek-1 Etik Onay Raporu

