

T.C.
AFYONKARAHİSAR SAĞLIK BİLİMLERİ ÜNİVERSİTESİ
DİŞ HEKİMLİĞİ FAKÜLTESİ

ORTODONTİ ANABİLİM DALI

ORTODONTİK TEDAVİ ÖNCESİ HASTA
KOOPERASYONUNUN YAPAY ZEKA İLE TAHMİNİ

Farhad SALMANPOUR
DİŞ HEKİMLİĞİNDE UZMANLIK TEZİ

Tez No: 26

Danışman

Doç. Dr. Hasan CAMCI

2022 – AFYONKARAHİSAR

BİLİMSEL ETİĞE UYGUNLUK

Bu çalışmadaki tüm bilgilerin, akademik ve etik kurallara uygun bir şekilde elde edildiğini beyan ederim. Aynı zamanda bu kural ve davranışların gerektirdiği gibi, bu çalışmanın özünde olmayan tüm materyal ve sonuçları tam olarak aktardığımı ve referans gösterdiğimi belirtirim.

Uzmanlık Öğrencisinin

Danışmanın

Adı Soyadı: Farhad SALMANPOUR

Adı Soyadı: Hasan CAMCI

İmza:

İmza:

TEŞEKKÜR

Uzmanlık eğitimim süresinde ve tezimin hazırlanması sırasında bana her zaman yol gösteren, destek olan, bilgi ve tecrübelerini benimle esirgemedi paylaşarak bana çok şey katan değerli danışman hocam ve ana bilim dalı başkanımız Sayın Doç. Dr. Hasan CAMCI'ya;

Ortodonti anabilim dalında beraber çalıştığım, geçirdiğimiz her andan büyük keyif aldığım asistan arkadaşlarım, Asiye Işıl ŞENOCAK, Ayşegül SÜĞÜRTİN, Merve ŞİRVANCI, Taha Tarık SARI ve Ömer GENİŞ'e;

Beni bu günlere getiren, desteklerini her zaman arkamda hissettiğim, tüm kararlarımda yanımda olan, emeklerine sonsuz şükran duyduğum sevgili babam ve canım annem'e, Sonsuz teşekkür ederim.

Farhad SALMANPOUR

Afyonkarahisar, Kasım 2022

ORTODONTİK TEDAVİ ÖNCESİ HASTA KOOPERASYONUNUN YAPAY ZEKA İLE TAHMİNİ

FARHAD SALMANPOUR

Afyonkarahisar Sağlık Bilimleri Üniversitesi Diş Hekimliği Fakültesi
Ortodonti Anabilim Dalı Uzmanlık Tezi

Kasım, 2022

Danışman: Doç. Dr. Hasan CAMCI

ÖZET

Amaç: Bu çalışmanın amacı hastanın ortodontik tedavi sırasında göstereceği işbirliğinin tedaviye başlamadan önce yapay zeka ile tahminin mümkün olup olmadığını test etmektir.

Yöntem: kliniğimizde sabit ortodontik tedavi gören 230 hasta tedavilerinin 12. Ayında doktorları tarafından doldurulan ortodontik hasta kooperasyonu skalasına göre uyumlu ve uyumsuz olarak iki farklı gruba yerleştirilmiştir. Gruplandırılmış hastaların cephe fotoğrafları, el yazısı örnekleri ve ses kayıtları elde edildi. Toplanan bu veriler çeşitli makine öğrenimi algoritmaları ve yapay sinir ağı modelleri ile analiz edilerek yüz fotoğrafları, el yazısı ve sesin hasta kooperasyonu ile ilişki ve hastanın kooperasyonunun tedaviye başlamadan önce tahmin edilebilirliği araştırılmıştır. Modellerin performansı ve başarı oranlarının yükseltilmesi için öğrenim aktarımı tekniği kullanılmıştır.

Bulgular: Yüz fotoğraflarını değerlendiren modellerden Xception ve DenseNet %66.0 başarı oranıyla en iyi sonuç elde eden modeller olmuştur. El yazı örneklerini değerlendirmek amacıyla kullanılan modellerden InceptionResNet %72.0 ve NasNetMobile %70.0 ile en iyi performansı sergileyen modeller olmuştur. Ses verilerini değerlendirilmesinde ESA modeli ile birlikte Linear discriminant analizi, K'ya en yakın komşu, Destek vektör makinesi, Ekstra ağaç sınıflandırıcı ve Yığılma sınıflandırıcı %57.0 başarı oranına ulaşarak en iyi performansı sergileyen algoritmalar olmuştur.

Sonuçlar: Yüzün fizyonomi özellikleri, el yazısının özellikleri, sesin tonu ve frekansı kooperasyon tahmini için kullanılabilir. El yazısı; yüz ve sese göre kooperasyon ile ilgili daha çok bilgi taşımaktadır. El yazısı örnekleri, yüz fotoğrafları ve ses kayıtlarının değerlendirilmesinde yapay sinir ağlarıyla elde edilen en yüksek başarı oranı sırasıyla %72.0, %63.0 ve %57.0 olmuştur.

Anahtar kelimeler: Evrişimli sinir ağları, Kooperasyon, Yapay zeka

PREDICTION OF PATIENT COOPERATION WITH ARTIFICIAL INTELLIGENCE BEFORE ORTHODONTIC TREATMENT

Farhad SALMANPOUR

**Afyonkarahisar Health Sciences University Faculty of Dentistry Department of
Ortodonti Specialization Thesis**

October 2022

Supervisor: Assoc. Prof. Hasan CAMCI

ABSTRACT

Aim: The aim of this study is to test whether it can predict the patient's cooperation during orthodontic treatment with artificial intelligence before starting the treatment.

Methods: According to the orthodontic patient cooperation scale that their physicians filled out in the 12th month of their treatment, 230 patients who had fixed orthodontic treatment in our clinic were split into two distinct groups cooperative and non-cooperative. Voice recordings, handwriting samples and facial photographs of the patients were obtained. These collected data were analyzed with various machine learning algorithms and artificial neural network models, and the relationship of facial photographs, handwriting, and voice with patient cooperation and the predictability of patient cooperation before starting treatment were investigated. The learning transfer technique was used to increase the performance and success rates of the models.

Results: With a success percentage of 66.0%, Xception and DenseNet were the models that performed the best among those that assessed the face pictures. Among the models used to evaluate handwriting samples InceptionResNet (72.0%) and NasNetMobile (70.0%) were the best performing models. The algorithms that performed best in the assessment of sound data were the ESA model together with Linear Discriminant Analysis, K-Nearest Neighbor, Support Vector Machine, Extra Tree Classifier, and Stacking Classifier, with a success percentage of 57.0%.

Conclusions: The physiognomy features of the face, features of handwriting, tone and frequency of the voice can be used for cooperation prediction. Handwriting; It carries more information about cooperation than face and voice. The highest success rate obtained with artificial neural networks in the evaluation of handwriting samples, face photographs and voice recordings was 72.0%, 63.0% and 57.0%, respectively.

Keywords: Artificial intelligence, Convolutional neural networks, Cooperation

İÇİNDEKİLER

Sayfa

T.C.	i
BİLİMSEL ETİĞE UYGUNLUK	ii
TEŞEKKÜR	iii
ÖZET	iv
ABSTRACT	v
İÇİNDEKİLER	vi
KISALTMALAR VE SİMGELER DİZİNİ	ix
TABLolar DİZİNİ	x
ŞEKİLLER DİZİNİ	xi
1. GİRİŞ VE AMAÇ	1
2. GENEL BİLGİLER	4
2.1. Ortodontide Hasta İşbirliği ve Önemi.....	4
2.2. Kooperasyonun Öngörülmesinin Önemi	4
2.3. Kooperasyonun Ölçülmesinde Kullanılan Parametreler	5
2.4. Kooperasyonu Etkileyen ve Kooperasyon Ölçümü veya Tahmininde Rol Alabilecek Faktörler	5
2.4.1. Yaş, Cinsiyet ve Sosyoekonomik Durum.....	6
2.4.2. Ailenin Ortodontik Tedaviye Gösterdiği İlgi ve İstek	7
2.4.3. Bireyin Kişilik Özellikleri	8
2.4.4. Hasta-Hekim İlişkisi.....	10
2.4.5. Maloklüzyonun Hasta Psikolojisi Üzerindeki Etkisi ve Tedavi İsteği.....	11
2.5. Hasta Kooperasyonu Ölçümünde Kullanılan Yöntemler	12
2.5.1. Ortodontik Hasta Kooperasyonu Skalası (Orthodontic Patient Cooperation Scale-OHKS).....	12
2.5.2. Ortodontik Davranış Anketi (Orthodontic Attitude Survey-ODA)	13
2.5.3. Ortodontik Kontrol Odağı Skalası (Orthodontic Locus Of Control Scale- OKOS)	14
2.5.4. Klinik Kooperasyon Değerlendirmesi (Clinical Compliance Evaluation- KKD).....	15
2.5.5. Hasta-Hekim İlişkisi Değerlendirme Formu	15
2.6. Yapay Zeka ve Makine Öğrenimi	16
2.6.1. Makine Öğrenim Çeşitleri	16

2.6.2. Makine Öğrenimi Teknikler:	18
2.6.3. Öğrenme Aktarımı ve Derin Öğrenme Aktarımı (Transfer Learning)....	35
3. GEREÇ VE YÖNTEM	37
3.1. Hasta seçimi	37
3.2. Çalışma gruplarının oluşturulması	38
3.3. Gereç.....	38
3.3.1. Fotoğraflar	38
3.3.2. El Yazısı	39
3.3.3. Ses Kaydı.....	39
3.3.4. Makine Öğrenimi	40
3.4. Yöntem.....	40
3.4.1. Verilerin İşlenmesinde Kullanılan Yapay Zeka Modelleri	40
4. BULGULAR	42
4.1. Bireylere Ait Bulgular	42
4.2. Makine Öğrenimi Modellerinin Performans Değerlendirilmesi	42
4.3. Yüz Fotoğraflarını Değerlendiren Modellere Ait Bulgular	43
4.3.1. ResNet50V2 Modelin Sonuçları	43
4.3.2. ResNet101V2 Modelin Sonuçları	44
4.3.3. ResNet152V2 Modelin Sonuçları	45
4.3.4. InceptionResnetV2 Modelin Sonuçları	46
4.3.5. Xception Modelin Sonuçları.....	47
4.3.6. MobilNetV2 Modelin Sonuçları	48
4.3.7. NasNetMobil Modelin Sonuçları	49
4.3.8. DenseNet121 Modelin Sonuçları	50
4.3.9. VGG16 Modelin Sonuçları.....	51
4.4. El Yazılarını Değerlendiren Modellere Ait Bulgular	53
4.4.1. ResNet50V2 Modelin Sonuçları	53
4.4.2. ResNet101V2 Modelin Sonuçları	54
4.4.3. ResNet152V2 Modelin Sonuçları	55
4.4.4. InceptionResNetV2 Modelin Sonuçları	56
4.4.5. Xception Modelin Sonuçları.....	57
4.4.6. MobilNetV2 Modelin Sonuçları	58
4.4.7. NasNetMobil Modelin Sonuçları	59
4.4.8. DenseNet121 Modelin Sonuçları	60
4.4.9. VGG16 Modelin Sonuçları.....	61

4.5. Ses Verilerini Değerlendiren ESA Modeli ve Makine Öğrenimi Algoritmalarına Ait Bulgular	63
5. TARTIŞMA.....	64
5.1. Çalışmanın Amacı	64
5.2. Gereç ve Yöntem.....	66
5.2.1. Bireyler	66
5.2.2. Veriler.....	67
5.2.3. Yöntem	70
5.3 Bulguların Tartışılması	71
5.3.1. Fotoğraflar ile Yapılan Kooperasyon Değerlendirilmesi	71
5.3.2. Ses Verileri ile Yapılan Kooperasyon Değerlendirilmesi	75
5.3.3. El Yazısı Verileri ile Yapılan Kooperasyon Değerlendirilmesi	77
6. SONUÇLAR.....	80
7. KAYNAKLAR	81
EKLER.....	99

KISALTMALAR VE SİMGELER DİZİNİ

%	Yüzde
DÖ	Derin Öğrenme
ESA	Evrişimli Sinir Ağları
ÖSA	Özyinelemeli Sinir Ağları
OHKS	Ortodontik Hasta Kooperasyonu Skalası
ODA	Ortodontik Davranış Anketi
OKOS	Ortodontik Kontrol Odağı Skalası
KKD	Klinik Kooperasyon Değerlendirilmesi
DVM	Destek Vektör Makinesi
DDA	Doğrusal Diskriminant Analizi
KEYK	K'ya En Yakın Komşu
YSA	Yapay Sinir Ağları
VGG	Visual Geometry Group
ResNet	Residual Network
SMA	Sinir Mimarisi Araştırması
UKVHA	Uzun Kısa Vadeli Hafıza Ağları

TABLÖLER DİZİNİ

Tablo 4.1. ResNet50V2 modelin konfüzyon matrisi.....	43
Tablo 4.2. ResNet101V2 modelin konfüzyon matrisi.....	44
Tablo 4.3. ResNet152V2 modelin konfüzyon matrisi.....	45
Tablo 4.4. InceptionResnetV2 modelin konfüzyon matrisi.....	46
Tablo 4.5. Xception modelin konfüzyon matrisi	47
Tablo 4.6. MobilNetV2 modelin konfüzyon matrisi.....	48
Tablo 4.7. NasNetMobil modelin konfüzyon matrisi	49
Tablo 4.8. DenseNet121 modelin konfüzyon matrisi	50
Tablo 4.9. VGG16 modelin konfüzyon matrisi	51
Tablo 4.10. Yüz fotoğraflarını değerlendiren ESA modellerine ait bulgular	52
Tablo 4.11. ResNet50V2 modelin konfüzyon matrisi.....	53
Tablo 4.12. ResNet101V2 modelin konfüzyon matrisi.....	54
Tablo 4.13. ResNet152V2 modelin konfüzyon matrisi.....	55
Tablo 4.14. InceptionResNetV2 modelin konfüzyon matrisi.....	56
Tablo 4.15. Xception modelin konfüzyon matrisi	57
Tablo 4.16. MobilNetV2 modelin konfüzyon matrisi.....	58
Tablo 4.17. NasNetMobil modelin konfüzyon matrisi.....	59
Tablo 4.18. DenseNet121 modelin konfüzyon matrisi.....	60
Tablo 4.19. VGG16 modelin konfüzyon matrisi	61
Tablo 4.20. El yazısı verilerini değerlendiren modellere ait bulgular.....	62
Tablo 4.21. Ses verilerini değerlendiren ESA modeli (YamNet) ve makine öğrenimi algoritmalarına ait bulgular	63

ŞEKİLLER DİZİNİ

Şekil 2.1. Yapay zeka alanlarının şematik görüntüsü.....	22
Şekil 2.2.Yapay sinir ağı şematik görüntüsü (89)	23
Şekil 2.3. Biyolojik sinir ağı şematik görüntüsü (97).....	25
Şekil 2.4. Yapay sinir ağı nöronların şematik görüntüsü (89)	25
Şekil 2.5. Yapay sinir ağı katmanlarının şematik görüntüsü, girdiler(i), birinci gizli katmana geçiş yapan veriler(g), ikinci gizli katmana geçiş yapan veriler(k), çıktılar(o) (100).....	26
Şekil 2.6. İleri yayılım ve Geri Yayılımda gerçekleşen fonksiyonların şematik görüntüsü (101).....	27
Şekil 2.7.Yapay sinir ağı öğrenme fonksiyonunu oluşturan aşamalarının şematik görüntüsü, girdi(x), tahmin edilmesi gereken değer(y), ağırlık(w), ağırlığa eklenen sabit değer(b) (101).....	28
Şekil 2.8. Evrişimli sinir ağı modelinin şematik görüntüsü (104).....	29
Şekil 2.9.Havuzlama işleminin şematik görüntüsü (106)	30
Şekil 2.10. Spektogram.....	33
Şekil 2.11. (X) Giriş katmanıdır. (h) Gizli katmandır ve önceki çıktının bilgisini tutar ve tekrar kullanır. (y) Çıktı katmanıdır A, B, C, modelin çıktısını iyileştirecek parametrelerdir. (122)..	34
Şekil 3.1. Hasta kooperasyonu tahmininin tespitinde kullandığımız modeller ve algoritmaların şematik görüntüsü	40
Şekil 4.1. ResNet50V2 modelin ROC eğrisi.....	43
Şekil 4.2. ResNet101V2 modelin ROC eğrisi.....	44
Şekil 4.3. ResNet152V2 modelin ROC eğrisi.....	45

Şekil 4.4. InceptionResnetV2 modelin ROC eğrisi.....	46
Şekil 4.5. Xception modelin ROC eğrisi	47
Şekil 4.6. MobilNetV2 modelin ROC eğrisi.....	48
Şekil 4.7. NasNetMobil modelin ROC eğrisi.....	49
Şekil 4.8. DenseNet121 modelin ROC eğrisi.....	50
Şekil 4.9. VGG16 modelin ROC eğrisi	51
Şekil 4.10. ResNet50V2 modelin ROC eğrisi.....	53
Şekil 4.11. ResNet101V2 modelin ROC eğrisi.....	54
Şekil 4.12. ResNet152V2 modelin ROC eğrisi.....	55
Şekil 4.13. InceptionResNetV2 modelin ROC eğrisi	56
Şekil 4.14. Xception modelin ROC eğrisi	57
Şekil 4.15. MobilNetV2 modelin ROC eğrisi.....	58
Şekil 4.16. NasNetMobil modelin ROC eğrisi.....	59
Şekil 4.17. DenseNet121 modelin ROC eğrisi.....	60
Şekil 4.18. VGG16 modelin ROC eğrisi	61
Şekil 5. 1. Yüz portresinden psikolojik özelliklerin tanınmasına yönelik yaklaşımlar (150).....	68
Şekil 5.2. IMM veri seti örnekleri	73
Şekil 5.3. FERET veri seti örnekleri.....	74

1. GİRİŞ VE AMAÇ

Başarılı bir ortodontik tedavi çeşitli faktörlere bağlıdır. Özellikle çocuk ve ergen hastalarda, hastaların ve ebeveynlerinin işbirliği, istenen sonuçların elde edilmesinde önemli bir rol oynamaktadır. Hasta işbirliği her ortodontistin tedaviyi sürdürebilmesi için gereken en önemli faktördür. Jarabak hasta işbirliğinin ne kadar önemli olduğunu şu şekilde anlatmaktadır: “Hasta işbirliğinin yetersizliği, mükemmel tedavi planının ve iyi tasarlanmış mekaniklerin bile başarısızlığına neden olabilir.” (1).

Hastalardan tedavi boyunca randevulara düzenli olarak gelmesi, lastik ve apaceylerin kullanım prosedürüne uyması, teller ve braketlere zarar verecek sert gıdaların çiğnemesinden kaçınması ve ağız hijyeni sağlanması gibi hususlara dikkat etmesi istenmektedir (2). Bu talimatların uygulanmasındaki eksiklikler, yalnızca tedavinin ideal sonuca ulaşmasını tehlikeye sokmakla kalmaz aynı zamanda tedavinin yavaş ilerlemesine, dişler ve yumuşak doku hasarına, fazladan diş çekimine, hekim ve hasta için zaman kaybına yol açabilir ve ortodontisti daha fazla strese sokabilir (3). Bu nedenle ortodontik tedaviye başlamadan önce klinik işbirliğini değerlendirmek önemlidir.

Tedavi ilerledikçe hastaların farklı derecelerde işbirliklerinin azalması ve ortodontistler tarafından sürekli bu işbirliği artırma çabası sık görülen bir durumdur. Halbuki tedavi başlangıcında hastaların büyük bir kısmı çok istekli olup tedavi prosedürlerine uyum göstermektedirler. Bu sebeple tedavi ilerledikçe hastaların işbirliğinin azalmasına sebep olan faktörlerin neler olabileceği her zaman klinisyenlerin merak konusu olmuştur (4).

Birçok çalışmada hasta işbirliği derecesinin yaş, cinsiyet, sosyoekonomik durum, hasta ve ailesinin tedaviye karşı olan ilgisi, kişisel özellikler, hekimin hasta ile olan ilişkisi, maloklüzyonun hasta üzerindeki etkisi ve psikolojik faktörlere bağlı olduğu söylenmektedir (2,5–9).

Bir ortodontist, verilen talimatı yerine getiren, diğer bir deyişle ağız hijyenine önem veren, lastiklerini düzgün bir şekilde kullanan ve beslenme kurallarına dikkat eden hastaların tedavisinin; uyumsuz hastalara göre daha başarılı bir şekilde

ilerleyeceğinin farkında olup hastanın kooperasyon derecesini dikkate alarak tedavi planı oluşturmaktadır. Hastanın tedavi esnasında uyumlu olup olmayacağı ortodontistin deneyimlerine göre bir miktar tahmin edilebilir olsa da bu öngörünün daha bilimsel ve kabul edilir bir yöntemin olması gerekmektedir. Bundan dolayı ortodontistin hasta uyumuna uygun bir tedavi planı ve yol haritası oluşturabilmesi için tedavi sırasında hastanın göstereceği uyumun tedaviye başlamadan önce öngörebilmesi oldukça önemlidir (10).

Tedaviye başlamadan önce hastaların kooperasyon açısından ayırt edilmesi ve uyum seviyesinin belirlenmesi tedavi planının doğru ve hastaya uygun bir şekilde oluşturulmasına, doğru mekanik seçimine, tedavi hedeflerini ve tedavi sırasında oluşabilecek problemlerin tahmin edilmesine ve doğru bir çözümün seçilmesine yardımcı olacaktır (5,8,11). Bu şekilde tedavi süresinin uzaması, buna bağlı olarak ortaya çıkan yumuşak doku harabiyeti ve diş çürükleri gibi biyolojik hasarların oluşma riski ve psikolojik yan etkilerin oluşumu en aza indirilmiş olacaktır (5).

Birçok araştırma, yüz ifadeleri, konuşma ve el yazısının insan duyguları ve davranışlarıyla bir bağlantısı olduğunu göstermektedir. İnsanoğlunun bu duyguları algılama ve tanımlama yeteneği, birbirimizi anlamamızı mümkün kılmaktadır (12). Duygular, insan kişiliğinde temel bir rol oynar ve sinir-bilim veya psikoloji gibi kişilik ile ilgili bilim dallarının çalışma alanlarında önemli bir yer tutar. Daha spesifik olarak, duygular ve yüz ifadeleri arasında ırk, cinsiyet, yaş veya kültürden bağımsız olarak ilişkiler bulunduğundan, hasta davranışları ve kişiliği, yüz ifadelerinden tahmin edilebilir (13).

Günümüzde yapay zeka, insan yaşamının hemen her alanında önemli bir yer tutar hale gelmiştir. Teknolojiler insanın ihtiyaçlarına göre uyarlanır ve teknoloji ile insan arasındaki bu uyumu mümkün kılan yapay zekadır (14).

Son yıllarda yapay zeka sağlık alanında hastanın kişiliğinin analizinde ve psikolojisinin incelemesinde etkin bir biçimde kullanılmaktadır. Günümüzde bu amaçla kullanılan çeşitli yapay zeka algoritmaları insan duygularının tanımlanması ve psikolojik karakter analizi gibi hususlarda başarılı bir şekilde kullanılmaktadır (14).

Son zamanlarda, Derin Öğrenme (DÖ) adı verilen gelişmiş bir makine öğrenimi yöntemi, önemli miktarda araştırmacı ve endüstrinin dikkatini çekmektedir.

Klasik tekniklerin aksine, bu algoritma kategorisi, potansiyel olarak yüksek performans saęlayan bir mimaridir (15).

Evriřimli Sinir Aęları (ESA) ve özyinelemeli sinir aęları (ÖSA) karakter tanıma alanında çok umut verici sonuçlar ortaya koyan güçlü modellerdirler. Derin Sinir Aęları, herhangi bir özellięin açıkça tanımlanmasını gerektirmez, bunun yerine ham veriler üzerinde çalışır ve en iyi öznitelikleri üretir ve bu özniteliklere baęlı girdileri farklı sınıflara yerleřtirir (16).

Literatürde hasta işbirliğinin tedaviye başlamadan tahmin edilmesi (2,5,7–9,17,18) ve kooperasyon ölçme yöntemleri (9,19,20) ile ilgili çalışmalar mevcuttur; ancak hasta işbirliğinin yapay zeka ile öngörölmesi daha önce hiçbir arařtırmaya konu olmamıřtır.

Bu çalışmanın amacı hastanın ortodontik tedavi sırasında göstereceęi işbirliğinin tedaviye başlamadan önce yapay zeka ile tahminin mümkün olup olmadığını test etmektir.

2. GENEL BİLGİLER

2.1. Ortodontide Hasta İşbirliği ve Önemi

Hasta işbirliği, tedavi boyunca hekim ile hastanın uygun bir şekilde uyum içerisinde olması, hastanın tedavisi süresince hekim tarafından söylenen talimatların yerine getirilmesi anlamına gelmektedir. Ortodonti açısından uyumlu hasta; ağız hijyenine dikkat eden, randevularını aksatmayan, braket kırmayan, lastiklerini düzgün bir şekilde kullanan, diyetine dikkat eden ve bu sayede ortodontistin belirlediği hedefe kolay ve sorunsuz bir şekilde ulaşmayı sağlayan hasta olarak tanımlanır (21).

Ortodontik tedavi sırasında kullanılan apareye bağlı olarak farklı düzeylerde hasta işbirliğine ihtiyaç duyulur. Tedavide hastaya uygulanan sabit apareylerin ağızda kalması, kooperasyon gerektiren headgear gibi hareketli apareyler ve lastiklerin kullanımının büyük bir kısmı hastaya bağlıdır. Aynı zamanda tedavinin hızlı ve doğru bir şekilde ilerlemesi hastanın ağız hijyenine özen göstermesine, randevularına sadık kalmasına ve diyetine dikkat etmesine de bağlıdır. Bu kriterlerin herhangi biri hasta tarafından ihmal edilirse tedavi süresinin gereğinden fazla uzaması ile birlikte amaçlanan ideal oklüzyonu elde etmek zorlaşacak veya bu hedeflere ulaşılmadan tedaviye son verilecektir. Bu yüzden iyi bir sonuç elde etmek için sadece hekimin bilgisi, becerisi, deneyimi ve tedavi doğru bir şekilde planlaması yeterli olmayıp aynı zamanda hasta uyumu ve iş birliğini de göz önünde bulundurulması gerekmektedir (10,11,20).

2.2. Kooperasyonun Öngörülmesinin Önemi

Hasta kooperasyonu açısından, tedavi gören hastanın işbirliğinin arttırılabilmesi ve tedavinin sağlıklı bir şekilde ilerlemesi için ortodontistin tedaviye başlamadan önce hasta uyumunu etkileyecek faktörleri belirleyerek hasta işbirliği düzeyini öngörebilme isteği mantıklıdır (8,10). Tedavi başında hasta kooperasyonunu öngörebilecek yöntemleri geliştirerek, hastanın uyum açısından değerlendirilmesi, hedeflerin belirlenmesi, tedavi sırasında ortaya çıkabilecek problemlerin tahmin edilmesi ve bu problemlerin etkilerini azaltarak başarısızlığa uğramanın engellenmesi gibi konularda ortodontiste yardımcı olabilir (8,11).

Ortodontist tedavi öncesinden itibaren tedavinin her aşamasında bilinçli veya bilinçsiz olarak, hasta ve ailesinin genel izlenimlerini dikkate alarak hasta uyumu ve kooperasyonunu ölçmeye ve tahmin etmeye çalışır. Bir araştırmada hasta kooperasyonunu tahmin etmek için ortodontistlerin %39.0'unun hastanın genel davranışlarını değerlendirdiği, %25.0'inin çocuğun ilgisini incelediği ve %36.0'sının hastanın ailesinden elde ettikleri verileri kullandıkları bildirilmiştir (8).

2.3. Kooperasyonun Ölçülmesinde Kullanılan Parametreler

Hasta tarafından iyi bir ağız hijyenin sağlanması, apareylerin önerilen şekilde kullanımı, korunması ve uygun şekilde bakımının sağlanması, randevu tarih ve saatlerine dikkat edilmesi gibi konular kooperasyon ölçümünün ana parametrelerini oluşturmaktadırlar (5,19,22,23). Yapılan bir çalışmada bu parametrelere bağlı ölçümlerin tedavi boyunca çok fazla değişmediği ve bu ölçümlerde var olan hasta uyum düzeyinin tedavi sonuna kadar çok fazla değişkenlik göstermediği bildirilmiştir (10).

Bu objektif ölçme yöntemlerin yanında ortodontik hasta kooperasyonu skalası (OHKS) gibi bazı ölçekler kullanılarak klinik ölçümlere ek olarak ortodontistin hasta ile ilgili görüşleri alınıp hasta ve ailesinin tedaviye gösterdikleri ilgi, uyum ve sergiledikleri davranışları değerlendirilerek kooperasyon ölçümü yapılmıştır (10). Bu yöntem güvenilir bir yöntem olarak kabul edilmiş ve birçok çalışmada kullanılmıştır (2,8,10,11,17,20).

2.4. Kooperasyonu Etkileyen ve Kooperasyon Ölçümü veya Tahmininde Rol Alabilecek Faktörler

Hasta kooperasyonunu etkileyen faktörler, demografik ve psikososyal faktörler olarak iki gruba ayrılabilir. Yaş, cinsiyet ve sosyoekonomik faktörler demografik faktörlerdir. Hastanın ailesiyle olan ilişkileri, hasta ve ailesinin tedaviye karşı tutumları ve hastanın kişisel özellikleri ise psikososyal faktörler olarak adlandırılabilir. Bu faktörler hasta kooperasyonunu doğrudan etkileyebilen ve kooperasyon tahmininde kullanılabilecek faktörlerdir (8,18,24,25).

2.4.1. Yaş, Cinsiyet ve Sosyoekonomik Durum

Erişkin hastalar kendi istekleri doğrultusunda tedaviye karar verdikleri için genellikle uyumlu ve yüksek kooperasyonlu hastalardır; ancak ortodontik tedavi gören hastaların büyük bir kısmını çocuk ve genç erişkin hastalar oluşturduğu için durum biraz daha farklıdır. Bu yaş grubundaki hastalar genellikle ailelerinin istekleri üzerine tedaviye başladıklarından ve tedavi giderleri ile ilgili kaygıları olmadığından durum erişkin hastalara göre daha farklı olabilmektedir.

Allan ve ark.'nın çalışmasında kooperasyon tahmini açısından yaşın en önemli faktör olduğu bildirilmiştir (24). Yapılan bazı çalışmalarda küçük yaştaki hastaların ailelerinin isteklerini kabul etmeye meyilli oldukları için kooperasyonlarının daha yüksek olduğu bildirilmiştir; fakat diğer bazı çalışmalarda kooperasyon ile yaş arasında ilişki olmadığı savunulmaktadır (4,8,18,20,26,27); ancak ortodonti tedavi gören hasta grubunu çoğunlukla ergen yaştaki bireyler oluşturduğu için kişinin üzerindeki aile etkisinin azalması ve ergenliğe bağlı psikolojik faktörler durumu değiştirebilmektedir (8). Sonuç olarak yaş doğrudan hasta kooperasyonunu etkilemese de yaşa bağlı psikolojik değişimler kooperasyon düzeyinde değişimlere sebep olmaktadır (18).

Bazı çalışmalarda ortodontik tedavi açısından, kızların kooperasyonunun erkeklerden daha yüksek olduğu savunularak cinsiyetin kooperasyon tahmininde bir faktör olarak kullanılabilirliği ileri sürülmüştür. Kızlar, yüz estetiğine erkeklerden daha çok önem verdikleri için ortodontik tedaviye daha olumlu yaklaştıkları ve kooperasyonlarının daha iyi oldukları savunulmaktadır (7,10,20,27,28); ancak başka bir çalışmada ilginç bir şekilde kızların yüz estetikleri ile ilgili memnuniyet seviyelerinin erkeklere nazaran daha düşük olduğu tespit edilmiştir ve bu durumun kızların kooperasyon düzeyini olumsuz etkilediği bildirilmiştir (29). Bununla birlikte Howells ve Show tarafından yapılan çalışmada cinsiyet ile kooperasyon arasında bir ilişki olmadığı bildirilerek yaş ve cinsiyetin kooperasyon tahmininde güvenilir kriterler olmadığı savunulmuştur (30).

Cucalon ve Smith'in çalışmasında hastanın sosyoekonomik durumu, kooperasyonu doğrudan etkilediği gösterilmiştir (27). Bu çalışmada yüksek sosyoekonomik duruma sahip olan hastaların, düşük sosyoekonomik duruma sahip

olan hastalara göre daha uyumlu ve tedaviye daha ilgili oldukları savunulmuştur. Var olan maloklüzyonun sosyal durum üzerindeki olumsuz etkileri, yüksek sosyoekonomik düzeye sahip olan hastalar için daha önemli olduğundan tedavi uyumlarının daha yüksek olduğu düşünülmektedir (27). Nanda ve Kierl'in çalışmasında bu sonuçların tam tersi yani daha düşük sosyoekonomik duruma sahip hastaların, yüksek sosyoekonomik duruma sahip olan hastalara göre daha iyi kooperasyona sahip olduğun savunulmuştur (2). Bahsi geçen çalışmalardan da anlaşıldığı gibi sosyal, ekonomik ve kültürel altyapı etkenlerin hasta kooperasyonu üzerinde değişken etkileri mevcuttur; ancak araştırmalar arasındaki tutarsızlıkları göz önünde bulundurduğumuzda, hasta kooperasyon öngörmesi için kullanılabilecek güvenilir kriterler olmadığını da anlamaktayız (8).

2.4.2. Ailenin Ortodontik Tedaviye Gösterdiği İlgi ve İstek

Mehra ve ark. ailenin tedavi ile ilgili tutumunun hasta kooperasyon tahmininde kullanılabılır bir kriter olabileceğini öne sürmüşlerdir (9). Önceden ortodontik tedavi görmüş olan ebeveynler çocukların tedavi gereksinimlerini daha iyi anlayıp ve tedaviye daha ılımlı yaklaşmaktadırlar (1,10); ancak ailenin tedavi üzerinde olan etkisi genellikle daha küçük yaştaki hastalar baskın olmaktadır ve hastanın yaşının ilerlemesine bağlı psikolojik değişiklikler bu olumlu etkinin azalmasına sebep olabilmektedir (9,10,18).

Kreit ve ark.'nın çalışmasında aile isteği üzerine tedaviye başlayan hastaların tedavi boyunca kooperasyonlarının iyi olduğu vurgulanmıştır. Bununla birlikte uyumsuz olan bireylerin aile ilişkilerinin de çok zayıf olduğu belirtilmiştir (31). Diğer bir çalışmada ailenin tedaviyle ilgili tutumlarının, tedavinin seyrini ve hasta kooperasyonunu olumsuz etkilediğini savunulmuştur. Ailenin tedaviye istekli olduğu durumlarda genç erişkin hastaların daha düşük kooperasyon gösterdikleri ve ailenin tedaviye ılımlı yaklaşmadığı durumlarda ise hastaların kooperasyonunun yüksek olduğu belirtilmiştir (18). Bu durum genç erişkin hastaların özgürlük ve bağımsızlık duygusunun daha baskın olmasıyla ilişkilendirilmektedir.

2.4.3. Bireyin Kişilik Özellikleri

Ortodontik tedavide hasta kooperasyonu üzerinde kişisel özelliklerin etkisi olduğu düşünüldüğü için bir takım psikolojik testlerin yapılması ve bu testlerin başarılı olup olmayacağı araştırılmıştır (9,25). Yapılan bu çalışmalarda bazı kişisel özelliklerin kooperasyon üzerinde etkisi olabileceği gösterilmiştir. Bu özelliklerin etkisini anlayabilmek için çeşitli psikolojik testler yapılmıştır; ancak orta düzeyde bir başarıya ulaşıldığı için kooperasyon tahmininde güvenilir bir yöntem olmadığı sonucuna varılmıştır (9,25).

Kooperasyon öngörüsünü daha kantitatif yöntemler ile araştırdığımızda özellikle davranış bilimleri ile karşılaşmaktayız. Davranış analizi ve psikolojisi, ortodonti klinik uygulamasında iki temel başlık altında değerlendirilebilir. Birinci başlık ortodontinin sosyal psikolojisi olarak adlandırılabilir ve bu başlık altında hastanın neden tedavi olmak istediği ve tedavinin psikososyal etkileri gibi alanları incelemektedir. İkinci başlık ise ortodontik motivasyon psikolojisi olarak isimlendirilebilir. Bu alanda hasta motivasyonu ve uyumunu arttırmak gibi konu başlıkları incelenmektedir (32).

Kişilik özelliklerinin kooperasyon üzerine olan etkilerini araştıran farklı çalışmalar mevcuttur. Örneğin Kişilik özelliklerin kooperasyon üzerindeki etkisini araştıran bir çalışmada “Sıfat Kontrol Listesi” (Adjective Check List) testi kullanılarak 30 hastanın kişilik özellikleri analiz edilmiştir. Bu testin sonucuna göre, dışa dönük, sorumluluk sahibi, enerjik, kararlı, özgüvenli gibi özelliklere sahip hastalar yüksek kooperasyona sahip oldukları ve sorumsuz, sabırsız, ilgisiz, inatçı, sinirli hastaların ise daha düşük kooperasyona sahip oldukları bildirilmiştir (24).

Kreit ve ark. 120 diş hekimi tarafından toplam 1386 hastaya uygulanan kişilik testi ile kötü kooperasyona sahip olan hastaların kişilik özelliklerini saptamaya çalışmışlardır. Bu çalışmada kötü kooperasyona sahip olan hastaların en dikkat çekici özelliği, ebeveynler ile problemlili ilişkiye sahip olması olarak belirtilmiştir (31); ancak bu çalışma sonucunun aksine Nanda ve Kierl’in çalışmasında genç erişkin hastaların aile ilişkilerinin kooperasyon üzerinde önemli etkiye sahip olmadığı savunularak, aile ilişkileri güçlü olan genç erişkin hastaların aile isteklerine daha çok önem verdikleri

ve aileye daha az bağı olan genç erişkin hastalar ise daha çok arkadaşlarının fikirlerine ve onayına önem verdikleri sonucuna ulaşmışlardır (2).

El-Mangoury'nin yaptığı bir çalışmada, birçok ortodontistin tedavi öncesi mevcut olan ağız hijyenini bir kooperasyon öngörü aracı olarak kullandıklarını; ancak bu uygulamanın herhangi bir bilimsel dayanak oluşturmadığını bildirerek bu şekilde yapılan bir kooperasyon tahmininin güvenilirlik ve geçerliliğinin düşük olacağını vurgulamıştır (5).

Hasta ve ailesinin psikolojik karakterlerini incelemekte olan bir çalışmada ebeveynler için Sosyal Arzu Edilirlik Skalası ve hastalar için Kişilik Araştırma Formu testleri uygulanmıştır. Bu çalışmada kişilik özelliklerinin hasta kooperasyon öngörüsünde kullanılabilir oldukları bildirmiştir (33).

Kooperasyonun tahmin edilmesi amaçlanan bazı çalışmalarda hastanın kişilik özellikleri ile hasta kooperasyonu arasında ilişki olmadığı bildirilmiştir (2,34). Nanda ve Kierl'in çalışmalarında Ortodontik Davranış Anketi, Sosyal Arzu Edilirlik skalası (Marlowe), Kişilik araştırma formu (Jackson) ve OHKS anketlerini kullanılmıştır. Bu testler yaşları 9 ile 16 yıl arası olan toplam 100 hasta ve 131 ebeveyne uygulanmıştır (3). Çalışmada elde edilen veriler incelendiğinde, hastaların cinsiyeti, tek bir ebeveyn veya her iki ebeveyn ile birlikte yaşıyor olmaları ve bunlara bağlı ortaya çıkan kişilik özelliklerinin, kooperasyon üzerine etkisi olmadığı ve kooperasyon tahmini amacıyla tedavi öncesi yapılan kişilik testlerinin güvenilir olmadıkları belirtilmiştir.

Albino ve ark.'nın yaptığı bir çalışmada hasta ve ailesine ortodontik davranış inceleme anketi (Orthodontic Attitude Survey) ve ortodontik kontrol odağı skalası (Orthodontic Locus of Control Scale) testleriyle birlikte genel kişilik testleri uygulanmıştır (11). Çalışma sonucuna göre ailenin tedaviyle ilgili tutumunun kooperasyon üzerinde etkili olduğu bildirilmiştir. Buna ek olarak ortodontik tedaviye daha olumlu yaklaşan, oklüzyonlarına bağlı estetik kaygıları olan ve oklüzal estetiğin fasiyal çekicilik üzerindeki etkisini yüksek bulan hastaların kooperasyonunun daha yüksek olduğu rapor edilmiştir.

Kontrol odağı skalası birkaç çalışmada kullanılmıştır (2,35); ancak bu test sağlık bilimlerinde hastaların genel davranışlarını değerlendirmede başarılı olsa da ortodonti hastalarının tedaviye karşı psikososyal yanıtının değerlendirmesinde

yeterince başarılı olmamıştır. Bundan dolayı bu yöntemin güvenilirlik ve verimliliğini arttırmak için bazı girişimler yapılmıştır (35).

Ortodontide hasta kooperasyonu tahmininde kişilik özelliklerin değerlendirilmesi için kullanılan psikolojik testler yeterince başarılı olmamıştır. Bunun sebebi, günümüze kadar ortodonti hastalarına özel psikolojik testlerin geliştirilmemiş olması düşünülmektedir (2).

2.4.4. Hasta-Hekim İlişkisi

Hasta-hekim ilişkisi, ortodontik tedavinin başarılı sonuca ulaşmasında rol oynayan en önemli unsurlardan biridir. Yapılan bir çalışmada hekimin hasta ile olan ilişkisinin, kooperasyon seviyesini belirleyecek en önemli etken olduğu bildirmiştir (36). Aynı konuda benzer sonuç bildiren çok sayıda araştırma mevcuttur (26,37–40).

Bu konuyla ilgili Nanda ve Kierl'in çalışmasında hasta-hekim ilişkisinin hasta kooperasyonunu etkileyen önemli bir faktör olduğu ve bu ilişkiyi değerlendiren çalışmalara yönelmeyi, hasta-hekim ilişkisinin tedavi sürecini nasıl etkileyeceği ve bu ilişkiyi nasıl yeterli bir seviyeye getirilebileceği makalelere daha çok önem verilmesi gerektiği vurgulanmıştır. Sonuç olarak bu ilişkinin güçlenmesi hasta kooperasyonunu olumlu etkileyeceği bildirmiştir (9).

Günümüzde hasta-hekim ilişkisi daha çok önem kazanmaktadır. Ortodontistin hastasıyla bağ oluşturabilmesi için zaman harcaması gerekmektedir ve bu bağı oluşturabilmenin en önemli araçları, dinleme, empati kurma ve tedavi ile yapılacak olan işlemler hakkında açıklama yapılması gibi davranışlardır. Yapılan bir çalışmada hastaya özgüvenli, arkadaşça ve sabırlı yaklaşımın hastalar üzerinde etkili olduğunu bildirilmiştir (34).

Tedavi başında hasta ile ilişki kurabilmek için harcanan zaman, tedavi sırasında bu ilişkinin kurulmamasından kaynaklanan zaman kaybından daha az olacaktır. Hekimin hastası ile iyi ilişkiler kurduktan sonra hastanın hekime güveni artacak ve önerilerini dikkate alacaktır. Bu da hastanın tedaviye özen göstermesine ve tedavi boyunca kooperasyonun yüksek olmasını sağlayacaktır. Bazı çalışmalarda ise ortodontistlerin hastalar ile iyi ilişkiler kurma konusunda eğitim almaları ve hastalara yapıcı eleştirilerde bulunmaları gerektiğine vurgu yapılmıştır (38,39).

Ortodontist ile hasta arasında, hekim hasta ilişkisi ile birlikte öğrenci öğretmen ilişkisi de kurulmalıdır. Ortodontist tedavi boyunca yapılması ve yapılmaması gerekenleri hastaya listeleme yerine, başarılı sonuca ulaşabilmesi ve hasta kooperasyonunu arttırabilmesi için bunları hastaya öğretmeyi ve motivasyonunu arttırmayı denerse daha başarılı olacaktır (32).

Hasta-hekim ilişkisinin iyi olması tedavi bitimindeki hasta memnuniyeti üzerinde de etkili olmaktadır. Bu yüzden ortodontistin sadece hasta uyumu üzerine odaklanması yerine, hasta-hekim ilişkisini iyileştirmeye ve geliştirmeye odaklanması planlanan tedavi amacına ulaşmasını sağlayacaktır (41).

Ortodontistin tedaviye gösterdiği ilgi ile birlikte hastanın duygularına ve kişiliğine de ilgi göstermelidir. Bu hastanın güvenini kazanmaya kendisine saygı duyulduğunu hissetmesini sağlayacaktır. Ortodontistin bu davranışı hasta kooperasyonunun artmasında ve istenilen tedavi sonuçların elde edilmesinde önemli rol oynamaktadır (19,32). Ortodontist, hastaya zaman ayırdığını, onu gerçekten dinlediğini ve isteklerine önem gösterdiğini doğru davranışlarla hastaya yansıtabilirse hastanın kooperasyon düzeyinin artmasını sağlayabilir (42).

2.4.5. Maloklüzyonun Hasta Psikolojisi Üzerindeki Etkisi ve Tedavi İsteği

Birçok hasta için ortodontik tedavinin psikolojik getirileri sağlık ve fonksiyonun iyileşmesinden daha önemli olabilir. Hastada var olan maloklüzyonu kendisi ve çevresindeki insanların nasıl algıladığı ortodontik tedavi planlaması açısından çok önemlidir. Aynı miktarda maloklüzyona sahip olan bireylerin bir kısmı bu sapmaları tolere edebilirken diğerleri için bu durum tolere edilemezdir. Bazıları orta derecedeki maloklüzyonu fark etmelerine rağmen onlar için bu durum önemli olmayabilir. Bazıları da az miktardaki maloklüzyonu büyük problem haline getirip sürekli memnuniyetsizliklerini beyan ederler (43). Buradan anlaşıldığı gibi hasta tarafından algılanan maloklüzyon gerçekte var olan maloklüzyon şiddetinden daha kritiktir. Gerçek şu ki dişsel görünüm kişinin hayat kalitesini etkilemektedir ve birçok hasta hayat kalitesini iyileştirmek amacıyla ortodontik tedaviye başlamaktadır (32).

Hastanın tedaviye ihtiyacı olup olmadığı kararının sadece uzman görüşüne bağlı olmadığı, hastanın kendi estetik beklentileri ve sosyal ortamının da bu kararda etkili olduğunu biliyoruz (44). Yapılan bir çalışmada 861 hastanın %64.0'üne

ortodontik tedavi ihtiyacı var teşhisi konulmasına rağmen hastaların hiçbir tedavi talebinde bulunmadıkları bildirilmiştir (45).

Sonuç olarak hastanın maloklüzyonu algılama biçimi ve istekleri gerçek maloklüzyona göre daha önemlidir (26). Ortodontist ilk muayenede hastalardan “dişlerin ile ilgili şikayetin nedir?” veya “dişlerin ile ilgili seni en çok rahatsız eden kısım nedir?” sorularını sormak, maloklüzyon şiddetini hastaya sormak veya anlatmaktan daha uygun olacaktır (21). Ortodontistler bu şekilde hastanın maloklüzyonu nasıl algıladığını ve tedaviden beklentilerini öğrenmiş olur ve ona göre bir tedavi planlaması yapabilirler.

Mehra ve ark.’nın çalışmasında hastanın tedaviden beklentisi, maloklüzyon ve yüz estetiği ile ilgili endişesi kooperasyon değerlendirmede en önemli on madde içerisinde yer aldığı ve bu faktörler hasta kooperasyonunu belirgin bir şekilde etkilediği bildirilmiştir (9).

2.5. Hasta Kooperasyonu Ölçümünde Kullanılan Yöntemler

Hasta kooperasyonu tahminine yönelik yapılan birçok çalışmada çeşitli yöntemler uygulanarak kooperasyonu etkileyen faktörler incelenmiştir; fakat bu yöntemlerin sadece birkaçının güvenilirliği kanıtlanmıştır (10).

2.5.1. Ortodontik Hasta Kooperasyonu Skalası (Orthodontic Patient Cooperation Scale-OHKS)

Slakter ve ark. 1980 yılında ortodontik tedavi gören hastaların kooperasyonunu ölçme amacıyla bu skalayı hazırlamışlardır (10). Bu skala, hastaların kooperasyon değerlendirmesinde sıklıkla göz önünde bulundurulmuş hasta davranışlarını içeren 10 maddeden oluşmaktadır. Her madde için düşük işbirliği ile yüksek işbirliği arasında 4 seçenek sunulmuş ve bu seçenekler 10-40 arası puanlanmıştır. Elde edilen toplam puana göre hasta kooperasyon seviyesi belirlenmiştir. Bu metot, kırk beş genç erişkin hastanın incelenmesi amacıyla kendi ortodontistleri tarafından tedavinin ikinci ve altıncı aylarında uygulanmıştır. Belirlenen periodlarda yapılan bu değerlendirmelerde benzer uyum skorları elde edilmiştir. Sonuç olarak OHKS’nin hasta kooperasyonu ölçme ve öngörmede kullanımı için uygun olduğu sonucuna varılmıştır. OHKS birçok

çalışmada kooperasyon ölçme ve öngörme amacıyla kullanılmış ve elde edilen sonuçlara göre bu yöntemin güvenilir olduğu teyit edilmiştir (2,17,18,20,46–48).

Albino ve ark. 39 ergen hastanın kooperasyonunu değerlendirmek amacıyla tedavinin 8.ay, 10.ay ve tedavi bitiminde OHKS kullanarak hasta kooperasyonunu etkileyen faktörleri araştırmışlardır. Elde edilen skorlara göre tedavinin başlarında, ebeveynlerin tutumu işbirliğinin en belirgin etkeni olarak belirlenmiştir; ancak aktif tedavinin sonunda, ergen hastaların kendi psikososyal durumları, kooperasyonda en önemli belirleyici olduğu sonucuna varılmıştır (18).

Nanda ve ark.’nın benzer bir çalışmasında 100 ergen hastanın davranışları incelenerek kooperasyonun tahmin edilebilirliğini araştırılmıştır. OHKS bu hastaları tedavi eden ortodontistler tarafından tedavinin 2. ve 6. aylarında doldurulmuştur. Araştırma sonucunda hasta kooperasyonunun tahmin edilmesinin zor olduğuna vurgu yapılmıştır. Ayrıca kooperasyon üzerinde en etkili olan faktör hasta-hekim ilişkisi olarak belirlenmiştir (2).

Ödül sisteminin kooperasyon üzerindeki etkisini araştıran bir çalışmada kooperasyon değerlendirmesi için tedavinin 6. ve 12. aylarında OHKS uygulanmıştır. Puanlamaya göre ortalamanın üstünde kalan hastalar uyumlu, ortalamanın altındakiler ise uyumsuz olarak kabul edilmiştir. Ortodontistin önerilerini yerine getiren hastalar ödüllendirilerek kooperasyon düzeyinin iyileştirilmesi amaçlanmıştır. Araştırmacılar ödüllendirme sisteminin, ortalama altında kalan hastaları motive etmeye yardımcı olduğu sonucuna varmışlardır (20).

2.5.2. Ortodontik Davranış Anketi (Orthodontic Attitude Survey-ODA)

Gerçek maloklüzyon ve estetik, insanlar tarafından farklı yorumlandığı için tedaviden istekleri ve beklentileri farklı olmaktadır. Bu değişken algıyı etkileyen faktörleri belirlemek için bazı bilimsel ve güvenilir çalışmalar yapılmıştır (49).

Geçmişte doğrudan hastaya sorulan sorularla etken faktörler değerlendirilmeye çalışılırken zaman geçtikçe daha tekrarlanabilir ve güvenilir yöntemler ile incelenmeye çalışılmıştır. “Ortodontik tedavi isteği” ve “kritik vaka tekniği” bu yöntemlerden bazılarıdır (49,50).

Albino ve ark. ilk olarak 1981 yılında yaptıkları çalışmada ODA yöntemini kullanmışlardır (33). Daha sonra Fox ve ark. 1982’de yaptıkları bir çalışmada bu yöntemin güvenilirliğini test etmişlerdir (51).

ODA ile hasta ve aile için farklı sorular içeren anketler kullanılarak maloklüzyon ve tedavisiyle ilgili detaylı ölçümler yapılmaktadır (33,51). Lewit ve Virolainen’in görüşlerinden yararlanarak geliştirilen ODA, hastaların maloklüzyonlarını, tedaviyle ilgili tutumlarını, beklenti ve isteklerini güvenilir bir şekilde değerlendirmek için geliştirilmiştir. Yirmi altı maddeden ve beş ana başlıktan oluşan bu anketin kooperasyonun öngörülmesi ve tedavinin psikososyal durum üzerindeki etkilerini değerlendirmede yararlı olduğu ifade edilmiştir (51).

Literatür incelendiğinde kooperasyon değerlendirme amacıyla yapılan birçok araştırmada ODA kullanılmıştır (2,18,33,46–48).

2.5.3. Ortodontik Kontrol Odağı Skalası (Orthodontic Locus Of Control Scale-OKOS)

Kontrol odağı; davranışların bilişsel sebeplerini araştırmakla ilgili bir kavramdır. Bir insanın, olayların meydana geliş biçiminin belirlenme sebebinin kendi davranışları, diğer insanların etkisi veya şans eseri olduğu inanışına “kontrol odağı” denilmektedir. Olayların belirlenmesinde kendi davranışlarının etken olduğunu düşünen bireyin iç kontrol odağına, diğer durumda ise dış kontrol odağına inandığı bilinmektedir (52).

Rotter’in tanıttığı bu analiz yöntemi birçok çalışmada kullanılmıştır. Daha sonra sağlık kontrol odağı olarak geliştirilmiştir; ancak geleneksel yöntemle göre güvenilirliğinin daha düşük olduğu söylenmektedir (52).

Sağlık alanlarında kullanılan bu davranış analizi, yapılan değerlendirmelerde başarılı olmasına rağmen maloklüzyon ile ilişkili psikososyal cevabın ölçümünde yetersiz kalmaktadır. Bundan dolayı Tedesko ve ark. Ortodonti hastalarına uyarlanmış özel bir OKOS geliştirilmişler (35).

OKOS, 37 sorudan ve altı seçenekli likert tipi cevaplama sisteminden oluşan bir ankettir. Bu anketle hastanın tedaviyle ilgili sorumluluklarını dış veya iç etkenlere bağlama derecesi ölçülmektedir. Bu test, kendisi (içsel) şans (dışsal), aile (dışsal) ve

başkaları (dışsal) olmak üzere hissedilen kontrolün dört kaynağını değerlendirmektedir. Skor bu dört kaynaktan hangisinde en yüksek ise hastanın o yönde eğiliminin olduğu söylenilebilir (18,35).

Araştırmacılar kontrol odağının kooperasyon ile ilişki olabileceğini düşünerek bazı çalışmalarda kooperasyonun öngörülmesi amacıyla OKOS kullanmışlar (24). Elde edilen sonuçların tutarlılığı yüksek olmamasına rağmen bu anketin kooperasyon ölçümünde yardımcı olabileceği düşünülmektedir. OKOS ile kooperasyon değerlendirilmesi yapılan çalışmaların sonucuna göre içsel kontrol odağıyla tedaviye başlayan bireylerin kooperasyon düzeyinin daha yüksek olduğu bildirilmiştir (5,8,18).

İçsel kontrol odağı ile yönlendirilen bireyler çevreleriyle daha iyi ilişki kurabilir, kendi davranışları ve oluşan sonuçlar arasındaki ilişkiyi daha rahat algılayabilmektedirler (5). Dışsal kontrol odağı ile yönlendirilen bireyler ise ortaya çıkan sonuçlarda kendilerini etkisiz bulup şans, aile veya başka insanların etkili olduğunu düşünmektedirler.

2.5.4. Klinik Kooperasyon Değerlendirmesi (Clinical Compliance Evaluation-KKD)

Klinik kooperasyon değerlendirmesinde nicel verilerin toplanması ve incelenen faktörler ile ilgili daha objektif verilerin elde edilmesi amacıyla geliştirilen bir yöntemdir (20). Bu değerlendirme formu ağız hijyeni, randevu takibi, aparey kullanım ve aparey bakımı olarak 4 ana başlıktan oluşmaktadır. Her başlık ise puanlama sistemine eşit miktarda katkı sağlamaktadır.

Nanda ve Kierl'in 1992'de ve Richter, Nanda 1998 yılında yaptıkları çalışmalarda OHKS ile birlikte KKD kullanarak kooperasyonu etkileyen faktörleri incelemeye çalışmışlardır (2,20).

2.5.5. Hasta-Hekim İlişkisi Değerlendirme Formu

Nanda ve Kierl'in, hasta kooperasyonunu değerlendirme amacıyla yaptıkları çalışmada, hasta-hekim ilişkisinin kooperasyon üzerindeki etkisi araştırılmış. Hastayı tedavi etmekte olan ortodontist ile ilgili sorulardan oluşan bu form hasta tarafından doldurularak hasta ve hekim arasındaki mevcut ilişki değerlendirilmiştir (2).

2.6. Yapay Zeka ve Makine Öğrenimi

Son yıllarda çok sayıda yapay zeka tanımları ortaya çıkmış olsa da, John McCarthy yapay zekayı "akıllı bilgisayar programları yapmak" olarak tanımlamaktadır. Bu, insan zekasını bilgisayarlara aktarmak olarak da tanımlanabilmektedir; ancak yapay zekanın biyolojik limitasyonlarla sınırlanması gerekmez (53).

En basit haliyle yapay zeka, bilgisayar bilimi ve veri setlerini birleştirerek problemi çözebilen bir yapı olarak tanımlanabilmektedir. Yapay zeka günümüzde sürekli bahsedilen makine öğrenimi ve derin öğrenme alanlarını da içermektedir. Bu disiplinler, veri setlerini işleyen ve elde ettiği bilgiler arasında ilişkiler kurarak sınıflandırmalar veya tahminler yapan yapay zeka algoritmalarından oluşmaktadır (54).

2.6.1. Makine Öğrenim Çeşitleri

Makine öğrenimi, planlanan hedefe göre aşağıda bahsedilen 4 ana başlığa ayrılabilir.

2.6.1.1. Denetimli Öğrenme

Denetimli öğrenmede veri seti, algoritmanın hangi sonuca ulaşacağına rehberlik etmektedir. Başka bir deyişle etiketli verileri ve bu verilerin işlenmesiyle ortaya çıkan sonuçları makineye tanıtarak bir fonksiyon üretilmesini sağlamaktadır. Böylece makine veriler arasındaki ilişkiyi öğrenerek sınıflandırma ve regresyon problemlerini doğru şekilde çözümlenmektedir (55,56).

Sınıflandırma, farklı kategorik gruplara ayrılabilen verilerin hangi gruba ait olduğunu tahmin etmek anlamına gelen bir kavramdır. Eşyalar veya hayvanların kategorize edilmesi, farklı seslerin gruplandırılması ve hava durumunun belirlenmesi gibi durumlarda kullanılmaktadır (55).

Regresyon, sonuçların tek bir çıktı şeklinde sürekli tahmin edilmeye çalışılması ve bu çıktının, girdilerin özelliklerine göre sürekli değişebilmesi şeklinde olmaktadır.

Fotoğraf üzerinden bireyin yaş tahmini veya vücut özelliklerine göre karakter analizi gibi durumlarda kullanılmaktadır (55,57).

Özet olarak; denetimli öğrenme, çıktı ile girdi özellikleri arasındaki ilişkilerden model oluşturup etiketli veri setlerinden öğrendiği ilişkileri kullanarak yeni veriler için çıktı değerlerini tahmin etmeye çalışmaktadır (58).

2.6.1.2. Denetimli Öğrenme

Denetimsiz öğrenme, bazı uzmanlara göre gerçek yapay zeka ile daha yakından bağlantılıdır. Bu yaklaşımda bir makinenin insanlar tarafından denetlenmeden karmaşık süreçleri ve kalıpları tanımlayabilmesi sağlanmaktadır (59). Oluşturulan modelin yapısı, öğrenmesi için bağımsız çalışmasına izin verilmektedir. Denetimsiz öğrenme algoritmaları, denetimli öğrenme algoritmalarına göre daha güçlüdürler ve karmaşık görevleri başarılı bir şekilde yerine getirebilmektedirler (55,60).

2.6.1.3. Yarı Denetimli Öğrenme

Denetimli ve denetimsiz öğrenmelerin birleşiminden oluşmaktadır. Bu yöntemde etiketlenmiş verilerin yanında etiketlenmemiş veriler kullanılır ve algoritmalar bu verileri tanımlamaya çalışır (61). Bu iki yöntemin birleşimi modelin doğruluğunu iyileştirilebileceği ve aynı zamanda onu oluştururken zamandan ve paradan tasarruf edilebileceği sonucuna götürür. Yarı denetimli ses tanımada veya genetik sıralama gibi alanlarda kullanılabilmektedir (62).

2.6.1.4. Güçlendirilmiş Öğrenme

Güçlendirilmiş öğrenmede algoritmalar deneme-yanılma yoluyla çalışarak amaçlanan işlevi en üst düzeyde yerine getirmeye çalışmaktadırlar. Algoritmaların deneyimleri arttıkça performansları genellikle artmaktadır. Bu sistemde algoritmaların karar sonuçları ceza veya ödül şeklinde geri bildirimler aldıklarından dolayı performansları periyodik olarak iyileşebilmektedir (63). Genellikle bu yöntem navigasyon uygulamalarında, bilgisayar oyunlarında ve robotik alanlarında kullanılmaktadır (64).

2.6.2. Makine Öğrenimi Teknikler:

Makine öğrenimi uygulamasının başlangıcından günümüze birçok teknik ortaya çıkmıştır. Bu yazıda güncel ve en fazla kullanılan teknikler tartışılacaktır.

2.6.2.1. Destek Vektör Makinesi (DVM)

Destek vektör makinesi, esas olarak regresyon ve sınıflandırma zorluklarını ele alan denetimli bir makine öğrenimi tekniğidir. Sınıflandırma durumunda, her veri ögesi uzayda noktalar olarak çizilir, her özelliğin değeri belirli bir koordinattan alınmaktadır (65). Daha sonra, sınıfları ayırmak için hiper düzlem olarak adlandırılan bir doğru çizilmektedir. Bu doğrunun çizildiği yer ise sınıf üyelerine en uzak olan yer olmalıdır. İki grubu ayırmak için birçok düzlem çizilebilir ancak DVM, her iki grup arasındaki en fazla aralığı yakalayan düzlemi tercih etmektedir. Gruplar arasındaki bu mesafe ne kadar fazla olursa başarı oranı o kadar artacaktır. DVM, iki sınıfı en iyi şekilde ayıran bir sınır olarak da tanımlanabilmektedir (66,67).

2.6.2.2. Karar Ağacı ve Rastgele Orman

Karar ağaçları (decision trees), modelleri eğitmek için etiketli girdi ve çıktı veri setlerinden yararlanan denetimli makine öğreniminde kullanılan bir yaklaşımdır. Bu teknik, esas olarak, sınıflandırma problemlerini çözmek için kullanılır (68,69). Karar ağaçları, belirli bir sonuca yönelik farklı kararları veya çözümleri eşleştirmeye yardımcı olan bir tahmine dayalı modelleme biçimidir. Karar ağacı “node” olarak tanımlanan farklı düğümlerden oluşur. Kök düğüm, genellikle makine öğrenimi içindeki ana veri seti olan karar ağacının başlangıcıdır. Yaprak düğümler, bir dalın uç noktası veya bir dizi kararın nihai çıktısıdır. Karar ağacı bir yaprak düğümden (leaf node) daha fazla dallanmaz. Makine öğrenimindeki karar ağaçları, girdi özellikleri analiz edilerek çıktıları tahmin edilen regresyon problemlerinde de kullanılmaktadır (67).

Rastgele orman (Random Forest), daha doğru bir tahmin için bir araya getirilen birden çok karar ağacından oluşmaktadır. Rastgele orman algoritmasının arkasındaki mantık, birbiriyle ilişkili olmayan bireysel karar ağaçlarının grup halinde daha iyi performans göstermesidir (70). Sınıflandırma için rastgele orman kullanıldığında, her ağaç bir sınıflandırmaya "oy" verir. Orman, “oyların” çoğunluğu ile sınıflandırmayı

seer. Regresyon iin rastgele orman kullanıldığında, orman tm aaların ıktılarının ortalamasını almaktadır (71). Buradaki anahtar, bireysel modeller arasında, yani daha byk rastgele orman modelini oluřturan karar aaları arasında dřk (veya hi) korelasyon olmaması gereėine dayanmaktadır. Bireysel karar aaları hatalar retebilirken, topluluk halindeki aalar yani ormanlar daha doėru sonular elde etmektedirler (71).

Saėlık hizmetlerinde Rastgele Orman; hastalıkları tanımlamak, bir hastanın tıbbi gemiřinin analizi, bir ilataki bileřenlerin doėru kombinasyonunu belirlemek veya ila duyarlılıėını tahmin etmek gibi alanlarda kullanılmaktadır.

2.6.2.3. K'ya En Yakın Komřu (K-Nearest Neighbors-KEYK)

K'ya en yakın komřu (KEYK) algoritması denetimli ėrenme tekniėine dayalı, sınıflandırma ve regresyon problemlerin özmnde kullanılan basit ve kullanışlı bir makine ėrenimi algoritmasıdır (72).

Henz sınıflandırılmamış verinin, veri setindeki diėer verilerle karřılařtırılarak bir uzaklık lm yapılır ve hesaplanan uzaklıėa gre en ideal sınıfa atanır. Elbette ki tekrarlanan bu sınırlayıcı algoritmik özm, iřlem srecinin uzamasına neden olmaktadır. Bundan dolayı literatrde Tembel ėrenci Algoritması olarak da tanıtılmaktadır (73).

2.6.2.4. Lojistik Regresyon

Lojistik regresyon, tahmine dayalı bir analiz algoritmasıdır ve olasılık kavramına dayanmaktadır. Doėrusal sınıflandırma problemlerinde yaygın bir biimde kullanılır. Regresyon denilmesine raėmen burada bir sınıflandırma sz konusudur. Lojistik regresyon, bir sonucu belirleyen bir veya daha fazla baėımsız deėiřken bulunan bir veri kmesini analiz etmek iin kullanılan istatistiksel bir yntemdir ve daha ok ikili sınıflandırma problemleri iin bařvurulan yntemdir (74).

2.6.2.5. Naive Bayes Sınıflandırıcı

Naive Bayes algoritması, adını matematikçi Thomas Bayes'den alan bir sınıflandırma algoritmasıdır. Naive Bayes sınıflandırması olasılık ilkelerine göre tanımlanmış bir dizi hesaplama ile sisteme sunulan verilerin sınıfını tespit etmeyi amaçlar. Naive Bayes sınıflandırmasında sisteme belirli bir oranda öğretilmiş veri sunulur. Öğretim için sunulan verilerin mutlaka bir sınıfı bulunmalıdır. Öğretilmiş veriler üzerinde yapılan olasılık işlemler sonucu elde edilen değerler ile sisteme sunulan yeni veriler işlenir ve hangi kategoriye ait oldukları tespit edilir. Sisteme sunulan öğretilmiş veri sayısı ne kadar artarsa yeni verilerin gerçek sınıflarının tespit edilmesi o kadar kesin olabilmektedir.

Gaussian Naive Bayes sınıflandırıcı Naive Bayes ailesine ait bir sınıflandırıcıdır. Gaussian Naive Bayes kabul edilebilir doğruluk seviyesine sahip olan, çok iyi çalışan hızlı ve basit bir sınıflandırma tekniğidir. Bu algoritmanın tipik uygulamaları, belgelerin sınıflandırılması, istenmeyen e-postaların filtrelenmesi veya tahmini gibi alanlardır (75).

2.6.2.6. Doğrusal Diskriminant Analizi (DDA)

Doğrusal diskriminant analizi veya kısaca DDA, denetimli öğrenme tekniğine dayalı bir sınıflandırma algoritmasıdır. Sınıf etiketine göre girdilerin ortalama ve standart sapma gibi istatistiklerini hesaplayarak çalışmaktadır. Bu istatistikler, eğitim verilerinden öğrenilen bilgileri temsil etmektedir. Girdilerden elde edilen istatistik değerlere göre bir girdinin bir sınıfa ait olma olasılığı tahmin edilir ve en büyük olasılıkla sonuçlanan sınıfa atanır (76).

2.6.2.7. AdaBoosting ve Gradyan Artırma Sınıflandırıcılar

Boosting (Arttırma), birçok zayıf öğreniciyi (weak learner) bir araya getirerek bir güçlü öğrenici (strong learner) oluşturmaktır. Birçok boosting metodunun temel yaklaşımı, tahmin edicileri kümülatif olarak eğitmektir. Genelde tahmin edici model olarak karar ağaçları kullanılır. Her ağaç orijinal bir veri kümesinin değiştirilmiş bir versiyonu ile eğitilir ve sonunda güçlü bir sınıflandırıcı oluşturulur. AdaBoost (1995, Y. Freund), Gradient Boosting (2001, Friedman) en sık kullanılan boosting modelleridir (77).

AsaBoosting: Bu modelde eğitim kümesi önce bir zayıf öğrenici ile eğitilir. Eğitim sonrası yanlış olarak tahminlenen örnekler bu algoritma için önemlidir. Bir sonraki eğitimde ilk tahminlemede yanlış öğrenilen eğitim verilerine daha fazla öncelik verilerek model tekrar eğitilir. Bu şekilde zayıf öğrenici çıkışı diğer öğreniciye giriş olacak şekilde eğitilerek devam edilir ve en sonunda sonuçlar birleştirilerek nihai karar sınırları oluşturulur.

Gradyan artırma sınıflandırıcılar birleştirilmiş AdaBoosting sınıflandırıcılardır. Gradyan artırma sınıflandırıcılarının amacı, eğitim örneğinin gerçek sınıf değeri ile tahmin edilen sınıf değeri arasındaki kaybı veya farkı en aza indirmektir (75).

2.6.2.8. Aşırı Gradyan Artırma Sınıflandırıcı

Aşırı gradyan artırma, gradyan artırma algoritmasının çeşitli düzenlemeler ile optimize edilmiş yüksek performanslı halidir. Tianqi Chen ve Carlos Guestrin'in 2016 yılında yayınladıkları “Aşırı gradyan artırma: bir ölçeklenebilir ağaç artırma sistemi” adlı makale ile hayatımıza dahil olmuştur (78). Ham verileri (görüntüler, metin vb.) içeren tahmin problemlerinde kullanıldığında birçok algoritmadan daha yüksek performans sergileyebilmektedir. Bu sınıflandırıcıda daha az kaynak kullanarak üstün sonuçlar elde etmek için yazılım ve donanım optimizasyon tekniklerini uygulanmıştır. Karar ağacı tabanlı algoritmaların en iyisi olarak gösterilmektedir (79).

2.6.2.9. Ekstra ağaçlar Sınıflandırıcı

Bu algoritma, veri setinin çeşitli alt örneklerinde bir dizi rasgele karar ağacına (diğer bir deyişle ekstra ağaçlar) uyan bir meta tahmin edici uygular ve tahmin doğruluğunu arttırmak ve aşırı uydurmayı önlemek için ağaçlardan elde edilen sonuçların ortalamasını kullanmaktadır (80).

2.6.2.10. Oylama Sınıflandırıcı

Çok sayıda modelden oluşan, bir çoklu model üzerinde eğitim alan ve çıktı olarak seçilen sınıfın en yüksek olasılıklarına dayalı bir çıktıyı (sınıfı) tahmin eden bir makine öğrenimi algoritmasıdır (81) .

2.6.2.11. Yığma Sınıflandırıcı

Birden çok modelin çıktılarını birleştirerek ve bunları başka bir makine öğrenimi modeli aracılığıyla çalıştırarak model tahminlerini iyileştiren bir makine öğrenim algoritmasıdır (82).

2.6.2.12. Gizli Markov Modeli (Hidden Markov Model-GMM):

Adını, ilgili istatistiksel teorilerin çoğunu geliştiren Rus matematikçi Andrey Andreyevich Markov'dan alan Gizli Markov Modeli (GMM) 1970'lerin başında tanıtılmış ve incelenmiştir. İlk olarak konuşma tanımda kullanılmıştır ve 1980'lerin sonlarından beri biyolojik dizilerin analizinde başarıyla uygulanmaktadır (83). Günümüzde, Bayes teorisine dayanan dinamik Bayes ağlarının özel bir biçimi olarak kabul edilmektedirler. GMM , istatistiksel örüntü tanıma ve sınıflandırmada yaygın olarak kullanılan olasılıksal bir grafik modeldir (84). Zayıf sinyalleri tespit etmek için güçlü bir araçtır ve konuşma, el yazısı, kelime anlamının belirleme ve biyoloji dizilerin analizi gibi zamansal örüntü tanımda başarıyla uygulanmaktadır (85,86).


2.6.2.13. Derin Öğrenme ve Yapay Sinir Ağları (Deep Learning and Artificial Neural Networks-DÖ ve YSA)

Yapay zekanın önemli parçalarından biri olan derin öğrenme, makine öğreniminin bir alt kümesidir. Yapay zeka, makinelerin insan beynini taklit etmesini sağlayan algoritmalarla ibarettir (87).



Şekil 2.1. Yapay zeka alanlarının şematik görüntüsü

Derin öğrenme (DÖ) insanın beyin ve sinir yapısından esinlenerek ortaya koyulmuş bir tür makine öğrenimi tekniğidir. Derin öğrenme modelleri, elde ettikleri verileri matematiksel ve mantıksal yapıları ile sürekli analiz ederler ve insanların çıkardıkları sonuçlara yakın bir sonuç elde etmeye çalışırlar (87). Bu amaca ulaşabilmeleri için sinir ağları (neural network) adı verilen katmanlardan oluşan bir algoritma yapısı kullanılmaktadır (88).



Şekil 2.Yapay sinir ağı şematik görüntüsü (89)

Sinir ağları insan beyninden ilham alarak tasarlanmıştır. Sinir ağları; beynimizin çeşitli bilgileri yorumlaması, işlemesi ve sınıflandırması gibi görevleri taklit ederek aynı görevleri veriler üzerinde gerçekleştirebilir (90). Sinir ağlarının katmanlarını, kalından inceye doğru ilerleyerek doğru sonucu tespit etmeye çalışan bir filtre olarak da tanımlanabilmektedir (88,90).

İnsan beyni yeni bir bilgi aldığı zaman onu bilinen nesneler veya daha önceden öğrenmiş olduğu bilgiler ile kıyaslamaya çalışır. Sinir ağları da aynı şekilde çalışmaktadır (87). Sinir ağları ile sınıflandırma, tahmin etme, regresyon ve kümeleme gibi çeşitli görevler gerçekleştirilebilmektedir (90).

Yapay sinir ağları (YSA), makine öğrenimi algoritmalarının asla üstesinden gelemeyeceği problemlerin çözülmesini sağlayan benzersiz yeteneklere sahiptir (91). Son yıllarda yapay zekadaki gelişmelerin hemen hemen hepsi derin öğrenme sayesinde gerçekleşmiştir (92).

Derin öğrenme ve yapay sinir ağlarının makine öğrenimi algoritmalarından daha güçlü olma sebebini şu şekilde açıklayabiliriz: Derin öğrenme kullanılmadan önce ortaya çıkan geleneksel makine öğrenimi algoritmalarının (Karar Ağaçları, DVM


ve Lojistik Regresyon gibi) normalde doğrudan resim veya metin gibi ham verilere uygulamadan evvel özellik çıkarma olarak adlandırılan bir ön işleme aşamasına ihtiyaçları vardır; ancak özellik çıkarma aşamasından sonra elde edilen veriler, ham veri olarak makine öğrenim algoritmaları tarafından kullanabilmektedir (90). Özellik çıkarma, verileri yeterli doğrulukla tanımlarken bu problemlerin üstesinden gelebilmek için değişken kombinasyonları oluşturan karmaşık yöntemleri içeren genel bir terimdir (93).

Derin öğrenme, sinir ağlarına sahiptir ve bu ağlar özellik çıkarma adımına ihtiyaç duymazlar. Katmanlar, ham verileri doğrudan ve kendi başlarına öğrenebilmektedirler (88). Burada yapay sinir ağlarının birkaç katmanı üzerinde ham verilerin özelliklerine dayalı daha sıkışmış ve soyut veriler üretilmektedir. Girdi verilerden elde edilmiş bu sıkıştırılmış veriler daha sonra sonucu üretmek için kullanılmaktadır. Başka bir deyişle, özellik çıkarma zaten yapay sinir ağı yapısının bir parçasıdır ve verileri işleme sürecinde özellik çıkarma işlemi zaten yapılmaktadır (90).

Derin öğrenmenin ikinci büyük avantajı büyük miktarda veri tarafından desteklenmesidir. Günümüzde büyük veri setleri derin öğrenmenin dolayısıyla teknolojinin gelişmesine fırsatlar üretmektedir. Google beyin projesinin liderlerinden biri olan Andrew Ng şöyle söylüyor: “Derin öğrenme modellerini roket motoruna benzetecek olursak bu motorun yakıtı veri olacaktır. Veri arttıkça motor roketi daha uzaklara götürecektir” (94).


DVM gibi makine öğrenimi algoritmaları veri işleme sırasında belirli bir doygunluğa ulaştıklarında gelişimi bırakırlar; ancak derin öğrenme modelleri veri arttıkça kendisini geliştirmeye devam etmektedir. Veri seti arttıkça doğruluk oranında da artış gözlenmektedir (95).

Yapay sinir ağları, insan beyninin biyolojik yapısında olduğu gibi nöronlardan oluşmaktadır ve biyolojik sinir ağlarının fonksiyonlarını taklit edecek şekilde çalışmaktadırlar (96). Nöronlar; bir gövdeden, bir aksondan ve dendritlerden oluşmaktadırlar. Akson; hücre gövdesinden uzanan hücresel bir uzantıdır. Dendritler; hücre gövdesine bağlanan ince alıcılardır. Nöronlar sinyalleri dendritler ile alıp aksonları boyunca iletirler (96).



Şekil 2 3. Biyolojik sinir ağı şematik görüntüsü (97)

Yapay sinir ağı nöronları sayısal değerin basit bir grafiği olarak tarif edilebilmektedir. Yapay nöronların arasındaki bağlantılar ise akson olarak kabul edilebilmektedir (96). Bu nöronlar arasındaki bağlantıların kurulması ve bilgilerin iletilmesi sayısal değerler olan ağırlıklar tarafından gerçekleştirilmektedir (98).




Şekil 2 4. Yapay sinir ağı nöronların şematik görüntüsü (89)

Yapay sinir ağların nöronları arasındaki bağlantı güçleri ve ağırlık değerleri eğitim sürecinde değişmektedir. Sınıflandırma gibi belirli bir görevde verileri doğru sınıflara atanabilmeleri için uygun ağırlıklar aranmaktadır (99). Bu ağırlıklar her görev ve her veri seti için değişiklik gösterebilmektedir. Bu ağırlık değerleri önceden tahmin edilemez; ancak yapay sinir ağları çalışırken bir taraftan bu değerlerin öğrenmesi gerçekleştirilmektedir. Bu öğrenme sürecine eğitim denilmektedir (99).

Sinir ağı mimarisi birden çok katmandan oluşmaktadır. İlk katmanı giriş katmanıdır. Giriş katmanı, sinir ağını eğitecek verilerin giriş yaptığı katmandır. Giriş

katmanı, girdi verilerle aynı sayıda nörona sahiptir ve bu katmanındaki her bir nöron bir girdi elemanını temsil etmektedir (98).

Son katman, çıktı katmanı olarak adlandırılır ve eğitim sonrası ağına ulaştığı sonuçlar bu katman vasıtasıyla dışarıya aktarılmaktadır. Sınıflandırma durumunda, çıktı katmandaki nöron sayısı sınıf sayısını temsil eder ve nöron sayısının sınıf sayısına eşit olması gerekmektedir. Giriş katmanından giren verilerin işlenmesi ve ağına eğitilmesi belirli matematiksel işlemlerle gerçekleşmektedir. Bu işlemler giriş ve çıktı katmanları arasında yer alan ve gizli katmanlar olarak adlandırılan bölgede sağlanmaktadır (98).



Şekil 2.5. Yapay sinir ağı katmanlarının şematik görüntüsü, girdiler(i), birinci gizli katmana geçiş yapan veriler(g), ikinci gizli katmana geçiş yapan veriler(k), çıktıları(o) (100)


Sinir ağını eğitmek yani parametrelerin değerlerini öğrenmek, derin öğrenmenin en özgün parçasıdır. Bir sinir ağındaki bu öğrenme süreci tekrarlanan “gidiş ve dönüş” süreçleri olarak tarif edilebilmektedir. Bilgilerin giriş katmanından çıktı katmanına doğru ilerlemesine ileriye doğru yayılma ve dönüşü ise geriye yayılma olarak isimlendirilmektedir (92).

İlk aşama olan ileriye yayılma, verilerin sinir ağına giriş yapması ve bu ağına bu verileri işleyerek hesaplanacak ağırlıkların tahmin edebilmesi için tüm ağı baştan sona geçtiği zaman meydana gelmektedir. Yani bir katmandaki nöronlar bir önceki katmandan aldığı bilgilere işlem yaptıktan sonra bir sonraki katmana göndererek verilerin ağı boyunca ilerlemelerini sağlamaktadır (92). Veri herhangi bir katmana geçtiğinde o katmandaki tüm nöronlar veri üzerindeki hesaplamalarını yaptıktan sonra elde edilen çıktı bir aktivasyon fonksiyonuna tabi tutulmaktadır. Aktivasyon fonksiyonu, girdinin ağırlık toplamının, ağına bir katmanındaki bir düğümden veya

düğümlerden bir çıktıya nasıl dönüştürüleceğini tanımlar ve bu şekilde çıktının ileri yayılmasını sağlar (99).

Veri örnekleri sinir ağı üzerinde hareketlerine devam ederken bir sonraki işlem kayıp fonksiyonu hesaplamadır. Kayıp fonksiyonu yapılan tahmin işlemindeki hata (kayıp) miktarını ve elde edilen sonucun ne kadar iyi veya kötü olduğunu ölçmek için kullanılmaktadır. Kayıp fonksiyonları, tahmini bir değer gerçek değerinden ne kadar uzak olduğunu ölçer. Kayıp fonksiyonları sabit değildir, mevcut göreve ve ulaşılmak istenen hedefe göre değişkenlik gösterebilmektedir (99).


Kayıp hesaplanma sonucu elde edilen değer bu defa tersine doğru yani çıktı katmanından giriş katmana doğru hareket eder. Bu süreç geri yayılım olarak adlandırılmaktadır. Kayıp sinyali çıktı katmanından başlayarak gizli katmandaki tüm nöronlara dağılır; ancak her nöron çıkan sonuca katkıda bulunduğu orana göre bu sinyalden pay almaktadır. Kayıp hesaplandıktan sonra bu bilgi geriye doğru yayılır. Bu işlem katkıda bulunan tüm nöronlar kayıp sinyali alana kadar katman katman devam eder (99).



Şekil 2.6. İleri yayılım ve Geri Yayılımda gerçekleşen fonksiyonların şematik görüntüsü
(101)

Kayıp bilgisi geri yayıldıktan sonra birinci döngü bitmiş olur ve artık ikinci bir ileri yayılma işlemi için nöronlar arasındaki bağlantıların ağırlıkları ayarlanabilmektedir. Amaç bir sonraki ileri yayılımda elde edilecek olan kayıp değerini mümkün oldukça sıfıra yaklaştırmaktır. Bunun için gradyan iniş adı verilen

bir teknik kullanılmaktadır. Bu teknik, kayıp fonksiyonunun türevini hesaplayarak ağırlıkları küçük artışlarla değiştirir (98).




Şekil 2.7.Yapay sinir ağı öğrenme fonksiyonunu oluşturan aşamalarının şematik görüntüsü, girdi(x), tahmin edilmesi gereken değer(y), ağırlık(w), ağırlığa eklenen sabit değer(b) (101).

Özetle öğrenme algoritmasındaki aşamalar aşağıdaki gibidir:

1. Ağırlık değerleri verilir. Genellikle ilk ağırlık değerleri rastgele seçilir.
2. Veri setinden belirli sayıda örnek alınır ve tahminleri elde etmek için giriş katmanından ağırlıklara iletilir.
3. Elde edilen tahminler, beklenen sonuç değerleriyle karşılaştırılır ve ona göre kayıp hesaplanır.
4. Elde edilen kayıp değerini katkıda bulunan nöronlara dağıtılmak için geri yayılım işlemi başlatılır.
5. Toplam kaybı azaltacak, doğruluk oranını yükseltecek ve daha güçlü model elde edilecek şekilde gradyan inişli sinir ağı parametrelerini güncellemek için bu yayılan bilgi kullanılır.
6. İyi bir model elde edilene kadar önceki adımlar yinelemeye devam eder (96).

Evrişimli Sinir Ağları (ESA)

Evrişimli sinir ağı (ESA); görüntü işlemede en yaygın kullanılan sinir ağı yapısıdır (102). ESA'nın rolü, sinir ağı daha kolay öngörülebilmesini sağlamak için mevcut görüntülerin özelliklerini kaybetmeden daha basit bir formata indirgemektir. Bir ESA, görüntü örneklerinin çeşitli özelliklerini öğrenebilen onlarca ve hatta yüzlerce katmandan oluşabilmektedir. Her katman görüntü örneğine farklı filtreler uygulayarak bazı özelliklerini öğrenmeye çalışır ve bir katman işlediği görüntüyü diğer özellikleri öğrenmesi için bir sonraki katmana aktarmaktadır. Filtreler, parlaklık



Şekil 2.9.Havuzlama işleminin şematik görüntüsü (106)

Evrişim ve havuzlama katmanlarından elde edilen çıktı, girdi görüntüsünün yüksek seviyeli özelliklerinin somutlaşmış örnekleridir.

Tam bağlantılı katmanın görevi, giriş katmanından giren görüntüyü, önceki katmanlarda belirlenen özelliklerine göre en uygun biçimde sınıflandırmaktır (107).

Günümüzde çok fazla bilinen bazı ESA mimarilerini şu şekilde listeleyebiliriz:

1. **VGGNet:** VGG (Visual Geometry Group), görsel geometri grubu anlamına gelir. Çoklu katmanlara sahip standart bir derin Evrişimli Sinir Ağı mimarisidir. VGG-16 veya VGG-19 gibi modellerdeki yazılan sayılar katman sayısını ifade eder. VGG mimarisi, çıkır açan nesne tanıma modellerinin temelidir. Derin bir sinir ağı olarak geliştirilen VGGNet, birçok görev ve veri setinde temel çizgileri aşmaktadır. Ayrıca, günümüzde hala en popüler görüntü tanıma mimarilerinden biri olarak kabul edilmektedir (107).
2. **ResNet:** Residual Network (ResNet); He ve ark.'nın makalesinde tanıtan ünlü derin öğrenme modellerinden biridir (108). Bu model ResNet16, ResNet18, ResNet34, ResNet50, ResNet101, ResNet110, ResNet164, ResNet1202 ve benzeri gibi birden çok varyasyona sahiptir. Makale 2015 yılında “Görüntü tanıma için derin residual öğrenme” olarak adlandırıldı. Bu residual blokların devreye girmesiyle çok derin ağları eğitme sorunu ortadan kalkmıştır.

ResNet'in ana fikri, çoğunlukla kısayol bağlantıları veya kimlik bağlantıları olarak adlandırılan atlama bağlantılarının kullanılması şeklindedir. Bu bağlantılar öncelikle bu katmanlar arasında kısayollar oluşturan bir veya birden fazla katmanın üzerinden atlayarak çalışır. Bu kısayol bağlantılarının tanıtılma amacı, derin ağların karşılaştığı eğim süresi sorununa çözüm sunmaktır. Bu bağlantı atlama işlemi ağı sıkıştırır dolayısıyla ağ daha hızlı öğrenir. Bağlantıların bu sıkıştırmasını, ağı kalan kısmının daha fazla özellik alanını eğitip keşfedebilmesi için katmanların genişletilmesi takip eder. ResNet modeli, şimdiye kadar en popüler ve en başarılı derin öğrenme modellerinden biri olarak kabul görmektedir (109).

3. **GoogleNet (Başlangıç Blokları):** Önceki modeller performans ve doğruluğu arttırmak için daha derine inerken, hesaplama maliyetinden ödün vermekteydiler; ancak başlangıç blokları bu konuda bir dönüm noktasına ulaşarak hız ve doğruluktan ödün vermeden hesaplama maliyetini büyük ölçüde azaltmayı mümkün kıldı. Öte yandan başlangıç blokları detaylı bir şekilde tasarlanmıştır. Hem hız hem de doğruluk açısından performansı arttırabilecek birçok özelliğe sahiptir (109).

Başlangıç blokları 2014 yılında, bir görüntü sınıflandırma yarışması olan ImageNet'in galibi oldu ve diğerlerine kıyasla nispeten daha düşük hata oranı gösterdi.


4. **Xception:** Başlangıç blokları mimarisinin altında yatan hipotezin daha güçlü bir versiyonudur ve "Aşırı başlangıç bloklar" anlamına gelmektedir. Xception mimarisi, ağı özellik çıkarma tabanını oluşturan 36 evrişim katmanına sahiptir. Xception'in bariz özelliklerinden biri daha az kod yazarak büyük ve karmaşık kütüphaneleri kullanabilmesidir (109).

5. **MobileNet:** MobileNet, verimli ve taşınabilir bir ESA mimarisidir. MobileNet'ler, daha hafif modeller oluşturmak için önceki mimarilerde kullanılan standart evrişimler yerine öncelikle derinlemesine ayrılabilir evrişimler kullanmaktadır. Bu model geliştiricilerin gereksinimlerine bağlı olarak modelin hızlı ve düşük boyutlu olmasını sağlayan iki yeni global hiperparametreye (genişlik çarpanı ve çözünürlük çarpanı) sahiptir (110). MobileNet'ler, derinlemesine ayrılabilir evrişim katmanları üzerine kuruludur. Derinlemesine ayrılabilir evrişim katmanlarının her biri, bir derinlikli evrişim

ve bir noktasal evrişimden oluşur. Derinlik ve noktasal evrişimler ayrı katmanlar olarak sayıldığında, bir MobileNet 28 katmana sahiptir (111).

6. **DenseNet:** DenseNet, en son teknolojiye sahip olan bir modern ESA mimarisidir. Temel olarak ResNet ile aynı yapıya sahip olmaktadır; ancak aralarında önemli farklılıklar mevcuttur (112). DenseNet, birleştirilmiş öznitelikleri ile birlikte önceki katman çıktısını sonraki katmanla birleştirir, ResNet ise önceki katmanı bir sonraki katmanlarla bağlamak için bir eklemeli öznitelik kullanır. Kısaca DenseNet, tüm katmanları doğrudan birbirine bağladığımız yoğun bloklar aracılığıyla katmanlar arasındaki yoğun bağlantıları kullanan bir tür evrişimli sinir ağıdır (113).
7. **NasNet:** Sinir mimarisi araştırması (SMA) anlamına gelen ve makine öğrenimi alanında yaygın olarak kullanılan bu model, yapay sinir ağlarının tasarımını otomatikleştiren bir tekniktir. Başka bir ifade ile belirli bir görevde en iyi performansı elde etmek için sinir ağlarının topolojisinin tasarımını otomatikleştirme sürecidir (114). SMA, elle tasarlanmış mimarilere eşit veya onlardan daha iyi performans gösteren ağlar tasarlamak için kullanılmıştır. SMA, hiperparametre optimizasyonu ve meta-öğrenme ile yakından ilişkilidir ve otomatik makine öğreniminin bir alt alanıdır (115).

ESA modelleriyle ses verilerinin işlenmesi ve sınıflandırılması da mümkündür. Bu teknikte ses sinyalleri görüntüye dönüştürülerek işlenmektedir. Ses tanıma problemi sinyallerin ön işlenmesi, belirli özniteliklerin çıkarılması ve sınıflandırılması olmak üzere üç farklı aşamadan oluşmaktadır (116). Sinyallerin ön işlenmesi aşamasında ses verileri spektrogram denilen görüntülere dönüştürülmektedir ve bir sonraki aşamada bu spektrogramların öznitelikleri çıkartılır ve son olarak elde edilen özniteliklere göre sınıflandırma yapılmaktadır (116).



Şekil 2.10. Spektogram


8. YamNet: YamNet ses tanıma görevleri için geliştirilmiş önceden eğitilmiş bir ESA modelidir. Bu model 2 milyondan fazla YouTube videosundan alınan 632 sınıf ses içeren bir veri seti olan AudioSet ile eğitilmiştir (117). AudioSet çevresel sesler, insan sesleri ve müzik türleri gibi çok çeşitli ses gruplarını içermektedir. YAMNet, MobileNet mimarisi üzerine kurulmuştur (110). MobileNet mimarilerinde standart evrişim, derinlemesine ayrılabilir evrişim ile değiştirilir. Bu özel yaklaşım, hesaplama maliyetinin standart evrişim ile karşılaştırıldığında dokuz kata kadar azaltılabileceği gösterilmiştir. YAMNet, giriş ve çıkış katmanlarına ek olarak 27 evrişimsel katman, 1 genel ortalama havuzlama katmanı ve 1 tam bağlantılı katman içermektedir. Standart evrişim ve derinlemesine ayrılabilir evrişimler, havuz katmanına kadar sırayla istiflenir. Son olarak çıktı katmanı, bir aktivasyon fonksiyonu ile ses sınıfını tahmin etmektedir. Derinlemesine ayrılabilir evrişimlerin etkisini daha iyi anlayabilmek için YAMNet'i ilk ESA'lardan birini olan AlexNet ile karşılaştırmak mümkündür. AlexNet'te bulunan parametre sayısı 8 katmanda 61 milyon iken, YAMNet 30 katmanda 3,7 milyondur (118,119). Daha az öğrenilebilir ağırlık bu tür mimarilerde aşırı uyum veya ezberleme risklerini daha da azaltmaktadır.

Özyinelemeli Sinir Ağları (ÖSA)

Özyinelemeli Sinir Ağları (ÖSA), tekrarlayan Sinir Ağı anlamına gelmektedir. ÖSA sıralı verileri işleyebilen, kalıpları tanıyabilen ve nihai çıktıyı tahmin edebilen bir tür yapay sinir ağıdır (120). Bu Sinir Ağı, bir dizi girdi üzerinde aynı görevi veya

işlemi tekrar tekrar gerçekleştirebildiği için özyinelemeli olarak adlandırılır. Özyinelemeli yapay sinir ağları, dahili bellekleri sayesinde aldıkları girdilerle ilgili kritik ayrıntıları hatırlayarak, bir sonraki adımda ne olacağını büyük bir doğrulukla tahmin edebilmektedir ve sistemin bağlam kazanmasına yardımcı olmaktadır (121). Bu nedenle doğal dil işleme gibi sıralı verileri işlemek için ÖSA uygun olacaktır. Bu tarz işlemler evrimsel sinir ağları veya ileri beslemeli sinir ağları tarafından yapılamaz çünkü bu ağların önceki giriş ile sonraki giriş arasındaki korelasyonu sıralayamamaktadırlar (120).

Bir ÖSA'nın temel mantığı, belirli katmanın çıktısını öğrenmek ve sonraki katmanların çıktısını tahmin etmek için onu girdi olarak kullanmaktır (120).



Şekil 2.11. (X) Giriş katmanıdır. (h) Gizli katmandır ve önceki çıktının bilgisini tutar ve tekrar kullanır. (y) Çıktı katmanıdır A, B, C, modelin çıktısını iyileştirecek parametrelerdir. (122)..

Sonuç olarak bir ÖSA'nın iki girişi vardır: şimdiki zaman ve yakın geçmiştir. Bu özellik veri dizisinin daha sonra ne olacağı hakkında kritik bilgiler sağladığından önemlidir ve bu nedenle bir ÖSA, diğer algoritmaların yapamayacağı görevleri gerçekleştirebilir (123).

ÖSA çeşitlerini şu şekilde açıklamak mümkündür:

- **BRNN (Çift yönlü özyinelemeli sinir ağları):** Farklı bir ağ tasarımına sahip bir ÖSA türüdür. Çift yönlü ÖSA doğruluğu arttırmak için gelecekteki verileri çekerken, tek yönlü tahminler oluşturmak için yalnızca önceki girdilerden yararlanırlar (124).
- **Uzun Kısa Vadeli Hafıza Ağları (UKVHA):** Bellek kapasitesini genişleten bir tür tekrarlayan sinir ağıdır (125). UKVHA'nın temel konsepti hücre durumu

ve kullandığı çeşitli kapılardır. Hücre durumu, tahmin yapmak için anlamlı bilgileri hücreler boyunca taşıyan bir iletişim hattı ve ağı hafızası olarak açıklanabilir. Modelin mevcut üç kapısı ise giriş, çıkış ve unutma olarak adlandırılmaktadır. Kapılar verileri 0 ile 1 aralığına sıkıştıran sigmoid aktivasyon fonksiyonunu kullanır. Sigmoid aktivasyonu sonucunda 0 olan bilgiler unutulur ve 1 olan bilgiler ise hücre durumu ile ilerlemeye devam eder. ÖSA'lar, UKVHA nedeniyle girdileri uzun süre geri çağırabilir. Bunun nedeni, UKVHA'nın bilgileri bir bilgisayarınkine benzer şekilde bellekte depolamasıdır. UKVHA, hafızasındaki verileri okuma, yazma ve silme yeteneğine sahiptir (124,125).

- **GRU (Kapılı tekrarlayan birimler):** Bu tip sinir ağı, ÖSA modellerinin kısa süreli bellek problemlerini de çözmeyi amaçladığı için Uzun kısa vadeli hafıza ağları (UKVHA) ile karşılaştırılabilir. Üç kapı yerine bir sıfırlama kapısı ve bir güncelleme kapısı olmak üzere yalnızca iki kapıya sahiptir. UKVHA'daki kapılar gibi sıfırlama ve güncelleme kapıları, ne kadar ve hangi bilgilerin tutulacağını belirlemektedir (124).

2.6.3. Öğrenme Aktarımı ve Derin Öğrenme Aktarımı (Transfer Learning)

Öğrenim aktarımı, bir görevde kullanılan modelden elde edilen bilginin başka bir görev için temel nokta olarak yeniden kullanılabileceği bir makine öğrenimi yöntemidir. Başka bir deyişle öğrenim aktarımı, yeni bir model için başlangıç noktası olarak önceden eğitilmiş bir modeli yeniden kullanan bir makine öğrenimi yöntemidir. Öğrenim aktarımında bir görev üzerinde eğitilmiş bir model, ikinci görevi modellerken hızlı ilerlemeye izin veren bir optimizasyon olarak ikinci bir ilgili görevde yeniden kullanılmaktadır. Öğrenim aktarımını yeni bir göreve uygulayarak az miktarda veriyle önemli ölçüde yüksek performans elde edilebilmektedir (126).

Doğal dil işleme ve görüntü tanıma gibi alanlar, öğrenim aktarımı için sıcak araştırma alanları olarak kabul edilmektedir. Önceden eğitilmiş sinir ağları/modelleri, derin öğrenme bağlamında öğrenme aktarımının temelini oluşturur ve “derin öğrenim aktarımı” olarak adlandırılır (127,128).

Öğrenme aktarımının geleneksel makine öğrenimi, modellerine göre avantajlarını şu şekilde sıralamak mümkündür (126,129):

1. Geleneksel makine öğrenimi modelleri, hesaplama açısından pahalı olan ve yüksek performans elde etmek için büyük miktarda veriye ve sıfırdan eğitime ihtiyaç duymaktadır. Öte yandan, öğrenim aktarımı hesaplama açısından verimlidir ve küçük bir veri seti kullanarak daha iyi sonuçlar elde edilmesine yardımcı olur.
2. Geleneksel makine öğrenimi, her modelin geçmiş bilgilere bağlı olmaksızın belirli bir amaç için bağımsız olarak eğitildiği izole bir eğitim yaklaşımına sahiptir. Bunun aksine öğrenim aktarımı, göreve devam etmek için önceden eğitilmiş modelden edinilen bilgiyi kullanmaktadır.
3. Öğrenim aktarımı modelleri, geleneksel makine öğrenimi modellerine göre optimum performansa daha hızlı ulaşmaktadır. Bunun nedeni, önceden eğitilmiş modellerden gerekli özellikleri zaten kavramış olmasıdır.

3. GEREÇ VE YÖNTEM

3.1. Hasta seçimi

Bu tez çalışmasına, Afyonkarahisar Sağlık Bilimleri Üniversitesi Diş Hekimliği Fakültesi Ortodonti Anabilim Dalı'nda sabit ortodontik tedavi gören sistemik ve mental olarak sağlıklı 320 kişi ön değerlendirmeye alınmıştır. Belirlenen kriterleri sağlayan 230 (144 kadın 86 erkek) birey çalışmaya dahil edilmiştir; ancak kriterleri sağlamayan 90 birey çalışma dışında bırakılmıştır. Çalışmaya dahil edilen bireylerin yaşları 12 ile 18 yıl arasında olup, yaş ortalaması 14.94 ± 2.4 'tür. Araştırma öncesinde Afyonkarahisar Sağlık Bilimleri Üniversitesi Girişimsel Olmayan Klinik Araştırmalar Etik Kurulu tarafından 07.01.2022 tarih ve 2022/30 sayılı karar ile etik onay verilmiştir. Çalışmaya dahil edilecek olan hastalar çalışma hakkında bilgilendirilmiş olup kabul edenlere gönüllü onam formu imzalatılarak çalışmaya başlanılmıştır.

Çalışmaya dahil edilme kriterleri:

- Fiziksel ve mental olarak sağlıklı olması
- Daha önce hareketli veya sabit ortodontik tedavi görmemiş olması
- Ortodontik sabit tedaviye ihtiyacı olmaları
- Tedavinin en az 12 ay sürecektir olması

Çalışma dışında tutma kriterleri:

- Fiziksel ve mental problemlerinin olması
- Daha önce herhangi bir ortodontik tedavi görmüş olması
- Bireyin yüzünde kaza veya cerrahi sonucu iz, skar dokusu veya deformasyonun olması
- Solunum yolu enfeksiyonunun olması
- Ses tellerini etkilemiş bir hastalık geçirilmesi
- Ses tellerini etkileyen herhangi bir operasyonun geçirilmiş olması
- Herhangi bir konuşma güçlüğüne sahip olması
- OHKS'ye göre skorun %41- 59 arasında bulunan bireyler

3.2. Çalışma gruplarının oluşturulması

Afyonkarahisar Sağlık Bilimleri Üniversitesi Diş Hekimliği Fakültesi Ortodonti Anabilim Dalı'nda uzmanlık eğitimi alan 8 araştırma görevlisinden, hastalarının kooperasyon düzeyinin değerlendirilmesi istendi. Bu amaçla hekimler çalışmaya uygun olan bireylerin tedavilerinin 12. ayında hastanın tedaviye gösterdiği uyumu değerlendiren, güvenilirlik ve geçerliliği daha önce yapılmış çalışmalarla onaylanan ortodonti hasta kooperasyon skalası-OHKS (Orthodontic patient cooperation scale) formunu doldurdular.

OHKS, Slakter ve ark. tarafından ortodontik tedavi gören hastaların kooperasyonunu ölçme amacıyla geliştirilen bir skaladır (10). Bu skala, hastaların kooperasyon değerlendirilmesinde sıklıkla göz önünde bulundurulmuş hasta davranışlarını içeren 10 maddeden oluşmaktadır. Her madde için düşük işbirliği ile yüksek işbirliği arasında 4 seçenek sunulmuş ve bu seçenekler 10-40 puan aralığında skorlanmıştır. Elde edilen toplam puana göre hasta kooperasyon seviyesi belirlenmiştir.

Toplam 286 hastaya OHKS doldurtuldu, bu skalaya göre toplam skorun %60 ve üzerini alan bireyler uyumlu hastalar grubuna (34 erkek 91 kadın), %40 ve altını alanlar ise uyumsuz hastalar grubuna (56 erkek 49 kadın) dahil edilmiştir. %41-59 arasında yer alan hasta grubu (25 kadın 31 erkek) sınırda kaldığı için çalışma dışında bırakılmıştır.

Ön değerlendirilmeye alınan 320 bireyin elli altısı OHKS puan kriterini karşılayamadıkları için, otuz dördü ise belirlenen diğer kriterlerin dışında kaldığı için çalışmaya dahil edilmemiştir.

3.3. Gereç

Yapay zekanın kooperasyon tahmini yapabilmesi için ihtiyacı olan veriler şu şekilde elde edilmiştir:

3.3.1. Fotoğraflar

Kurumumuzda ortodontik tedaviye başlamak isteyen hastaların tedaviye başlamadan önce standart olarak ağız dışı ve ağız içi fotoğrafları çekilmektedir. Ağız

dışı fotoğraflar kliniğin fotoğraf odasında standart olarak belirlenmiş uzaklık (1.5 metre) ve aynı aydınlatma kuralları altında Canon (EOS 60D, Japonya-Tokyo) fotoğraf makinesi (deklanşör hızı =1\125, diyafram = F22, ISO = 100) ile çekilmektedir. Fotoğraf çekimi sırasında hastanın doğal baş pozisyonunda ve yüzünün ifadesiz olmasına dikkat edilmektedir. Bu çalışmaya dahil edilecek olan hastalar belirlendikten sonra hastaların yukarıda belirtilmiş olan standartlara göre çekilmiş olan cephe fotoğrafları arşivden alınmıştır. Cephe fotoğrafları bu standartlara uymayan hastalar çalışmaya dahil edilmemiştir.

3.3.2. El Yazısı

Çalışmaya dahil edilecek hastalar belirlendikten sonra hastalardan önceden hazırlanmış ortodontik tedavi sırasında dikkat etmeleri gereken maddeleri içeren bir metnin el yazısıyla yazmaları istendi. Bu metnin kısa olmasına, hastalar için yorucu ve sıkıcı olmamasına dikkat edildi. Hastalar bu metni önceden belirlenmiş PENSAN (Türkiye-İstanbul) markalı mavi kalem ile çizgisiz A4 kağıt üzerinde yazdılar. Yazma sırasında araştırmacı tarafından herhangi bir yönlendirme ve müdahale olmadan sadece metnin aynısını yazmaları istenmiştir. Elde edilen belgeler EPSON WorkForce Pro (WF-M5690, Japonya-Suwa) tarayıcı ile OPG formatında taranıp dijital ortama aktarılarak yapay zeka modelinde kullanılmak için uygun hale getirildi.

3.3.3. Ses Kaydı

Ses kaydı verilerini elde etmek için hastalardan, hazırlanmış metni elle yazdıktan sonra yüksek sesle okumaları talep edildi. Hastalar bu metni okurken sesleri Iphone (Apple 12 pro max, ABD- Kaliforniya) cep telefonu ile kayıt altına alındı.

Yukarıda bahsedilen verilerin hepsi hastane gürültüsünden uzak ve sessiz ortama sahip bir odada toplanmıştır. Ses kaydı esnasında kayıt cihazıyla hasta arasındaki mesafe standardize edildi, araştırmacı dışında kimsenin odada bulunmamasına özen gösterildi, hasta konsantrasyonunu ve ses kaydı kalitesini etkileyecek çalışan bilgisayarlar ve diğer cihazlar kapatıldı. Hasta sesi dışında ses kaydını etkileyecek diğer seslerin elimine edilmesine dikkat edildi. Standart

olabilmesi için hastaların ikinci kez metni okumalarına izin verilmedi ve sadece ilk okunuşta alınan kayıt işleme alındı.

3.3.4. Makine Öğrenimi

Python dili kullanarak IDLE (Integrated Development and Learning Environment, Entegre geliştirme ve öğrenme ortamı) ortamında kodlama işlemi yapılmıştır. Hasta kooperasyonu tahmininin yapay zeka yardımı ile gerçekleştirilmesindeki akış diyagramı şekil 3.1 de verilmiştir.



Şekil 3.1. Hasta kooperasyonu tahmininin tespitinde kullandığımız modeller ve algoritmaların şematik görüntüsü

3.4. Yöntem

3.4.1. Verilerin İşlenmesinde Kullanılan Yapay Zeka Modelleri

OHKS sonuçlarına göre uyumlu ve uyumsuz gruplara ayrılan hastaların verileri (fotoğraf, ses, el yazısı) ayrı ayrı yapay zeka algoritmalarına tanıtıldı bu verilerin %80.0'i algoritmaların eğitimi için %20.0'si test için kullanıldı.

Fotoğraf ve el yazısı verileri için günümüzde en çok kullanılan evrişimli yapay sinir ağları olan VGG16, ResNet50V2, ResNet101V2, ResNet152V2, InceptionResnetV2, Xception, MobilNetV2, NasNetMobil ve DenseNet121, modelleri kullanıldı. Derin öğrenmede veri setinin büyük olması başarı oranının yüksek olma ihtimalini arttırmaktadır. Bu çalışma için kullanacağımız verilerin az olduğunu düşünerek öğrenme aktarımı kullanılmasına karar verildi ve bu şekilde modellerin sergileyebilecekleri en yüksek performansa ulaşabilmesi sağlandı.

Öğrenme aktarımı ile önceden daha büyük görüntü veri setleri üzerinde eğitilmiş ve başarılı sonuçlar elde etmiş modellerin ağırlıklarının bu çalışmada kullanılan veri setleri üzerine uygulanması daha iyi sonuçların elde edilmesini olanak tanımıştır.

Ses kaydı analizi için makine öğrenme algoritması olan KEYK sınıflandırıcı, Lojistik regresyon, Rastgele orman sınıflandırıcı, DVM, Karar ağacı sınıflandırıcı, Gaussian NB, Linear Discriminant analizi, AdaBoost sınıflandırıcı, Gradyan arttırma sınıflandırıcı, Aşırı gradyan arttırma sınıflandırıcı, Ekstra ağaç sınıflandırıcı, Oylama sınıflandırıcı, Yığma sınıflandırıcı ve ESA modeli olan YamNet kullanıldı.



4. BULGULAR

4.1. Bireylere Ait Bulgular

Çalışmamızda 230 hastaya ait veriler değerlendirilmiştir. Bireylerin yaş aralığı 12 ile 18 yıldır ve yaş ortalaması 14.94 ± 2.4 olarak hesaplanmıştır. Hastaların cinsiyet dağılımı 130 (%56.5) kadın ve 100 (%43.5) erkek şeklindedir.

4.2. Makine Öğrenimi Modellerinin Performans Değerlendirilmesi

Modellerin performansı; doğruluk (accuracy), kesinlik (precision), duyarlılık (recall), F1 skoru, konfüzyon matrisi ve ROC eğrisine göre değerlendirilmiştir. Bu kavramların ne anlama geldiği aşağıda açıklanmıştır.

Doğruluk değeri; modelde doğru tahmin edilen verilerin toplam veri setine bölünmesiyle hesaplanmaktadır. Kesinlik; bu kavramı bir örnek ile açıklayacak olursak A grubu olarak tahmin edilmiş değerlerin gerçekten kaç adedinin A grubuna ait olduğunu gösteren değerdir. Duyarlılık; ölçümlerin birbirine yakınlığı olarak tanımlanır ve sapma olarak ifade edilmektedir. Duyarlılık; aynı değeri yeniden elde etme becerisi olarak da tanımlanabilmektedir. F1 skor değeri ise bize kesinlik ve duyarlılık değerlerinin harmonik ortalamasını göstermektedir. Konfüzyon matrisi; gerçek değerlerin bilinmekte olduğu bir dizi test verisi üzerinde, bir sınıflandırma modelinin performansını tanımlamak için sıklıkla kullanılan bir tablodur. ROC eğrisi; ikili sınıflandırma algoritmalarının performansının grafiksel bir gösterimidir ve AUC ile değerlendirilir. AUC değeri ROC eğrisinin altındaki alanı temsil eder ve ideal değeri 1 olmalıdır.


4.3. Yüz Fotoğraflarını Değerlendiren Modellere Ait Bulgular

4.3.1. ResNet50V2 Modelin Sonuçları

ResNet50V2 modelin konfüzyon matriks çıktısı tablo 4.1’de ve ROC eğrisi şekil 4.1’de gösterilmiştir. Modelin doğruluk oranı: %62.0, kesinlik değeri: 0.636, duyarlılık değeri: 0.467 ve F-skoru: 0.538 olarak bulundu.

Tablo 4.1. ResNet50V2 modelin konfüzyon matriksi

Konfüzyon matriksi			
		TAHMİN	
		UYUMLU	UYUMSUZ
GERÇEK	UYUMLU	20	7
	UYUMSUZ	10	9




Şekil 4.1. ResNet50V2 modelin ROC eğrisi

4.3.2. ResNet101V2 Modelin Sonuçları

ResNet101V2 modelin konfüzyon matrisi çıktısı tablo 4.2’de ve ROC eğrisi şekil 4.2’de gösterilmiştir. Modelin doğruluk oranı: %48.0, kesinlik değeri: 0.441, duyarlılık değeri: 0.473 ve F-skoru: 0.456 olarak bulundu.

Tablo 4.2. ResNet101V2 modelin konfüzyon matrisi

Konfüzyon matrisi			
		TAHMİN	
		UYUMLU	UYUMSUZ
GERÇEK	UYUMLU	13	14
	UYUMSUZ	10	9




Şekil 4.2. ResNet101V2 modelin ROC eğrisi

4.3.3. ResNet152V2 Modelin Sonuçları

ResNet152V2 modelin konfüzyon matrisi çıktısı tablo 4.3'te ve ROC eğrisi şekil 4.3'te gösterilmiştir. Modelin doğruluk oranı: %61.0, kesinlik değeri: 0.607, duyarlılık değeri: 0.548 ve F-skoru: 0.576 olarak bulundu.

Tablo 4.3. ResNet152V2 modelin konfüzyon matrisi

Konfüzyon matrisi			
		TAHMİN	
		UYUMLU	UYUMSUZ
GERÇEK	UYUMLU	17	10
	UYUMSUZ	9	10




Şekil 4.3. ResNet152V2 modelin ROC eğrisi

4.3.4. InceptionResnetV2 Modelin Sonuçları

InceptionResnetV2 modelin konfüzyon matriks çıktısı tablo 4.4'te ve ROC eğrisi şekil 4.4'te gösterilmiştir. Modelin doğruluk oranı: %53.0, kesinlik değeri: 0.519, duyarlılık değeri: 0.452 ve F-skoru: 0.483 olarak bulundu.

Tablo 4.4. InceptionResnetV2 modelin konfüzyon matriksi

Konfüzyon matriksi			
		TAHMİN	
		UYUMLU	UYUMSUZ
GERÇEK	UYUMLU	16	11
	UYUMSUZ	11	8




Şekil 4 4. InceptionResnetV2 modelin ROC eğrisi

4.3.5. Xception Modelin Sonuçları

Xception modelin konfüzyon matriks çıktısı tablo 4.5’de ve ROC eğrisi şekil 4.5’te gösterilmiştir. Modelin doğruluk oranı: %66.0, kesinlik değeri: 0.640, duyarlılık değeri: 0.582 ve F-skoru: 0.610 olarak bulundu.

Tablo 4.5. Xception modelin konfüzyon matriksi

Konfüzyon matriksi			
		TAHMİN	
		UYUMLU	UYUMSUZ
GERÇEK	UYUMLU	19	8
	UYUMSUZ	8	11




Şekil 4.5. Xception modelin ROC eğrisi

4.3.6. MobilNetV2 Modelin Sonuçları

MobilNetV2 modelin konfüzyon matriks çıktısı tablo 4.6'da ve ROC eğrisi şekil 4.6'da gösterilmiştir. Modelin doğruluk oranı: %.62.0, kesinlik değeri: 0.596, duyarlılık değeri: 0.509 ve F-skoru: 0.549 olarak bulundu.

Tablo 4.6. MobilNetV2 modelin konfüzyon matriksi

Konfüzyon matriksi			
		TAHMİN	
		UYUMLU	UYUMSUZ
GERÇEK	UYUMLU	19	8
	UYUMSUZ	9	10




Şekil 4.6. MobilNetV2 modelin ROC eğrisi

4.3.7. NasNetMobil Modelin Sonuçları

NasNetMobil modelin konfüzyon matriks çıktısı tablo 4.7’de ve ROC eğrisi şekil 4.7’de gösterilmiştir. Modelin doğruluk oranı: %57.0, kesinlik değeri: 0.537, duyarlılık değeri: 0.400 ve F-skoru: 0.458 olarak bulundu.

Tablo 4.7. NasNetMobil modelin konfüzyon matriksi

Konfüzyon matriksi			
		TAHMİN	
		UYUMLU	UYUMSUZ
GERÇEK	UYUMLU	19	8
	UYUMSUZ	12	7




Şekil 4.7. NasNetMobil modelin ROC eğrisi

4.3.8. DenseNet121 Modelin Sonuçları

DenseNet121 modelin konfüzyon matrisi çıktıları tablo 4.8’de ve ROC eğrisi şekil 4.8’de gösterilmiştir. Modelin doğruluk oranı: %66.0, kesinlik değeri: 0.630, duyarlılık değeri: 0.586 ve F-skoru: 0.607 olarak bulundu.

Tablo 4.8. DenseNet121 modelin konfüzyon matrisi

Konfüzyon matrisi			
		TAHMİN	
		UYUMLU	UYUMSUZ
GERÇEK	UYUMLU	19	8
	UYUMSUZ	8	11




Şekil 4.8. DenseNet121 modelin ROC eğrisi

4.3.9. VGG16 Modelin Sonuçları

VGG16 modelin konfüzyon matriks çıktısı tablo 4.9’da ve ROC eğrisi şekil 4.9’da gösterilmiştir. Modelin doğruluk oranı: %53.0, kesinlik değeri: 0.500, duyarlılık değeri: 0.367 ve F-skoru: 0.423 olarak bulundu.

Tablo 4.9. VGG16 modelin konfüzyon matriksi

Konfüzyon matriksi			
		TAHMİN	
		UYUMLU	UYUMSUZ
GERÇEK	UYUMLU	18	9
	UYUMSUZ	12	7



Şekil 4.9. VGG16 modelin ROC eğrisi

Başarı değerlendirmesinde ana parametre olarak doğruluk oranı (accuracy) kabul edildiğinde modellerin en başarılıdan en başarısız doğru sıralaması tablo 4.10’da gösterilmiştir.

Tablo 4.10. Yüz fotoğraflarını değerlendiren ESA modellerine ait bulgular

ESA Modelleri	Doğruluk	Kesinlik	Duyarlılık	F1-Skoru
Xception	%66.0	0.640	0.582	0.610
DenseNet121	%66.0	0.630	0.586	0.607
ResNet50V2	%62.0	0.636	0.467	0.538
MobilNetV2	%62.0	0.596	0.509	0.549
ResNet152V2	%61.0	0.607	0.548	0.576
NasNetMobil	%57.0	0.537	0.400	0.458
InceptionResNetV2	%53.0	0.519	0.452	0.483
VGG16	%53.0	0.500	0.367	0.423
ResNet101V2	%48.0	0.441	0.473	0.456


4.4. El Yazılarını Değerlendiren Modellere Ait Bulgular

4.4.1. ResNet50V2 Modelin Sonuçları

ResNet50V2 modelin konfüzyon matriks çıktısı tablo 4.11’de ve ROC eğrisi şekil 4.10’da gösterilmiştir. Modelin doğruluk oranı: %46.0, kesinlik değeri: 0.312, duyarlılık değeri: 0.263 ve F-skoru: 0.286 olarak bulundu.

Tablo 4.11. ResNet50V2 modelin konfüzyon matriksi

Konfüzyon matriksi			
		TAHMİN	
		UYUMLU	UYUMSUZ
GERÇEK	UYUMLU	16	11
	UYUMSUZ	14	5




Şekil 4.10. ResNet50V2 modelin ROC eğrisi

4.4.2. ResNet101V2 Modelin Sonuçları

ResNet101V2 modelin konfüzyon matriks çıktısı tablo 4.12’de ve ROC eğrisi şekil 4.11’de gösterilmiştir. Modelin doğruluk oranı: %65.0, kesinlik değeri: 0.588, duyarlılık değeri: 0.526 ve F-skoru: 0.556 olarak bulundu.

Tablo 4.12. ResNet101V2 modelin konfüzyon matriksi

Konfüzyon matriksi			
		TAHMİN	
		UYUMLU	UYUMSUZ
GERÇEK	UYUMLU	20	7
	UYUMSUZ	9	10




Şekil 4.11. ResNet101V2 modelin ROC eğrisi

4.4.3. ResNet152V2 Modelin Sonuçları

ResNet152V2 modelin konfüzyon matrisi çıktısı tablo 4.13'te ve ROC eğrisi şekil 4.12'de gösterilmiştir. Modelin doğruluk oranı: %65.0, kesinlik değeri: 0.588, duyarlılık değeri: 0.526 ve F-skoru: 0.556 olarak bulundu.

Tablo 4.13. ResNet152V2 modelin konfüzyon matrisi

Konfüzyon matrisi			
		TAHMİN	
		UYUMLU	UYUMSUZ
GERÇEK	UYUMLU	20	7
	UYUMSUZ	9	10




Şekil 4.12. ResNet152V2 modelin ROC eğrisi

4.4.4. InceptionResNetV2 Modelin Sonuçları

InceptionResNetV2 modelin konfüzyon matrisi çıktısı tablo 4.14’te ve ROC eğrisi şekil 4.13’te gösterilmiştir. Modelin doğruluk oranı: %72.0, kesinlik değeri: 0.667, duyarlılık değeri: 0.632 ve F-skoru: 0.649 olarak bulundu.

Tablo 4.14. InceptionResNetV2 modelin konfüzyon matrisi

Konfüzyon matrisi			
		TAHMİN	
		UYUMLU	UYUMSUZ
GERÇEK	UYUMLU	21	6
	UYUMSUZ	7	12




Şekil 4.13. InceptionResNetV2 modelin ROC eğrisi

4.4.5. Xception Modelin Sonuçları

Xception modelin konfüzyon matriks çıktısı tablo 4.15'te ve ROC eğrisi şekil 4.14'te gösterilmiştir. Modelin doğruluk oranı: %67.0, kesinlik değeri: 0.750, duyarlılık değeri: 0.316 ve F-skoru: 0.444 olarak bulundu.

Tablo 4.15. Xception modelin konfüzyon matriksi

Konfüzyon matriksi			
		TAHMİN	
		UYUMLU	UYUMSUZ
GERÇEK	UYUMLU	25	2
	UYUMSUZ	13	6




Şekil 4.14. Xception modelin ROC eğrisi

4.4.6. MobilNetV2 Modelin Sonuçları

MobilNetV2 modelin konfüzyon matriks çıktısı tablo 4.16’da ve ROC eğrisi şekil 4.15’te gösterilmiştir. Modelin doğruluk oranı: %65.0, kesinlik değeri: 0.600, duyarlılık değeri: 0.474 ve F-skoru: 0.529 olarak bulundu.

Tablo 4 16. MobilNetV2 modelin konfüzyon matriksi

Konfüzyon matriksi			
		TAHMİN	
		UYUMLU	UYUMSUZ
GERÇEK	UYUMLU	21	6
	UYUMSUZ	10	9




Şekil 4.15. MobilNetV2 modelin ROC eğrisi

4.4.7. NasNetMobil Modelin Sonuçları

NasNetMobil modelin konfüzyon matriks çıktısı tablo 4.17’de ve ROC eğrisi şekil 4.16’da gösterilmiştir. Modelin doğruluk oranı: %70.0, kesinlik değeri: 1.000, duyarlılık değeri: 0.263 ve F-skoru: 0.417 olarak bulundu.

Tablo 4.17. NasNetMobil modelin konfüzyon matriksi

Konfüzyon matriksi			
		TAHMİN	
		UYUMLU	UYUMSUZ
GERÇEK	UYUMLU	27	0
	UYUMSUZ	14	5




Şekil 4.16. NasNetMobil modelin ROC eğrisi

4.4.8. DenseNet121 Modelin Sonuçları

DenseNet121 modelin konfüzyon matriks çıktısı tablo 4.18’de ve ROC eğrisi şekil 4.17’de gösterilmiştir. Modelin doğruluk oranı: %59.0, kesinlik değeri: 0.500, duyarlılık değeri: 0.368 ve F-skoru: 0.424 olarak bulundu.

Tablo 4.18. DenseNet121 modelin konfüzyon matriksi

Konfüzyon matriksi			
		TAHMİN	
		UYUMLU	UYUMSUZ
GERÇEK	UYUMLU	20	7
	UYUMSUZ	12	7




Şekil 4.17. DenseNet121 modelin ROC eğrisi

4.4.9. VGG16 Modelin Sonuçları

VGG16 modelin konfüzyon matriks çıktısı tablo 4.19’da ve ROC eğrisi şekil 4.18’de gösterilmiştir. Modelin doğruluk oranı: %61.0, kesinlik değeri: 1.000, duyarlılık değeri: 0.053 ve F-skoru: 0.100 olarak bulundu.

Tablo 4.19. VGG16 modelin konfüzyon matriksi

Konfüzyon matriksi			
		TAHMİN	
		UYUMLU	UYUMSUZ
GERÇEK	UYUMLU	27	0
	UYUMSUZ	18	1



Şekil 4.18. VGG16 modelin ROC eğrisi

Başarı değerlendirmesinde ana parametre olarak doğruluk oranı (accuracy) kabul edildiğinde modellerin en başarılıdan en başarısız doğru sıralaması tablo 4.20’de gösterilmiştir.

Tablo 4.20. El yazısı verilerini değerlendiren modellere ait bulgular

ESA Modelleri	Doğruluk	Kesinlik	Duyarlılık	F1-Skoru
InceptionResNetV2	%72.0	0.667	0.632	0.649
NasNetMobil	%70.0	1.000	0.263	0.417
Xception	%67.0	0.750	0.316	0.444
MobilNetV2	%65.0	0.600	0.474	0.529
ResNet101V2	%65.0	0.588	0.526	0.556
ResNet152V2	%65.0	0.588	0.526	0.556
VGG16	%61.0	1.000	0.053	0.100
DenseNet121	%59.0	0.500	0.368	0.424
ResNet50V2	%46.0	0.312	0.263	0.286

4.5. Ses Verilerini Değerlendiren ESA Modeli ve Makine Öğrenimi Algoritmalarına Ait Bulgular

Başarı değerlendirmesinde ana parametre olarak doğruluk oranı (accuracy) kabul edildiğinde ESA modeli ve makine öğrenimi algoritmaların en başarılıdan en başarısıza doğru sıralaması tablo 4.21’de gösterilmiştir.

Tablo 4.21. Ses verilerini değerlendiren ESA modeli (YamNet) ve makine öğrenimi algoritmalarına ait bulgular

ESA modeli ve makine öğrenimi algoritmaları	Doğruluk	Kesinlik	Duyarlılık	F1-Skoru
YamNet	%57.0	0.710	0.640	0.677
Linear discriminant analizi	%57.0	0.720	0.581	0.643
K’ya en yakın komşu	%57.0	0.704	0.613	0.655
DVM	%57.0	0.677	0.677	0.677
Ekstra ağaç sınıflandırıcı	%57.0	0.677	0.677	0.677
Yığılma sınıflandırıcı	%57.0	0.677	0.677	0.677
Gradyan artırma sınıflandırıcı	%55.0	0.692	0.581	0.632
Lojistik regresyon	%53.0	0.667	0.581	0.621
AdaBoost sınıflandırıcı	%51.0	0.682	0.484	0.566
Rastgele orman sınıflandırıcı	%49.0	0.640	0.516	0.571
Gaussian NB	%49.0	0.621	0.581	0.600
Gradyan artırma sınıflandırıcı	%43.0	0.577	0.484	0.526
Oylama sınıflandırıcı	%43.0	0.571	0.516	0.542
Karar ağacı sınıflandırıcı	%40.0	0.579	0.355	0.440

5. TARTIŞMA

5.1. Çalışmanın Amacı

Ortodontik tedavinin başarısı çeşitli biyolojik, biyomekanik ve psikososyal faktörlere bağlıdır (26,41). Farklı çalışmalarda hasta işbirliğinin etkisi değerlendirilmiş ve sonuç olarak hasta kooperasyonu ile tedavinin başarısı arasında güçlü bir ilişki olduğu bulunmuştur (1,33,130). Sağlık alanında kooperasyon; bireyin çevresine uyum sağlamasına ve böylece akranlarıyla uyumlu bir ilişki kurmasına olanak sağlayan yapıcı bir davranış biçimi olarak tanımlanabilmektedir (131).

Hasta uyumu birçok faktöre bağlı olabilmektedir. Bu faktörlerden bazıları ortodontistler tarafından bazıları ise hastalar veya aileleri tarafından kontrol edilmektedir (29). Literatüre göre hasta işbirliği hastanın kişilik özelliklerinden etkilenebilmektedir (132–134). Yüksek kooperasyona sahip hastalar enerjik, coşkulu, sosyal, sorumlu ve çalışkan olma eğilimindedirler (135). Ayrıca yaş, cinsiyet, sosyoekonomik durum, psikososyal yönelim, hastanın veya ailesinin ortodontist ile arasındaki etkileşim gibi birçok faktör hasta işbirliğini etkilemektedir (136,137).

İşbirliği yapmayan hastalar, tedavilerinin gereğinden fazla uzamasına, erken sonlandırılmasına veya ertelenmesine, diş ve periodontal doku hasarlarına, ekstra diş çekimine, tedavinin nüks etmesine ve ortodontistin stres düzeyinin artmasına neden olabilmektedir (3). Bu nedenle ortodontik tedaviye başlamadan önce hasta kooperasyonunun değerlendirilmesi önemlidir (3). Hasta işbirliği sadece apareyler veya ortodontik lastiklerin düzenli kullanımı ile sınırlı değildir. Aynı zamanda ağız hijyeninin korunması ve hastaların randevulara özen göstermesi konularıyla da ilişkilidir (138).

Özellikle ortodonti alanında hekim-hasta ilişkisi kooperasyonun temel faktörüdür. Planlanmış hedeflere ulaşılabilmesi ve hastanın ağız sağlığının tedavi boyunca korunabilmesi için hekimin hastasıyla iyi bir ilişki içerisinde olması gerekmektedir. Bu konuyla ilgili birçok çalışmada ortodontisti ile ilişkisi iyi olan ergen hastaların tedavi boyunca yüksek işbirliği sergiledikleri bildirilmiştir (130,137,139).

Maloklüzyon şiddeti kooperasyonu etkileyen faktörler arasında yer almaktadır. Sarul ve ark.'nın çalışmasında maloklüzyon şiddetinin hasta kooperasyonu üzerindeki etkisini araştırmış ve şiddetli maloklüzyona sahip hastaların hareketli apareylerini daha düzenli kullandıkları bildirmişlerdir (132).

Hasta kooperasyonunun değerlendirilmesi, ortodontik tedavi sırasında hastanın tedaviye karşı olan davranışlarını analiz etme tekniğidir (26,140). İşbirliğini ölçmek için en iyi bilinen araç Slakter, Albino, Fox ve Lewis tarafından tasarlanan Ortodontik Hasta Kooperasyonu Skalasıdır (OHKS) (10). Bu skala, kooperasyonun farklı çevresel faktörler ve kişilik özelliklerden etkilendiğini göstermektedir (141). OHKS aracılığıyla, ortodontik tedavi süresince hasta işbirliğindeki değişiklikler takip edilebilmektedir (26).

Son yıllarda ortodonti alanında önemli gelişmelere tanık olmaktadır. Ortodontik tedavide güncel ve daha estetik seçeneklerin ortaya çıkması ve tamamen dijital iş akışına geçiş, hem hastalar için hem de ortodontistler için yeni bir odak noktası meydana getirmiştir (142). Bunun yanı sıra ortodontik teşhis ve tedavi sürecinde verimlilik ve doğruluğu arttırmak için son yıllarda yapay zeka kullanımı önemli ölçüde artmıştır (143). Bununla birlikte yapay zekanın elde ettiği sonuçların doğruluğunun son derece başarılı olduğundan ve insan hatalarını önleyebileceğinden belirli klinik kararlarının verilmesinde ortodontiste yardımcı olabilmektedir (144).

Yapay zekanın temel amacı bir makineye öğrenme yeteneği sunmak ve makinenin öğrendiği bilgiler doğrultusunda problemleri kendi başına çözebilmesini mümkün kılmaktır. Makine öğrenimi yapay zekanın temel taşıdır ve veri setlerine dayalı sonuçları tahmin eden algoritmalarla ibarettir (145). Bu algoritmaların amacı, makinelerin öğrenmesini kolaylaştırmak ve sorunları insan müdahalesi olmadan çözebilmelerini sağlamaktır. Makine öğreniminin en yaygın kullanılan teknikleri arasında DVM, lojistik regresyon , karar ağacı, rastgele orman, KEYK, ESA, ÖSA gibi teknikler yer almaktadır (144,145).

Derin öğrenme, makine öğreniminin ayrılmaz bir parçasıdır ve girdi verilerini analiz etmek için farklı katmanlara sahip ağları kullanır. Derin öğrenme konuşma analizi, görsel nesne tanıma ve duygu analizi gibi birçok alanda kullanılabilmektedir (144,145).

Derin öğrenme, katmanlarda ilerleyen parametrelerin nasıl değiştirilmesi gerektiğini belirtmek için geri yayılım algoritmasını kullanarak karmaşık görevleri başarılı bir şekilde tamamlamaktadır. ESA; görüntü, video ve ses işlemede kullanılırken ÖSA; metin ve konuşma gibi sıralı verilerin işlenmesinde kullanılmaktadır (53).

Bu bilgiler doğrultusunda çalışmamızın amacı; hastanın ortodontik tedavi sırasında göstereceği işbirliğinin tedaviye başlamadan önce yapay zeka ile tahminin mümkün olup olmadığını test etmektir.

5.2. Gereç ve Yöntem

5.2.1. Bireyler

Literatürde kooperasyon tahmini yapılan çalışmalara bakıldığında birey seçiminde sınırlı bir yaş aralığı tercih edildiği görülmektedir. Slakter ve ark.'nın çalışmasında 11.9 – 16.9 yaş arasındaki bireyler dahil edilmiştir (10). Nanda ve ark.'nın çalışmasındaki bireylerin yaş aralığı 9 – 16 yıldır (2). Albino ve ark.'nın çalışmasında 11- 14 yaş arasındaki bireyler dahil edilmiştir (18). Sandra ve ark. çalışmalarını 10-17 yaş aralığındaki bireyler üzerinde yürütmüşlerdir (146). Benzer başka bir çalışmada 11-17 yaş aralığındaki bireyler çalışmaya dahil edilmiştir (147). Bu bilgilerden yola çıkarak ve genellikle sabit ortodontik tedavinin 12 ile 18 yaş arasında yapıldığı göz önünde bulundurularak bu yaş aralığındaki bireyler çalışmamıza dahil edildi.

Çalışmamızda yer alan bireylerin dağılımı 150 kadın 90 erkek şeklindedir. Kooperasyon değerlendirilmesi yapılan önceki çalışmalara bakıldığında cinsiyet açısından homojen bir dağılım görülmektedir (2,10,48,132); ancak bizim çalışmamızda erkeklerin sayısı kadınlara göre daha fazladır. Bazı çalışmalarda ortodontik tedavi açısından, cinsiyetin kooperasyon tahmini için bir faktör olarak kullanılabilirliği savunulurken (7,10,20,27) Howells ve Shaw'ın çalışmasında (30) cinsiyet ve kooperasyon arasında bir ilişki bulunmadığı ve cinsiyetin kooperasyon tahmininde kritik bir faktör olmadığı bildirilmiştir.


5.2.2. Veriler

Hasta işbirliğinin düzeyi ortodontik tedavi süreci ve sonucunu ciddi bir şekilde etkilemektedir. Bu yüzden tedaviye başlamadan önce hasta uyumunun öngörülmesi oldukça önemlidir. Hasta kooperasyonunu değerlendiren birçok çalışmada kooperasyon ölçümü için OHKS kullanılmıştır. Albino ve ark. otuz dokuz ergen hastada tedavilerinin 8.ay, 10.ay ve tedavi bitiminde OHKS kullanarak hasta kooperasyonunu etkileyen faktörleri araştırmışlardır (18). Nanda ve ark.nın yaptığı benzer bir çalışmada 100 ergen hastanın kooperasyon düzeylerinin tespitinde OHKS kullanılmıştır (2). Albino ve ark. da kooperasyon değerlendirmesi amacıyla ortodontik davranış inceleme anketi ve ortodontik kontrol odağı skalası ile birlikte OHKS'yi kullanmışlardır (11). Richter ve ark.'nın çalışmasında OHKS kullanılmış ve yazarlar tarafından bu yöntemin doğruluğu ve güvenilirliği teyit edilmiştir. Çalışmamızda literatür örnek alınarak hasta kooperasyonunun seviyesini ölçmek ve elde edilen sonuçlara göre yüksek kooperasyonlu ve düşük kooperasyonlu hastaları iki gruba ayırmak için OHKS' kullanılmıştır.

Literatür incelendiğinde bireylerin kişilik özelliği analizi ve duygu tanımları konularında genellikle cephe fotoğrafları, el yazısı örnekleri veya ses verileri kullanılmıştır(128,148,149).

Araştırmacılar ve psikologlara göre psikolojik özelliklerin tanınmasında yüz, anketler ve nöropsikolojik testlere göre daha nicel veriler sunabilmektedir ve kişinin yüz fotoğraflarının incelenmesi psikolojik özellikler hakkında bilgi edinmeye olanak sağlamaktadır (150). Yüz insanın sosyal bilişinde çok önemli bir rol oynamaktadır. Yüz ifadeleri, içsel durumların - duygular ve niyetlerin - önemli işaretleridir (151). Yüz sadece geçici duyguları (zevk ve öfke patlamaları, hayal kırıklığı ve nefret) tanımlamamızı sağlamakla kalmaz, aynı zamanda kişilik ve karakterin daha derin ve süregelen nitelikleri hakkında doğru kararlar vermemize de yardım edebilmektedir. Yüz analizinin çağdaş uygulamalarıyla sadece psikolojik özellikleri değil aynı zamanda genel sağlık durumu ile ilgili değerlendirmeler de yapılabilmektedir. Örneğin, yüz yapısını ve yüz özelliklerini etkileyen 700'den fazla genetik sorun bilinmektedir ve bu hastalıkların tanımlaması için özel yazılımlar geliştirilmiştir (152,153).

Ağız dışı cephe fotoğraflarından psikolojik özelliklerin tanınmasına yönelik üç ana yaklaşım vardır: 1. Fizyonomi, 2. Faz yüz portresi, 3. Oftalmogeometri. Bizim çalışmamızda bu üç temel yaklaşımdan fizyonomi kullanılmıştır. Fizyonomi, kişinin dış görünüşünün öncelikle yüzün, yüz özelliklerinin, cilt dokusunun ve kalitesinin değerlendirilmesinin, kişinin karakteri veya kişiliği hakkında fikir verebileceği düşüncesine dayanan bir teoridir (150). Fabio ve ark.'nın yüz analizi ile kişilik tanımlanması adlı çalışmasında 604 kadın ve 393 erkek olmak üzere toplam 997 fotoğraf incelenmiştir (154). Li Yao ve ark. yüz ifadesinin tahmini için yapay zeka modellerini kullandıkları çalışmada 35.886 yüz fotoğrafı içeren bir veri seti kullanılmıştır. Benzer başka çalışmalarda internette bulunan ve çok sayıda yüz fotoğrafları içeren veri setleri kullanılarak bireylerin karakteristik özelliklerinin tahmin edilmesi amaçlanmıştır (127,155,156).



Şekil 5. 1. Yüz portresinden psikolojik özelliklerin tanınmasına yönelik yaklaşımlar (150)

Ses, iletişimde önemli bir araçtır ve konuşmacının kendisini ifade etmesini sağlamaktadır. Çünkü beynimiz bir kişiye ait ilk izlenimlerini oluştururken belirli özel kriterlere göre yüzleri ve sesleri işler, bu durum görsel olmayan ipuçlarına dayalı olarak kişilerin karakterleri hakkında yorumlarda bulunabileceğimiz anlamına gelmektedir (157,158). Araştırmacılar sesten kişilik özellikleri ve duyguların başarılı şekilde çıkarılabilmesi konusunda hemfikirlerdir (159,160). Dinleyiciler, konuşmacının kişilik özelliklerine ait bilgileri sesleri aracılığıyla tahmin edebilirler. Yapılan çalışmalarda ses özelliklerine göre, insanlar duygu (161), yeterlilik (162),

dürüstlük (163), güvenilirlik (164) hakkında çıkarımlarda bulunmuşlardır. Örneğin Degroot ve ark.'nın çalışmasında sesin bireysel liderlik özelliklerini taşıdığı belirtilerek sesin çekicilik seviyesinin yüksek olması bireyin siyasi aday olarak seçilme olasılığının artmasını sağlayacağı ifade edilmiştir (165). Yapılan diğer bir çalışmanın sonucunda insan sesinin toplumsal algı için önemli bir bilgi kaynağı olduğu ve bireylerin ahlaki düzeylerini algılamada önemli bir veri olabileceği gösterilmiştir (159). Literatür incelendiğinde birçok çalışmada kişilik ve duygu analizi yapmak için ses ve konuşma kayıtlar kullanılmıştır. Örneğin Jacob'ın yaptığı çalışmada konuşmacıların sesleri yapay zeka algoritmalarıyla analiz edilerek sinirli ve heyecanlı gibi duygular sınıflandırılmıştır (166). Vedika ve ark.'nın çalışmasında yirmi dört kadın ve erkek oyuncu sesi yapay zekaya tanıtılarak seslerde mevcut olan duyguların tahmin edilmesi sağlanılmıştır (7). Benzer bir diğer çalışmada on beş bireye ait ses verileri incelenerek yapay zeka ile kişilik tiplerinin tahmin edilmesi amaçlanılmıştır (167).

El yazısı; yazarın fiziksel, zihinsel ve duygusal durumu hakkında bilgi edinmek için en zengin bilgileri taşıyan parmak izi gibi benzersiz bir veridir. El yazısını analiz etme bilimine grafoloji denir. Grafolojiye göre, diğer davranış şekilleri gibi, el yazısı da insanın kişiliği hakkında bilgi vermektedir. Bunun nedeni el yazısı şekillerinin yazarların çeşitli psikolojik özelliklerini taşımasıdır (168,169). Çoğu psikolog el yazısını birey kişiliğinin uygun deneysel kanıtlarını içerebilen kritik bir teşhis aracı olarak görür (170,171). Grafolojistler, her insanın metinlerini yazarken benzersiz eylemler gösterdiklerini söylemektedirler. Bireyin eylemleri ve jestleri, kişinin görev sırasındaki iradesini ve kararını belirtir ve görevi yerine getirirken içsel güçlerinin içsel birliğini yansıtır (172). El yazısı işleme sanatı eski metinleri geliştirmek, kelimeleri tanımak, metindeki karakterleri ayırmak, yazarı belirlemek, bireyin kişiliğini incelemek vb. gibi çeşitli amaçlarla gerçekleştirilmektedir (168). Amerika Birleşik Devletleri'nde National Pen şirketi tarafından yapılan anketlere göre, yazılardaki boşlukların nasıl uygulandığı, noktaların nasıl yerleştirildiği, harflerin nasıl döndürüldüğü ve kelimelerin sola veya sağa eğilimli olmaları gibi özellikler yaklaşık 5.000 farklı değişkeni ortaya çıkarabilir (173). Literatürde el yazılarını psikolojik açıdan değerlendiren birçok çalışma bulunmaktadır. Örneğin Das ve ark.'nın çalışmasında el yazıları kullanılarak bireylerin kişilik özellikleri incelenilmiştir (85). Navonil ve ark. yüzlerce el yazısından oluşan “bilinç akışı

denemeleri“ adlı veri setini inceleyerek el yazısı ile yazarların kişilikleri arasındaki ilişkiyi araştırmışlardır.

Yukarıda bahsi geçen literatür bilgileri ışığında çalışmamızda OHKS ile tespit ettiğimiz uyumlu ve uyumsuz hastalardan cephe fotoğrafları, el yazısı örnekleri ve ses verileri elde edildi ve kooperasyon tahmininin sağlanması için bu veriler makine öğrenimi algoritmalarına tanıtılarak incelendi.

5.2.3. Yöntem

Duygu tahmini ve kişilik öngörülmesi gibi çalışmalarda çeşitli yöntemler ve farklı algoritmalar içeren yapay zeka modelleri kullanılmıştır (13,128,174). Kalani ve Fernando 2016 yılında yaptıkları çalışmada DVM ve YSA modelini kullanarak yüz fotoğrafları üzerinden duygu tahmininde bulunmuşlardır (175). Bu çalışmada 66 fotoğraftan oluşan Karolinska veri seti kullanılmıştır. Murugappan ve ark. seksen beş öğrencinin fotoğrafını yapay zekaya tanıtarak KEYK, karar ağacı, YSA, rastgele orman ve DVM kullanarak yüzün duygusal ifadelerini sınıflandırmışlardır (176). Aynı amaçla yapılan farklı bir çalışmada duyguların sınıflandırılması için VVG16 modeli kullanılmıştır (177). Jia ve ark.’nın yapay zeka ile kişisel özelliklerin tahmini konulu çalışmasında 8000’den fazla fotoğrafın analizi MobilNetV2 ve ResNet50 modelleri ile yapılmıştır; ancak literatürde yapay zeka ile ortodontik tedavi gören hastaların kooperasyonunun öngörülmesiyle ilgili bir çalışma bulunmamaktadır.

El yazısı örneklerini kullanan çalışmalara bakıldığında Das ve ark. İngilizce metinlerden oluşan el yazılarını incelemek için yapay zeka modeli olan GMM kullanmışlardır (85). Aynı amaçla yapılan başka bir çalışmada ESA modelinden yardım alınmıştır (15). Ghods ve ark.’nın çalışmasında Farsça dilindeki el yazıları GMM modeline tanıtılarak bazı Farsça karakterlerinin tahmin edilmesi sağlanmıştır (178). Sun ve ark.’nın çalışmasında yapay zeka yardımıyla el yazıları analiz edilerek bireylerin psikolojik özellikleri tanımlanmıştır (179). Bunun için ESA ve ÖSA modellerinin birleşiminden elde edilen hibrit bir model kullanılarak kabul edilebilir sonuçlar elde edilmiştir.

Literatürde ses ya da konuşma analizinde yapay zeka modellerinin kullanımını gösteren çalışmalar da mevcuttur. Mohammedpour ve Farokhi çalışmalarında YSA modeli ile ses kayıtları üzerinden sayıların tanımını sağlamışlardır (180). Agnes ve ark.'nın çalışmasında on kadının ses kaydı lojistik regresyon ve karar ağaçları algoritmalarıyla incelenerek seslerde mevcut olan sevinç, üzüntü, sinirlilik ve heyecan gibi duyguların tanımlanması sağlanmıştır (166). Benzer bir diğer çalışmada Ashraf tahseen ve ark. makine öğrenimi ile ses tanıma konulu çalışmalarında rastgele orman, KEYK, karar ağacı ve naive bayes modellerinin performansı karşılaştırılmıştır (181). Brusa ve ark. 2021 yılında düzgün çalışan ve arızalı elektrikli makine motorlarının sesinden oluşan bir veri seti üzerinde çalışarak farklı arızalara sahip ve sorunsuz motor sesleri YamNet modeli kullanılarak sınıflandırılmıştır. 2020 yılında George ve ark. yüz bir kişiden elde ettikleri ses verilerini uzmanlar tarafından incelendikten sonra 4 kategoriye ayrılmış ve daha sonra YamNet ile bu verileri sınıflandırarak bu derin öğrenme modelin performansı test edilmiştir (182).

Bu bilgilerden yola çıkılarak çalışmamızda ses, el yazısı ve yüz fotoğraflarını analiz etmek için literatürde en çok tercih edilen makine öğrenimi algoritmaları ve ESA modellerinin kullanımına karar verildi. Yüz fotoğrafları ve el yazılarının işlenilmesinde InceptionResNetV2, NasNetMobil, Xception, MobilNetV2, ResNet101V2, ResNet152V2, VGG16, DenseNet121 ve ResNet50V2 olan derin öğrenme modelleri kullanıldı. Ses verilerinin işlenmesinde makine öğrenimi algoritmaları olan Linear discriminant analizi, KEYK, DVM, Ekstra ağaç sınıflandırıcı, Yığılma sınıflandırıcı, Gradyan artırma sınıflandırıcı, Lojistik regresyon, AdaBoost sınıflandırıcı, Rastgele orman sınıflandırıcı, Gaussian NB, Gradyan artırma sınıflandırıcı ve güncel derin öğrenme modeli olan YamNet kullanıldı.

5.3 Bulguların Tartışılması

5.3.1. Fotoğraflar ile Yapılan Kooperasyon Değerlendirilmesi

Literatürde yüz fotoğraflarını değerlendiren çalışmalarda kullanılan çeşitli makine öğrenimi algoritmalar ile farklı başarı oranları elde edilmiştir. Yüz fotoğraflarını kullanarak duygusal ifadeleri sınıflandıran bir çalışmada seksen beş fotoğraftan oluşan veri setinde KEYK, karar ağaçları, YSA, rastgele orman ve DVM kullanılarak karşılaştırma yapılmıştır (176). Bu çalışmanın sonucuna göre rastgele

orman %98.2 doğruluk oranına ulaşarak diğer algoritmalarından daha başarılı bir sınıflandırma yapmıştır. Aynı amaçla yapılan başka bir çalışmada 593 fotoğraftan oluşan CK+ data seti ESA yapısına sahip olan AlexNet'e tanıtılıp modelin sınıflandırma yapması sağlanılmıştır ve bu işlem sonunda %76.6 başarı oranına ulaşılmıştır (183). Gao ve ark.'nın çalışmasında VGG16 modeli kullanılarak %80.5 başarıya ulaşılmıştır (177). Maiwan ve ark.'nın ise 2021 yılında öznitelik seçimine dayalı yüz ifadesinin sınıflandırılması başlıklı çalışmasında CK+ veri seti üzerinde KEYK, karar ağaçları, DVM, rastgele orman ve YSA modeli denenmiştir (156). Karşılaştırma sonucu KEYK sınıflandırıcı ile en yüksek başarı oranına (%94.9) ulaşıldığı bildirilmiştir. Diğer bir çalışmada DVM ve YSA modellerin performansı karşılaştırılmış ve YSA %98.5 başarı oranına ulaşarak daha başarılı bulunmuştur; ancak bu çalışmalarda sevinçli, sinirli, üzgün gibi belirgin ifadelerle sahip yüzlerin tanınması sağlanmıştır ve fotoğraflarda belirgin olan duygulara göre sınıflandırma yapılmıştır. Mutlu veya üzgün bir yüzün ayrımı bir insan için kolay olduğu gibi makine öğrenimi için de kolaydır. Bizim çalışmada nötr veya ifadesiz yüzlerden alınan fotoğraflar kullanılmıştır. Bu şekilde ESA modelleri belirgin yüz ifadelerini kullanarak duyguları tahmin etmek yerine ifadesiz yüzlerden hasta kooperasyonun yeteri olup olmadığını tahmin etmiş olacaktır. Kooperasyon tahmini daha çok bir sezgisel davranış olduğundan kullanılan ESA modelleri bir uzman gibi fizyonomi kurallarından yararlanarak mimiksiz yüzün yapılarını ve bu yapılar arasındaki özel ilişkileri kullanarak tahminlerde bulunmuş olacaktır. Böylece yapay zeka sınırlarını zorlayarak sezgisel bir davranışın matematiksel yöntemlerle taklit edilmesi sağlanmış olacaktır.

Az da olsa yöntem açısından çalışmamıza benzeyen birkaç araştırma literatürde mevcuttur. Jingferg ve Hongli'nin çalışmasında 240 yüz fotoğrafından oluşan IMM (Informatics and Mathematical Modelling, Bilişim ve Matematiksel Modelleme) veri seti kullanılarak fotoğraf sahiplerinin en belirgin kişilik özelliği (dışa dönüklük, açıklık, uyumluluk ve titizlik) üç farklı yapıya sahip YSA ile sınıflandırılmıştır (184). Sonuçlara göre bu modeller ile %77.2, %81.5 ve %85.3 başarı oranına ulaşılmıştır. Jingferg ve Hongli'nin çalışması kullanılan fotoğraf sayısı ve sınıflandırılmış psikolojik davranışlar açısından bizim çalışmaya yakındır; fakat kullanılan veri setindeki fotoğraflar belli bir duygu durumunu yansıtmaktadır; ancak bizim

çalışmamızda kullanılan cephe fotoğrafları istirahatte alınmış ve herhangi bir duygu durumunu yansıtmamaktadır.



Şekil 5.2. IMM veri seti örnekleri

Konsinski'nin çalışmasında birçok farklı ülke ve ırklardan katılan 1.085.795 katılımcının siyasi parti (liberal veya muhafazakâr) yönelimleri çevrimiçi anketler kullanılarak tespit edilip daha sonra katılımcıların sosyal medya profil fotoğrafları VGG face2 derin öğrenme modeli ile anket sonuçlarına göre sınıflandırılmıştır (148). Çalışma sonucunda modelin %73.0 oranında doğru sınıflandırma yapabildiği bildirilmiştir. Daha önceden belirtildiği gibi bu çalışmada da kullanılan fotoğraflar ifadesiz yüz fotoğrafları olmamakla birlikte vücudun diğer uzuvlarını kapsayan ve daha önemlisi bireylerin giyim ve hayat tarzını yansıtan ayrıntıları içeriyordu. Bu ayrıntıların belirgin veriler anlamına geldiği için yapay zekanın yorumlamasını kolaylaştırabildiğini düşünmekteyiz. Çalışmamıza benzer başka bir çalışmada 94 erkek ve 94 kadın ifadesiz yüz fotoğrafından oluşan veri seti oluşturulduktan sonra fotoğraf sahiplerinin zeka ve kişilik özellikleri ESA modeli kullanılarak tespit edilmeye çalışılmıştır (185). Elde edilen sonuçlar önceden uygulanmış psikolojik testler ile karşılaştırılmış ve her sınıfın başarısı ayrı ayrı değerlendirilmiştir. Sınıflandırma işleminde %53.4 – 82.0 arası ve ortalama %61.6 başarı elde edilmiştir.

Literatürde; “beş büyük kişilik özelliği” olarak bilinen açıklık, sorumluluk, dışadönüklük, uyumluluk ve duygusal denge özelliklerinden oluşan model birçok çalışmada araştırma konusu olmuştur. Ruh biliminde “beş büyük kişilik özelliği” deneysel araştırma ile keşfedilmiş beş önemli etmen veya kişilik boyutudur. Bu model

hakkında ilk genel ima, 1933 yılında Amerikan Psikoloji Birliği için yapılan başkanlık söylevinde, L. L. Thurstone tarafından yapılmıştır (186). Bu modelin içerdiği kişilik özellikleri yapay zeka ile ilgilenen araştırmacıların dikkatini de çekmiştir. Örneğin Al moubayet ve ark.'nın çalışmasında 829 fotoğraf kullanılarak fotoğraf sahiplerinin bu beş özellikten hangisine daha yakın olduğu yapay zeka ile tespit edilmiştir. Bu çalışmada sınıflama için DVM algoritması kullanılmıştır ve sonuç olarak %70.0 başarı elde edilmiştir (187); ancak çalışmada kullanılan fotoğraflar bireylerin çeşitli duygularını içeren ve ifadesiz olmayan fotoğraflardan oluşan FERET (The Facial Recognition Technology, Yüz Tanıma Teknolojisi) veri setinden elde edilmiştir.



Şekil 5.3. FERET veri seti örnekleri

Bizim çalışmamızda ise 230 ifadesiz cephe fotoğrafı kullanıldı ve çeşitli modeller ile incelendi. En başarılı sonuçlar %66.0 oranla Xception ve DenseNet modeller ile elde edildi ve en başarısız sonuç %48.0 ile ResNet101V2 modeli ile kayıtlı edilmiştir.

Konfüzyon matrisi incelendiğinde ResNet50V2 %70.4 başarı oranıyla uyumlu hastaların tahmininde, Xception ve DenseNet121 ise %57.9 başarı oranıyla uyumsuz hastaların tahmininde en yüksek performansı sergilemiştir.

Önceden bahsettiğimiz ve çok çeşitli limitasyona sahip olan çalışmalara rağmen literatürde ister kullanılan fotoğrafların standardizasyonu açısından ister araştırmanın amacı açısından bizim çalışmaya yakın olan bir çalışma mevcuttur. Hashemi ve Salonu'nin çalışmasında Ulusal Standartlar ve Teknoloji Enstitüsü Özel Veri Tabanından elde edilmiş 5000 suçlu erkek ve kadının ifadesiz cephe fotoğrafları ile birlikte diğer çevrimiçi veri tabanlarından elde edilmiş 5000 suçsuz erkek ve

kadının ifadesiz cephe fotoğraflarından bir veri seti oluşturulmuştur. Ardından bir ESA tasarlanarak bu fotoğrafların suçlu veya suçsuz olarak hangi guruba ait oldukları tahmin edilmiştir (188). Bu çalışmanın bizim için önem taşıdığı noktalardan birisi veri setinin büyüklüğü ve diğeri kullanılan fotoğrafların ifadesiz yüzden elde edilmiş olmasıdır. Veri setinin büyük olması çalışma sonucunu ve güvenilirliğini arttırmaktadır. Fotoğrafların ifadesiz olması ise çalışma metodunun bizim çalışmaya ne kadar yakın olduğunu göstermektedir. Çalışma sonucunda kayda değer ve yüksek bir başarı oranı elde edilmiştir. Tasarlanan ESA modeli %97.0 oranla başarılı bir şekilde sınıflandırma işlemini gerçekleştirmiştir. Elde edilmiş olan bu başarı oranı umut vericidir. Gelecekte, Çalışmamızda kullandığımız veri setinin büyüklüğünün artırılması ve kullanılan yapay zeka modellerinin geliştirilmesi durumunda bizimde yüksek başarı oranına ulaşmamız mümkün olabilecektir.

5.3.2. Ses Verileri ile Yapılan Kooperasyon Değerlendirilmesi

Çeşitli çalışmalarda psikolojik değerlendirme amacıyla ses verilerinin yapay zeka ile incelenmesi uygun bulunmuştur; ancak fotoğraflarda olduğu gibi seslerin belirgin özellikleri veya heyecan gibi belirgin duygularından faydalanılarak tanıma ve sınıflandırma yapılmıştır. Yapılan bir çalışmada arızalı elektrikli motorların sağıamlardan ayırt edilmesi için motor sesleri YamNet modeline tanıtılıp modelin başarısı değerlendirilmiştir (126). YamNet bu görevde %90.0 oranına başarı göstermiştir. Gupta ve ark.'nın çalışmasında seslerin taşıdıkları duygulara göre sınıflandırılması için dört yapay zeka modeli kullanılmıştır (7). Bu çalışmanın sonuçlarına göre rastgele orman algoritmasıyla %76.0 ESA modeli ile %91.0, DVM ile %50.0 ve karar ağacı algoritması ile %80.0 oranında başarı kaydedilmiştir. Srinarong ve Mongkolnavin'nin çalışmasında 92 ses kaydı kullanılarak duygu tanıma yapılmıştır (189). Bu çalışmada lojistik regresyon, DVM, rastgele orman algoritmalarıyla birlikte ESA modeli kullanılarak sırasıyla %73.0, %71.0, %64.0 ve %75.0 başarı oranına ulaşılmıştır. Jawankar ve ark.'nın çalışmasında YSA ile 50 ses kaydı işlenerek konuşmacının tahmin edilmesi sağlanılmıştır (190). Sonuç olarak %99.0 oranında başarı elde edildiği bildirilmiştir. Diğer bir çalışmada ise konuşmacı tespiti için DVM kullanılarak %92.0 başarı oranına ulaşılmıştır (191). Tahseen ve ark.'nın çalışmasında çeşitli veri setleri üzerinde yapay zeka algoritmaların ses tanıma performansının araştırılması sonucunda en başarılı algoritma %98.0 ile rastgele orman

ve ikinci sırada ise %92.0 başarı oranı ile Naive Bayes olduğu bildirilmiştir (181). Sağlık alanında da ses tanıma teknolojilerinden yararlanılmaktadır. Hao ve ark. yapay zeka ile bireylerin sesinden vokal fold hastalığının teşhis edilmesi amacıyla tasarladıkları ESA modeli ile %66.9 başarı oranına ulaşılmıştır.

Bahsettiğimiz bu çalışmalarda seslerin belirgin özelliklerinden yararlandıkları için kullandıkları yöntem bireyin kişiliği ile ilgili sınırlı bilgiler vermektedir. Fotoğrafların analizinde olduğu gibi psikolojik özelliklerin çıkarılması ve onların değerlendirilmesi kooperasyon tahmini açısından daha yararlı olabilmektedir. Kişilik özelliklerinin belirlenmesi ve psikolojik davranışların incelenmesi açısından Ses verilerini değerlendiren çalışmalar da literatürde bulunmaktadır. Örneğin Zhen-tao ve ark.'nın çalışmasında beş büyük kişilik özelliğine göre hazırlanmış SSPNet (Scale Selection Pyramid Network, Ölçek Seçimi Piramit Ağı) veri seti kullanılarak DVM, KEYK ve lojistik regresyon algoritmalarının kişilik özelliklerinin tanımlanmasındaki performansları değerlendirilmiştir (192). Değerlendirme sonucu bu algoritmalarla kaydedilen en yüksek değerler %72.0 (DVM), %70.0 (KEYK) ve %71.0 (lojistik regresyon) olarak bildirilmiştir. Fallahzade ve ark.'nın benzer bir çalışmasında beş büyük kişilik özelliğinin sınıflandırılması için DVM algoritmasının başarı seviyesi değerlendirilmiştir (193). Bunun için NEO-FFI psikolojik inceleme testine göre değerlendirilmiş 140 kişinin ses kaydı elde edildikten sonra DVM ile sınıflandırılmış ve çeşitli modifikasyonlar ile %74.0- 80.0 arası başarıya ulaşılmıştır. Polzehl ve ark.'nın çalışmasında aynı yöntem ve algoritma 220 ses kaydı üzerine uygulanmıştır ve %60.0 başarıya ulaşıldığı bildirilmiştir (194). George ve Tabias'ın çalışmasında davranışları dört uzman tarafından değerlendirilmiş ve kişiliklerine göre üç farklı gruba yerleştirilmiş 87 yaşlı bireyin ses verileri farklı YSA modelleri ile sınıflandırılmış ve sonuç olarak ortalama %50.0 oranında başarıya ulaşıldığı bildirilmiştir (195). Çalışmamızda ses özelliklerinden yararlanarak hastaların koopere olup olmadığını tespit etmek amacıyla çeşitli makine öğrenimi algoritmaları ve bir ESA modeli kullanıldı ve en yüksek başarı oranı %57.0 olarak beş farklı makine öğrenimi algoritması (Liner diskriminant analizi, KEYK, DVM, ekstra ağaç sınıflandırıcı, yığma sınıflandırıcı) ve YamNet modeli ile elde edildi. En düşük tahmin yüzdesi ise %40.0 olarak karar ağacı sınıflandırıcısı ile kaydedildi.

5.3.3. El Yazısı Verileri ile Yapılan Kooperasyon Değerlendirilmesi

El yazısı parmak izi gibi kişiye has bir özelliktir ve incelenmesi ile bireyin kişiliği ve karakteri hakkında nicel veriler elde edilebilmektedir. Literatüre bakıldığında el yazısının çeşitli yapay zeka algoritmaları ile incelenmesi sonucu farklı düzeyde başarılar elde edilmiştir. Sun ve ark.'nın çalışmasında psikoloji alanıyla ilgili olan “bilinç akışı denemeleri” adlı veri setindeki el yazısı örnekleri LSTM ve ESA kullanılarak beş büyük kişilik özeliğine (açıklık, sorumluluk, dışadönüklük, uyumluluk ve duygusal denge) göre sınıflandırılmıştır (179). Bu çalışmada LSTM modeli ile %58.0, ESA modeliyle %51.0 ve LSTM+ESA kombinasyonu ile oluşturulmuş model ile %59.0 oranında başarıya ulaşılmıştır. Navonil ve ark.'nın çalışmasında “bilinç akışı denemeleri” veri seti üzerinde daha farklı mimariye sahip olan bir ESA modeli ile kişilik sınıflandırılması yapılarak %63.0 başarı oranı kaydedilmiştir (196). Fallah ve Khottanlu'nin çalışmasında psikolojik kişilik testi olan MMPI (Minnesota Multiphasic Personality Inventory, Minnesota Çok Yönlü Kişilik Envanteri) ile değerlendirilmiş 70 kişiden elde edilen el yazısı örnekleri YSA modeli ile MMPI sonuçlarına göre sınıflandırılmış ve bu işlem sonucu %61.0 oranında başarıya ulaşıldığı bildirilmiştir (197). Diğer bir çalışmada 56 öğrencinin kişilik tipi psikolojik testlere göre tespit edildikten sonra 7 gruba ayrılmıştır (198). Bu öğrencilerden elde edilen el yazısı örnekleri öznitelik çıkarma işlemine tabi tutulduktan sonra DVM, KEYK, Ada boost algoritmaları ve YSA modeli kullanılarak sınıflandırma yapılmıştır. Sonuç olarak kullanılan algoritmalar ve YSA modeli ile sırasıyla %66.1, %68.0, %73.0 ve %84.0 başarı oranına ulaşılmıştır. Yapay zeka ile kişilik tahmini yapılan başka bir çalışmada 83 bireyin kişilik tipi Jung-Myers testi ile tespit edildikten sonra bireylerden elde edilen arapça el yazıları öznitelik çıkarma aşaması ardından farklı makine öğrenimi modelleriyle sınıflandırılmıştır (199). Bu çalışmada elde edilen başarı sıralanması şu şekilde bildirilmiştir: karar ağacı sınıflandırıcı %71.0, KEYK sınıflandırıcı %61.0, rastgele orman sınıflandırıcı %60 ve basit lojistik sınıflandırıcı %66.0. Jose ve ark.'nın çalışmasında beş büyük kişilik özeliğine göre sınıflandırılmış el yazı örneklerinden oluşan veri seti kullanılarak yazarlar tarafından tasarlanmış bir ESA modelinin sınıflandırma performansı test edilmiş ve elde edilen sonuç AUC eğrisine göre değerlendirilmiştir (149). AUC değeri ROC eğrisinin altındaki alanı temsil eder ve ideal değeri 1 olmalıdır. Bu çalışmada elde edilen AUC değeri 0.502 olarak bildirilmiştir. Bazı araştırmacıların el

yazılarından yazarların kişiliğini tanıma amaçlı yaptıkları çalışmalarda el yazısı örneklerini incelemek için farklı mimarilere sahip YSA modeller tasarlanarak yüksek başarı oranlarına ulaşılmıştır. Örneğin; Gavrilesca ve Vizireanu'nun çalışmasında beş büyük kişilik özelliğine göre gruplandırılmış el yazılarının başarılı bir şekilde sınıflandırılabilmesi için bir YSA modeli tasarlanmış ve bu model ile %84.0 başarıya ulaşıldığı bildirilmiştir (200). Gavrilesca'nın diğer bir çalışmasında el yazılarının yazarların kişiliğine göre sınıflandırmasını yapan ve daha önce kullanılan modellere göre daha farklı bir mimariye sahip olan YSA modeli geliştirilmiştir ve bu YSA modeli %87.0 oranında başarılı olduğu bildirilmiştir.

Bizim çalışmamızdan elde edilen sonuçlar yukarıda bahsedilen çalışmaların sonuçlarıyla kıyaslandığında birçoğundan daha yüksek başarı oranına ulaştığını görmekteyiz. Kullanılan modellerden InceptionResNet ile %72.0 ve NasNetMobile ile %70.0 başarı oranına ulaşılmıştır. Bu da bireyin el yazısı ile kooperasyonu arasında güçlü bir ilişkinin olduğunu ve el yazısının incelenmesi kooperasyon tahmini için güvenilir bir yöntem olduğunu göstermiştir.

Konfüzyon matrisi incelendiğinde NasNetMobile ve VGG16 %100 başarı oranıyla uyumlu hastaların tahmininde, InceptionResNetv2 ise %63.1 başarı oranıyla uyumsuz hastaların tahmininde en yüksek performansı sergilemiştir.

Tüm bulgular göz önünde bulunduğunda çalışmamızda en verimli sonuçlar el yazısı verilerin işlenmesiyle elde edilmiştir (%72.0). Fotoğraf verilerin incelenmesi sonucunda ise %66.0 başarı oranına ulaşılmıştır. Elde edilen bu sonuç literatürdeki benzer çalışmaların sonucuyla karşılaştırıldığında ortalamaya yakın bir başarı oranının elde edildiği söylenilebilir. Ses verilerin değerlendirilmesi ile maksimum %57.0 başarı oranı kaydedilmiştir. Bu oran el yazısı ve yüz fotoğraflarından elde edilen değerlere göre daha düşüktür; ancak ortodontistlerin hasta kooperasyonu ile ilgili fikir edinmesine yardımcı olabileceğini düşünmekteyiz.

Çalışmamızın bazı limitasyonları mevcuttur. Bunlardan en önemlisi veri setimizin yeterince büyük olmamasıdır. Önceden de bahsedildiği gibi veri setinin büyüklüğü modeller ve algoritmaların eğitimi ve sonuçların doğruluğu ve güvenilirliği açısından önemlidir. Her ne kadar bu eksikliği öğrenim aktarımı tekniği ile telafi etmeye çalışsak da her zaman veri setinin büyük olması önemli bir avantaj

sayılmaktadır. Veri setinin küçük olması hastaları uyumlu ve uyumsuz olarak sadece iki grup halinde sınıflandırmamıza olanak vermiştir; ancak daha büyük veri setlerin olması durumunda OHKS formundan elde edilen skorlara göre hastaları 1 ile 10 arasında birçok gruba ayırmak mümkün olabilirdi. Bu şekilde hasta kooperasyonunun seviyesi da ölçülmüş olurdu. Diğer bir limitasyon görsel verilerin işlenmesinde kullanılan modellerin standart bir mimariye sahip olmasıdır. Modellerin mimarisi geliştirilerek araştırmanın amacına uygun bir tasarım ile modifiye edilmesi veya uyumlu ve uyumsuz hastaların tahmininde en yüksek başarıyı elde edilen modellerin kombinasyonu ile hibrit bir modelin oluşturulması, elde edilen başarı oranının yükseltilmesine yardımcı olabilirdi.

Bu çalışmada sadece ortodontistlerin klinik izlenimine dayanılarak kooperasyon durumu değerlendirilmiştir. Bu verilere ek olarak hastanın cinsiyeti, yaşı, maloklüzyonunun şiddeti, ebeveyni ile ilişkisi gibi kişiye özel bilgilerin veri setine eklenmesi çalışma sonuçlarını olumlu bir şekilde etkileyebilirdi; ancak biz bu çalışmada özellikle fotoğraf, ses ve el yazısının kooperasyon değerlendirmesindeki yalın etkisini test etmek istedik.

Sonuç olarak çalışmamızda çeşitli makine öğrenimi modelleri ve algoritmaları kullanarak en iyi sonucu elde etmeye çalıştık; ancak bu alanda daha ileri çalışmaların yapılmasına ihtiyaç olduğunu düşünmekteyiz.

6. SONUÇLAR

Hastalardan elde edilen fotoğraflar, ses verileri ve el yazısı örneklerinin çeşitli makine öğrenimi algoritmaları ve ESA modelleriyle işlenmesi sonucu hasta kooperasyonunu tedaviye başlamadan önce tahmin edebilen bir yöntemi araştırdığımız bu çalışmada görsel verilerin analizi için 9 farklı ESA modeli ve ses verileri için 13 makine öğrenimi algoritması ve bir ESA modeli kullanılmıştır. Bu algoritma ve modellerin performansını karşılaştırma neticesine şu sonuçlara ulaşılmıştır:

- Yüzün fizyonomi özellikleri, sesin tonu ve frekansı, el yazısının özellikleri kooperasyon tahmini için kullanılabilir.
- El yazısı; yüz ve sese göre kooperasyon ile ilgili daha çok bilgi taşımaktadır.
- El yazısı örneklerinin değerlendirilmesinde kullanılan modellerden InceptionResNetV2 %72.0 ve NasNetMobile %70.0 ile en yüksek başarıyı kaydeden modeller olmuşturlar.
- Yüz fotoğrafların değerlendirilmesinde kullanılan modellerden Xception ve DenseNet modelleri %66.0 ile en yüksek başarı oranına ulaşmışlardır.
- Ses verilerinin değerlendirilmesinde kullanılan algoritmalarından beşi, (Liner discriminant analizi, KEYK, DVM, ekstra ağaç sınıflandırıcı, yığma sınıflandırıcı) ESA modeli olan YamNet ile birlikte %57.0'ye ulaşarak en yüksek performansı sergilemişlerdir.

7. KAYNAKLAR

1. Clemmer E, orthodontics EH-A journal of, 1979 undefined. Patient cooperation in wearing orthodontic headgear. Elsevier [Internet]. [cited 2022 Feb 21]; Available from: <https://www.sciencedirect.com/science/article/pii/0002941679900708>
2. Nanda R, Dentofacial MK-AJ of O and, 1992 undefined. Prediction of cooperation in orthodontic treatment. Elsevier [Internet]. [cited 2022 Feb 21]; Available from: <https://www.sciencedirect.com/science/article/pii/0889540692700108>
3. Bos A, Hoogstraten J, ... BP-A of orthodontics and, 2003 undefined. On the use of personality characteristics in predicting compliance in orthodontic practice. ajodo.org [Internet]. [cited 2022 Mar 23]; Available from: [https://www.ajodo.org/article/S0889-5406\(03\)00050-7/abstract](https://www.ajodo.org/article/S0889-5406(03)00050-7/abstract)
4. Lyons E, Orthodontics DR-S in, 2000 undefined. A self-regulation model of patient compliance in orthodontics: implications for the design of a headgear monitor. Elsevier [Internet]. [cited 2022 Feb 21]; Available from: <https://www.sciencedirect.com/science/article/pii/S1073874600800481>
5. El-Mangoury NH. Orthodontic cooperation. Am J Orthod. 1981 Dec 1;80(6):604–22.
6. Dubey R, Jalili VP, Garg S. Oral hygiene and gingival status in orthodontic patients. J Pierre Fauchard Acad. 1993;7(2):43–54.
7. Gupta V, Juyal S, Pal Singh G, Killa C, Gupta N. Emotion recognition of audio/speech data using deep learning approaches © Emotion recognition of audio/speech data using deep learning approaches. 2020;41(6):1309–17. Available from: <https://www.tandfonline.com/action/journalInformation?journalCode=tios20>
8. Sergl HG, Klages U, Pempera J. On the prediction of dentist-evaluated patient compliance in orthodontics. Eur J Orthod [Internet]. 1992 Dec [cited 2022 Feb 22];14(6):463–8. Available from: <https://pubmed.ncbi.nlm.nih.gov/1486932/>
9. Mehra T, Nanda R, Orthodontist PS-TA, 1998 undefined. Orthodontists' assessment and management of patient compliance. meridian.allenpress.com [Internet]. [cited 2022 Feb 21]; Available from: <https://meridian.allenpress.com/angle-orthodontist/article-abstract/68/2/115/58388>
10. Slakter MJ, Albino JE, Fox RN, Lewis EA. Reliability and stability of the orthodontic patient cooperation scale. Am J Orthod. 1980 Nov 1;78(5):559–63.
11. Albino J. albino Predicting cooperation in orthodontic treatment. - Search Results - PubMed [Internet]. [cited 2022 Feb 22]. Available from: <https://pubmed.ncbi.nlm.nih.gov/?term=albino+Predicting+cooperation+in+or>

thodontic+treatment.

12. Govindan VK, Shivaprasad AP. Character recognition — A review. *Pattern Recognit.* 1990 Jan 1;23(7):671–83.
13. Mantas J. An overview of character recognition methodologies. *Pattern Recognit.* 1986 Jan 1;19(6):425–30.
14. Noorbakhsh-Sabet N, Zand R, Zhang Y, Abedi V. Artificial Intelligence Transforms the Future of Health Care. *Am J Med.* 2019 Jul 1;132(7):795–801.
15. Yadav U, Verma S, Xaxa DK, Mahobiya C. A deep learning based character recognition system from multimedia document. 2017 *Innov Power Adv Comput Technol i-PACT 2017.* 2017;2017-January:1–7.
16. Weng Y, Xia C. A New Deep Learning-Based Handwritten Character Recognition System on Mobile Computing Devices. *Mob Networks Appl* [Internet]. 2020 Apr 1 [cited 2022 Jun 28];25(2):402–11. Available from: <https://link.springer.com/article/10.1007/s11036-019-01243-5>
17. Albino JEN, Lawrence SD, Tedesco LA. Psychological and social effects of orthodontic treatment. *J Behav Med.* 1994 Feb;17(1):81–98.
18. Albino JEN, Lawrence SD, Lopes CE, Nash LB, Tedesco LA. Cooperation of adolescents in orthodontic treatment. *J Behav Med.* 1991 Feb;14(1):53–70.
19. Fields RS. Influencing patient cooperation. *J Clin Orthod.* 1980 Jun;14(6):417–21.
20. Richter D, Nanda R, ... PS-TA, 1998 undefined. Effect of behavior modification on patient compliance in orthodontics. *meridian.allenpress.com* [Internet]. [cited 2022 Feb 21]; Available from: <https://meridian.allenpress.com/angle-orthodontist/article-abstract/68/2/123/58392>
21. Egolf R, BeGole E, and HU-AJ of O, 1990 undefined. Factors associated with orthodontic patient compliance with intraoral elastic and headgear wear. Elsevier [Internet]. [cited 2022 Feb 23]; Available from: <https://www.sciencedirect.com/science/article/pii/088954069070106M>
22. Beckwith F, Jr RA, ... CC-A journal of, 1999 undefined. An evaluation of factors affecting duration of orthodontic treatment. Elsevier [Internet]. [cited 2022 Feb 21]; Available from: <https://www.sciencedirect.com/science/article/pii/S0889540699702659>
23. Gross A, Samson G, orthodontics MD-A journal of, 1985 undefined. Patient cooperation in treatment with removable appliances: a model of patient noncompliance with treatment implications. Elsevier [Internet]. [cited 2022 Feb 27]; Available from: <https://www.sciencedirect.com/science/article/pii/000294168590199X>
24. Allan TK, Hodgson EW. The use of personality measurements as a

- determinant of patient cooperation in an orthodontic practice. *Am J Orthod* [Internet]. 1968 [cited 2022 Feb 28];54(6):433–40. Available from: <https://pubmed.ncbi.nlm.nih.gov/5239301/>
25. Crawford TP. A multiple regression analysis of patient cooperation during orthodontic treatment. *Am J Orthod* [Internet]. 1974 Apr 1 [cited 2022 Mar 1];65(4):436–7. Available from: <http://www.ajodo.org/article/000294167490284X/fulltext>
 26. Orthodontics JA-S in, 2000 undefined. Factors influencing adolescent cooperation in orthodontic treatment. Elsevier [Internet]. [cited 2022 Feb 22]; Available from: <https://www.sciencedirect.com/science/article/pii/S107387460080047X>
 27. III AC, Orthodontist RS-TA, 1990 undefined. Relationship between compliance by adolescent orthodontic patients and performance on psychological tests. *meridian.allenpress.com* [Internet]. [cited 2021 Dec 20]; Available from: <https://meridian.allenpress.com/angle-orthodontist/article-abstract/60/2/107/56061>
 28. Profile of an Excellent Orthodontic Patient | The Angle Orthodontist [Internet]. [cited 2022 Feb 28]. Available from: <https://meridian.allenpress.com/angle-orthodontist/article/45/2/141/56581/Profile-of-an-Excellent-Orthodontic-Patient>
 29. Sergl H, Orthodontics AZ-S in, 2000 undefined. Predicting patient compliance in orthodontic treatment. Elsevier [Internet]. [cited 2022 Jul 15]; Available from: <https://www.sciencedirect.com/science/article/pii/S1073874600800493>
 30. Howells DJ, Shaw WC. The validity and reliability of ratings of dental and facial attractiveness for epidemiologic use. *Am J Orthod* [Internet]. 1985 [cited 2022 Feb 28];88(5):402–8. Available from: <https://pubmed.ncbi.nlm.nih.gov/3864374/>
 31. Kreit L, Burstone C, dent LD-JA coll, 1968 undefined. Patient cooperation in orthodontic treatment. *acd.org* [Internet]. 1968 [cited 2022 Mar 1];35(4). Available from: https://www.acd.org/wp-content/uploads/1968_35_04.pdf#page=32
 32. Keim RG. Behavioral considerations in orthodontic treatment. In: Bishara SE, editor. *Textbook of Orthodontics*. 2001. p. 454–62.
 33. Albino J. Development of Methodologies for Behavioral Measurement Related to Malocclusion. 1981 [cited 2022 Mar 3]; Available from: <https://www.google.com/books?hl=tr&lr=&id=raoTAQAAMAAJ&oi=fnd&pg=PR3&dq=Albino+JE.+Development+of+methodologies+for+behavioral+measurements+related+to++malocclusion.&ots=9KYLTIUKt4&sig=eT3aDx84aqbFNueSAPc5SbwqSeU>
 34. Sinha P, Nanda R, and DM-A journal of orthodontics, 1996 undefined.

- Perceived orthodontist behaviors that predict patient satisfaction, orthodontist-patient relationship, and patient adherence in orthodontic treatment. Elsevier [Internet]. [cited 2022 Mar 3]; Available from: https://www.sciencedirect.com/science/article/pii/S0889540696700379?casa_token=nC_VKwwojtEAAAAA:n-dXjKplBL1RdCWlMNCs-kLBgp6TmD5w-6SuSm9ELG2g4MKSzzFfXw2TS0Q8IFqQK-xqJtWmLrg
35. Tedesco LA, Albino JE, Cunat JJ. Reliability and validity of the Orthodontic Locus of Control Scale. *Am J Orthod* [Internet]. 1985 [cited 2022 Mar 4];88(5):396–401. Available from: <https://pubmed.ncbi.nlm.nih.gov/3864373/>
 36. Bartsch A, Witt E, Sahm G, Schneider S. Correlates of objective patient compliance with removable appliance wear. *Am J Orthod Dentofacial Orthop* [Internet]. 1993 [cited 2022 Mar 4];104(4):378–86. Available from: <https://pubmed.ncbi.nlm.nih.gov/8213661/>
 37. Ackerman J, orthodontist WP-TA, 1995 undefined. Communication in orthodontic treatment planning: bioethical and informed consent issues. *meridian.allenpress.com* [Internet]. [cited 2022 Mar 4]; Available from: <https://meridian.allenpress.com/angle-orthodontist/article-abstract/65/4/253/57163>
 38. Brattström V, Ingelsson M, Aberg E. Treatment co-operation in orthodontic patients. *Br J Orthod*. 1991;18(1):37–42.
 39. orthodontics JC-A journal of, 1976 undefined. Oral hygiene in the orthodontic practice: Motivation, responsibilities, and concepts. *europemc.org* [Internet]. [cited 2022 Mar 4]; Available from: <https://europemc.org/article/med/1061502>
 40. Forte G, Journal AR-BD, 1990 undefined. Patient compliance and medical audit in orthodontics. *nature.com* [Internet]. [cited 2022 Mar 4]; Available from: <https://www.nature.com/articles/4807389>
 41. Bos A, Vosselman N, ... JH-TA, 2005 undefined. Patient compliance: a determinant of patient satisfaction? *meridian.allenpress.com* [Internet]. [cited 2022 Mar 5]; Available from: <https://meridian.allenpress.com/angle-orthodontist/article-abstract/75/4/526/58153>
 42. Sahm G, Bartsch A, Koch R, Witt E. Subjective appraisal of orthodontic practices. An investigation into perceived practice characteristics associated with patient and parent treatment satisfaction. *Eur J Orthod* [Internet]. 1991 Feb [cited 2022 Mar 5];13(1):15–21. Available from: <https://pubmed.ncbi.nlm.nih.gov/2032562/>
 43. Espeland L, and AS-AJ of O, 1991 undefined. Perception of personal dental appearance in young adults: relationship between occlusion, awareness, and satisfaction. Elsevier [Internet]. [cited 2022 Mar 5]; Available from: <https://www.sciencedirect.com/science/article/pii/088954069170060A>
 44. Albino J, Tedesco L. Esthetic need for orthodontic treatment. In: Melsen B, editor. *Current Controversies in Orthodontics*. 1991. p. 12–23.

45. Sheats R, McGorray S, ... SK-TA, 1998 undefined. Occlusal traits and perception of orthodontic need in eighth grade students. [meridian.allenpress.com](https://meridian.allenpress.com/angle-orthodontist/article-abstract/68/2/107/58393) [Internet]. 1998 [cited 2022 Mar 7]; Available from: <https://meridian.allenpress.com/angle-orthodontist/article-abstract/68/2/107/58393>
46. Albino J. Effects of orthodontics on psychosocial functioning. National Institute of Dental Research. Bethesda; 1990.
47. Albino J, Lewis E, Slakter M, Tedesco L. Patient characteristics and cooperation in orthodontic treatment. Paper presented at the annual session of the International Association for Dental Research. Chicago; 1981.
48. Albino J, Lopes C, Tedesco L, Cornell J, Cunat J. Predicting cooperation in orthodontic treatment. Paper presented at the annual session of the International Association for Dental Research. Chicago; 1987.
49. Lewit D, development KV-C, 1968 undefined. Conformity and independence in adolescents' motivation for orthodontic treatment. JSTOR [Internet]. [cited 2022 Mar 8]; Available from: https://www.jstor.org/stable/1127283?casa_token=7ELK1v2wCj8AAAAA:CgtCRHXJ7_sTE4yEFd86zRS87FGbXfqYVPEogq9V7oiSx5GWzvIS09ktwmk0ynNodyHzBDTnIWHCXz7hkf6p8hZ6OKtmOsAYtMFEt9kHVpcOf8BmKWY
50. Behavior EL-J of H and H, 1966 undefined. Social meanings of dental appearance. JSTOR [Internet]. [cited 2022 Mar 8]; Available from: https://www.jstor.org/stable/2948777?casa_token=1c1K06qw0t8AAAAA:SBDIaG33G5fjW3XuI17ARn466ot6i-YIXTGvhVxPpkgbFZsL5IGbPIUwT0-Xlfd-2J2xC1rbDAwTdEWbSMMk5msag3O8jUn4g2yupj0FfRhCWC1MJEW
51. Fox RN, Albino JE, Green LJ, Farr SD, Tedesco LA. Development and Validation of a Measure of Attitudes Toward Malocclusion. *J Dent Res*. 1982;61(9):1039–43.
52. Dergisi İD-TP, 2002 undefined. Kontrol odağı ölçeği (KOÖ): Ölçek geliştirme, güvenirlik ve geçerlik çalışması. app.trdizin.gov.tr [Internet]. [cited 2022 Mar 8]; Available from: <https://app.trdizin.gov.tr/publication/paper/detail/TWpReE5UVT0>
53. McCarthy J. WHAT IS ARTIFICIAL INTELLIGENCE? [Internet]. Stanford University. 2004. Available from: <http://www-formal.stanford.edu/jmc/>
54. Sunali D, Khanna S, Dhaimade PA, Khanna S. Artificial Intelligence: Transforming Dentistry Today. *Indian J Basic Appl Med Res*. 2017;(6):161–7.
55. Wang YH, Li Y, Yang SL, Yang L. Classification of substrates and inhibitors of P-glycoprotein using unsupervised machine learning approach. *J Chem Inf Model* [Internet]. 2005 May [cited 2022 Mar 14];45(3):750–7. Available from: <https://pubs.acs.org/doi/abs/10.1021/ci050041k>
56. Sen PC, Hajra M, Ghosh M. Supervised Classification Algorithms in Machine

- Learning: A Survey and Review. *Adv Intell Syst Comput.* 2020;937:99–111.
57. Niculescu-Mizil A, Caruana R. Predicting good probabilities with supervised learning. *ICML 2005 - Proc 22nd Int Conf Mach Learn.* 2005;625–32.
 58. Laskov P, Düssel P, Schäfer C, Rieck K. Learning intrusion detection: Supervised or unsupervised? *Lect Notes Comput Sci (including Subser Lect Notes Artif Intell Lect Notes Bioinformatics).* 2005;3617 LNCS:50–7.
 59. Ghahramani Z. Unsupervised learning. *Lect Notes Comput Sci (including Subser Lect Notes Artif Intell Lect Notes Bioinformatics).* 2004;3176:72–112.
 60. computation HB-N, 1989 undefined. Unsupervised learning. *direct.mit.edu [Internet].* [cited 2022 Mar 21]; Available from: <https://direct.mit.edu/neco/article-abstract/1/3/295/5492>
 61. Prakash VJ, Nithya DLM. A Survey on Semi-Supervised Learning Techniques. *Int J Comput Trends Technol [Internet].* 2014 Feb 19 [cited 2022 Mar 21];8(1). Available from: <http://arxiv.org/abs/1402.4645>
 62. Ouali Y, Hudelot C, Tami M. An Overview of Deep Semi-Supervised Learning. 2020 Jun 9 [cited 2022 Mar 21]; Available from: <http://arxiv.org/abs/2006.05278>
 63. Sutton R, Bowling M, Schuurmans D, Bulitko V. Reinforcement learning and artificial intelligence. 2006 [cited 2022 Mar 15]; Available from: <https://pdfs.semanticscholar.org/e847/7dd88c5936a105c558fd5c41886bd64dc5c.pdf>
 64. Resources LF-APJ of H, 1998 undefined. The challenge of 'empowered learning'. *journals.sagepub.com [Internet].* [cited 2022 Mar 21]; Available from: <https://journals.sagepub.com/doi/abs/10.1177/103841119803600106>
 65. Caruana R, Niculescu-Mizil A. An empirical comparison of supervised learning algorithms. *ACM Int Conf Proceeding Ser.* 2006;148:161–8.
 66. Duan KB, Keerthi SS. Which is the best multiclass SVM method? An empirical study. *Lect Notes Comput Sci.* 2005;3541:278–85.
 67. Kotsiantis S, Zaharakis I, Review PP-AI, 2006 undefined. Machine learning: a review of classification and combining techniques. *Springer [Internet].* 2006 Nov [cited 2022 Mar 15];26(3):159–90. Available from: https://idp.springer.com/authorize/casa?redirect_uri=https://link.springer.com/article/10.1007/s10462-007-9052-3&casa_token=dhdlfS1rnIIAAAAA:utLAlPtUEXYFfpiPpMzZlsgB4Clhb2-dKQjrRODAGUitME0EyJWi8xV9jReUT2l-7qd0Sp8Mp0LT2VUw
 68. Gehrke J, Ramakrishnan R, Knowledge VG-DM and, 2000 undefined. RainForest—A framework for fast decision tree construction of large datasets. *Springer [Internet].* 2000 [cited 2022 Mar 21];4:127–62. Available from: <https://link.springer.com/article/10.1023/A:1009839829793>

69. Priyanka undefined, ... DK-J of I and D, 2020 undefined. Decision tree classifier: A detailed survey. *inderscienceonline.com* [Internet]. [cited 2022 Mar 21]; Available from: <https://www.inderscienceonline.com/doi/abs/10.1504/IJIDS.2020.108141>
70. on CQ-P of 2011 IC, 2011 undefined. Research on incremental decision tree algorithm. *ieeexplore.ieee.org* [Internet]. [cited 2022 Mar 21]; Available from: <https://ieeexplore.ieee.org/abstract/document/6022930/>
71. Breiman L, Last M, Rice J. Random Forests: Finding Quasars. *Stat Challenges Astron.* 2006 May 25;243–54.
72. Kramer O. K-Nearest Neighbors. 2013;13–23.
73. Peterson LE. K-nearest neighbor. *Scholarpedia.* 2009;4(2):1883.
74. LaValley MP. Logistic Regression. *Circulation* [Internet]. 2008 May 6 [cited 2022 Jun 28];117(18):2395–9. Available from: <https://www.ahajournals.org/doi/abs/10.1161/CIRCULATIONAHA.106.682658>
75. Jahromi AH, Taheri M. A non-parametric mixture of Gaussian naive Bayes classifiers based on local independent features. 19th CSI Int Symp Artif Intell Signal Process AISP 2017. 2018 Mar 23;2018-January:209–12.
76. Izenman AJ. Linear Discriminant Analysis. 2013;237–80.
77. An TK, Kim MH. A new Diverse AdaBoost classifier. *Proc - Int Conf Artif Intell Comput Intell AICI 2010.* 2010;1:359–63.
78. Chen T, Guestrin C. XGBoost: A Scalable Tree Boosting System. *Proc 22nd ACM SIGKDD Int Conf Knowl Discov Data Min* [Internet]. [cited 2022 Jun 28]; Available from: <http://dx.doi.org/10.1145/2939672.2939785>
79. Chen Z, Jiang F, Cheng Y, Gu X, Liu W, Peng J. XGBoost Classifier for DDoS Attack Detection and Analysis in SDN-Based Cloud. *Proc - 2018 IEEE Int Conf Big Data Smart Comput BigComp 2018.* 2018 May 25;251–6.
80. Sharaff A, Gupta H. Extra-Tree Classifier with Metaheuristics Approach for Email Classification. *Adv Intell Syst Comput* [Internet]. 2019 [cited 2022 Jun 28];924:189–97. Available from: https://link.springer.com/chapter/10.1007/978-981-13-6861-5_17
81. Biggs F, Zantedeschi V, Guedj B. On Margins and Generalisation for Voting Classifiers. 2022 Jun 9 [cited 2022 Jun 28]; Available from: <https://arxiv.org/abs/2206.04607v1>
82. Kshatri SS, Singh D, Narain B, Bhatia S, Quasim MT, Sinha GR. An Empirical Analysis of Machine Learning Algorithms for Crime Prediction Using Stacked Generalization: An Ensemble Approach. *IEEE Access.* 2021;9:67488–500.

83. Franzese M, Iuliano A. Hidden markov models. *Encycl Bioinforma Comput Biol ABC Bioinforma*. 2018 Jan 1;1–3:753–62.
84. Vasilakes J, Zhou S, Zhang R. Natural language processing. *Mach Learn Cardiovasc Med*. 2020 Jan 1;123–48.
85. Das R, Prasad B, Computer GS-IJ of, 2012 undefined. HMM based offline handwritten writer independent english character recognition using global and local feature extraction. *Citeseer* [Internet]. 2012 [cited 2022 Aug 10];46(10):975–8887. Available from: <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.736.8570&rep=rep1&type=pdf>
86. Kinz-Thompson CD, Bailey NA, Gonzalez RL. Precisely and Accurately Inferring Single-Molecule Rate Constants. *Methods Enzymol*. 2016;581:187–225.
87. Schulz H, Intelligenz SB-K-K, 2012 undefined. Deep learning. Springer [Internet]. [cited 2022 Mar 21]; Available from: <https://link.springer.com/article/10.1007/s13218-012-0198-z>
88. Deng L, Yu D. Deep learning: Methods and applications. *Found Trends Signal Process*. 2013;7(3–4):197–387.
89. Dünyayı Değiştirmekte Olan Yapay Sinir Ağları Nedir? - Tıpacı [Internet]. [cited 2022 Mar 23]. Available from: <https://www.tipacilar.com/dunyayi-degistirmekte-olan-yapay-sinir-aglari-nedir/>
90. Hao X, Zhang G, Ma S. Deep Learning. *Int J Semant Comput*. 2016 Sep 1;10(3):417–39.
91. Ravì D, Wong C, ... FD-I journal of, 2016 undefined. Deep learning for health informatics. *ieeexplore.ieee.org* [Internet]. [cited 2022 Mar 21]; Available from: <https://ieeexplore.ieee.org/abstract/document/7801947/>
92. Choi R, ... AC-... VS&, 2020 undefined. Introduction to machine learning, neural networks, and deep learning. *iovs.arvojournals.org* [Internet]. [cited 2022 Mar 21]; Available from: <https://iovs.arvojournals.org/article.aspx?articleid=2762344>
93. Ethem A. Introduction to Machine Learning Second Edition Adaptive Computation and Machine Learning. Massachusetts Inst Technol [Internet]. 2015 [cited 2022 Mar 17];41–470. Available from: https://kkpatel7.files.wordpress.com/2015/04/alppaydin_machinelearning_2010.pdf
94. Ng AY. Feature selection, L1 vs. L2 regularization, and rotational invariance. *Proceedings, Twenty-First Int Conf Mach Learn ICML 2004*. 2004;615–22.
95. Schulz H, Behnke S. Deep Learning: Layer-Wise Learning of Feature Hierarchies. *KI - Kunstl Intelligenz*. 2012 Nov 1;26(4):357–63.

96. networks JS-N, 2015 undefined. Deep learning in neural networks: An overview. Elsevier [Internet]. [cited 2022 Mar 21]; Available from: <https://www.sciencedirect.com/science/article/pii/S0893608014002135>
97. Sinir Ağları: Kısa sunum ve Perceptron hakkında notlar. [Internet]. [cited 2022 Mar 23]. Available from: <https://ichi.pro/tr/sinir-aglari-kisa-sunum-ve-perceptron-hakkinda-notlar-127877967711292>
98. Nielsen M. Neural networks and deep learning. 2015 [cited 2022 Mar 21]; Available from: http://mde.tw/lab/downloads/Neural_Networks_and_Deep_Learning.pdf
99. Kriegeskorte N, Biology TG-C, 2019 undefined. Neural network models and deep learning. Elsevier [Internet]. [cited 2022 Mar 21]; Available from: <https://www.sciencedirect.com/science/article/pii/S0960982219302040>
100. Geri Yayılım Algoritması'na Matematiksel Yaklaşım - Derin Öğrenme | Deep Learning [Internet]. [cited 2022 Mar 23]. Available from: <https://www.derinogrenme.com/2018/06/28/geri-yayilim-algoritmasina-matematiksel-yaklasim/>
101. Profesor e investigador en Inteligencia Artificial y Supercomputación [Internet]. [cited 2022 Mar 23]. Available from: <https://torres.ai/>
102. O'Shea K, Nash R. An Introduction to Convolutional Neural Networks. 2015 Nov 26 [cited 2022 Mar 22]; Available from: <http://arxiv.org/abs/1511.08458>
103. Aghdam H, York EH-N, Springer N, 2017 undefined. Guide to convolutional neural networks. Springer [Internet]. [cited 2022 Mar 22]; Available from: <https://link.springer.com/content/pdf/10.1007/978-3-319-57550-6.pdf>
104. Image Processing using CNN | Beginner's Guide to Image Processing [Internet]. [cited 2022 Mar 23]. Available from: <https://www.analyticsvidhya.com/blog/2021/06/image-processing-using-cnn-a-beginners-guide/>
105. Gu J, Wang Z, Kuen J, Ma L, Shahroudy A, Recognition BS-P, et al. Recent advances in convolutional neural networks. Elsevier [Internet]. [cited 2022 Mar 22]; Available from: <https://www.sciencedirect.com/science/article/pii/S0031320317304120>
106. 1: Max pooling and average pooling | Download Scientific Diagram [Internet]. [cited 2022 Mar 23]. Available from: https://www.researchgate.net/figure/Max-pooling-and-average-pooling_fig5_343675998
107. Lavin A, on SG-P of the I conference, 2016 undefined. Fast algorithms for convolutional neural networks. cv-foundation.org [Internet]. [cited 2022 Mar 22]; Available from: https://www.cv-foundation.org/openaccess/content_cvpr_2016/html/Lavin_Fast_Algorithms_for_CVPR_2016_paper.html

108. He K, Zhang X, Ren S, Sun J. Deep residual learning for image recognition. *Proc IEEE Comput Soc Conf Comput Vis Pattern Recognit.* 2016 Dec 9;2016-December:770–8.
109. Chandola Y, Virmani J, Bhadauria HS, Kumar P. End-to-end pre-trained CNN-based computer-aided classification system design for chest radiographs. *Deep Learn Chest Radiogr.* 2021 Jan 1;117–40.
110. Howard AG, Zhu M, Chen B, Kalenichenko D, Wang W, Weyand T, et al. Mobilenets: Efficient convolutional neural networks for mobile vision applications. *arxiv.org [Internet].* [cited 2022 Aug 14]; Available from: <https://arxiv.org/abs/1704.04861>
111. Elfatimi E, Eryigit R, Access LE-I, 2022 undefined. Beans leaf diseases classification using mobilenet models. *ieeexplore.ieee.org [Internet].* [cited 2022 Sep 21]; Available from: <https://ieeexplore.ieee.org/abstract/document/9681085/>
112. Zhu Y, on SN-2017 I international conference, 2017 undefined. Densenet for dense flow. *ieeexplore.ieee.org [Internet].* [cited 2022 Sep 21]; Available from: <https://ieeexplore.ieee.org/abstract/document/8296389/>
113. Hu H, Dey D, Giorno A Del, Hebert M, Andrew Bagnell J. Log-densenet: How to sparsify a densenet. *arxiv.org [Internet].* [cited 2022 Sep 21]; Available from: <https://arxiv.org/abs/1711.00002>
114. Qin X, arXiv:1912.03151 ZW preprint, 2019 undefined. Nasnet: A neuron attention stage-by-stage net for single image deraining. *researchgate.net [Internet].* [cited 2022 Sep 21]; Available from: https://www.researchgate.net/profile/Xu-Qin-12/publication/337830328_NASNet_A_Neuron_Attention_Stage-by-Stage_Net_for_Single_Image_Deraining/links/5e193ee3299bf10bc3a34e94/NASNet-A-Neuron-Attention-Stage-by-Stage-Net-for-Single-Image-Deraining.pdf
115. Qin X, Wang Z. NASNet: A Neuron Attention Stage-by-Stage Net for Single Image Deraining. 2019 Dec 6 [cited 2022 Sep 21]; Available from: <http://arxiv.org/abs/1912.03151>
116. Khamparia A, Gupta D, Nguyen NG, Khanna A, Pandey B, Tiwari P. Sound classification using convolutional neural network and tensor deep stacking network. *IEEE Access.* 2019;7:7717–27.
117. Gemmeke JF, Ellis DPW, Freedman D, Jansen A, Lawrence W, Moore RC, et al. Audio Set: An ontology and human-labeled dataset for audio events. *ICASSP, IEEE Int Conf Acoust Speech Signal Process - Proc.* 2017 Jun 16;776–80.
118. Drossos K, Mimitakis SI, Gharib S, Li Y, Virtanen T. Sound event detection with depthwise separable and dilated convolutions. *ieeexplore.ieee.org [Internet].* [cited 2022 Aug 14]; Available from: <https://ieeexplore.ieee.org/abstract/document/9207532/>

119. Krizhevsky A, Sutskever I, Hinton GE. ImageNet classification with deep convolutional neural networks. *Commun ACM*. 2017 Jun 1;60(6):84–90.
120. Scholarpedia SG-, 2013 undefined. Recurrent neural networks. scholarpedia.org [Internet]. [cited 2022 Mar 22]; Available from: http://scholarpedia.org/article/Recurrent_neural_network
121. Medsker L, Jain L. Recurrent neural networks: design and applications. 1999 [cited 2022 Mar 22]; Available from: https://books.google.com/books?hl=tr&lr=&id=ME1SAkN0PyMC&oi=fnd&pg=PA1&dq=recurrent+neural+networks&ots=7cwy9L8VQn&sig=XZuIJvdSHyBjf_GcW08_4f6IXfM
122. An Introduction to Recurrent Neural Networks — DATA SCIENCE [Internet]. [cited 2022 Mar 23]. Available from: <https://datascience.eu/machine-learning/an-introduction-to-recurrent-neural-networks/>
123. Pascanu R, Mikolov T, ... YB on machine, 2013 undefined. On the difficulty of training recurrent neural networks. *proceedings.mlr.press* [Internet]. [cited 2022 Mar 22]; Available from: <https://proceedings.mlr.press/v28/pascanu13.html>
124. Computing AS-J of AI and S, 2019 undefined. Performance evaluation of deep neural networks applied to speech recognition: RNN, LSTM and GRU. *infona.pl* [Internet]. 2019 [cited 2022 Mar 22];9(4):235. Available from: <https://www.infona.pl/resource/bwmeta1.element.baztech-0106e25d-92b6-4c93-8317-367a9f574578>
125. Lipton ZC, Kale DC, Elkan C, Wetzel R. Learning to diagnose with LSTM recurrent neural networks. 4th Int Conf Learn Represent ICLR 2016 - Conf Track Proc. 2016;
126. Brusa E, Delprete C, Di Maggio LG. Deep Transfer Learning for Machine Diagnosis: From Sound and Music Recognition to Bearing Fault Detection. *Appl Sci* 2021, Vol 11, Page 11663 [Internet]. 2021 Dec 8 [cited 2022 Aug 14];11(24):11663. Available from: <https://www.mdpi.com/2076-3417/11/24/11663/htm>
127. Modi S, Bohara MH. Facial emotion recognition using convolution neural network. *Proc - 5th Int Conf Intell Comput Control Syst ICICCS* 2021. 2021 May 6;1339–44.
128. Yu J, Markov K, Karpov A. Speaking Style Based Apparent Personality Recognition. *Lect Notes Comput Sci (including Subser Lect Notes Artif Intell Lect Notes Bioinformatics)* [Internet]. 2019 Aug 20 [cited 2021 Dec 24];11658 LNAI:540–8. Available from: https://link.springer.com/chapter/10.1007/978-3-030-26061-3_55
129. Tan C, Sun F, Kong T, Zhang W, Yang C, Liu C. A survey on deep transfer learning. *Lect Notes Comput Sci (including Subser Lect Notes Artif Intell Lect Notes Bioinformatics)*. 2018;11141 LNCS:270–9.

130. Daniels A, Seacat J, Orthodontics MI-AJ of, 2009 undefined. Orthodontic treatment motivation and cooperation: a cross-sectional analysis of adolescent patients' and parents' responses. Elsevier [Internet]. [cited 2022 Jul 7]; Available from: <https://www.sciencedirect.com/science/article/pii/S0889540609007124>
131. Rojas S, Cárdenas J, Sierra Á, Psicología DR-G-C, 2019 undefined. Análisis Rasch de la medida de cooperación del paciente ortodóncico en adolescentes de Medellín. scielo.org.co [Internet]. [cited 2022 Jul 8]; Available from: http://www.scielo.org.co/scielo.php?script=sci_arttext&pid=S2011-30802019000100043
132. Sarul M, Lewandowska B, ... BK-... in C and, 2017 undefined. Objectively measured patient cooperation during early orthodontic treatment: Does psychology have an impact? advances.umw.edu.pl [Internet]. [cited 2022 Jul 8]; Available from: <https://advances.umw.edu.pl/pl/article/2017/26/8/1245/>
133. Ur U~, Ar A~, Doruk C, Altug A, Bıçakçı ~, Büküşog N. The role of psycho-social factors in headgear compliance. academic.oup.com [Internet]. 2005 [cited 2022 Jul 8];27:263–7. Available from: <https://academic.oup.com/ejo/article-abstract/27/3/263/457452>
134. Fazli M, Kavandi M, Behavioral BM-P-S and, 2014 undefined. A method towards children's psychological health on dental visits. Elsevier [Internet]. [cited 2022 Jul 8]; Available from: <https://www.sciencedirect.com/science/article/pii/S1877042813053627>
135. Kirshenblatt S, Chen H, Dieltjens M, ... BP-... of the CD, 2018 undefined. Adherence to treatment with removable oral appliances: the past and the future. jcda.ca [Internet]. [cited 2022 Jul 8]; Available from: <https://jcda.ca/i3>
136. Shapiro G, Breathing CS-S and, 2010 undefined. Factors that influence CPAP adherence: an overview. Springer [Internet]. [cited 2022 Jul 15]; Available from: https://idp.springer.com/authorize/casa?redirect_uri=https://link.springer.com/article/10.1007/s11325-010-0391-y&casa_token=LQfQVMRQWkoAAAAA:gh_a1MOv2DiY1BrbHL0QKTGQlciPRr_XzYgCGntwki1Y9UiE6EGi7yfiB3V8qR6ZgfjxajgrOYiVcJHm
137. Bos A, ... JH-TEJ of, 2005 undefined. Towards a comprehensive model for the study of compliance in orthodontics. academic.oup.com [Internet]. 2005 [cited 2022 Jul 15];27:296–301. Available from: <https://academic.oup.com/ejo/article-abstract/27/3/296/457469>
138. Traklyali G, Isik-Ozdemir F, ... TT-I-J of I, 2009 undefined. Anxiety among adolescents and its affect on orthodontic compliance. jisppd.com [Internet]. [cited 2022 Jul 16]; Available from: <https://www.jisppd.com/article.asp?issn=0970-4388;year=2009;volume=27;issue=4;spage=205;epage=210;aulast=Traklyali>
139. Mtaya M, Brudvik P, Åstrøm AN. Prevalence of malocclusion and its

- relationship with socio-demographic factors, dental caries, and oral hygiene in 12- to 14-year-old Tanzanian schoolchildren. *Eur J Orthod* [Internet]. 2009 Oct 1 [cited 2022 Jul 16];31(5):467–76. Available from: <https://academic.oup.com/ejo/article/31/5/467/480312>
140. Skidmore KJ, Brook KJ, Thomson WM, Harding WJ. Factors influencing treatment time in orthodontic patients. *Am J Orthod Dentofac Orthop* [Internet]. 2006 Feb 1 [cited 2022 Jul 16];129(2):230–8. Available from: <http://www.ajodo.org/article/S088954060501098X/fulltext>
 141. Amado J, Sierra AM, Gallón A, Cristina ;, Lvarez B ; A', Baccetti T. Relationship between personality traits and cooperation of adolescent orthodontic patients. *meridian.allenpress.com* [Internet]. 2008 [cited 2022 Jul 16];78. Available from: <https://meridian.allenpress.com/angle-orthodontist/article-abstract/78/4/688/58600>
 142. ... VA-O&, 2019 undefined. Orthodontics in the era of big data analytics. *Wiley Online Libr* [Internet]. 2019 May 1 [cited 2022 Jul 16];22(S1):8–13. Available from: https://onlinelibrary.wiley.com/doi/abs/10.1111/ocr.12279?casa_token=36COdWqhAZkAAAAA:sS5WEKw8Lr5DqjtfxZBaqIlz_FKkYuWfQkswwN4ZYjmf26Z_1kPgln8RfKp9BtvdJZregAPdtHPrenU
 143. Mohammad-Rahimi H, Nadimi M, Rohban MH, Shamsoddin E, Lee VY, Motamedian SR. Machine learning and orthodontics, current trends and the future opportunities: A scoping review. *Am J Orthod Dentofac Orthop*. 2021 Aug 1;160(2):170-192.e4.
 144. Khanagar S, Al-Ehaideb A, ... PM-J of dental, 2021 undefined. Developments, application, and performance of artificial intelligence in dentistry–A systematic review. *Elsevier* [Internet]. [cited 2022 Jul 16]; Available from: <https://www.sciencedirect.com/science/article/pii/S1991790220301434>
 145. Jordan MI, Mitchell TM. Machine learning: Trends, perspectives, and prospects. *Science* (80-). 2015 Jul 17;349(6245):255–60.
 146. Rojas S. Análisis Rasch de la medida de cooperación del paciente ortodóncico en adolescentes de Medellín Rasch Analysis of Cooperation Measure of the adolescent Orthodontic Patient in Medellin. 2019;
 147. Büyükbayraktar Z, Ortodontyczne/Orthodontic ZY-F, 2022 undefined. Psychology and Patient Cooperation in Orthodontics: Is There a Relationship between Them? *termedia.pl* [Internet]. [cited 2022 Jul 22]; Available from: <https://www.termedia.pl/Psychology-and-Patient-Cooperation-in-Orthodontics-Is-There-a-Relationship-between-Them-,143,46059,0,1.html>
 148. Kosinski M. Facial recognition technology can expose political orientation from naturalistic facial images. *Sci Reports* 2021 111 [Internet]. 2021 Jan 11 [cited 2022 Aug 17];11(1):1–7. Available from: <https://www.nature.com/articles/s41598-020-79310-1>

149. Valdez-Rodríguez JE, Calvo H, Felipe-Riverón EM. Handwritten Texts for Personality Identification Using Convolutional Neural Networks. *Lect Notes Comput Sci (including Subser Lect Notes Artif Intell Lect Notes Bioinformatics)* [Internet]. 2019 [cited 2022 Aug 22];11188 LNCS:140–5. Available from: https://link.springer.com/chapter/10.1007/978-3-030-05792-3_13
150. Kamenskaya E, Kukharev G. Recognition of Psychological Characteristics from Face. 2008;(1).
151. Sociobiology NB-E and, 1995 undefined. The evolutionary psychology of physical attractiveness: Sexual selection and human morphology. Elsevier [Internet]. [cited 2022 Aug 15]; Available from: <https://www.sciencedirect.com/science/article/pii/0162309595000682>
152. Boehringer S, Vollmar T, Tasse C, ... RW-EJ of, 2006 undefined. Syndrome identification based on 2D analysis software. *nature.com* [Internet]. [cited 2022 Aug 15]; Available from: <https://www.nature.com/articles/5201673>
153. Loos H, Wieczorek D, Würtz R, ... CM-EJ of, 2003 undefined. Computer-based recognition of dysmorphic faces. *nature.com* [Internet]. [cited 2022 Aug 15]; Available from: <https://www.nature.com/articles/5200997>
154. Anselmi F, Noceti N, Rosasco L, Ward R. Genuine personality recognition from highly constrained face images. *Lect Notes Comput Sci (including Subser Lect Notes Artif Intell Lect Notes Bioinformatics)* [Internet]. 2019 [cited 2022 Aug 11];11751 LNCS:421–31. Available from: https://link.springer.com/chapter/10.1007/978-3-030-30642-7_38
155. Xu J, Tian W, Lv G, Liu S, Fan Y. Prediction of the Big Five Personality Traits Using Static Facial Images of College Students with Different Academic Backgrounds. *IEEE Access*. 2021;9:76822–32.
156. Abdulrazaq MB, Mahmood MR, Zeebaree SRM, Abdulwahab MH, Zebari RR, Sallow AB. An Analytical Appraisal for Supervised Classifiers' Performance on Facial Expression Recognition Based on Relief-F Feature Selection. *J Phys Conf Ser* [Internet]. 2021 Feb 1 [cited 2022 Aug 11];1804(1):012055. Available from: <https://iopscience.iop.org/article/10.1088/1742-6596/1804/1/012055>
157. Leongómez J, Binter J, ... LK-E and H, 2014 undefined. Vocal modulation during courtship increases proceptivity even in naive listeners. Elsevier [Internet]. [cited 2022 Aug 16]; Available from: <https://www.sciencedirect.com/science/article/pii/S1090513814000786>
158. Belin P, Fecteau S, sciences CB-T in cognitive, 2004 undefined. Thinking the voice: neural correlates of voice perception. Elsevier [Internet]. [cited 2022 Aug 16]; Available from: <https://www.sciencedirect.com/science/article/pii/S1364661304000257>
159. Addington DW. The relationship of selected vocal characteristics to personality perception. *Speech Monogr*. 1968 Nov;35(4):492–503.

160. Cantril: Judging personality from voice - Google Akademik [Internet]. [cited 2022 Aug 16]. Available from: [https://scholar.google.com/scholar_lookup?title=Judging personality from voice&publication_year=1934&author=GW Allport&author=H Cantril](https://scholar.google.com/scholar_lookup?title=Judging+personality+from+voice&publication_year=1934&author=GW+Allport&author=H+Cantril)
161. Andreasen N, Alpert M, General MM-A of, 1981 undefined. Acoustic analysis: an objective measure of affective flattening. jamanetwork.com [Internet]. [cited 2022 Aug 16]; Available from: <https://jamanetwork.com/journals/jamapsychiatry/article-abstract/492506>
162. Kreiman J, Today DS-A, 2011 undefined. Voices and listeners: Toward a model of voice perception. acousticstoday.org [Internet]. [cited 2022 Aug 16]; Available from: https://acousticstoday.org/wp-content/uploads/2017/09/Article_1of4_from_ATCODK_7_4.pdf
163. Apple W, Streeter L, and RK-J of personality, 1979 undefined. Effects of pitch and speech rate on personal attributions. psycnet.apa.org [Internet]. [cited 2022 Aug 16]; Available from: <https://psycnet.apa.org/record/1980-27958-001>
164. Chebat J, skills KH-... and motor, 2007 undefined. Voice and persuasion in a banking telemarketing context. journals.sagepub.com [Internet]. 2007 Apr [cited 2022 Aug 16];104(2):419–37. Available from: <https://journals.sagepub.com/doi/abs/10.2466/pms.104.2.419-437>
165. DeGroot T, Kluemper D. Evidence of predictive and incremental validity of personality factors, vocal attractiveness and the situational interview. Int J Sel Assess. 2007 Mar;15(1):30–9.
166. Jacob A. Modelling speech emotion recognition using logistic regression and decision trees. Int J Speech Technol [Internet]. 2017 Dec 1 [cited 2022 Aug 9];20(4):897–905. Available from: <https://link.springer.com/article/10.1007/s10772-017-9457-6>
167. Londhe ND, Ahirwal MK, Lodha P. Machine learning paradigms for speech recognition of an Indian dialect. Int Conf Commun Signal Process ICCSP 2016. 2016 Nov 22;780–6.
168. Anari MS, Rezaee K, Ahmadi A. TraitLWNet: a novel predictor of personality trait by analyzing Persian handwriting based on lightweight deep convolutional neural network. Multimed Tools Appl [Internet]. 2022 Mar 1 [cited 2022 Aug 16];81(8):10673–93. Available from: <https://link.springer.com/article/10.1007/s11042-022-12295-3>
169. Demir Ü, Uğurlu B, Onsekiz Ç, Üniversitesi M. EL YAZISINDAN KİŞİLİK ANALİZİNE YÖNELİK BİR KARAR DESTEK MODELİ ÖNERİSİ. Uluslararası Batı Karadeniz Mühendislik ve Fen Bilim Derg [Internet]. 2021 Dec 31 [cited 2022 Sep 16];3(2):47–71. Available from: <https://dergipark.org.tr/en/pub/umufed/issue/67816/953602>
170. Ayzeren Y, Erbilek M, Access EÇ-I, 2019 undefined. Emotional state prediction from online handwriting and signature biometrics.

ieeexplore.ieee.org [Internet]. [cited 2022 Aug 16]; Available from: <https://ieeexplore.ieee.org/abstract/document/8894349/>

171. Chaudhari K, applications AT-E systems with, 2019 undefined. Survey on handwriting-based personality trait identification. Elsevier [Internet]. [cited 2022 Aug 16]; Available from: <https://www.sciencedirect.com/science/article/pii/S0957417419300284>
172. Dargan S, Kumar M. Writer Identification System for Indic and Non-Indic Scripts: State-of-the-Art Survey. *Arch Comput Methods Eng*. 2019 Sep 1;26(4):1283–311.
173. Simon, Schuster. *Your Handwriting Can Change Your Life*. Rodgers V, editor. New York; 2013.
174. Zhang H, Jolfaei A, Access MA-I, 2019 undefined. A face emotion recognition method using convolutional neural network and image edge computing. ieeexplore.ieee.org [Internet]. [cited 2022 Mar 21]; Available from: <https://ieeexplore.ieee.org/abstract/document/8884205/>
175. Ilmini K, Fernando T. Persons' Personality Traits Recognition using Machine Learning Algorithms and Image Processing Techniques Automatic Personality Assessment with Machine Learning View project Root Approximation Using Nature Inspired Algorithms View project Persons' Personality Traits Recognition using Machine Learning Algorithms and Image Processing Techniques. 2018 [cited 2022 Aug 10]; Available from: <https://www.researchgate.net/publication/323356879>
176. M M, A M. Facial geometric feature extraction based emotional expression classification using machine learning algorithms. *PLoS One* [Internet]. 2021 [cited 2022 Aug 12];16(2):e0247131. Available from: <https://journals.plos.org/plosone/article?id=10.1371/journal.pone.0247131>
177. Gao Y, Gao L, Informatics XL-IT on I, 2020 undefined. A generative adversarial network based deep learning method for low-quality defect image reconstruction and recognition. ieeexplore.ieee.org [Internet]. [cited 2022 Aug 12]; Available from: <https://ieeexplore.ieee.org/abstract/document/9139269/>
178. Ghods V, Sohrabi MK. Online Farsi Handwritten Character Recognition Using Hidden Markov Model. *J Comput*. 2016;11(2):169–75.
179. Sun X, Liu B, Cao J, Luo J, Shen X. Who am I? Personality detection based on deep learning for texts. *IEEE Int Conf Commun*. 2018 Jul 27;2018-May.
180. Pour M, Farokhi F. An advanced method for speech recognition. 2009 [cited 2022 Aug 12]; Available from: <http://citeseerx.ist.psu.edu/viewdoc/summary?doi=10.1.1.193.1460>
181. Tahseen Ali A, Abdullah HS, Fadhil MN. Voice recognition system using machine learning techniques. *Mater Today Proc*. 2021 Apr 30;
182. Boateng G, Sels L, Kuppens P, Hilpert P, Kowatsch T. Speech emotion

recognition among couples using the peak-end rule and transfer learning. ICMI 2020 Companion - Companion Publ 2020 Int Conf Multimodal Interact. 2020 Oct 25;17–21.

183. Mukhopadhyay M, Dey A, Shaw RN, Ghosh A. Facial emotion recognition based on Textural pattern and Convolutional Neural Network. 2021 IEEE 4th Int Conf Comput Power Commun Technol GUCON 2021. 2021 Sep 24;
184. Fu J, Zhang H. Personality trait detection based on ASM localization and deep learning. Sci Program. 2021;2021.
185. Zhang T, Qin RZ, Dong QL, Gao W, Xu HR, Hu ZY. Physiognomy: Personality traits prediction by learning. Int J Autom Comput. 2017;14(4):386–95.
186. review LT-P, 1934 undefined. The vectors of mind. psycnet.apa.org [Internet]. [cited 2022 Aug 23]; Available from: <https://psycnet.apa.org/journals/rev/41/1/1/>
187. Moubayed N Al, Vazquez-Alvarez Y, ... AM-P of the, 2014 undefined. Face-based automatic personality perception. dl.acm.org [Internet]. 2014 Nov 3 [cited 2022 Aug 17];1153–6. Available from: <https://dl.acm.org/doi/abs/10.1145/2647868.2655014>
188. Hashemi M, Hall M. Criminal tendency detection from facial images and the gender bias effect. J Big Data [Internet]. 2020 Dec 1 [cited 2022 Aug 17];7(1):1–16. Available from: <https://journalofbigdata.springeropen.com/articles/10.1186/s40537-019-0282-4>
189. Srinarong N, Mongkolnavin J. A Development of Personality Recognition Model from Conversation Voice in Call Center Context. ACM Int Conf Proceeding Ser. 2021 Jun 29;
190. Jawarkar NP, Holambe RS, Basu TK. Use of fuzzy min-max neural network for speaker identification. Int Conf Recent Trends Inf Technol ICRTIT 2011. 2011;178–82.
191. Xing YJ, Li H, Tan P. Hierarchical fuzzy speaker identification based on FCM and FSVM. Proc - 2012 9th Int Conf Fuzzy Syst Knowl Discov FSKD 2012. 2012;311–5.
192. Liu ZT, Rehman A, Wu M, Cao WH, Hao M. Speech Personality Recognition Based on Annotation Classification Using Log-Likelihood Distance and Extraction of Essential Audio Features. IEEE Trans Multimed. 2021;23(JULY):3414–26.
193. Fallahnezhad M, Vali M, Khalili M. Automatic Personality Recognition from reading text speech. 2017 25th Iran Conf Electr Eng ICEE 2017. 2017;(C):18–23.
194. Polzehl T, Möller S, Metze F. Automatically assessing personality from

- speech. Proc - 2010 IEEE 4th Int Conf Semant Comput ICSC 2010. 2010;134–40.
195. Boateng G, Kowatsch T. Speech emotion recognition among elderly individuals using multimodal fusion and transfer learning. ICMI 2020 Companion - Companion Publ 2020 Int Conf Multimodal Interact. 2020;12–6.
 196. Majumder N, Poria S, Gelbukh A, Cambria E. Deep Learning-Based Document Modeling for Personality Detection from Text. IEEE Intell Syst. 2017 Mar 1;32(2):74–9.
 197. Fallah B, Khotanlou H. Identify human personality parameters based on handwriting using neural network. 2016 Artif Intell Robot IRANOPEN 2016. 2016 Aug 2;120–6.
 198. Chen Z, Lin T. Automatic personality identification using writing behaviours: an exploratory study. <http://dx.doi.org/10.1080/0144929X.2017.1304994> [Internet]. 2017 Aug 3 [cited 2022 Aug 22];36(8):839–45. Available from: <https://www.tandfonline.com/doi/abs/10.1080/0144929X.2017.1304994>
 199. Mostafa MA, Al-Qurishi M, Mathkour HI. Towards personality classification through arabic handwriting analysis. Springer Proc Complex [Internet]. 2019 [cited 2022 Aug 22];557–65. Available from: https://link.springer.com/chapter/10.1007/978-3-030-30809-4_51
 200. Gavrilescu M, Vizireanu N. Predicting the Big Five personality traits from handwriting. Eurasip J Image Video Process. 2018 Dec 1;2018(1).

EKLER

EK-1 ETİK KURUL ONAYI



T.C.
AFYONKARAHİSAR SAĞLIK BİLİMLERİ ÜNİVERSİTESİ
KLİNİK ARAŞTIRMALAR ETİK KURULU

Birimi : Tıbbi Etik Kurul Başkanlığı
Kodu : 2011-KAEK-2
Sayı : 2022/30
Konu : Tıbbi Etik Kurul Kararı

07.01.2022

Sayın; Dr. Öğr. Üyesi Hasan CAMCI
Afyonkarahisar Sağlık Bilimleri Üniversitesi
Dış Fakültesi
AFYONKARAHİSAR

İlgi: Klinik Araştırmalar Etik Kurulu'nun 07.01.2022 tarih ve 2022/30 sayılı kararı.

Sorumluluğunuzda yürütülecek olan “Ortodontide Hasta Kooperasyonunun Yapay Zeka ile Değerlendirilmesi” başlıklı çalışmanıza ilişkin alınan ilgi sayılı Etik Kurul Kararı ekte gönderilmiştir.

Bilgilerinizi ve gereğini rica ederim.

Prof. Dr. Dağıstan Tolga ARIÖZ
Etik Kurul Başkanı

EK:

1-İlgi sayılı karar (1 sayfa)

Ali Çetinkaya kampüsü, Afyon – İzmir Yolu 8.Km 03200 / AFYONKARAHİSAR
Ayrıntılı bilgi için irtibat: Bulent ÜNAL
Telefon: 0. 272.2463301– 2463304 Faks: 0. 272.2462707
e-posta: klinikarastirmalar@aku.edu.tr

T.C.
AFYONKARAHİSAR SAĞLIK BİLİMLERİ ÜNİVERSİTESİ
KLİNİK ARAŞTIRMALAR ETİK KURULU KARARLARI

Toplantı Tarihi	07.01.2022	Toplantı Numarası	2022/1	Toplantı Saati	09:00	Etik Kurul Kodu
						2011-KAEK-2

- 30- Dr. Öğr. Üyesi Hasan CAMCI' nın sorumluluğunda yürütülecek olan "Ortodontide Hasta Kooperasyonunun Yapay Zeka ile Değerlendirilmesi" konulu Girişimsel Olmayan Klinik Araştırmalar için başvuru dosyası incelendi. Araştırma protokolüne uyularak, Sağlık Bakanlığı'nın 13.04.2013 tarih 28617 sayılı Klinik Araştırmalar Hakkındaki Yönetmeliği ve yayımlanan kılavuzlarında belirtilen hususlar dikkate alınarak, sorumluluk araştırmacılara ait olmak üzere araştırmanın yapılmasında etik sakınca olmadığına toplantıya katılan üyelerin oy birliği ile karar verildi.

EK-2 İNTİHAL YAZILIM PROGRAMI RAPORU

ORJİNALLİK RAPORU

%**3**

BENZERLİK ENDEKSİ

%**2**

İNTERNET KAYNAKLARI

%**0**

YAYINLAR

%**1**

ÖĞRENCİ ÖDEVLERİ

BİRİNCİL KAYNAKLAR

1

tr.wikipedia.org

İnternet Kaynağı

<%**1**

2

Submitted to Celal Bayar Üniversitesi

Öğrenci Ödevi

<%**1**

3

ichi.pro

İnternet Kaynağı

<%**1**

4

www.veribilimiokulu.com

İnternet Kaynağı

<%**1**

5

acikbilim.yok.gov.tr

İnternet Kaynağı

<%**1**

6

Submitted to Baskent University

Öğrenci Ödevi

<%**1**

7

Submitted to Istanbul Aydın University

Öğrenci Ödevi

<%**1**

8

9lib.net

İnternet Kaynağı

<%**1**

9

Submitted to Karadeniz Teknik University

Öğrenci Ödevi

<%**1**

10	Submitted to Ege Üniversitesi Öğrenci Ödevi	<% 1
11	www.gecekitapligi.com İnternet Kaynağı	<% 1
12	ERKMEN, Nurtekin and ÇETİN, M. Çağrı. "Beden eğitimi öğretmenlerinin denetim odağının bazı değişkenlere göre incelenmesi", Selçuk Üniversitesi, 2007. Yayın	<% 1
13	dspace.trakya.edu.tr:8080 İnternet Kaynağı	<% 1
14	tod.org.tr İnternet Kaynağı	<% 1
15	dergipark.org.tr İnternet Kaynağı	<% 1
16	scholar.archive.org İnternet Kaynağı	<% 1
17	www.matematiksel.org İnternet Kaynağı	<% 1
18	www.scribd.com İnternet Kaynağı	<% 1

EK-3 BİLGİLENDİRİLMİŞ ONAM FORMU

	T.C. AFYONKARAHİSAR SAĞLIK BİLİMLERİ ÜNİVERSİTESİ DİŞ HEKİMLİĞİ FAKÜLTESİ BİLGİLENDİRİLMİŞ ONAM FORMU
---	--

CALIŞMANIN ADI: Ortodontik Tedavi Öncesi Hasta Kooperasyonunun Yapay Zeka İle Tahmini

*Aşağıda bilgileri yer almakta olan bir araştırma çalışmasına katılmanız istenmektedir. Çalışmaya katılıp katılmama kararı tamamen size aittir. Katılmak isteyip istemediğinize karar vermeden önce araştırmanın neden yapıldığını, bilgilerinizin nasıl kullanılacağını, çalışmanın neleri içerdiğini, olası yararları ve risklerini ya da rahatsızlık verebilecek yönlerini anlamanız önemlidir. Lütfen aşağıdaki bilgileri dikkatlice okumak için zaman ayırınız. Eğer çalışmaya katılma kararı verirsiniz, **Çalışmaya Katılma Onayı Formu**'nu imzalayınız. Çalışmadan herhangi bir zamanda ayrılmakta özgürsünüz. Çalışmaya katıldığınız için size herhangi bir ödeme yapılmayacak ya da sizden herhangi bir maddi katkı/malzeme katkısı istenmeyecektir.*

CALIŞMANIN KONUSU VE AMACI :

Ortodontik tedavi öncesinde hastanın tedaviye uyum sağlayıp sağlayamayacağını anlamamız için hastadan tedaviye başlamadan önce ,fotoğraflar,tedavi esnasında uyulması gereken konular ile ilgili hazırlanan metni okurken alınan ses kaydı ve aynı metnin el yazısıyla yazılmış halini yapay zekaya tanıtip ve yeni başlanacak hastanın uyumlu olup olmadığını tahmin etmesi sağlanacaktır. Ayrıca hastalara ait yaş, cinsiyet, eğitim durumu gibi sosyodemografik veriler de yapay zeka eğitiminde kullanılacaktır. Hastalardan alınan kişisel bilgiler, fotoğraflar, ses kayıtları ve el yazıları sadece araştırmacı hekimler tarafından değerlendirilecektir. Araştırmacılar dışında kimse hiçbir şekilde çalışma için toplanan verilere erişemeyecektir.

Yapay zeka tıp ve diş hekimliği alanlarında hasta değerlendirilmesi ve tedavi planlamasında kullanılan bir bilgisayar uygulamasıdır ve hekimin daha iyi sonuçlar elde etmesine yardımcı olur. Çalışmamızda ise 500 gönüllü hastadan alınan fotoğraflar, ses kayıtları ve el yazıları verileri yapay zeka programlarıyla değerlendirilerek hasta uyumunun tedavi başlangıcında tahmin edilebilmesi sağlanacaktır.

ÇALIŞMA İŞLEMLERİ:

Rutin olarak her hastada aldığımız fotoğraflara ilave olarak el yazısıyla dolduracakları formlar ve muayene esnasında doktoru tarafından alınacak ses kayıtları üzerinde çalışma yapılacaktır.

ÇALIŞMADA YER ALMAMIN YARARLARI NELERDİR?

Ortodontik tedavi öncesinde yapılacak planlamalarda hekimin her hastaya özel olarak daha uygun tedavi seçeneklerini tercih etmeyi kolaylaştıracaktır. Ayrıca Ortodontik tedavi sonunda daha sağlıklı ve başarılı sonuçlar elde edilebilmesine olanak tanıyacaktır.

BU ÇALIŞMAYA KATILMAMIN MALİYETİ NEDİR? (Bu bölüm aynen korunacaktır)

Çalışmaya katılmakla parasal yük altına girmeyeceksiniz ve size de herhangi bir ödeme yapılmayacaktır.

ÇALIŞMAYA KATILMALI MIYIM?

Bu çalışmada yer alıp almamak tamamen size bağlıdır. Şu anda bu formu imzalarsanız bile istediğiniz herhangi bir zamanda bir neden göstermeksizin çalışmayı bırakmakta özgürsünüz. Eğer katılmak istemez iseniz veya çalışmadan ayrılırsanız, doktorunuz tarafından sizin için en uygun tedavi planı uygulanacaktır. Aynı şekilde çalışmayı yürüten doktor çalışmaya devam etmenizin sizin için yararlı olmayacağına karar verebilir ve sizi çalışma dışı bırakabilir, bu durumda da sizin için en uygun tedavi seçilecektir.

ÇOCUĞUMUN KİŞİSEL BİLGİLERİ NASIL KULLANILACAK? (Bu bölüm aynen korunacaktır)

Çalışma doktorunuz çocuğunuz ile ilgili kişisel bilgileri, araştırmayı ve istatistiksel analizleri yürütmek için kullanacaktır. Çalışmanın sonunda, bu bilgiler hakkında bilgi istemeye hakkınız vardır. Çalışma sonuçları çalışma bitiminde tıbbi literatürde yayınlanabilecektir ve çocuğunuzun tedavi başlangıcında alınan fotoğrafları yayın içerisinde yer alabilecektir.

İzleyiciler, yoklama yapan kişiler, Etik Kurul, Sağlık Bakanlığı ve diğer ilgili sağlık otoriteleri orijinal tıbbi kayıtlarınıza doğrudan erişebilir. Bu yazılı bilgilendirilmiş gönüllü olur formunu imzalayarak yalnızca adı geçen kişi ve kurumlara erişim izni vermiş olacaksınız. Araştırmacılar dışında kimse hiçbir şekilde çalışma için toplanan (fotoğraflar, kişisel bilgiler gibi) verilere erişemeyecektir.

SORU VE PROBLEMLER İÇİN BAŞVURULACAK KİŞİLER :

ADI : Hasan CAMCI
GÖREVİ : Doktor Öğretim Üyesi
TELEFON :

ADI : Farhad Salmanpour
GÖREVİ : Araştırma Görevlisi
TELEFON :

AFYONKARAHİSAR SAĞLIK BİLİMLERİ ÜNİVERSİTESİ DİŞ HEKİMLİĞİ
FAKÜLTESİ /ORTODONTİ ANABİLİM DALI

CALIŞMAYA KATILMA ONAYI

Yukarıdaki bilgileri ilgili araştırmacı ile ayrıntılı olarak tartıştım ve kendisi bütün sorularımı cevapladı. Bu bilgilendirilmiş olur belgesini okudum ve anladım. Bu araştırmaya katılmayı kabul ediyor ve bu onay belgesini kendi hür irademle imzalıyorum. Bu onay, ilgili hiçbir kanun ve yönetmeliği geçersiz kılmaz. Araştırmacı, saklamam için bu belgenin bir kopyasını çalışma sırasında dikkat edeceğim noktaları da içerecek şekilde bana teslim etmiştir.

<i>Gönüllü Adı Soyadı:</i>		<i>Tarih ve İmza:</i>
<i>Telefon:</i>		

<i>Velisinin Adı Soyadı:</i>		<i>Tarih ve İmza:</i>
<i>Telefon:</i>		

<i>Araştırmacı Adı Soyadı:</i>	Dr.Hasan CAMCI	<i>Tarih ve İmza:</i>
<i>Telefon:</i>		

1: Gönüllünün bilgilendirilme işlemine başından sonuna dek tanıklık eden kişi

2:Gönüllüyü araştırma hakkında bilgilendiren kişi

EK-4 Ortodontik Hasta Kooperasyonu Skalası

Ortodonti Hasta kooperasyon skalası

Lütfen bu formda adı geçen hastayı göz önünde bulundurarak aşağıdaki davranış listesini okuyun. Her madde için, hastanın davranışını en iyi şekilde ifade eden yanıtı işaretleyin.

Hastanın adı:

1.Hasta randevu tarihlerine ve saatlerine uyar.

Her zaman Sıklıkla Bazen Nadiren Hiçbir zaman

2. Hastada deforme teller ve/veya kırılmış braketler vardır.

Her zaman Sıklıkla Bazen Nadiren Hiçbir zaman

3. Hastanın ebeveynlerinin tedaviye önem verdikleri ve ilgilendikleri gözlemlenmektedir.

Her zaman Sıklıkla Bazen Nadiren Hiçbir zaman

4. Hasta ailevi sorunlardan veya ebeveynler ile zayıf bir ilişkiden söz ediyor veya ebeveynlerle iletişimlerinde problemleri gösteriyor.

Her zaman Sıklıkla Bazen Nadiren Hiçbir zaman

5. Hasta tedaviye hevesli ve ilgilidir.

Her zaman Sıklıkla Bazen Nadiren Hiçbir zaman

6. Hasta somurtkan, agresif veya kabadır.

Her zaman Sıklıkla Bazen Nadiren Hiçbir zaman

7. Hasta aparey ve/veya lastik kullanımında işbirliği yapıyor.

Her zaman Sıklıkla Bazen Nadiren Hiçbir zaman

8. Hasta tedavi işlemlerinden şikayetçidir.

Her zaman Sıklıkla Bazen Nadiren Hiçbir zaman

9. Hasta mükemmel ağız hijyeni sergiler.

Her zaman Sıklıkla Bazen Nadiren Hiçbir zaman

10. Hasta ağızındaki diş telinden yakınıyor.

Her zaman Sıklıkla Bazen Nadiren Hiçbir zaman

EK-4 Bireyin el yazısı örneği ve ses kaydı alınmasında kullanılan metin

ORTODONTİK TEDAVİLERİN BAŞARILI SONUCLANMASI İÇİN DİKKAT EDİLMESİ GEREKENLER:

- Ön dişlerinizle yumuşak veya sert hiçbir gıdayı (sandviç, hamburger, tost, yemek, mısır, meyve vs)ısırarak yemeyiniz. Yiyecekleri elinizle kopararak veya çatal-bıçak yardımıyla bölerek küçük lokmalar halinde yiyiniz.
- Meyvelerinizi soyarak ve bölerek küçük lokmalar halinde yiyiniz.
- Cips gibi gıdaları yemeyiniz, eğer kesinlikle yemek istiyorsanız cipsleri önce toz haline getirip sonra kaşık yadımı ile yiyiniz.
- Kabuklu ve kabuksuz kuruyemişleri kesinlikle tüketmeyiniz.
- Sert gıdalardan (ekmek kabuğu, yapışkan şekerler vs) uzak durunuz.
- Yapışkan gıdalar (karamel, şekerler vs) tüketmeyiniz, sakız çiğnemeyiniz.
- Zeytin, kiraz, yeşil erik gibi yemişlerin öncelikle dışarıda çekirdeğini çıkardıktan sonra yiyiniz.
- Asitli ve şekerli içecekleri (kola, gazoz) tüketmeyiniz. Bu içecekler dişlerde lekelenme ve çürüklere neden olmaktadır.
- Tellerinizde batan ve sivri çıkıntılar fark ederseniz bu bölgelere ortodontik mum yerleştiriniz.

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı, Soyadı: Farhad SALMANPOUR
Uyruğu: İran
Doğum Tarihi ve Yeri:
Medeni durum: Bekar
E-posta :

EĞİTİM

Lisans, Yüksek Lisans:

YABANCI DİL

YAYINLAR / BİLİMSEL ETKİNLİK

A. Uluslararası SCI dergilerde yayımlanan makaleler :

A1. CAMCI HASAN, SALMANPOUR FARHAD (2022). Impact of intraoral scanning conditions on the accuracy virtual aligners (VA). Australasian Orthodontic Journal, 38(1), 102-110., Doi: 10.21307/aoj-2022.010 (Çeyreklik Dilim=Q4)

A2. CAMCI HASAN, SALMANPOUR FARHAD (2022). Estimating the size of unerupted teeth: Moyers vs deep learning. American journal of orthodontics and dentofacial orthopedics, Doi: 10.1016/j.ajodo.2021.03.015 (Çeyreklik Dilim=Q2)

A3. Camcı Hasan, Salmanpour Farhad (2020). Effect of saliva isolation and intraoral light levels on performance of intraoral scanners. AMERICAN JOURNAL OF ORTHODONTICS AND DENTOFACIAL ORTHOPEDICS, 158(5), 759-766., Doi: DOI: 10.1016/j.ajodo.2020.03.022 (Çeyreklik Dilim=Q2)

B. Uluslararası diğer alan indekslerinde taranan dergilerde yayımlanan makaleler :

B1. CAMCI HASAN, SALMANPOUR FARHAD (2021). A new technique for testing accuracy and sensitivity of digital bite registration: A prospective comparative study. International Orthodontics, 19, 425-432., Doi: 10.1016/j.ortho.2021.06.008

B2. CAMCI HASAN, SALMANPOUR FARHAD (2021). Effect of sinus proximity, alveolar bone level, and initial buccolingual inclination on behavior of upper first molar under the expansion force: a finite element analysis . Journal of the World Federation of Orthodontists, Doi: 10.1016/j.ejwf.2021.12.001

B3. CAMCI HASAN, SALMANPOUR FARHAD (2021). Effects of Type and Amount of Orthodontic Tooth Movement on Digital Model Superimposition Accuracy. Turkish Journal of Orthodontics, 34, 220- 226., Doi: 10.5152/TurkJOrthod.2020.20146

B4. CAMCI HASAN, SALMANPOUR FARHAD (2021). Comparison of skeletal and dentoalveolar effects of two different mandibular advancement methods: Conventional technique vs aesthetic approach. European Oral Research, Doi: 10.26650/eor.2022903844

B5. Camcı Hasan, Salmanpour Farhad (2020). Cephalometric Evaluation of Anterior Cranial Base Slope in Patients with Skeletal Class I Malocclusion with Low or High SNA and SNB Angles . Turkish Journal of Orthodontics, 33(3), 171-176., Doi: DOI: 10.5152/TurkJOrthod.2020.20017

C. Uluslararası bilimsel toplantılarda sunulan ve bildiri kitaplarında basılan bildiriler:

C1. Mandibular Retrognati Tedavisine Estetik Bir Yaklaşım: Essix Plaklarla İlerletme , CAMCI HASAN, SALMANPOUR FARHAD (2021).. 17.Türk Ortodonti Derneği Uluslararası Sanal Kongresi, (Özet bildiri)

C2. Orthodontic Treatment of Class II Malocclusion Using Pendex Appliance: A Case Report , SALMANPOUR FARHAD, CAMCI HASAN, Canbaz Çevik Şeyda (2021).. 17. Türk Ortodonti Derneği Uluslararası Sanal Sempozyumu (28-29 KASIM 2021), (Özet bildiri)

C3. İSKELETSEL SINIF 2 MALOKLÜZYONUN ŞİDDETİ İLE SERVİKAL SPİNA POSTÜRÜ ARASINDAKİ KOLERASYONUN DEĞERLENDİRİLMESİ , CAMCI HASAN, SALMANPOUR FARHAD (2019).. 26. Uluslararası İzmir Dişhekimleri Odası Kongresi ve Sergisini, (Özet bildiri)

C4. skeletsel Maturasyonun El-Bilek Filmi ile Değerlendirilmesinde Yapay Zeka: Derin Öğrenme Algoritmasının Başarı Oranı , CAMCI HASAN, SALMANPOUR FARHAD (2021).. 17.Türk Ortodonti Derneği Uluslararası Sanal Kongresi, (Özet bildiri)

C5. An Easy Mechanic For Upper Second Molar Uprighting: A Case Report , SALMANPOUR FARHAD, CAMCI HASAN (2021).. 17. Türk Ortodonti Derneği Uluslararası Sanal Sempozyumu (28-29 KASIM 2021), (Özet bildiri)

C6. Sınıf II Malokluzyonların Tedavi Seçeneğinin Yapay Zeka ile Belirlenmesi: Hareketli veya Sabit Fonksiyonel Aparey? , SALMANPOUR FARHAD, Canbaz Çevik Şeyda, CAMCI HASAN (2021).. 17.Türk Ortodonti Derneği Uluslararası Sanal Kongresi, (Özet bildiri)

C7. Orta Hat Düzeltiminde Diagonal Elastiklerin Etkinliği: Bir Vaka Raporu, SALMANPOUR FARHAD, AKIN ŞUAYIP, ŞENOCAK ASIYE IŞIL, CAMCI HASAN (2021).. 17.Türk Ortodonti Derneği Uluslararası Sanal Kongresi, (Özet bildiri)