

ANKARA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

DOKTORA TEZİ

TEMPOROMANDİBULAR EKLEM DÜZENSİZLİĞİ İÇİN MAKİNE
ÖĞRENMESİ TABANLI YENİ BİR YAKLAŞIM

Şifa ÖZSARI

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

ANKARA
2023

Her hakkı saklıdır

ÖZET

Doktora Tezi

TEMPOROMANDİBULAR EKLEM DÜZENSİZLİĞİ İÇİN MAKİNE ÖĞRENMESİ TABANLI YENİ BİR YAKLAŞIM

Şifa ÖZSARI

Ankara Üniversitesi
Fen Bilimleri Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı

Danışman: Doç. Dr. Mehmet Serdar GÜZEL

Çenenin açılması, kapanması ve çiğneme gibi temel işlevleri etkileyebilen temporomandibular eklem bozuklukları yaygın olarak görülen bir hastalıktır. Temporomandibular eklem hastalıklarının kökeni tam olarak bilinmemekle birlikte, çeşitli risk faktörleriyle ilişkilendirildiği düşünülmektedir. Günümüzde, teşhisi genellikle bir diş hekimi veya maksillofasiyal cerrah tarafından muayene ile konulmaktadır ve otomatik bir sistem kullanılmamaktadır. Bu tez çalışması kapsamında MR taramalarından oluşan özgün bir veri seti oluşturulmuştur. Bu veri seti Ankara Üniversitesi Diş Hekimliği Fakültesi ile beraber hazırlanmış olup etik onayı alınmıştır. İlgili veri seti kapsamında, 4 farklı hastalık üzerinde çalışılmıştır. İlgili hastalıklar: ağız açık pozisyonda diskin önde olması, ağız kapalı pozisyonda diskin önde olması, sinoviyal sıvıda artış olması ve kondil kemikte dejenerasyon olmasıdır.

Bu kapsamda hastalık teşhisi için evrişimli sinir ağı modelleri üzerinde çalışılmıştır. Problem üzerinde popüler derin öğrenme mimarileri (GoogleNet, VGG, Xception, ResNet, MobileNet, Inception, DenseNet, ConvNeXt) ve ViT yaklaşımı uygulanmıştır. Yöntemlerin başarıları çeşitli metrikler kullanılarak incelenmiş, modeller arasındaki uyum SKK değeri ile yorumlanmıştır. Yapılan deneyler sonucunda en iyi sonucu popüler derin öğrenme yaklaşımları vermiş olup, modeller arasında kabul edilebilir uyum olduğu gözlemlenmiştir. Ortalama olarak %80 ve üzeri bir başarı elde edilmiştir. Ayrıca Grad-CAM görüntüleri ile diş hekimi tarafından işaretlenen kısımlar karşılaştırıldığında ağların genel olarak hastalıkla ilgili kısımlara odaklandığı görülmüştür. Ayrıca, literatürde yer alan TME hastalıkları üzerinde yapılmış olan bilgisayar temelli yaklaşımlar ele alınmış, TMD yayınları tek tek açıklanmıştır. Böylece, bu alandaki çalışmaların anlaşılması ve ileride yapılacak olan yeni uygulanmalarda yol göstermesi amaçlanmıştır.

Aralık 2023, 93 sayfa

Anahtar Kelimeler: Temporomandibular eklem, temporomandibular eklem düzensizlikleri, derin öğrenme

ABSTRACT

Ph.D. Thesis

A NEW MACHINE LEARNING BASED APPROACH FOR TEMPOROMANDIBULAR JOINT DISORDERS

Şifa ÖZSARI

Ankara University
Graduate School of Natural and Applied Sciences
Department of Computer Engineering

Supervisor: Assoc. Prof. Dr. Mehmet Serdar GÜZEL

The temporomandibular joint disorders, which can affect basic functions such as opening, closing, and chewing of the jaw, are a common ailment. The etiology of temporomandibular joint disorders remains incompletely elucidated; nevertheless, they are postulated to be linked with a range of risk factors. Presently, diagnosis is typically performed through clinical examination by a dentist or maxillofacial surgeon, without the use of an automated system. Within the scope of this thesis, an original dataset composed of MR scans has been created. This dataset was prepared in collaboration with Ankara University Faculty of Dentistry and obtained ethical approval. Within the dataset, study has been conducted on four different diseases: anterior disc displacement with reduction, anterior disc displacement without reduction, increased synovial fluid, and condylar bone degeneration.

In this context, convolutional neural network models were employed for disease diagnosis. Popular deep learning architectures, including GoogleNet, VGG, Xception, ResNet, MobileNet, Inception, DenseNet, ConvNeXt, and the ViT approach, were applied. The performance of the methods was examined using various metrics, and the consistency between the models was interpreted using the ICC value. As a result of the experiments, popular deep learning approaches yielded the best results, with acceptable consistency observed among the models. On average, an accuracy rate of 80% or higher was achieved. Furthermore, when comparing the areas marked by dentists on Grad-CAM images, it was observed that the networks generally focused on regions related to the disease. Moreover, computer-based approaches on TMJ disorders were addressed, and TMD publications were individually elucidated. Thus, the aim was to enhance the understanding of studies in this field and provide guidance for future implementations.

December 2023, 93 pages

Key Words: Temporomandibular joint, temporomandibular joint disorders, deep learning

TEŞEKKÜR

Tez çalışmam boyunca, rehberliğini, desteğini, bilgilerini esirgemeyen ve beni cesaretlendiren, aynı zamanda hem akademik hayatımda hem insan ilişkilerinde tecrübelerini paylaşarak gelişmeme yardımcı olan danışman Hocam Sayın Doç. Dr. Mehmet Serdar GÜZEL’e,

Tez izleme komitemin üyeleri olan, değerli yorum ve katkıları ile çalışmanın niteliğini arttıran sayın Doç. Dr. Gazi Erkan BOSTANCI ve Prof. Dr. Kıvanç KAMBUROĞLU’na (Ankara Üniversitesi Diş Hekimliği Fakültesi, Klinik Bilimler Bölümü, Ağız, Diş ve Çene Radyolojisi Anabilim Dalı); tez jürimde bulunan, önerileri ile tezimin şekillenmesine yardımcı olan sayın Prof. Dr. İhsan Tolga MEDENİ (Ankara Yıldırım Beyazıt Üniversitesi, İşletme Fakültesi, Yönetim Bilişim Sistemleri Bölümü) ve Dr. Öğr. Üyesi Dilek YILMAZ’a (Başkent Üniversitesi Ağız, Diş ve Çene Radyolojisi Anabilim Dalı),

Çalışmada kullanılan veri setimizi oluşturmada katkısı bulunan ve yardımlarını esirgemeyen sayın Dr. Öğretim Üyesi Dilek YILMAZ’a, her zaman yanımda olan sevgili arkadaşım Arş. Gör. Mürüvvet KALKAN’a,

Maddi manevi desteklerini esirgemeyen, her daim yanımda olan anneme, babama, kardeşime, Melek’e, neşe ve motivasyon kaynağım olan yeğenim Mihra’ya en derin duygularla teşekkür ederim.

Şifa ÖZSARI
Ankara, Aralık 2023

İÇİNDEKİLER

TEZ ONAYI

ETİK.....	i
ÖZET	ii
ABSTRACT	iii
TEŞEKKÜR.....	iv
SİMGELER DİZİNİ.....	vii
ŞEKİLLER DİZİNİ	ix
ÇİZELGELER DİZİNİ.....	xi
1. GİRİŞ.....	1
1.1 Genel Bilgi.....	1
1.2 Motivasyon ve Tez Kapsamı.....	2
1.3 Tezin Yapısı.....	3
2. KAYNAK ÖZETLERİ VE KURAMSAL TEMELLER.....	4
2.1 Temporomandibular Eklem ve Rahatsızlıkları.....	4
2.2 Kaynak Özetleri.....	8
2.2.1 TME segmentasyonu	9
2.2.2 TME OA.....	11
2.2.3 JİA.....	12
2.2.4 Karar destek sistemleri	13
2.2.5 Derleme çalışmaları.....	15
2.2.6 Ses verisi kullanılan çalışmalar.....	16
2.2.7 TMD	19
3. MATERYAL VE YÖNTEMLER.....	34
3.1 MRG Veri Seti	34
3.2 Yapay Zekâ	41
3.3 Derin Öğrenme	42
3.3.1 GoogleNet.....	44
3.3.2 VGG.....	45
3.3.3 Xception	45
3.3.4 ResNet.....	46

3.3.5 MobileNetV2.....	46
3.3.6 InceptionV3.....	47
3.3.7 DenseNet-121	47
3.3.8 ConvNeXt.....	48
3.3.9 ViT	49
3.4 Başarı Metrikleri	50
4. TARTIŞMA VE SONUÇ.....	54
4.1 Parametre Ayarları	54
4.2 Deney Sonuçları.....	56
4.3 Tartışma	64
KAYNAKLAR.....	67
EK 1 MR TARAMASINDA KULLANILAN CİHAZ	78
ÖZGEÇMİŞ.....	79

SİMGELER DİZİNİ

g	Gradient (Gradyan)
m	Hareket (Momentum)
t	İterasyon sayısı (Time step)
w	Ağırlık (Weight)
ϵ	Epsilon

Kısaltmalar

ADAM	Adaptive Moment Estimation
AUC	Area Under Curve
BİA, BBN	Bayesian İnanç Ağı (Bayesian Belief Network)
BT, CT	Bilgisayarlı Tomografi (Computed Tomography)
CNN	Convolutional Neural Network
Colab	Google Colaboratory
CVPR	Computer Vision and Pattern Recognition
DDL, NLP	Doğal Dil İşleme (Natural Language Processing)
DenseNet	Dense Convolutional Network
DNN	Deep Neural Network
DN, TN	Doğru Negatif, True Negative
DÖ, DL	Derin Öğrenme (Deep Learning)
DP, TP	Doğru Pozitif (True Positive)
DSCI	The Data Storage for Computation and Integration
EMG	Elektromiyografi
GA	Genetik Algoritma
Grad-CAM	Gradient-weighted Class Activation Mapping
HFV	High Frequency Value
ICC	Intraclass Correlation Coefficients
JİA, JIA	Juvenil İdiopatik Artrit (Juvenile Idiopathic Arthritis)
KBB	Kulak Burun Boğaz

KDS	Karar Destek Sistemi
KIBT, CBCT	Konik Işınlı Bilgisayarlı Tomografi, Cone-Beam Computed Tomography
LR	Lojistik Regresyon
MERGE	Multiple Echo Recombined Gradient Echo
MLP	Multi Layer Perceptron
MÖ, ML	Makine Öğrenmesi (Machine Learning)
MRG, MRI	Manyetik Rezonans Görüntüleme (Magnetic Resonance Imaging)
NN	Neural Network
NPV	Negative Predictive Value
OA	Osteoartrit
PD	Proton Density
PPV	Positive Predictive Value
ResNet	Residual Network
RF	Random Forest
ROC	Receiver Operating Characteristic
RMSprop	Root Mean Square Propagation
sEMG	Surface Electromyography
SOM	Self-Organizing Map
SSD	Single-Shot Detector
T	Tesla
TMD, TMD	Temporomandibular Eklem Düzensizlikleri (Temporomandibular Joint Disorders)
TME, TMJ	Temporomandibular Eklem (Temporomandibular Joint)
VGG	Visual Geometry Group
ViT	Vision Transformer
YN, FN	Yanlış Negatif (False Negative)
YP, FP	Yanlış Pozitif (False Positive)
YZ, AI	Yapay Zekâ (Artificial Intelligence)

ŞEKİLLER DİZİNİ

Şekil 2.1 TME'nin anatomik yapısı (Kulesa vd. 2022)	5
Şekil 2.2 TME ile ilişkili hastalıklar	6
Şekil 2.3 Temporomandibular eklem kemik ve eklem diski arasındaki ilişkisi: (A1) ağız açık pozisyonunda disk normal, (A2) ağız kapalı pozisyonunda disk normal, (B1) ağız açık pozisyonda disk önde, (B2) ağız kapalı pozisyonda disk önde...	8
Şekil 2.4 Küçük görüş alanı taramalarını bölümlere ayırmak için TMJSeg'in adımları (Brosset vd. 2021)	10
Şekil 2.5 Sağlıklı ve TME OA (a): Sağlıklı kişi (b) TME OA (Bianchi vd. 2020)	11
Şekil 2.6 Örnek bir karar destek sistemi (Ofilas 2020)	14
Şekil 2.7 (Lin vd. 2021) çalışmasının genel aşamaları	20
Şekil 3.1 Sagittal oblik düzlemde sağ TME, PD serisinde: (a) ağız kapalı, (b) ağız açık, (kırmızı ok) normal disk pozisyonu görünümü, (c) sagittal oblik düzlemde sağ ağız kapalı TME efüzyonu (kırmızı oklar), MERGE serisi, (d) sagittal düzlemde sağ ağız kapalı TME	36
Şekil 3.2 Ağız açık pozisyonda diskin durumu (a) önde (b) normal	38
Şekil 3.3 Ağız kapalı pozisyonda diskin durumu (a) önde (b) normal	38
Şekil 3.4 Kondil kemik durumu (a) dejenerasyon var (b) dejenerasyon yok.....	39
Şekil 3.5 Sinoviyal sıvı seviyesi (a) artış var (b) artış yok.....	39
Şekil 3.6 Kesilmiş görüntüler. 1 ağız kapalı: (a) disk önde, (b) disk normal. 2 ağız açık: (a) disk önde, (b) disk normal. 3 sinoviyal sıvı seviyesi: (a) artış var, (b) normal. 4 kondil kemik dejenerasyonu: (a) var, (b) yok.....	40
Şekil 3.7 Örnek bir evrişimli sinir ağı yapısı	43
Şekil 3.8 Problem çözümünde takip edilen adımların akış şeması	44
Şekil 3.9 InceptionV3 temel yapısı (Medium 2021).....	48
Şekil 3.10 DenseNet yapısı (Li vd. 2020).....	48
Şekil 3.11 ViT yapısı	50
Şekil 3.12 Grad-CAM colormap	53
Şekil 4.1 Kayıp(loss) grafikleri (a) Ağız kapalı MobileNet (b) Ağız açık Xception (c) Sinoviyal sıvı ResNet (d) Kondil kemik MobileNet	61
Şekil 4.2 Doğruluk (accuracy) grafikleri (a) Ağız kapalı MobileNet (b) Ağız açık	

Xception (c) Sinoviyal sıvı ResNet (d) Kondil kemik MobileNet	62
Şekil 4.3 Grad-CAM sonuçları. 1: Ağız kapalı MobileNet, 2: Ağız açık Xception, 3: Sinoviyal sıvı ResNet, 4: Kondil kemik MobileNet. (a) Diş hekimi tarafından yapılan işaretleme, (b) Model tarafından yapılan renklendirme.....	63



ÇİZELGELER DİZİNİ

Çizelge 2.1 TME üzerinde yapılmış çalışmaların özeti	17
Çizelge 2.2 TMD çalışmaları 2014-2018.....	25
Çizelge 2.3 TMD çalışmaları 2019-2020.....	26
Çizelge 2.4 TMD çalışmaları 2021	28
Çizelge 2.5 TMD çalışmaları 2022-2023	30
Çizelge 3.1 Veri seti dağılımı.....	35
Çizelge 4.1 Ağız kapalı pozisyonda modellerin performansı	57
Çizelge 4.2 Ağız açık pozisyonda modellerin performansı	57
Çizelge 4.3 Sinoviyal sıvı için modellerin performansı.....	58
Çizelge 4.4 Kondil kemik için modellerin performansı.....	59
Çizelge 4.5 ICC değerleri.....	63

1. GİRİŞ

1.1 Genel Bilgi

Temporomandibular eklem, çenenin kafatasına bağlandığı eklem olup ağız açma, kapama ve çiğneme gibi hareketlerin gerçekleşmesini sağlar. TME, çiğneme kasları ve çene kemikleri ile koordinasyon halinde çalışarak ağız hareketlerini yönlendirir. Temporomandibular eklem düzensizliği genel bir ifade ile, bu eklemlerde meydana gelen bir dizi rahatsızlık veya ağrıdır. Günümüzde TME bozukluklarının teşhisi otomatik bir sistem kullanılmadan hekimin klinik ve radyolojik muayenesi ile yapılmaktadır. Bundan dolayı teşhis ve tedavi süreci uzayabilmektedir.

Geçmişten günümüze insanlara olan bağımlılığı en aza indirmek, günlük yaşamdaki işleri daha hızlı ve kolay bir şekilde yapma temel hedeflerden biri olmuştur. Bu istek, teknolojinin hızla ilerlemesine imkân tanımaktadır. Teknoloji, genellikle bilim, mühendislik ve pratik deneyimin birleşimini ifade eder; yeni ürünler, sistemler veya süreçlerin tasarlanmasını, geliştirilmesini, üretilmesini ve kullanılmasını içerir. İnsanların çeşitli ihtiyaçlarına çözümler sunarak iş verimliliğini artırır ve yaşam konforunu yükseltir. Bu gelişmeler, yaşam tarzımızı, çalışma şeklimizi ve dünyayla etkileşimimizi şekillendirir. Hemen hemen her alanda etkin bir rol oynayan teknoloji, sağlık alanında da oldukça etkili ve yaygındır. Diş hekimliği alanında da çeşitli uygulamaları bulunmakta olup, bu uygulamalar diş sağlığı hizmetlerinin daha etkili, hassas ve verimli bir şekilde sunulmasına olanak tanımaktadır. Bundan dolayı, TME rahatsızlıklarının da otomatik olarak teşhis edilmesi hem hekime yol göstermesi hem de zamandan tasarruf sağlaması açısından oldukça önemlidir.

Bu tez çalışması, temporomandibular eklem hastalıklarının teşhisi ve sınıflandırılması probleminin önemli bir yönünü ele almaktadır. Elde ettiğimiz çıktıların önemli sonuçlar sunduğuna ve gerçekleştirdiğimiz literatür araştırmasının ilerideki çalışmalara ışık tutacağına inanıyoruz.

1.2 Motivasyon ve Tez Kapsamı

Günümüzde, teşhisi genel olarak bir diş hekimi veya çene cerrahı tarafından yapılan temporomandibular eklem rahatsızlıkları oldukça yaygındır. Teşhis, hastanın fiziksel muayenesi ve çeşitli görüntüleme yöntemleri ile yapılmakta olup bir dizi adımlar takip edilmektedir:

- Hastanın anamnezinin alınması
- Fiziksel muayene
- Görüntüleme testleri

Bu süreçte otomatik bir sistem kullanılmamaktadır. Hastalık tanısının hızlı ve doğru bir şekilde yapılması, tedavi sürecinin etkinliği açısından oldukça önemlidir (Young-Wook vd. 2015). Bu alanda, klinik muayeneye yardımcı olarak MR taramaları teşhis için kullanılan önemli görüntüleme yöntemlerinden birisidir. Ancak, MR görüntülerine ait raporların eksiksiz yorumlanması ve doğru şekilde raporlandırılarak hastaya teslimi bazen haftalar sürebilmektedir, bu durum ise teşhis ve tedavi sürecinin uzamasına neden olmaktadır. Gelişen teknoloji sayesinde üretilen bilgisayar tabanlı tanı sistemleri bu sorunun çözümüne katkı sağlayabilecek potansiyele sahiptir. Bu tez çalışmasında, kendi oluşturduğumuz MR veri seti üzerinde derin öğrenme yaklaşımları kullanılarak 4 farklı TME hastalığının otomatik olarak teşhisi amaçlanmıştır. Bu rahatsızlıklar:

1. Ağız açık pozisyonda disk önde
2. Ağız kapalı pozisyonda disk önde
3. Sinoviyal sıvıda artış var
4. Kondil kemikte dejenerasyon var

Çalışmada kullanılan veriler Ankara Üniversitesi Diş Hekimliği Fakültesinden etik onayı alınmış görüntülerdir. Medikal görüntülerin alınmasının ve düzenlenmesinin etik açıdan zor bir süreç olduğu dikkate alındığında, kendi verilerimiz ile deney yapmamız oldukça önemlidir. Çalışma kapsamında hem kendi ağımız oluşturulmuş hem popüler derin ağlar (GoogleNet, VGG, Xception, ResNet, MobileNet, Inception,

DenseNet, ConvNeXt) transfer öğrenme yaklaşımı ile problem üzerinde uygulanmıştır. Bunlara ek olarak son zamanlarda oldukça popüler olan ViT problem üzerinde uygulanmıştır. Böylece farklı şekillerde problemin çözümü ele alınmıştır. Çalışmada yürütülmüş olan derin öğrenme mimarilerinin gerçek dünya problemini çözmedeki başarısı çeşitli metrikler ve istatistiksel testler kullanılarak incelenmiştir. Ayrıca Grad-CAM görüntüleme yöntemi ile çıkarımın hangi kısımlardan yapıldığı gözlemlenmiştir. Otomatik olarak çıkarım yapacak bir sistem ile hem zamandan tasarruf edilmesi hem de yeni diş hekimlerine rehberlik edilmesi hedeflenmiştir. Ek olarak, TME hastalıkları üzerine bilgisayar temelli yaklaşımların literatür taraması yapılmıştır. Özellikle TMD hakkında mevcut kaynaklar ayrıntılı bir şekilde incelenmiştir. Bu şekilde, TME ile ilgili hastalıklarda kullanılan bilgisayar temelli yöntemler özetlenmiştir. Bu özetlemelerin gelecekte bu alandaki çalışmalar için metodoloji ve kavramlar anlayışını artırıcı bir rol oynaması beklenmektedir.

1.3 Tezin Yapısı

Tez çalışmasının devamı şu şekilde düzenlenmiştir:

- ✓ Bölüm 2’de çalışma kapsamında incelenmiş TME ile ilgili rahatsızlıklar ve bu hastalıklar üzerinde uygulanmış olan bilgisayar temelli yaklaşımların literatür özeti sunulmuştur. Literatür taraması sonucunda TMD ile ilişkili (bilgisayar temelli) elde edilmiş tüm yayınlar açıklanmıştır. Diğer hastalıklardan bazıları hakkında bilgi verilmiş olup, tablolar ile detaylandırılmıştır.
- ✓ Bölüm 3’te kendi oluşturduğumuz veri seti ayrıntılı bir şekilde tanıtılmış, problem üzerinde uygulanmış olan yöntemler hakkında açıklayıcı bilgi verilmiştir. Ayrıca, başarı değerlendirme kriterlerine de bu bölümde değinilmiştir.
- ✓ Son olarak, 4. bölüm gerçekleştirilen deneyleri, bu yürütümlerden elde edilen sonuçları, bu çıktıların değerlendirmesini ve gelecek çalışmadaki hedefleri içermektedir.

2. KAYNAK ÖZETLERİ VE KURAMSAL TEMELLER

Tez çalışmasının bu bölümünde temporomandibular eklem hakkında detaylı bilgi verilmiş, TME hastalıkları açıklanmış ve bu rahatsızlıklar üzerinde uygulanmış olan bilgisayar temelli yaklaşımlar incelenmiştir. TMD ile ilgili çalışmalar detaylı olarak tek tek ele alınmıştır.


2.1 Temporomandibular Eklem ve Rahatsızlıkları

Temporomandibular eklem, yüz ve çene yapılarının hareketlerini kontrol eden bir eklem tipi olup çenenin yukarı aşağı ve yanlara doğru hareket etmesine olanak tanır. Temporomandibular eklem çigneme kasları ve stomatognatik sistemin diğer bileşenleri üzerinde etkisi vardır (Fonseca vd. 2009). TME, temporal kemik (kafatasının yan tarafındaki kemik) ile alt çenenin alt tarafında bulunan mandibula kemiğinin birleşiminden oluşmaktadır. TME bileşenleri arasında mandibula kondili, glenoid kavite, artiküler tüberkül, artiküler disk, retrodiskal doku, sinoviyal membran ve eklem kapsülü bulunmaktadır. Özellikle, artiküler disk, mandibula kondili ile temporal kemik arasında yer almaktadır ve bu şekilde her iki kemik parçasının doğrudan temasını engelleyerek yastık görevi yapmaktadır (Okeson 2013), (Mahl ve Silveira 2002). TME, çigneme, konuşma ve yüz ifadeleri gibi günlük aktiviteler sırasında önemli bir rol oynar. **Şekil 2.1**'de TME'nin anatomik yapısı sunulmuştur (Kulesa vd. 2022).

Bazı durumlarda TME'nin aktivitesinde rahatsızlıklar ortaya çıkabilmektedir. Bunlar:

- Çene ağrısı veya çenede rahatsızlık
- Çene eklemi çatırtısı veya tıklaması
- Ağız açma sırasında kısıtlanma, eklem bölgesinde ağrı (Dworkin ve LeResche 1992), (Peroz ve Tai 2002)
- Baş ağrısı veya boyun ağrısı
- Çigneme gücü veya ağrısı

gibi çeşitli semptomlara neden olabilmektedir.




Şekil 2.1 TME'nin anatomik yapısı (Kulesa vd. 2022)

Temporomandibular eklem hastalıklarının kökeni tam olarak aydınlatılamamış olmakla birlikte, bu hastalıkların çeşitli risk faktörleri ile ilişkilendirildiği düşünülmektedir. Bu faktörler arasında:

- Travma
- Parafonksiyonel alışkanlıklar,
- Vücut duruş pozisyonu
- Okluzal mikrotravma
- Biyolojik etkenler (ör. cinsiyet hormonları)
- Anatomik genotip farklılıkları
- Sistemik hastalıklar
- Uyku bozuklukları
- Zararlı psikososyal etkenler (stres, ağrı, duygusal durumlar gibi)

yer almaktadır (Cunha vd. 2007), (Silveira vd. 2007), (Grossmann vd. 2013), (Hunter ve Kalathingal 2013), (Maixner vd. 2011). **Şekil 2.2'**te bu tez çalışması kapsamında literatür taraması yapılmış olan (bilgisayar temelli çözümü olan) TME ile ilgili

hastalıklar gösterilmiştir.



Şekil 2.2 TME ile ilişkili hastalıklar


TME osteoartriti, TME bölgesindeki kemiğin bozulduğu ve yıprandığı bir dejeneratif eklem hastalığıdır (Cardoneanu vd. 2022). TME OA, genellikle yaşla birlikte ortaya çıkar (Kalladka vd. 2014) ve eklem yüzeyinin düzgün çalışmasını engelleyen kıkırdak hasarına yol açar. Juvenil idiyopatik artrit genç yaşlardaki bireyleri etkileyen bir tür kronik enflamatuvar eklem hastalığıdır. Bu rahatsızlıkta, bağışıklık sistemi yanlışlıkla kendi eklem dokularına karşı savunma reaksiyonu geliştirir. JİA'nın bir türü, temporomandibular eklemleri de (çene eklemleri) etkileyebilir.

Disk yer değiştirmesi olarak ortaya çıkan iç düzensizlik, TMD'nin yaygın bir şeklidir. Bu anormallikler, temporomandibular eklem içindeki tempolar kemik, kondil ve artiküler disk bileşenleri arasındaki dengenin bozulması sonucu ortaya çıkar. Medial, posterior ve lateral kaymaların aksine ön disk yer değiştirmesi ile daha sık karşılaşılır (Whyte vd. 2006). Enflamatuvar bir yanıt olan TME efüzyonu, TME içinde ve çevresinde aşırı sıvı birikmesidir. Bu tepki, romatoid hastalıklar, artrit, travma ve enflamatuvar değişikliklere bağlı içsel anormallikler sonucunda meydana gelir. Osteoartrit, TME yapılarında dejeneratif değişiklikler ve kondil düzensizlikleri olarak tanımlanır (Maizlin vd. 2010), (Peroz ve Tai 2002). Temporomandibular eklem bozukluğu, 20-40 yaşları arasındaki bireylerde diğer yaş gruplarına göre daha sık gözlenmektedir ve kadınlarda erkeklere göre daha fazla görülmektedir (Detamore

ve Athanasiou 2003), (Detamore vd. 2007), (Van Loon vd. 2002), (Warren ve Fried 2001). Temporomandibular eklemin, kemik ve eklem diski arasındaki ilişkisi **Şekil 2.3** gösterilmiştir.

TME hastalığının teşhisi için genellikle aşağıdaki adımlar izlenir:

- Hasta hikayesinin alınması: Hastanın semptomları, ağrıları, çene hareketleriyle ilgili yaşadığı herhangi bir kısıtlama veya zorluk hakkında bilgiler alınır.
- Fiziksel muayene: Bir diş hekimi uzmanı tarafından, hastanın çenesi, yüzü ve boyun bölgesi muayene edilir.
- Görüntüleme testleri: Teşhisi doğrulamak ve TME yapısını görsel olarak değerlendirmek için çeşitli görüntüleme yöntemleri kullanılır. Bunlar:
 - Radyografi: Genellikle çene eklemine iki boyutlu olarak değerlendirmeye olanak tanıyan radyografiler (TME radyografi ve panoramik radyografi) veya BT ve KIBT taramaları kullanılır.
 - MRG: TME' nin daha ayrıntılı görüntülenmesine yardımcı olabilir ve yumuşak dokuların ve özellikle diskin durumunu incelemek için kullanılır.
 - Ultrasonografi: Bazı durumlarda, çene eklemi ultrasonografisi de kullanılabilir.
- Laboratuvar testleri: TME hastalıkları bazen başka sağlık sorunları ile ilişkilendirilebilir. Bu nedenle, kan testleri gibi diğer laboratuvar testleri bazı durumlarda teşhis sürecine dahil edilebilir.
- Diğer uzmanların konsültasyonu: Bazı karmaşık TME vakalarında, bir KBB uzmanı veya romatolog gibi diğer uzmanların görüşüne başvurulabilir.



Şekil 2.3 Temporomandibular eklemin kemik ve eklem diski arasındaki ilişkisi: (A1) ağız açık pozisyonunda disk normal, (A2) ağız kapalı pozisyonunda disk normal, (B1) ağız açık pozisyonunda disk önde, (B2) ağız kapalı pozisyonunda disk önde

2.2 Kaynak Özetleri

Bu bölümde TME hastalıkları üzerinde bilgisayar temelli yapılmış olan çalışmaların incelemesi yapılmıştır. İncelenen yayınlar aşağıdaki gibi gruplara ayrılmıştır:

- TME Segmentasyonu
- TME OA
- JİA
- Karar Destek Sistemleri
- Ses Verisi ile Yapılan Çalışmalar
- Derleme
- TMD

TMD üzerine olan tüm çalışmalar tek tek ele alınmış ve detaylı olarak açıklanmıştır.

2.2.1 TME segmentasyonu


Görüntü segmentasyonu, dijital bir görüntünün farklı bölgelere veya parçalara bölünmesini sağlayan bir süreçtir (Cheng vd. 2001). Bu bölgeler, görüntüdeki nesnelerin veya yapıların özelliklerine dayalı olarak tanımlanır. Görüntü segmentasyonu için birçok farklı teknik ve algoritma bulunmaktadır. Bu teknikler görüntüdeki nesneleri veya yapıları tanımlamak için kontrast, renk, parlaklık, kenarlar ve piksel yoğunlukları gibi çeşitli özellikleri kullanır. Görüntü segmentasyonu, bilgisayarlı görüş projelerinde ve uygulamalarında verilerin daha iyi anlaşılmasına ve işlenmesine yardımcı olan önemli bir araç olarak kabul edilir. Bundan dolayı farklı çalışmalarda kendisine yer bulmuştur (Akbulut vd. 2017), (Heshmati vd. 2016), (Guo ve Sengur 2013), (Xu vd. 2018).

Otomatik TME segmentasyonu, bilgisayar-temelli algoritmalar ve yapay zekâ yöntemleri kullanılarak medikal görüntülerden TME sınırlarının otomatik olarak belirlenmesidir. Sağlık çalışanlarına TME ile ilişkili hastalıkları ve bozuklukları daha etkili bir şekilde teşhis etme ve tedavi etme konusunda yardımcı olacağından dolayı, bu süreç, tıbbi görüntü analizi açısından önemli bir role sahiptir. Bu nedenle, bu çalışmada TME üzerinde gerçekleştirilen segmentasyon çalışmaları da ele alınmıştır.

Ito ve arkadaşları (Ito vd. 2022) tarafından, temporomandibular bozukluğun teşhisini desteklemek amacıyla MRG’de eklem disklerini otomatik olarak tanımlayan ve bölen bir sistem sunulmuştur. Bu çalışmada, derin öğrenme-temelli semantik segmentasyon yöntemi ve normal veya yerinden oynamış eklem disklerini gösteren hastalardan alınan 217 adet manyetik rezonans görüntüsü kullanılmıştır. Derin öğrenmeye dayalı üç semantik segmentasyon yaklaşımı (3DiscNet, U-Net ve SegNet-basic) yöntemleri değerlendirilmiştir. Ayrıca, 12 ve 6 yıl deneyime sahip iki uzman ortodontist ile bir

uzman diş hekimi ve 25 yıl deneyime sahip bir maksillofasiyal radyolog, bağımsız olarak MR görüntülerinden TME'leri manuel olarak belirlemiştir. Bu algoritmalar arasında, SegNet-Basic ve 3DiscNet, hassasiyet, dice katsayısı ve pozitif prediktif değer metriklerinde benzer sonuçlar göstermiştir.

Brosset vd. (Brosset vd. 2021) “DSCI” olarak adlandırdıkları açık kaynaklı web tabanlı bir yazılım sunmuşlardır. Bu platform, bilgileri emniyetli bir biçimde koruma, algoritmaları uygulama ve işlemleri web tabanlı bir platformda yürütme hedefiyle oluşturulmuştur. DSCI, yüksek çözünürlüklü hacimsel görüntüler kullanarak TME segmentasyonu için otomatik bir görüntü işleme aracı, KIBT görüntülerinden mandibula otomatik segmentasyonunu gerçekleştiren U-Net mimarisi ve dijital diş modellerini otomatik olarak bölen RUNET modeli sunmaktadır. Dişlerin dijital modelleri, ağız içi tarayıcılar kullanılarak üretilmiştir. Kullanılan model, ResNet'e benzeyen ve artık bağlantılara sahip özelleştirilmiş bir U-Net türevidir. **Şekil 2.4** (Brosset vd. 2021), küçük görüş alanlı taramaların segmentasyon adımlarını göstermektedir.



Şekil 2.4 Küçük görüş alanı taramalarını bölümlere ayırmak için TMJSeg'in adımları (Brosset vd. 2021)


KIBT'den TME hacminin ve şeklinin nicel analizi için mandibular kondilin ve glenoid fossanın hassas segmentasyonu oldukça önemlidir. Araştırmacılar, TME'nin tam 3 boyutlu rekonstrüksiyonu için DL tabanlı otomatik segmentasyon aracını tanıtmışlardır (Vinayahalingam vd. 2023). Kondil ve glenoid fossayı bölümlerine ayırmak için 3D U-Net temelli üç aşamalı bir yaklaşım geliştirmişlerdir. Önerilen

yöntemi eğitmek ve test etmek için manuel olarak bölümlendirilmiş 154 KIBT görüntüsü kullanılmıştır. TME rekonstrüksiyonuna odaklanan başka bir çalışma ise Brosset ve arkadaşları tarafından yayınlanmıştır (Brosset vd. 2020).

Segmentasyon ile ilgili diğer çalışmalar arasında (Hidaka vd. 2023), (Fan vd. 2019), (Nozawa vd. 2022), (Burget vd. 2011), (Liu vd. 2021), (Kim vd. 2021), (Kwak vd. 2020), (Li vd. 2022) referansları yer almaktadır.

2.2.2 TME OA

Nüfusun %5 ila %12'sini etkileyen temporomandibular eklem osteoartriti, çiğneme bozukluğu, krepitasyon ve diş-yüz deformitesi dahil olmak üzere çeşitli şikayetlere neden olabilmektedir (Wang vd. 2015). Yaşlanma ile bu hastalığın ortaya çıkma olasılığı artış göstermektedir. Bu nedenle, morfolojik bozulma başlamadan önce durumun tespit edilmesi son derece kritiktir. **Şekil 2.5**'te sağlıklı bir TME ve OA'sı olan bir TME gösterilmiştir (Bianchi vd. 2020).



Şekil 2.5 Sağlıklı ve TME OA (a): Sağlıklı kişi (b) TME OA (Bianchi vd. 2020)

Bianchi ve arkadaşları (Bianchi vd. 2020) çalışmalarında, hastalık ve sağlıklı ile ilgili biyobelirteçler arasındaki etkileşimleri derinlemesine incelemek için yeni bir görselleştirme yöntemi tanıtmışlardır. TME OA' nın karmaşık kökenlerini daha iyi anlamak için, veri tabanlı yaklaşımlarına bilgi modeli entegre etmişlerdir. Araştırma,

veri yönetimi, klinik ve biyomoleküler veri toplama, standartlaştırılmış görüntüleme, TME OA hastalarını ve sağlıklı kontrol grubundaki bireyleri standart demografik verilere göre eşleştirme ve çeşitli veri havuzlarından toplanan hastaların verilerini çapraz kontrol etme işlemlerini içermektedir. 52 değişkeni değerlendirmek için makine öğrenme yöntemlerini kullanmışlardır ve en önemli entegratif özellik havuzlarını makine öğrenme algoritmalarını kullanarak tanımlamışlardır. Standartlaştırılmış hasta özellikleri, istatistiksel makine öğrenme algoritmaları ile çeşitli kaynaklardan bir araya getirilmiştir.

TME OA üzerinde yapılmış olan bilgisayar temelli çalışmalara ayrıca (Lee vd. 2020), (Choi vd. 2021), (Jung vd. 2021), (Shoukri vd. 2019), (Ribera vd. 2019), (Le vd. 2021), (Kim vd. 2020), (de Dumast vd. 2018), (Eşer vd. 2023) referansları örnek olarak verilebilir.

2.2.3 JİA

Jüvenil idiyopatik artrit, çoğunlukla 16 yaşından önce başlayan, 6 hafta veya daha fazla süren sürekli bir artrit türüdür. Genellikle çocuk yaştaki kişileri etkilese de yetişkinlerde de nadir olarak görülebilmektedir. Bu hastalığın tam nedeni henüz bilinmemektedir. Genetik ve çevresel faktörlerin de hastalığın ilerlemesinde etken olabileceği düşünülmektedir. Dış hekimliği açısından, bu durum, TME'yi etkileyebilen ve yüz gelişim bozukluklarına, ağrılara ve/veya çene işlevlerinde bozulmalara neden olabilen bir kronik enflamatuvar hastalık olarak kabul edilmektedir. (Larheim vd. 2015).

JİA'nın teşhisi, hastanın ayrıntılı tıbbi geçmişinin değerlendirilmesini, fiziksel muayenesini ve eklem iltihabını doğrulamak için laboratuvar testlerini barındıran bir süreci içerir. Erken tanı ve doğru tedavi, eklem hasarını engellemek ve uzun vadeli sonuçları iyileştirmek bakımından hayati bir rol oynamaktadır.

TME hastalığının teşhisi için MRG genellikle kabul gören bir yöntem olmasına rağmen, EMG kayıtları bu işlem için alternatif bir seçenek sunmaktadır (Perpetuini vd. 2021). EMG, erken ve hızlı teşhis yapmaya olanak tanıyan bir yöntemdir. Perpetuini ve ekibi, araştırmalarında, çok sayıda değişkeni içeren bir genel lineer model tabanlı veri analizi yaklaşımının etkinliğini değerlendirmişlerdir. Bu yöntem, EMG oranını (sEMG M/T) temsil eden fMRI özelliklerini kullanarak EMG oranını tahmin etme yeteneğini ele almaktadır ve bu oran, çene kasları ile temporalis kasları arasındaki orandır. Ayrıca, bu modelin sonuçlarını hastalar ile sağlıklı kontrol grupları arasında ayırmak için kullanmışlardır.

JİA ile ilgili çalışmalara referans olarak (Eng vd. 2021) ile (Van vd. 2019) yayınlarına atıfta bulunulabilir.

2.2.4 Karar destek sistemleri

Karar destek sistemi, çeşitli seçenekler arasında seçim yapmayı kolaylaştıran ve problem çözme ile karar alma süreçlerini hızlandıran bilgisayar tabanlı bir bilgi sistemidir. Teknolojinin hızlı gelişimi sonucunda, biriken veri miktarı önemli ölçüde artmıştır. Tıbbi cihazlar, sağlık dosyaları, klinik gözlemler ve görüntüleme çalışmaları gibi çeşitli kaynaklardan gelen veriler, büyük bir bilgi rezervuarını oluşturur (Al vd. 2021). Bu verilerin etkili bir şekilde yönetilmesi, analiz edilmesi ve anlamlı bilgilerin çıkarılması nüfus sağlığını ve genel refahı artırma açısından önemlidir. KDS'lerde temel amaçlar şunlardır:

- Bilgi Toplama ve Depolama: Karar verme süreçleri için gerekli olan verilerin toplanması, depolanması ve düzenlenmesi.
- Analiz ve Değerlendirme: Verilerin analizi ve değerlendirilmesi, gelecekteki sonuçları tahmin etme yeteneği.
- Alternatiflerin Oluşturulması: Alıcıya olası çözüm yollarının sunulması.
- Modelleme ve Simülasyon: Bazı KDS'ler, çeşitli senaryoları modellemek ve simüle etmek için kullanılabilirken böylece olası sonuçlar daha iyi anlaşılabilir.

- Karar Verme Desteği: Karar vericilerin bilgi ve verilere dayalı olarak daha iyi kararlar almasına yardımcı olur.
- Görselleştirme: Verileri, grafikler, tablolar ve raporlar gibi görsel biçimlerde sunarak anlamlı bir şekilde iletebilir.

Şekil 2.6' da karar destek sistemi örnek olarak görselleştirilmiştir (Ofilas 2020).



Şekil 2.6 Örnek bir karar destek sistemi (Ofilas 2020)

Gelişen teknolojilerin entegrasyonu, diş hekimliği alanlarının pek çoğunda kendine yer bulmuştur (Elżbieta vd. 2020). Bu dijital yaklaşımlar, tedavi ve tanı süreçlerine önemli katkılarda bulunmaktadır.

AI ve arkadaşları tarafından yürütülen (Al vd. 2021) çalışmada, ortodonti alanındaki klinik karar destek sistemlerinde kullanılan veri bilimi yaklaşımları incelenmiştir. Bununla birlikte, yazarlar, temporomandibular eklem ve diş hekimliği klinik karar destek sistemleri için özel olarak oluşturulan bir web tabanlı veri yönetim sistemi sunmuşlardır.

Hekimlerin uzmanlığına büyük ölçüde dayalı olan teşhis ve tedavi planlaması dikkate

alındığında, desen tanıma yöntemleri hem sağlık profesyonelleri hem de hastalar için büyük bir potansiyele sahip görünmektedir. Machoy ve arkadaşları (Elżbieta vd. 2020), hem araştırma hem de klinik diş hekimliğinde GA gibi yapay zekâ uygulamaları ve klinik karar destek sistemlerini incelemişlerdir.

(Waked vd. 2020), (Mago vd. 2012), (Polášková vd. 2013), (Mendoca 2004) çalışmaları karar destek sistemleri üzerine olan diğer yayınlardır.

2.2.5 Derleme çalışmaları

Bu tez çalışmasında, çeşitli akademik derleme çalışmaları da incelenmiştir. Bu derleme çalışmaları, ilgili literatürdeki anahtar konuların kapsamlı bir gözden geçirilmesini sağlamış ve bu tezde sunulan araştırmanın bağlamını daha iyi anlamamıza yardımcı olmuştur. Derleme çalışmaları, mevcut bilgilerin eksiksiz bir şekilde toplanmasına ve bu alandaki önemli boşlukların belirlenmesine katkı sağlamıştır. Ayrıca, bu derlemeler, tezde ele alınan araştırma sorularının daha ayrıntılı bir şekilde geliştirilmesine yardımcı olmuştur.

Ele alınan yayınlardan ilki Farook ve arkadaşları tarafından yürütülen (Farook vd. 2021) yayınıdır. Bu çalışmada, yazarlar çeşitli diş hekimliği alanlarında makine öğrenme uygulamalarının klinik etkilerini, başarılarını, sınırlamalarını ve karşılaştırmalı sonuçlarını araştırmışlardır. İncelenen alanlar arasında periodontal hastalıklar, diş hastalıkları, kistler ve tümörler, travma ve nevraljiler, bez hastalıkları ile diş ve orofasiyal ağrıya neden olan kemik ve TME hastalıkları yer almaktadır. Yazarlar, bu incelemeleri yaparken 29 Ekim 2020'ye kadar Scopus, PubMed ve Web of Science veri tabanlarını sistemli bir şekilde taramışlardır. PRISMA-DTA yönergelerini takip ederek ilgili makalelerin kapsamlı bir taramasını ve incelemesini gerçekleştirmişlerdir. Bunlara ek olarak, makaleler klinisyenlerin kullandığı MI-CLAIM kontrol listesi ile karşılaştırılarak değerlendirilmiştir.

İncelediğimiz diğer bir derleme makalesi, Bianchi ve arkadaşları tarafından yazılmıştır (Bianchi vd. 2021). Bu araştırma, temporomandibular eklem osteoartriti teşhisini incelemek için yapay zekâ ve makine öğrenme tekniklerini ele almıştır, özellikle görüntü işleme için kullanılan veri bilimi yöntemlerine odaklanmışlardır. Araştırmacılar, verilerin saklanması, yönetilmesi ve işlenmesi için web tabanlı bir sistem kullanmışlardır.

Derleme çalışmalarına (Chen vd. 2020), (Almăsan vd. 2023), (Grischke vd. 2020), (Corbella vd. 2021), (Brickley vd. 1998), (Jha vd. 2022), (Farook ve Dudley 2023) referans olarak verilebilir.

2.2.6 Ses verisi kullanılan çalışmalar

TME sesleri, çenenin hareketi sırasında çıkan seslerdir ve TME rahatsızlıkları durumunda bu seslerde anormal değişiklikler olabilir. Bu sesler, çene eklemi ve çevresindeki dokulardaki problemlerin bir göstergesi olabilir. Bundan dolayı, bu seslerin kaydedilmesi ve analizi, TME hastalıklarının teşhisine yardımcı olabilmektedir.

TME seslerinin incelenmesi, diş malokluzyonları ile çeşitli ses türleri arasındaki potansiyel ilişkiler hakkında bilgi sağlamaktadır (Akan vd. 2006). Akan ve arkadaşları (Akan vd. 2006) araştırmalarında, lateral çapraşıklık ve Sınıf II Bölüm 1 uyumsuzluğu gösteren hastalarda çene açma ve kapama döngülerindeki temporomandibular eklem titreşimlerini ivme ölçerler kullanarak kaydetmişlerdir. Daha sonra, bu sinyallere kesikli evrimsel dönüşüm uygulanmış ve sinyallerin zaman-frekans anıları evrimsel spektrumdan türetilmiştir. Bu hesaplanmış zamanda-frekans özellikleri, TME titreşimlerinin sınıflandırılmasına katkıda bulunan bir sinir ağı içinde kullanılan özelliklerdir.

Ayrıca, temporomandibular eklem seslerinin ayrı bir incelemesi de yapılmıştır

(Djurđjanovic vd. 2000). TME'nin işlevsel hareketleri sırasında tıklama ve/veya çıtırtı gibi seslerin değerlendirilmesi teşhis açısından önem taşır. Yazarlar, TME seslerini sınıflandırmak için en iyi sinyal temsili ve desen tanıma yöntemini belirlemeye çalışmışlardır. Özellikle, zaman kaydırmalı invariyanın etkinliğinin olmadığı durumu, ölçek invariyanın olduğu bir durum ile karşılaştırmışlardır.

(Ghodsi vd. 2009), (Kaymak vd. 2019), (Yang vd. 1998) çalışmaları ses verisinin kullanıldığı diğer yayınlardır. **Çizelge 2.1**'de segmentasyon, JİA, TME OA ve ses çalışmalarında kullanılan veri seti ve yöntemlerin özeti verilmiştir. Burada seg. segmentasyana karşılık gelmektedir.

Çizelge 2.1 TME üzerinde yapılmış çalışmaların özeti

Yazar	Veri seti	Metot	Kategori
(Ito vd. 2022)	MRG	3DiscNet, U-Net, Seg-Net Basic	Seg.
(Brosset vd. 2021)	KIBT	U-Net, RUNET (RESNET'e benzer artık bağlatıların olduğu U-Net)	Seg.
(Brosset vd. 2023)	KIBT	Gürültü giderme, 3D aktif kontur ve morfolojik işlemler	Seg.
(Fan vd. 2019)	KIBT	Marker-based watershed transform.	Seg.
(Nozawa vd. 2022)	MRG	U-Net	Seg.
(Burget vd. 2011)	MRG	19 farklı yöntem	Seg.
(Liu vd. 2021)	BT	U-Net + izleme tabanlı algoritma	Seg.
(Kim vd. 2021)	KIBT	U-Net tabanlı model	Seg.
(Kwak vd. 2020)	KIBT	U-Net, Seg-Net	Seg.
(Vinayahalingam vd. 2023)	KIBT	3D U-Net model	Seg.
(Perpetuini vd. 2021)	EMG	Genel doğrusal modele dayalı çok değişkenli veri odaklı yaklaşım	JİA
(Van vd. 2019)	Immune signature	Rastgele orman, YSA, SVM	JİA


Çizelge 2.1 TME üzerinde yapılmış çalışmaların özeti (devam)

(Bianchi vd. 2020)	KIBT	LR, rastgele orman, LightGBM, XGBoost	TME OA
(Lee vd. 2020)	KIBT	SSD model	TME OA
(Choi vd. 2021)	Panoramik OPG	Inception, ResNetV2	TME OA
(Jung vd. 2021)	Panoramik görüntü	ResNet152, EfficientNetB7	TME OA
(Shoukri vd. 2019)	-	NN	TME OA
(Ribera vd. 2019)	KIBT	Shape variation analyzer, NN	TME OA
(Le vd. 2021)	-	TMJOAI (diagnostic tool)	TME OA
(Kim vd. 2020)	Panoramik görüntü	r-CNN VGG16	TME OA
(de Dumast vd. 2018)	KIBT	DNN tabanlı sınıflandırıcı	TME OA
(Eşer vd. 2023)	KIBT DCOM	YOLO v5	TME OA
(Akan vd. 2006)	Ses	Ayrık evrimsel dönüşüm, MLP	Ses
(Djurdjanovic vd. 2000)	TME Ses	Nearest linear combination, Nearest neighbor, Nearest constrained linear combination	Ses
(Ghodsi vd. 2009)	Ses	Singular spectrum analysis	Ses
(Kaymak vd. 2019)	Ses	Evolutionary spectral analysis	Ses
(Yang vd. 1998)	TME clicks	Nearest linear combination, Nearest neighbor, Nearest constrained linear combination	Ses

2.2.7 TMD

TMD üzerinde incelenen çalışmalardan ilk ele alınanı, Lin ve diğerleri tarafından gerçekleştirilmiştir (Lin vd. 2021). Bu çalışmada, TME MR görüntülerinden ön disk deplasmanının otomatik olarak tespit edilmesi amaçlanmaktadır. Bu sistemi, tedavi sonrası potansiyel ciddi komplikasyonları azaltma amacıyla geliştirmişlerdir. Çalışmada, toplamda 9009 adet sagittal TME MR görüntüsü kullanmışlardır. Karşılaştırma metrikleri olarak doğruluk oranı, AUC, derin öğrenme mimarisi olarak ResNet uygulamışlardır. Bunlara ilaveten, 5-kat çapraz doğrulama, aşırı örnekleme ve veri artırma gibi yöntemleri kullanmışlardır. **Şekil 2.7**'de çalışmanın akış şeması gösterilmiştir.

Araştırmacılar, yürüttükleri çalışmalarında TME patolojilerinin MRG ile sınıflandırılması için önerilen makine öğrenimi modelinin başarısını incelemişlerdir (Orhan vd. 2021). Yazarlar, 217 TME verisi kullanmış olup bunlar TMD belirtileri ve semptomları gösteren 107 hastadan alınmıştır. Temporomandibular eklem patolojileri, kondil kemik değişiklikleri ve disk yer değişiklikleri ile ilgili görüntü özelliklerini almak için bir radyomik platform kullanmışlardır. Ardından, özellik seçimi, sınıflandırma ve tahmin işlemleri için radyomik özelliklere LR dahil olmak üzere çeşitli makine öğrenimi algoritmaları uygulanmıştır. Temporomandibular eklem patolojilerini tahmin etmek için toplamda 6 sınıflandırıcı kullanılmıştır. Bu sınıflandırıcılar arasında karar ağacı, k-en yakın komşu algoritması, destek vektör makinesi, lojistik regresyon, rastgele orman ve XGBoost yer almaktadır. Yöntemlerin başarısını incelemek için duyarlılık, özgüllük ve ROC eğrisi gibi metriklerden faydalanılmıştır. Deney sonuçlarına göre, temporomandibular eklem patolojilerini tahmin etmede en iyi makine öğrenimi modellerinin k-en yakın komşu ve rastgele orman sınıflandırıcıları olduğu çıkarımı yapılmıştır.



Şekil 2.7 (Lin vd. 2021) çalışmasının genel aşamaları

Sharma ve arkadaşları yürüttüğü çalışmada (Sharma vd. 2019), kişilerin risk faktörlerine ve semptomlarına bağlı olarak TME bozukluğu yaşıyıp yaşamadığını tespit etmek için bir sinir ağı modeli önermiştir.

Diniz ve arkadaşları tarafından yapılan çalışmada (Diniz vd. 2022), destek vektör makinesi, k-en yakın komşu ve çok katmanlı algılayıcı metotlarının, kızılötesi termografi görüntülerinden TMD teşhisi için özellik çıkarmadaki performansları incelenmiştir. Çalışma için Fonseca anketi ve RDC/TMD kriterlerine göre 37 kontrol ve 41 TMD teşhisi konulmuş olmak üzere toplamda 78 hasta seçilmiştir. Süreç sırasında, her hastanın kızılötesi termografi yan projeksiyonları elde edilmiş ve sonrasında özellik çıkarma işlemi için maseter ve temporal kasları belirlenmiştir.

İncelenen diğer bir çalışmada ise TME disk perforasyonu konusuna odaklanılmıştır (Kim J. vd. 2021). MRG çıktıları göz önüne alınarak TME disk perforasyonunun

tespiti için derin öğrenme temelli bir teknik oluşturulmuştur. Elde edilen sonuçlar ile daha önceki çalışmaların çıktıları kıyaslanarak algoritmanın performansı yorumlanmıştır. 289 hastaya ait 299 TME, disk perforasyonunun olup olmamasına göre iki gruba bölünmüştür. Disk perforasyonu olan hastalar cerrahi operasyon ile doğrulanmış kişilerdir. Profesyonel incelemeciler, algoritmanın kullanması için gerekli özellikleri TME MR görüntülerini yorumlayarak belirlemişlerdir. Farklı yöntemlerin performansı, ROC AUC metriği kullanılarak değerlendirilmiştir. Çok katmanlı algılayıcı algoritması, 0.940 AUC ile en yüksek başarıyı göstermiştir. Bu yaklaşımı 0.918 AUC ile rastgele orman takip etmektedir. Karşılaştırma olarak, yalnızca disk şeklinin kullanılması 0.791 AUC değerini vermiştir.

Lee ve arkadaşları (Lee vd. 2021) çalışmalarında, biyolojik ve psikososyal faktörlerin TME hastalıklarının ilerlemesinde önemli bir rol oynayıp oynamadığını yapay zekâ teknikleri ile belirmeye çalışmışlardır. Stres, sosyoekonomik durum ve çalışma koşulları gibi faktörler ele alınmıştır. Araştırmada 4744 katılımcının TMD durumu, demografik faktörleri, sosyoekonomik durumu, çalışma koşulları ve sağlık durumu hakkında bilgileri içeren veri seti kullanmışlardır. Araştırmacılar temporomandibular hastalıklarla ilişkili faktörleri belirlemek için rastgele orman, lojistik regresyon, karar ağaçları, naîve Bayes, destek vektör makineleri ve yapay sinir ağı gibi altı yapay zekâ yöntemini uygulamışlardır.

Ebadian ve arkadaşları (Ebadian vd. 2020), TME bozuklukları olan, yaşları 20-50 arasında olan 200 hastayı incelemiştir. Oklüzal faktörlerin ve parafonksiyonel alışkanlıkların TMD ile ilişkisini, ki-kare testleri ve bağımsız örneklem t testi kullanarak gözlemlemişlerdir. Ayrıca, karıştırıcı değişkenlerini dikkate alarak ikili lojistik regresyon analizi uygulamışlardır. Aynı konuyu ele alan diğer bir çalışma da (Magalhães vd. 2014), temporomandibular eklem bozukluklarına bağlı olası risk faktörlerini incelemek için lojistik regresyon analizi yapmıştır.

Temporomandibular eklem sesleri temporomandibular eklem hastalıklarının yaygın belirtilerindendir. Taşkiran ve Çunkaş (Taşkiran ve Çunkaş 2021) tarafından derin öğrenme ve yapay sinir ağları temelli bir karar destek sistemi önerilmiştir. Geliştirilen

sistem sesleri kaydetme işlemini de yerine getiren bir ara yüze sahiptir. Araştırma verileri içerisinde, sol ve sağ temporomandibular eklem ses kayıtları, çevresel gürültü, klinik belirtiler, doktor notları, tanı ve tedavi bilgileri bulunmaktadır. Bu verileri YSA, derin öğrenme ve sinyal işleme yaklaşımları kullanarak sınıflandırmışlardır. Yöntemler arasında derin öğrenme %94.5 ve üzeri sonuçlar ile en başarılı algoritma olmuştur. Önerilen karar destek sistemi, TME sesleri ile TMD'leri doğru bir şekilde teşhis etme bakımından genel anlamda etkili bir sonuç sergilemiştir.

Ele alınan diğer bir çalışma Lee ve arkadaşları tarafından derin öğrenme ile TMD hastalarında ön disk deplasmanının otomatik teşhisi üzerine gerçekleştirilen yayındır (Lee vd. 2022). Çalışmada, 2520 TME'nin sagittal MRG'si kullanılmıştır. Optimizer olarak ADAM uygulanmış olup, veri artırma yapılmıştır.

TME rehabilitasyonunun hastalardaki etkisinin incelendiği Kulesa ve arkadaşları tarafından yürütülen çalışmada (Kulesa vd. 2022), titreşim analizi, masseter kaslarının sEMG kayıtları ve çiğneme kaslarının hipertoni verileri kullanılmıştır. Bilgileri kullanılan hastalardan 10'u kadın, 5'i erkektir. Çalışmada k-en yakın komşu yaklaşımının başarısı analiz edilmiştir.

Bayes teoremi temporomandibular bozukluklar üzerine çalışmalarda yaygın olarak kullanılan yöntemlerden birisidir. Iwasaki (Iwasaki 2015), MR görüntülerinde Bayesian inanç ağı kullanarak temporomandibular bozuklukların ilerlemesini analiz etmiştir. Çalışmada kullanılan veri seti temporomandibular eklem 295 adet 1.5-T MRG taramasını içermektedir. Bayesian inanç ağı'nın başarısı, regresyon analizi, yapay sinir ağı ve "necessary path condition, maximum log likelihood, path condition, Chow-Liu tree, Rebane-Pearl poly tree, greedy search-and-score with Bayesian information criterion, tree augmented naive Bayes model, K2, and C4.5, minimum description length, Akaike information criterion" algoritmaları ile karşılaştırılmıştır. Ashraf ve arkadaşları tarafından hazırlanmış olan (Ashraf vd. 2022) yayını diğer bir Bayes temelli TMD çalışmasıdır.

Jung ve arkadaşları (Jung vd. 2015), ağız açma zorluklarının ve ağrının TME iç bozukluğu olan hastalar için etkili bir belirti olup olmadığını incelemişlerdir. Bunun için 39 kadın ve 9 erkekten oluşan toplam 48 hastanın 96 TME MR görüntülerini kullanmışlardır. Veriler üzerinde çoklu lojistik regresyon analizi uygulanmıştır.

(Troka vd. 2022) yayınında yazarlar SOM metodu ile TME kas aktivasyonlarına göre hastaları sınıflandırmışlardır. Çapraz-korelasyon ile birlikte, TME kas testi sırasında elde edilen sEMG sinyali kullanılarak çıkarım gerçekleştirilmiştir.

İncelenen bir diğer çalışmada (Nam vd. 2018) TMD kaynaklı olmayıp TMD teşhisi yapılmasına sebep olan semptomlar üzerinde odaklanılmıştır. TMD teşhisi konulmasına yol açan bu tür belirtilere çeşitli patolojiler ve gelişimsel/genetik anormallikler neden olabilmektedir. TMD'den kaynaklı sebepler doğal dil işleme ve “recursive segmentasyon” yöntemleri ile ayırt edilmiştir. 29 hastanın tıbbi geçmişleri, TMD benzeri semptomlar gösteren 290 hastanın verileri ile kıyaslanmıştır. Temel şikayetler ve medikal geçmiş verilerinde doğal dil işleme kullanılırken, “recursive segmentasyon” ile sahte TMD ve gerçek TMD'yi ayırmada en uygun ağız açıklığı belirlenmiştir.

Nocera ve arkadaşları (Nocera vd. 2020), çeşitli TMD şikayetleri ile orofasiyal ağrı kliniğine giden hastaların otomatik olarak teşhis edilmesi üzerine bir çalışma yürütmüşlerdir. Bu çalışmada yazarlar, uygulama yapmış ve bazı makine öğrenimi yaklaşımlarını kullanmışlardır. Alanındaki uzman ile birlikte mevcut elektronik hasta notları incelenerek 451 hastaya ait bir veri seti oluşturmuşlardır. Yürütülen makine öğrenimi yaklaşımları arasında rastgele orman, SVM, LR ve k-NN yer almaktadır.

Jeon ve arkadaşları (Jeon vd. 2022), ağız açma ve kapama videolarını analiz etmek için otomatik bir hareket izleme yaklaşımı sunmuşlardır. Bu sistemden üretilen sonuçlar ile MRG'deki disk konumu arasındaki ilişki incelenmiştir. 91 hastaya ait MR taraması yapılmış ağız açma ve kapama videoları kullanılmış olup, bu videolar

dijital bir kamera ile çekilmiştir. Bu sistem temel olarak iki adıma sahiptir: kayıtlardan üst ve alt dudakların otomatik olarak yerinin belirlenmesi ve tespit edilen konumların grafiksel olarak gösterilmesi ile izlenme sonuçlarının otomatik olarak hesaplanması. Tüm izlenen sonuçlar MR görüntülerinden tespit edilen disk konumu kullanılarak değerlendirilmiştir. Elde edilen çıktılarına göre sistemin etkili olduğu sonucuna varılmıştır.

Kreiner ve Vilorio çalışmalarında (Kreiner ve Vilorio 2022) bir giriş katmanı, 5 gizli katman ve bir çıkış katmanından oluşan birçok katmanlı algılayıcı kullanmışlardır. Bu ağı eğitmek için geri yayılım algoritmasından faydalanmışlardır. Farklı orofasiyal ağrı türlerinden ve temporomandibular eklem bozukluğu TMD klinik vakalarından elde edilen sonuçlar, 12 ayrı diş hekiminin koymuş olduğu teşhislerle karşılaştırılmıştır.

Ele alınan yeni bir çalışmada Inception, ResNetV2, InceptionV3, DenseNet169 ve VGG16 gibi mimariler 300 görüntüden oluşan bir veri seti üzerinde uygulanmıştır (Kao vd. 2023). Veri seti TME bozukluğu olan 52 hasta ve 32 sağlıklı kişiye ait görüntülerden oluşmaktadır. İlk olarak temporal kemiği ve mandibular kondili ayıran eklem alanını 100 TME sagittal MR görüntülerine U-Net modelini uygulayarak tespit etmişlerdir. Daha sonra, yukarıda adı geçen mimarileri kullanarak sınıflandırma yapmışlardır. InceptionV3 modelinin duyarlılık, kesinlik, doğruluk oranı ve F1-skor metrikleri için sırasıyla değerleri 1.0, 0.81, 0.85 ve 0.9 olarak bulunmuştur. DenseNet169 ise aynı metrikler için sırasıyla 0.92, 0.86, 0.85 ve 0.89 değerlerini vermiştir.

Çizelge 2.2, 2.3, 2.4 2.5'te incelenen çalışmaların sırasıyla 2014-2018, 2019-2020, 2021 ve 2022-2023 yıllarına göre özeti verilmiştir. TMD üzerinde yapay zekâ uygulamalarına dair literatürde fazla çalışma olmadığı görülmektedir. Bu tez çalışması ile literatüre yapıcı katkı sağlanması hedeflenmektedir.

Çizelge 2.2 TMD çalışmaları 2014-2018

Yazar	Veri seti	Metot	Çıktı
(Magalhães vd. 2014)	Cinsiyet, ekonomik sınıf, yaş ve medeni durum. 1000 hasta (15-70 yaş aralığı, %57'si 30 yaş üzeri ve %83'ü kadın. %53'ü bekar) 3 sınıfa ayrılmıştır: A Sınıfı (yüksek sosyal sınıf), B/C Sınıfı (orta sınıf) ve D/E Sınıfı (çok düşük sosyal sınıf).	Pearson Ki-kare oran testi, Fisher'ın kesin testi, parametric olmayan Mann-Whitney testi ve ikili lojistik regresyon analizi.	Hiçbir katılımcı A sınıfı çıkmamıştır, %72'si B/C sınıfına ve %28'i D/E sınıfına aittir.
(Iwasaki 2015)	MRG, 295 hasta, 590 sağ ve sol TME (54 erkek; 241 kadın) 10-kat çapraz doğrulama	BBN 11 farklı algoritma ile karşılaştırılmıştır.	BBN %0,99 doğruluk sağlamıştır.
(Jung vd. 2015)	MRG, ağrı ve ağız açmada zorluk için klinik muayeneler. 96 TME (48 hasta, 39 kadın ve 9 erkek)	Çoklu lojistik regresyon	Veri analizi, ağrı ile MRG'de disk yer değiştirmesi derecesi arasında istatistiksel olarak anlamlı ilişkiler ortaya koymuştur ($p < 0.05$). Orta ila belirgin hastalarda ağrı yaşama ihtimali normal vakalara kıyasla 9.69 kat daha fazladır.

Çizelge 2.2 TMD çalışmaları 2014-2018 (devam)

(Nam vd. 2018)	TMD olan 290 hastanın tıbbi kayıtları (61 erkek ve 229 kadın; ortalama yaş, 31.2 ± 15.8) ve TMD'yi taklit eden koşullara sahip 29 hasta (14 erkek ve 15 kadın; ortalama yaş, 39.5 ± 23.2). 10 kat çapraz doğrulama kullanılmıştır.	NLP	Model, TMD taklit koşullarını öngörmede %96.6'lık doğruluk, %69.0 duyarlılık ve %99.3 özgüllük sunmuştur.
-----------------------	--	-----	---

Çizelge 2.2 incelendiğinde, 2014-2018 yıllarında 4 çalışma yer almaktadır. Bu yayınlarda çalışmaların ağırlık olarak makine öğrenmesi yaklaşımlarını baz aldığı görülmektedir. Sadece bir çalışmada derin öğrenme tabanlı NLP kullanılmıştır.

Çizelge 2.3 TMD çalışmaları 2019-2020

Yazar	Veri seti	Metot	Çıktı
(Sharma vd. 2019)	Veri setinde, 2300 hastaya ait (TMD sendromu olan) bilgiler yer almaktadır. Bu hastalar çene kitlenmesi veya sınırlı hareket, ağrılı tıklama, çıtırtı veya gıcırtı sesleri, üst ve alt dişlerin uyumsuzluğu, yüz, çene veya boyunda yayılan ağrı, kulak çevresindeki ağrı, çene kaslarında sertlik gibi belirtiler ve genetik yatkınlık, diyabet, paratiroid sorunları ve D vitamin eksikliği gibi temel faktörler de dahil olmak üzere altta yatan sebepler vardır.	ANN'de 17 epok, gizli katmanda 20 nöron (1 gizli katman)	TME bozukluğu tahmini için regresyon eğrisi açısından korelasyon katsayısının %98.9'u.

Çizelge 2.3 TMD çalışmaları 2019-2020 (devam)

(Ebadian vd. 2020)	200 hasta (yaşları 20 ile 50 arasında). Demografik bilgiler, yaş, cinsiyet ve eğitim seviyesi gibi değişkenler. Para-fonksiyonel yönler sıkma ve gıcırdatma gibi davranışlar, tırnak yeme ve sakız çiğneme gibi alışkanlıklar. Oklüzyon faktörler diş ilişkileri, lateral oklüzyon düzeni, merkezi oklüzyon ve maksimal interkuspidasyon arasındaki yatay farklar ve maksimal interkuspidasyon ile mandibular dinlenme pozisyonu arasındaki farklar.	TME analizi, $\alpha = 0.05$ anlamlılık değerinde Chi-kare testleri ve bağımsız örneklem t-testi ile uygulanmıştır. Ayrıca, olası karıştırıcı değişkenleri hesaba katılarak ikili lojistik regresyon analizi gerçekleştirilmiştir.	TME yaygınlığı %58.9 olarak tespit edilmiştir. İncelenen parafonksiyonel ve oklüzyon faktörleri arasında sadece bruksizm, TME ve TME olmayan gruplar arasında istatistiksel olarak anlamlı bir fark gözlemiştir ($p < 0.05$). Diğer parafonksiyonel ve oklüzyon faktörlerinin TME'nin oluşmasında kaydadeğer bir etkisi görülmemiştir.
(Nocera vd. 2020)	451 hasta (320 kadın ve 131 erkek), 8 ila 93 yaşları arasındaki hastane notları alınmıştır, ortalama yaş 43.4'tür. 141 değişken (3 sürekli, 138 ikili: yaş, ağrı şiddeti ve maksimum ağız açıklığı milimetredir). 5 katlı çapraz doğrulama uygulanmıştır.	HPV multilabel, rastgele orman multilabel, rastgele orman, Logit, SVM, ve k-NN. HFV için THF= 0:67 alınmıştır, rastgele ormanda 100 ağaç vardır, SVM'de C=1 alınmıştır ve Logit için SAG kullanılmıştır.	Doğruluk oranı %75.60 - %96.8, hatırlama %46.27 - %98.21, hassasiyet %52.40 - %97.38 ve F-1 skoru 0.56 - 0.96 arasında değişmektedir.

Çizelge 2.3 incelendiğinde 2019-2020 yılları arasında 3 çalışma olduğu görülmektedir. Bu çalışmalarda da ağırlıklı olarak makine öğrenmesi temelli yaklaşımlar kullanılmıştır.

Çizelge 2.4 TMD çalışmaları 2021

Yazar	Veri seti	Metot	Çıktı
(Lin vd. 2021)	507 hasta (426 kadın, 81 erkek) 9009 MRG %80 eğitim, %10 doğrulama, %10 test 5-fold çapraz doğrulama	ResNet34, öğrenme oranı 0.001, 20 iterasyon eğitim, yatay döndürme, 10% yakılaştırma, 10% kaydırma	Ağız açık pozisyonda, 0.970 (± 0.007) doğruluk ve 0.990 (± 0.005) AUC. Kapalı ağız pozisyonda, tanı Kriteri 1, 0.863 (± 0.008) doğruluk ve 0.922 (± 0.009) AUC tanı Kriteri 2'nin sonuçları ise (0.839 ± 0.013 , $p=0.009$; AUC 0.885 ± 0.018 , $p=0.003$)
(Orhan vd. 2021)	MRG, 107 hastadan 214 TME %80 eğitim, %20 test	Lojistik regresyon, rastgele orman, karar ağacı, k-NN, XGBoost, SVM	k-NN ve RF sınıflandırıcıları en etkili makine öğrenme yaklaşımı olarak değerlendirilmiştir.
(Kim J. vd. 2021)	MRG, 289 hastadan 299 disk (168 non perforated, 131 perforated) %80 eğitim, %20 doğrulama	Rastgele orman, MLP. Veri arttırma ve ön işlem yok	MLP, 0.940 AUC ile en iyi sonucu vermiştir, onu 0.918 AUC ile rastgele orman izlemiştir ve sadece disk şekli 0.791 AUC çıktısı vermiştir.

Çizelge 2.4 TMD çalışmaları 2021 (devam)

(Lee vd. 2021)	4744 katılımcının TME'lerin (demografik faktörler, çalışma koşulları, sosyoekonomik durum ve sağlıkla ilgili belirleyiciler) 37 bağımsız değişkeni. %75 eğitim, %25 test	Karar ağacı, lojistik regresyon, rastgele orman, naif Bayes, SVM ve YSA kullanılmıştır. Karar ağacında GINI yöntemini seçilmiştir, rastgele orman 1000 ağaçtan oluşmaktadır, SVM için çekirdek olarak radyal taban fonksiyonu kullanılmıştır, YSA'da 2 gizli katman (10-10) olup, ağırlık optimizasyon yöntemi olarak yaklaşık Newton (lbfgs) kullanılmıştır.	Random Forest algoritmasının seçtiği faktörler ile doktorun seçtiklerinin benzer olduğu gözlemlenmiştir.
(Taşkıran ve Çunkaş 2021)	48 farklı bireyin ses verilerini içeren kayıtlar bulunmaktadır (21 sağlıklı ve 27 TME hastası). Yapay Sinir Ağı (YSA) için 76 veri noktası kullanılmıştır (48 sağlıklı, 28 TMD). Bu veri, 54'ü eğitim için, 11'i doğrulama için ve 11'i test için ayrılmıştır. Derin Öğrenme (DL) için ise, veri 3'e bölünmüş ve toplam veri sayısı 3 katına çıkarılmıştır.	Sinyal işleme, YSA, DL. YSA'da, 10 ara katman vardır ve sigmoid aktivasyon fonksiyonu kullanılmıştır. DL' de, her ara katman, birer tane Convolution2D, ReLU ve Maxpooling2D katmanı içermektedir. Ara katmanlardan sonra sırasıyla bir tam bağlantılı, bir softmax ve bir sınıflandırma çıkış katmanı yer almaktadır.	Frekans tabanlı özellik çıkarma yaklaşımı ile yapılan YSA sınıflandırmasının ortalama başarı oranı %78.6 olarak hesaplanmıştır. İstatistik tabanlı özellik çıkarma yöntemiyle yapılan YSA sınıflandırmasının ise ortalama başarı oranı %89'dır. Ayrıca, DL tabanlı yaklaşımın ortalama başarı oranı %94.5'tir.

2021 yılında TMD üzerinde yapılmış çalışmalara bakıldığında (Çizelge 2.4) 5 çalışma

olduğu görülmektedir. Bu çalışmalardan 3 tanesinde makine öğrenmesi yöntemlerinden faydalanılırken, 2 tanesinde derin öğrenme yaklaşımları kullanılmıştır.

Çizelge 2.5 TMD çalışmaları 2022-2023

Yazar	Veri seti	Metot	Çıktı
(Kulesa vd. 2022)	Temporomandibular eklem ağrısı olan 27 yaşındaki bir kadın hastanın iyileştirme sürecinden örnek sonuçlar, test için 15 hasta (10 kadın ve 5 erkek).	k-NN, k=1	k-NN algoritması %62.5 ile %82.1 arasında değişen sonuçlar ortaya koymuştur. İleri doğru egzersizlerde, titreşim ve EMG kullanımı sırasıyla %71,1 ve %75,0 etkinlik sağlarken, birleşik sınıflandırma %79,1 sonucunu üretmiştir. Veri birleştirmenin ardından, hızlı açma tanıma verimliliği %73,6'dan %85,3'e yükselmiştir. Fakat yavaş açma ve yavaş ileri doğru egzersizleri için elde edilen sonuçlar beklenenden daha düşük çıkmıştır.
(Diniz vd. 2022)	IT, 78 hasta (37 kontrol, 41 TMD) %70 eğitim, %30 test çapraz doğrulama uygulanmıştır	k-NN, SVM and MLP k=5 (k-NN), 2.katmanda 8 nöron, 3. ve 4 katmanlar 6 nöron, 5. katman 4 nörona sahiptir. Hopkins istatistik, Shapiro–Wilk, ANOVA ve Tukey testleri kullanılmıştır, anlamlılık düzeyi 5% ($p < 0.05$).	Anlamsal ve radyomik-anlamsal ilişkiler ile radyomik özellikler arasında doğruluk, kesinlik(precision) ve hassasiyet (sensitivity) değerlerinde istatistiksel olarak anlamlı farklar gözlemlenmiştir (sırasıyla $p=0.008$, $p=0.016$ ve $p=0.013$).

Çizelge 2.5 TMD çalışmaları 2022-2023 (devam)

(Ashraf vd. 2022)	Anket (18 yaş ve üzeri 9922 davet edilen katılımcı). 530 bireyin klinik ağız muayenesi, şiddetli baş ağrısı bilgileri. Veri kümesi 1 (n=345) ve veri kümesi 2 (n=464) ana veri kümesinden oluşturulmuştur.	Bayesian lojistik regresyon modelleri	Takip sırasındaki migren varlığı, başlangıçtaki TMD ile ilgili ağrı değişkenleriyle ilişkilendirilmemiştir (posterior etki tahminleri: -0.12, %95 güven aralığı [CI] -0.49–0.24 ve 0.11, %95 CI -0.38–0.59, sırasıyla mTMD ve jTMD için). Bununla birlikte, başlangıçtaki mTMD, takip sırasındaki gerilim tipi baş ağrısı (TTH) varlığı ile ilişkilendirilirken (posterior etki tahmini 0.36, %95 CI 0.02–0.69), jTMD, TTH'nin takip sırasındaki varlığı ile anlamlı olacak şekilde ilişkilendirilmemiştir (posterior etki tahmini -0.32, %95 CI -0.94–0.25).
(Lee vd. 2022)	2520 MRI (861 erkek, 399 kadın; ortalama yaş 37.33 ± 18.83). 2051 eğitim, 468 test, eğitimin %20'si doğrulama	VGG16 (sıfırdan eğitime, fine-tuning ve ağı dondurma), veri arttırma uygulanmıştır. ADAM optimizier kullanılmıştır.	Fine-tune modelinin AUC değeri 0.8775, doğruluk oranı ile 0.83%'tür. Sıfırdan eğitime ve dondurma modelleri için AUC değerleri sırasıyla 0.8269 ve 0.5858'tir.
(Troka vd. 2022)	Çene hareketleri esnasında TME kaslarının sEMG sinyalleri. 42 kişi gönüllü olarak yer almıştır.	SOM kullanılmıştır ve çapraz doğrulama gerçekleştirilmiştir.	SOM analizi, kas aktivasyonunu yorumlamaya ve TME sağlığını değerlendirmeye yardımcı olmuştur.

Çizelge 2.5 TMD çalışmaları 2022-2023 (devam)

(Kreiner ve Vilora 2022)	Klinik vakalar	MLP, geri yayılım ile eğitim.	MLP'nin doğruluk oranı, genel diş hekimlerinden iyi sonuç vermiştir. İstatistiksel olarak anlamlı bir fark görülmüştür ($p=0.0072$).
(Jeon vd. 2022)	91 hastaya (17 kadın ve 74 erkek; ortalama yaş, 38.42' dir) ait ağız açma ve kapama videoları kullanılmıştır.	Otomatik model, şu bileşenleri içerir: (I) video görüntüsü içinde hem üst dudakta hem de alt dudakta landmarkları algılayan otomatik bir sistem oluşturma; (II) izleme grafiğinin görsel bir temsilini oluşturma ve ardından grafik yüksekliğinin (ağız açma uzunluğunu gösteren) ve genişliğinin (yan yatay değerleri temsil eden) otomatik hesaplama.	Deneyler, iki grup arasında istatistiksel olarak anlamlı bir ilişki olduğunu göstermiştir ($\chi^2=38.113$, $P<0.001$).
(Kao vd. 2023)	MRI, 52 TME hastası ve 32 sağlıklı kişi. 300 görüntü (105 normal, 195 hasta) 5 katlı çapraz doğrulama, U-Net için 100 MRI kullanılmıştır.	Eklem boşluğu tespiti için U-Net, sınıflandırma için InceptionResNetV2, InceptionV3, DenseNet169 ve VGG16	InceptionV3 ve DenseNet169 en başarılı mimari olmuştur. InceptionV3 için recall, precision, doğruluk ve F1 skoru sırasıyla 1, 0.81, 0.85 ve 0.9'dur. DenseNet169 için bu değerler sırasıyla 0.92, 0.86, 0.85 ve 0.89'dur.

Çizelge 2.5 incelendiğinde 8 çalışma ile en çok çalışmanın bu yıllar arasında yapıldığı görülmektedir. Diğer yıllara benzer olarak bu yıllarda da yine makine öğrenmesi

algoritmaları ağırlıklıdır.

Çizelge 2.1, 2.2, 2.3, 2.4 ve 2.5 incelendiğinde, TME soruları üzerinde bazı bilgisayar temelli metodolojilerin kullanıldığı görülmektedir. Ancak, burada dikkat çeken nokta DL tabanlı algoritmalar, segmentasyon çalışmalarının 7'sinde, TME OA ile ilgili 4 yayında ve TMD ile ilgili 5 makalede kendisine yer bulmuştur. Derin öğrenme yöntemlerinin başarısı göz önüne alındığında bu sayıların artacağı çıkarımı yapılabilir. Segmentasyon alanında başarısını kanıtlamış olan U-Net mimarisi 7 segmentasyon çalışmasının 6'sında kullanılmıştır. Yine segmentasyon alanında popüler olan SegNet modeli 2 çalışmada kullanılmıştır. Fakat, bu sayının ilerleyen zamanlarda artacağı düşünülmektedir. JİA ile ilgili yayınlarda klasik makine öğrenmesi yaklaşımlarından faydalanılmıştır. Fakat, bu alanda oldukça az çalışma olduğu görülmektedir. TME OA üzerinde gerçekleştirilmiş uygulamalarda derin öğrenme metotları makine öğrenmesi yaklaşımlarına oranla daha çok kullanılmıştır. TMD temelli yayınlara bakıldığında derin öğrenme yaklaşımlarının makine öğrenmesine göre daha az olduğu dikkat çekmektedir. Ses analizi ile ilgili çalışmalar ele alındığında, sinyal işleme yaklaşımlarının kullanıldığı görülmektedir. Fakat, mevcut literatürde teşhis için hem görüntü hem sesin aynı anda kullanıldığı örneğin olmadığı görülmektedir. Ayrıca diğer bir önemli nokta ise tüm rahatsızlıklarda bazı ML ve DL algoritmalarının hiç uygulanmamış olmasıdır.

3. MATERYAL VE YÖNTEMLER

Bu bölümde tez çalışmasında kullanılmış olan veri seti ve yöntemler hakkında detaylı bilgi verilmiştir.

3.1 MRG Veri Seti

Manyetik rezonans görüntüleme, güçlü mıknatıslarla oluşturulan güçlü manyetik alan içinde radyo dalgaları kullanılarak vücudun görüntülerini oluşturmak için kullanılan tıbbi bir tekniktir. MRG'nin temel prensibi şu şekildedir:

- Manyetik Alan: İlk olarak, MRG taraması sırasında bir güçlü manyetik alan oluşturmaktır. Bu manyetik alan, vücuttaki hidrojen atom çekirdeklerinin belirli bir yönde hizalanmasına neden olur.
- Radyo Dalgaları: Bir radyo frekansı kullanılarak vücuda kısa süreli radyo dalgaları gönderilir. Bu dalgalar, manyetik alanda hizalanmış hidrojen çekirdeklerini uyarır ve enerji verir.
- Sinyal Algılama: Hidrojen çekirdekleri radyo dalgalarına tepki verir ve bu tepkiler özel bir alıcı tarafından algılanır. Bu sinyaller bilgisayarlarda işlenir ve görüntüler oluşturulur.

MRG eklem disk yapısı ve konumu ile ilişkili temporomandibular eklem bozukluklarının, ek olarak sinovyal sıvı ve yumuşak dokudaki değişikliklerin tanısal görüntülemesi için referans standart olarak kabul edilmektedir (Jung vd. 2015). MRG'de iyonize edici radyasyon olmadığı için diğer x ışını temelli görüntüleme yöntemlerine (radyografi, bilgisayarlı tomografi vs.) göre daha güvenli kabul edilir. Ayrıca, çok detaylı görüntüler sunar ve yumuşak dokuları iyi bir şekilde gösterir. Bu nedenle, teşhis ve tedavi planlamasında önemli bir araçtır. Ek 5.1'de MR cihazına ait örnek bir görüntü verilmiştir.


Bu tez çalışmasında, 2015-2021 yılları arasında Ankara Üniversitesi Diş Hekimliği Fakültesi, Ağız, Diş ve Çene Radyolojisi ve Ağız, Diş ve Çene Cerrahisi Klinikleri'ne

TME bozuklukları için başvuran 200 hastaya ait manyetik rezonans görüntüleri kullanılmıştır. Veri seti için etik onayı Ankara Üniversitesi Diş Hekimliği Fakültesi Etik Kurulu'ndan da alınmış olup (36290600/34/2021), hastaların bilgilendirilmiş onayı da mevcuttur. Çene ve yüz bölgesinden cerrahi operasyon geçiren hastalar ve yüz sendromu olan kişiler dahil edilmemiştir. MR görüntüleri, kapalı ve açık çene pozisyonlarında 1.5 Tesla makinesi kullanılarak taranmıştır. İki taraflı TME (3 mm kalınlığında) serilerinin T1 ağırlıklı (T1 weighted), T2 ağırlıklı (T2 weighted), MERGE ve PD görüntüleri, sagittal rekonstrüksiyonlarla alınmıştır. MR görüntülerinin sayısını artırmak için eklem diski konumu için T1 ve PD görüntüleri, efüzyon için T2 ve MERGE görüntüleri, kondil dejenerasyonu değerlendirmesi için ise T1 ve PD serileri kullanılmıştır. **Şekil 3.1** de PD' de alınan örnek MR görüntüleri sunulmuş olup, gruplara ait veri sayısı **Çizelge 3.1** yer almaktadır.

Çizelge 3.1 Veri seti dağılımı

Grup	Normal	Hasta
Ağız açık pozisyonda	369	357
Ağız kapalı pozisyonda	253	274
Sinoviyal sıvı durumu	479	476
Kondil kemik durumu	178	190

Çizelge 3.1'de "Hasta", ağız açık ve kapalı disk pozisyonu için diskin önde olması durumuna, sinoviyal sıvı için sıvıda artış olması durumuna ve kondil kemik için kondil kemikte dejenerasyon olmasına karşılık gelmektedir.



Şekil 3.1 Sagittal oblik düzlemde sağ TME, PD serisinde: (a) ağız kapalı, (b) ağız açık, (kırmızı ok) normal disk pozisyonu görünümü, (c) sagittal oblik düzlemde sağ ağız kapalı TME efüzyonu (kırmızı oklar), MERGE serisi, (d) sagittal düzlemde sağ ağız kapalı TME

Bu durumda, toplamda 8 ayrı kategori olup şu şekildedir:

1. Ağız açık pozisyonda disk önde
2. Ağız açık pozisyonda disk normal
3. Ağız kapalı pozisyonda disk önde
4. Ağız kapalı pozisyonda disk normal
5. Sinoviyal sıvıda artış var
6. Sinoviyal sıvıda artış yok
7. Kondil kemikte dejenerasyon var
8. Kondil kemikte dejenerasyon yok

5, 6, 7 ve 8. sınıflar aşağıdaki kıstaslara göre tespit edilmiştir:


- 5 için: T2 ve MERGE sekansında TME aralığında yoğunluk artışı gözlenmez.
- 6 için: T2 ve MERGE sekansında TME aralığında hiperintensite var.
- 7 için: T1 ve Proton yoğunluk dizisinde alt çene kondil yüzeyinde düzgün ve yuvarlak bir çizginin görülmesi.
- 8 için: Alt çene kondil yüzeyinde T1 ve Proton densite dizisinde düzensizlik, düzleşme ve osteofit (kuş gagası görünümü) görünümüdür.

Sinoviyal sıvı, eklemleri çevreleyen ve eklem hareketini daha kolay hale getiren bir sıvıdır. Bu sıvı, eklem yüzeylerinin sürtünmesini azaltır ve eklem hareketini kolaylaştırır. Sinoviyal membran adı verilen bir zar tarafından üretilir ve eklem iç yüzeyini kaplar. Sinoviyal sıvı, kıkırdakları ve eklemi besleyen damarları korur, besin sağlar ve eklemi yağlar. Sinoviyal sıvının miktarı ve kalitesi, eklem sağlığı için son derece önemlidir. Kondil kemik dejenerasyonu, TME bölgesinde bulunan kondil kemiklerinin hasar görmesi veya bozulmasıdır. Bu durum sıklıkla temporomandibular eklem bozukluğu ile ilişkilendirilir. Kondil kemikleri, alt çene kemiğinin eklemde bulunan iki yuvarlak yapıdır ve bu eklem hareketini sağlarlar. Kondil kemiklerinin dejenerasyonu, çeşitli nedenlerle ortaya çıkabilir. Bunlar arasında kıkırdak erozyonu, yaralanmalar, eklemi aşırı kullanma, iltihaplanma ve diğer faktörler bulunur. Bu dejenerasyon sonucunda kondil kemiklerinde hasar, erozyon, kireçlenme veya başka bozulmalar oluşabilir.

Şekil 3.2, 3.3, 3.4 ve 3.5' te sırasıyla ağız açık durumda diskin konumu, ağız kapalı durumda diskin konumu, kondil kemik yapısı ve sinoviyal sıvı seviyesine ait örnek MR görüntüleri verilmiştir. Kullanılan MR görüntülerinin, deneyimli bir diş-çene-yüz radyoloji uzmanı tarafından değerlendirmesi yapılmıştır. Diş-çene-yüz radyoloji uzmanının karara varamadığı durumlarda, daha deneyimli bir diş-çene-yüz uzmanına gidilmiş ve karar verilmiştir (MR görüntülerini okumada 15 yıllık deneyimli). Toplam 2576 görüntü, tanısı konulmuş 200 hastanın MR görüntülerinden oluşturulmuştur.




(a)




(b)

Şekil 3.2 Ağız açık pozisyonda diskin durumu (a) önde (b) normal




(a)




(b)

Şekil 3.3 Ağız kapalı pozisyonda diskin durumu (a) önde (b) normal



Şekil 3.4 Kondil kemik durumu (a) dejenerasyon var (b) dejenerasyon yok



Şekil 3.5 Sinoviyal sıvı seviyesi (a) artış var (b) artış yok


Medikal görüntülerin toplanması etik izninin ve hasta onayının alınmasından dolayı basit bir süreç değildir. Bu tez çalışması kapsamında karşılaşılan negatif taraflar:

- Çalışma için daha fazla veri elde edilerek bir veri seti tanıtılması hedeflenmiştir, fakat etik sakıncalardan dolayı istenilen kadar veri toplanamamıştır.
- Yeteri kadar görüntü olmaması veri setindeki yaş aralığı çeşitliliğin azalmasına

ve sıfırdan model oluşturmamaya neden olmuştur.

- MR taramalarının orijinal haliyle eğitim yapıldığında sonuçlar çok düşük çıkmıştır. Bundan dolayı, eldeki mevcut veriler **Şekil 3.2, 3.3, 3.4 ve 3.5**'te gösterildiği haliyle kullanılamamıştır. Çünkü, bu görüntüler kulak, göz, beyin vs. gibi ağır yanlış odaklanmasına neden olabilecek kısımları da içermektedir.
- Görüntülerin orijinal haliyle çalışan bir sistem tasarlamak için çok fazla sayıda veriye ihtiyaç vardır.

Yukarıda belirtilen sebeplerden dolayı görüntüler, diskle ilgili bölgeyi içerecek şekilde kesilmiş ve bu şekilde eğitim test işlemi gerçekleştirilmiştir. **Şekil 3.6**'da örnek kesilmiş görüntüler sunulmuştur.



Şekil 3.6 Kesilmiş görüntüler. 1 ağız kapalı: (a) disk önde, (b) disk normal. 2 ağız açık: (a) disk önde, (b) disk normal. 3 sinoviyal sıvı seviyesi: (a) artış var, (b) normal. 4 kondil kemik dejenerasyonu: (a) var, (b) yok

3.2 Yapay Zekâ

Teknoloji eğitimden ulaşım, finanstan iletişime birçok alanda kendine yer bulmaktadır. Sağlık sektörü, teknolojinin aktif bir şekilde etkileşim içinde olduğu başta gelen alanlardan birisidir. Tıp alanında teknoloji, hastalıkların teşhis edilmesi, tedavi yöntemlerinin geliştirilmesi, tıbbi görüntüleme, cerrahi operasyonlar ve hasta yönetimi gibi birçok yönü etkilemektedir. Özellikle yapay zekâ, makine öğrenmesi ve derin öğrenme temelli yaklaşımlar oldukça önemli bir yere sahiptir (Li vd. 2020), (Lorencin vd. 2020), (Ochoa vd. 2020), (Yang vd. 2020), (Zhang vd. 2020).

Yapay zekâ, bilgisayar sistemlerinin insan benzeri zekâ ve yetenekleri taklit etmesini sağlayan alandır. YZ'nin temel amacı, bilgisayarları düşünme, öğrenme, problem çözme ve karar verme gibi insan benzeri yeteneklere sahip hale getirmektir. Bu alanın en önemli özelliği, öğrenme yeteneği ve deneyimle gelişme kabiliyetine sahip olmasıdır. YZ üzerine olan çalışmalar 1950 yılında Alan Turing'in Turing makinesini tanıtması ile başlayıp 1970'lerde hız kazanmıştır. 2010'lardan sonra derin öğrenme ile beraber çok büyük gelişmeler kaydedilmiştir. Yapay zekâ genel bir terim olup alt alanlara sahiptir:

- Makine Öğrenimi: Bilgisayar sistemlerinin veri analizi ve desen tanıma yoluyla öğrenme kabiliyeti kazandığı bir alandır. Algoritmalar, veriye dayalı olarak modeller oluşturur ve bu modelleri kullanarak tahminlerde bulunabilir veya kararlar alabilir.
- Derin Öğrenme: Makine öğreniminin bir alt dalıdır. Derin öğrenme, yapay sinir ağları adı verilen karmaşık ve çok katmanlı yapılar kullanarak veri özelliklerini otomatik olarak çıkarabilir ve öğrenebilir.
- Doğal Dil İşleme: Bilgisayarların insan dilini anlamasını ve üretmesini sağlayan bir alandır. Chatbotlar, metin analizi ve dil çevirisi gibi uygulamalarda kullanılır.
- Görüntü İşleme: Bilgisayarların görsel veriyi anlamasını sağlayan bir alandır. Nesne tanıma, yüz tanıma, görüntü sınıflandırma gibi konularda kullanılır.

3.3 Derin Öğrenme

Günümüzde oldukça popüler bir alan olan derin ağların temeli yapay sinir ağlarına dayanmaktadır. YSA ilk olarak 1943 yılında Warren McCulloch ve Walter Pitts tarafından (McCulloch ve Pitts 1943) çalışmalarında geliştirilen biyolojik sinir hücresini taklit eden yapay sinir ile ortaya çıkmıştır. Daha sonra 1957'de Rosenblatt tarafından "perceptron" (Rosenblatt 1958) olarak isimlendirilen bir yapay sinir ağı tanıtılmıştır. Takip eden yıllarda bu yapay model sınıflandırma problemlerinde kullanılmaya başlanmıştır. Yapay sinir ağlarının ilerlemesi 1986 yılında Rumelhart ve arkadaşları tarafından (Rumelhart vd. 1986) çalışmasında "backpropagation (Türkçe geri yayılım)" yöntemini tanıtması ile hız kazanmıştır. 2000'li yıllardan sonra çok katmanlı yapay sinir ağlarının katman sayısının arttırılması ile derin ağların temeli atılmıştır.


Görüntülerin günlük hayattaki etkinliğinin artmasıyla, görüntü işleme problemleri önem kazanmıştır. Fakat klasik makine öğrenme algoritmaları veya çok katmanlı algılayıcılar bu konuda yetersiz kalmıştır. CNN modellerinin kullanılmaya başlaması ile 2010 yılından sonra görüntü işleme çalışmaları hız kazanmıştır. Bu yapılar sadece görüntü değil ses, metin gibi verilerin işlenmesinde de oldukça etkili performans göstermektedirler. Temel bir CNN ağı aşağıdaki katmanlardan oluşmaktadır:

- Evrişim Katmanı (Convolutional Layer): Girdi olarak verilen görüntüden özellik haritaları (feature maps) çıkarmak için bu görüntü üzerinde filtrenin (kernel) uygulandığı katmandır. Bu katman görüntünün yerel niteliklerini belirlemek için kullanılır.
- ReLU (Rectified Linear Activation) Katmanı: Evrişim katmanından sonra gelen bu katmanda ağı daha ayrıntılı özellikleri öğrenmesi amaçlanmaktadır. Temel olarak her pikselin değeri sıfırdan büyükse aynı kalır, değilse sıfıra eşitlenir.
- Pooling Katmanı: Bu katmanda, özellik haritalarının boyutunu küçültmek ve hesaplamaları daha hızlı hale getirmek amaçlanmaktadır. MaxPooling, AveragePooling gibi farklı yöntemler kullanılmaktadır.
- Fully Connected Katmanı: CNN ağının sonunda yer alan katmandır. Özellik

haritalarına düzleştirme işlemi uygulanır.

- Çıkış Katmanı: Ağın sonuç ürettiği katmandır.

Şekil 3.7’de temel katmanlardan oluşan örnek bir CNN ağı gösterilmiştir.




Şekil 3.7 Örnek bir evrişimli sinir ağı yapısı

Bu ağların güvenilir sonuçlar üretebilmesi için çok sayıda veriye ihtiyaç duyulmaktadır. Az sayıda girdi olması durumunda ağlar yanıltıcı sonuç üretebilmektedir. Fakat, her zaman her problem için veri edinimi kolay bir süreç olmamaktadır. Özellikle sağlık alanındaki görüntülerin edinimi kişisel verilerin korunumu ve etik izninden dolayı maliyetli olabilmektedir. Bundan dolayı, transfer öğrenmesi yaklaşımı bu tip durumlarda daha çok tercih edilmektedir. Transfer öğrenmesi bir problemi çözmede öğrenilen bilgilerin farklı fakat ilgili başka görevde kullanılmasıdır. Bu bağlamda, genel olarak ya özellik transferi ya da model transferi yapılabilmektedir. Özellik transferi bir görevde öğrenilmiş olan niteliklerin başka bir problemde kullanılmasıdır. Model transferi ise bir ağın sıfırdan eğitilmesi yerine fine-tune (ince ayar) yapılmasıdır. Diğer bir ifadeyle, ağın belli bir sayıda katmanı dondurularak kalan katmanlarının eğitilmesidir.

Bu tez çalışmasında temel bir CNN ağı, 8 farklı fine-tune yapılmış, GoogleNet

(Szegedy vd. 2015), VGG16 (Simonyan ve Zisserman 2014), Xception (Chollet 2017), ResNet-101 (He vd. 2016), MobileNetV2 (Sandler vd. 2018), InceptionV3 (Szegedy vd. 2016), DenseNet-121 (Huang vd. 2017) ve ConvNeXt (Xie vd. 2017) mimarileri problem üzerinde uygulanmıştır. Ayrıca ViT'nin başarısıda gözlemlenmiştir. Uygulamaya ait akış şeması **Şekil 3.8** gösterilmiştir.



Şekil 3.8 Problem çözümünde takip edilen adımların akış şeması

3.3.1 GoogleNet

GoogleNet (Szegedy vd. 2015), Google araştırmacıları tarafından geliştirilmiş olup 2015 yılında CVPR konferansında tanıtılmıştır. Bu model aynı zamanda InceptionV1 olarak adlandırılmaktadır. GoogleNet'in en etkili özelliği, daha fazla derinleşmiş ve karmaşık bir yapının, daha fazla hesaplama gerektirmeden başarılabilmesidir. Bu,

önceki CNN yapılarından farklıdır; çünkü GoogleNet, iç içe geçmiş çok çeşitli boyuttaki evrişim ve havuzlama katmanlarını içerir. Bu bloklara "Inception" blokları adı verilir. Her Inception bloğu, farklı boyutlardaki evrişim ve havuzlama çıktılarını birleştirir, böylece daha geniş bir özellik yelpazesi elde edilir. Bu, farklı ölçeklerdeki özelliklerin tespit edilmesine ve modelin daha çeşitli desenleri tanımasına yardımcı olur. GoogleNet'in bu yapısal özelliği hem daha etkili özellik çıkarma hem de daha düşük hesaplama maliyeti sağlar.

3.3.2 VGG

VGG (Simonyan ve Zisserman 2014), 2014 yılında Oxford Üniversitesi'nde geliştirilen bir evrişimli sinir ağı modelidir. VGG, görsel algılama ve sınıflandırma sorunlarını çözmek amacıyla tasarlanmış bir mimari olarak öne çıkar. VGG mimarisi, özellikle modelin derinliği konusunda etkileyici bir adım atmıştır. VGG'nin belirgin özelliği, diğer birçok derin öğrenme modelinden ayrılan şekilde ardışık olarak 3x3 boyutlu evrişim katmanları kullanmasıdır. Bu, daha küçük boyutlu filtrelerin kullanımına ve daha fazla parametrenin paylaşılmasına olanak tanır. Ayrıca, VGG mimarisi ardışık evrişim katmanlarını birkaç kez üst üste koyarak daha derin bir yapı elde etmeyi tercih eder.

VGG mimarisi, farklı derinlik seviyelerinde değişiklikler içerebilir. En yaygın olanları VGG16 ve VGG19'dur. VGG16, 16 katmana sahipken, VGG19 19 katmana sahiptir. Bu katmanlar, evrişim ve ardışık havuzlama katmanlarından oluşur ve tam bağlı katmanlarla sona erer. VGG mimarisi, özellikle evrişimli sinir ağlarının derinliğinin önemini öne çıkarmak bakımından değerlidir. Ancak bu derinlik, modelin daha fazla parametreye ve hesaplama gücüne ihtiyaç duymasına yol açabilir. VGG, genellikle görsel algılama görevlerindeki başarıları ve öğrenilebilir özelliklerini vurgulamasıyla tanınır.

3.3.3 Xception

Xception (Chollet 2017) (Extreme Inception) mimarisi Inception modelinin gelişmiş versiyonudur. Bu yöntem, 2016 yılında François Chollet tarafından "Xception: Deep Learning with Depthwise Separable Convolutions" (Chollet 2017) isimli makalede sunulmuştur. Xception mimarisinde, temel amaç derinlik tabanlı ayrılabilir evrişimleri kullanarak daha etkili öğrenmedir. Derinlik tabanlı ayrılabilir evrişimler, geleneksel evrişimlere göre daha hafif ve parametre açısından daha az yoğundur. Böylece hafıza ihtiyacının azalması ve öğrenmenin hızlanması hedeflenmiştir. Xception ağının sağladığı temel faydalar şu şekildedir:

1. Daha etkili öğrenme: Derinlik tabanlı ayrılabilir evrişimler, ağırlık paylaşımı ve daha az parametre ile daha iyi öğrenme sağlar.
2. Daha hafif model: Böylece daha hızlı eğitim ve tahmin yapmaya olanak tanır.
3. Genel performans iyileştirmesi: Xception, pek çok görüntü tanıma probleminde başarılı olmuş ve daha büyük veri setlerinde etkili bir genelleme yapmıştır.

3.3.4 ResNet

ResNet (He vd. 2016) 2015 yılında He ve arkadaşları tarafından önerilen bir derin evrişimli sinir ağı türüdür. ResNet, derin ağlarda ortaya çıkan derinleştikçe performans azalması sorununa çözüm olarak çıkmış bir modeldir. Bu bağlamda "residual blocks" yapıları ağı eklemiştir. Bu yapılar önceki katmanların çıktısını doğrudan bir sonraki katmana iletmektedir. Böylece, ağ derinleştikçe öğrenme yeteneğinin düşme sorunun azalması amaçlanmıştır. Bu atlama bağlantıları sayesinde, geriye doğru gradyanların kaybolma sorunu azalmaktadır. Katman sayısının arttırılabilmesi ile ağ daha iyi bir genelleme yapabilecektir.

3.3.5 MobileNetV2

Google tarafından geliştirilen bu model (Sandler vd. 2018) MobileNet (Howard vd. 2017)'in özelliklerini temel almaktadır. MobileNet'ten farklı olarak daha iyi performans ve daha az hesaplama maliyeti sağlanması amaçlanmıştır. Önceki

versiyonda olduğu gibi bu mimaride telefon gibi kısıtlı verinin olduğu ortamlar için geliştirilmiştir. Temel nitelikleri şu şekildedir:

- Inverted Residuals ve Linear Bottlenecks: MobileNetV2’de kullanılan bu yapılar ile ağ derinleştikçe hesaplama maliyetinin daha az olması amaçlanmaktadır. "Inverted Residuals" ile daha iyi özellik birleştirmesi sağlanmaktadır.
- Derinlik Temelli Ayrıştırılmış Evrişim (Depthwise Separable Convolution): MobileNetV1’de de bulunan bu yapı, V2’de daha da geliştirilmiştir.
- Dar Boğaz Katmanları (Bottleneck Layers): Bu dar boğaz katmanları, özellik boyutunu indirmek ve ağı daha basit hale getirmek için kullanılır.


3.3.6 InceptionV3

Daha önceki Inception mimarilerinin geliştirilmiş versiyonu olan bu model (Szegedy vd. 2016), Google tarafından sunulmuştur. InceptionV3 daha derin ağlar oluşturmaya olanak tanır ve parametre sayısının çok fazla artmamasını sağlamaktadır. Bu mimaride, "Inception" blokları olarak adlandırılan yapılar kullanılır. Her bir Inception bloğu, farklı boyutlarda filtreleri içeren paralel evrişim ve pooling katmanlarından oluşmaktadır. Bu paralel katmanların çıktıları daha sonra birleşir, böylece daha zengin ve karmaşık özellikler elde edilir. **Şekil 3.9**’da InceptionV3’ün temel yapısı gösterilmiştir (Medium 2021).


3.3.7 DenseNet-121

DenseNet-121 (Huang vd. 2017) 2017 yılında CVPR konferansında Huang ve arkadaşları tarafından tanıtılmıştır. 121 katmandan oluşan bu model orjinal DenseNet’in bir versiyonudur. Bu mimaride temel yapı her bir katmanın önceki katmanların çıktılarıyla birleştirildiği dense bloklardır. Bu bağlantılar sayesinde CNN ağlarında görülen bilgi kaybolması veya azalması olmamakta, ağ üzerindeki bilgi akışı iyileşmektedir. Diğer modellere göre DenseNet-121 daha az parametreye sahiptir. Görüntü sınıflandırma, nesne tespiti, nesne tanıma ve semantik

segmentasyon gibi çeşitli görüntü işleme problemlerinde yaygın olarak kullanılmaktadır. Şekil 3.10’da DenseNet temel yapısı sunulmuştur.



Şekil 3.9 InceptionV3 temel yapısı (Medium 2021)



Şekil 3.10 DenseNet yapısı (Li vd. 2020)


3.3.8 ConvNeXt

2017 yılında CVPR konferansında sunulmuş olan bu mimari (Xie vd. 2017) karmaşık görüntü işleme problemleri üzerinde uygulanmak için geliştirilmiştir. Transformers içeren bu model ağın derinliğini arttırmak ve daha etkili özellik öğrenimi gerçekleştirmek üzerine tasarlanmıştır. ConvNeXt, NeXt adı verilen ve paralel olarak çalışan birtakım hücrelerden oluşur. Her bir hücrede, farklı boyutlardaki filtreler işlenir ve daha sonra bu filtrelerin çıktıları birleştirilir. ConvNeXt, aşağıdaki temel özelliklere sahiptir:

- Kesirli (Fractal) Bloklar: ConvNeXt mimarisi, Inception bloklarının kesirli bir versiyonunu kullanır. Bu, farklı boyutlardaki konvolüsyonlar ve etkileşimli filtre gruplarını içerir. Bu sayede daha geniş ve derin ağların daha verimli bir şekilde eğitilmesini sağlar.
- Paralel Evrişimler: ConvNeXt, farklı boyutlardaki çekirdekleri kullanarak paralel konvolüsyon işlemleri gerçekleştirir. Bu, özellik haritalarının daha iyi bir şekilde öğrenilmesini ve görsel bilgiyi daha etkili bir şekilde temsil etmeyi amaçlar.
- Filtre Grupları: ConvNeXt, özel olarak tasarlanmış "filtre grupları" adı verilen birimler kullanır. Bu gruplar, her bir evrişim katmanının farklı büyüklükteki filtrelerle sahip olmasını sağlar. Bu, ConvNeXt'in öğrenme yeteneklerini artırır.
- Derinlik ve Genişlik: ConvNeXt aynı zamanda daha derin ve daha geniş ağların eğitimini destekler. Bu, görsel tanıma görevlerinde daha yüksek başarı elde etmek için önemlidir.

3.3.9 ViT

ViT (Dosovitskiy vd. 2020) dil işlemede kullanılan ve başarılı sonuçlar üretmiş olan attention (dikkat) (Vaswani vd. 2017) temelli bir yaklaşımı görüntü işleme alanına uyarlanmış derin öğrenme modelidir. Dikkat mekanizmasında görüntüler, küçük parçalara ayrılır ve her bir parça bir dizi özellik vektörüne dönüştürülür. Daha sonra, bu özellik vektörleri işlenerek sınıflandırma gerçekleştirilir. ViT, özellikle büyük veri setleri kullanılarak eğitildiğinde ve uygun şekilde ayarlandığında, görüntü işleme problemlerinde başarılı sonuçlar verebilir. Fakat, ViT, daha az ağırlık paylaşımına sahip olmasına rağmen büyük ölçekli modelleri eğitmek için daha az veri gerektirebilir. **Şekil 3.11**'de ViT iç yapısı gösterilmiştir.



Şekil 3.11 ViT yapısı

3.4 Başarı Metrikleri

Başarı metrikleri, bir modelin veya bir algoritmanın performansını ölçmek ve değerlendirmek için kullanılan ölçütlerdir. Bu metrikler, bir modelin ne kadar iyi veya kötü çalıştığını anlamaya yardımcı olur. Çalışmada modellerin başarısı doğruluk oranı (İngilizce accuracy rate), hassasiyet (İngilizce precision), duyarlılık (İngilizce recall), F1-skor, negatif tahmin değeri (İngilizce NPV), özgüllük (İngilizce specificity), ROC eğrisinin altında kalan alan (İngilizce AUC), kappa, sınıf için korelasyon katsayısı (İngilizce ICC) metrikleri kullanılarak incelenmiştir. Ayrıca en başarılı olan mimarilerin Grad-CAM sonuçları da gözlemlenmiştir.

- Doğruluk oranı, sınıflandırıcı modelin doğru tahminlerinin toplam verilere oranıdır.
- Hassasiyet, pozitif olarak tahmin edilen örneklerin gerçekte pozitif olan örneklerin oranına karşılık gelir. Ne kadar tahminin doğru olduğunu ölçer.
- Duyarlılık, gerçekten pozitif olan örneklerin, model tarafından pozitif olarak tahmin edilen örneklere oranıdır.

- F1 skoru, hassasiyet ve duyarlılığın harmonik ortalamasıdır.
- ROC eğrisi, sınıflandırıcının precision ile specificity değerleri arasındaki ilişkiyi gösteren grafiklerdir.
- AUC ise ROC eğrisinin altındaki alanın büyüklüğüdür.

Doğruluk, hassasiyet, duyarlılık, F1- skor, NPV, özgüllük ve kappa değerine ait formüller sırasıyla eşitlik (3.1), (3.2), (3.3), (3.5), (3.6) ve (3.7)'de gösterilmiştir.

$$Doğruluk = \frac{TP + TN}{TP + TN + FP + F} \quad (3.1)$$

$$Precision = \frac{TP}{TP + FP} \quad (3.2)$$

$$Recall = \frac{TP}{TP + FN} \quad (3.3)$$

$$F1 - skor = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (3.4)$$

$$NPV = \frac{TN}{TN + FN} \quad (3.5)$$

$$Specificity = \frac{TN}{TN + FP} \quad (3.6)$$

$$Kappa = \frac{Po - Pe}{1 - Pe} \quad (3.7)$$

Eşitlik (3.1), (3.2), (3.3), (3.5), (3.6) için TP, FP, TN ve FN değerlerinin ne anlama geldiği aşağıdaki gibi özetlenebilir:

- TP modelin doğru bir şekilde tanımladığı pozitif vakaların sayısını
- FP modelin yanlışlıkla pozitif olarak sınıflandırdığı negatif vakaların sayısını
- TN modelin doğru bir şekilde tanımladığı negatif vakaların sayısını
- FN modelin yanlışlıkla negatif olarak sınıflandırdığı pozitif vakaların sayısını göstermektedir.

Eşitlik (3.7)' de 'Po' gözlemlenen anlaşmanın oranını, 'Pe' ise şans eseri beklenen anlaşmanın oranını ifade etmektedir.

Sınıf içi korelasyon katsayısı bir ölçü veya test tekrarlanabilirliği veya güvenilirliği değerlendirmek için kullanılır. ICC, bir ölçümün veya testin aynı nesne veya özellik üzerinde farklı ölçüm veya değerlendirmeler arasındaki uyumsuzluğu ne kadar iyi yakaladığını belirlemeye yardımcı olur. ICC, birçok farklı varyasyon ve uygulama şekliyle gelir, ancak genel olarak "karıştırma" ve "karıştırmama" varyasyonlarını değerlendirmek için kullanılır. "Karıştırma" varyasyonu, aynı özellik üzerinde yapılan ölçümlerin birbirine ne kadar benzediğini ölçer. Yani, farklı gözlemciler veya farklı zamanlarda yapılan ölçümler arasındaki uyumsuzluğu değerlendirir. "Karıştırmama" varyasyonu ise aynı nesne veya özellik üzerindeki farklı ölçümler arasındaki farklılığı ölçer. Yani, farklı nesneler veya özellikler arasındaki farkı değerlendirir. ICC'nin değeri genellikle 0 ile 1 arasında bir sayıdır. Değer ne kadar 1'e yaklaşırsa, ölçümün veya testin daha yüksek güvenilirliği olduğunu gösterir. Bu tez çalışmasında değer aralıkları şu şekilde dikkate alınmıştır:

- 0: Hiçbir uygunluk yok. Herhangi bir güvenilirlik veya tutarlılık göstermez.
- 0 - 0.20: Zayıf uygunluk. Ölçülenler arasında düşük bir uygunluk veya tutarlılık seviyesini yansıtır.
- 0.21 - 0.40: Zayıf ila orta düzeyde uygunluk. Ölçülenler arasında zayıf-orta arası düzeyde uygunluk veya tutarlılık gösterir.
- 0.41 - 0.60: Orta düzeyde uygunluk. Ölçülenler arasında orta düzeyde uygunluk veya tutarlılık seviyesini yansıtır.
- 0.61 - 0.80: Orta ila yüksek düzeyde uygunluk. Ölçülenler arasında orta-yüksek arası bir uygunluk veya tutarlılık gösterir.
- 0.81 - 1.00: Yüksek uygunluk. Ölçülenler arasında yüksek bir uygunluk veya tutarlılık seviyesini yansıtır.

Grad-CAM, bir derin öğrenme modelinin girdi verilerini sınıflandırma kararında hangi bölgelerin ne kadar etkili olduğunu görsel olarak açıklayan bir tekniktir. Genellikle, özellikle görüntü sınıflandırma veya nesne tanıma problemlerinde, modelin sınıflandırma kararlarını yorumlamak ve hangi özelliklerin model tarafından

özellikle vurgulandığını anlamak için kullanılır. Bu, modelin güvenilirliğini artırmak, modelin hatalarını teşhis etmek ve nesnelerin model tarafından nasıl algılandığını anlamak için son derece faydalıdır. Bu nedenle Grad-CAM, modelin kararlarını daha şeffaf hale getirir ve modelin güvenilirliğini artırır. **Şekil 3.12'** de Grad-CAM renk haritası gösterilmiştir.



Şekil 3.12 Grad-CAM colormap

Grad-CAM görüntülerinde kırmızı bölge ağıın en çok odaklandığı noktaları, yani çıkarım yaptığı kısımları göstermektedir.

4. TARTIŞMA VE SONUÇ

Tezin bu bölümünde yapılan deneyler hakkında bilgi verilmiştir. Deneylerin yapıldığı ortam, parametre ayarları ve sonuçlar detaylı olarak açıklanmıştır.

4.1 Parametre Ayarları

Tüm deneyler Colab ortamında yürütülmüştür. Colab, Google tarafından sunulan ücretsiz bir bulut tabanlı Jupyter defteri hizmetidir. Birçok Python kütüphanesini içerdiği için makine öğrenimi, veri analizi ve görselleştirme gibi çalışmalar için oldukça popülerdir. Ayrıca, ücretsiz GPU ve TPU kaynakları sunarak büyük veri işleme ve derin öğrenme modeli eğitme olanağı sağlar. Çalışma için temin edilen veri miktarı yetersiz olduğundan, veri artırma (İngilizce data augmentation) tekniklerine başvurulmuştur. Veri artırma özellikle derin öğrenme ve makine öğrenme modelleri eğitirken kullanılan bir yöntemdir. Bu yaklaşım, mevcut eğitim veri kümesini çeşitlendirmeyi hedefler. Veri artırma, eğitim verilerinin çeşitliliğini artırarak modelin daha iyi genelleme yapmasına yardımcı olabilir. Veri artırma sırasında, veriyi bozmamaya dikkat edilmiştir; yani, veri büyütme işlemleri sonucunda verinin anlamsız hale gelmemesi veya yanıltıcı hale gelmemesi için özen gösterilmiştir. Bu bağlamda, verilere döndürme, yansıtma ve kontrast gibi hafif değişiklikler uygulanmıştır. Her bir değişiklik, veri sayısını iki katına çıkarmıştır. Parametre ayarlaması ön deneyler sonucunda yapılmıştır. Ön deneyler farklı iterasyon sayısı ve optimizier denenerek gerçekleştirilmiştir. Bu deneyler sonucunda en iyi değerler dikkate alınarak, tüm modeller için aynı parametre değerleri kullanılmış olup şu şekilde ayarlanmıştır:

- Tüm verilerin %80'i eğitim, %20'si test, eğitim verilerinin %20'si doğrulama olarak kullanılmıştır.
- Optimizier olarak ADAM (Kingma ve Ba 2014) kullanılmıştır. Farklı optimizierlar ilede deneyler gerçekleştirilmiş, fakat en iyi ADAM algoritmasında sonuç alınmıştır.
- İterasyon sayısı 100 olarak ayarlanmıştır.

Yukarıda belirtildiği gibi optimizier olarak ADAM seçilmiştir. ADAM, modelin öğrenme hızını adaptif bir şekilde ayarlayarak eğitim sırasında daha hızlı ve verimli şekilde ilerlemesini sağlayan, makine öğrenimi ve derin öğrenme alanlarında yaygın olarak kullanılan bir optimizasyon algoritmasıdır. Uyarlanabilir bir öğrenme oranına sahip olan ADAM, Kingma ve Ba tarafından (Kingma ve Ba 2014) çalışmasında tanıtılmıştır. ADAM iki popüler yöntemin (AdaGrad (Duchi vd. 2011) ve RMSProp¹) avantajlarını içermektedir. ADAM algoritmasının etkili tarafları şu şekildedir:

- Eğitim sırasında ağırlıkların güncellenmesi için momentum kavramını kullanır. Momentum, önceki güncellemelerin hızının birikmesine izin verir. Bu, algoritmanın minimuma daha hızlı ve daha doğru bir şekilde yaklaşmasına yardımcı olur.
- Her parametre için özelleştirilmiş öğrenme hızlarını hesaplamak için RMSprop ile birleşmektedir. Bu, her parametrenin güncellenme hızını bağımsız olarak ayarlamasına olanak tanır.
- Öğrenme hızı gibi önemli hiperparametreleri otomatik olarak ayarlar.
- Önceki güncellemelerin hafızasını kullanırken, sınırlı bellek kullanımı sağlar. Bu durum, büyük modellerle ve büyük veri setleriyle çalışırken avantaj sağlamaktadır.
- Algoritma, her parametre için birinci ve ikinci mertebeli momentleri birleştirerek öğrenme hızını daha iyi kontrol eder.

ADAM optimizasyon algoritmasında kullanılan güncelleme formülü aşağıdaki gibidir:

$$m(t) = \beta_1 x m(t - 1) + (1 - \beta_1) x g \quad (3.7)$$

$$v(t) = \beta_2 x v(t - 1) + (1 - \beta_2) x g \quad (3.8)$$

¹<https://web.cs.toronto.edu/>

$$m'(t) = m(t) / (1 - \beta_1^t) \quad (3.9)$$

$$v'(t) = v(t) / (1 - \beta_2^t) \quad (3.10)$$

$$w(t + 1) = w(t) - \alpha \times v'(t) / (\sqrt{v'(t)} + \varepsilon) \quad (3.11)$$

Burada α öğrenme hızını, β_1 hareket momentumunun üssünü, β_2 RMSProp üssünü ifade etmektedir. Eşitlik (3.7) momentum güncellemesi, (3.8) RMSprop güncellemesi, (3.9) momentum için bias düzenlemesi, (3.10) RMSprop için bias düzeltmesi ve (3.11) ağırlık güncellemesi formülüne karşılık gelmektedir.

Çalışmada, çapraz doğrulama (cross validation) uygulanmamıştır. Çapraz doğrulama, bir modelin aşırı uydurmayı (overfitting) engellemesi ve genelleme yeteneğini artırmaya yardımcı olmasını sağlayan bir yöntemdir. Bu yaklaşım genellikle, verinin dengesiz olduğu durumlarda tercih edilmektedir. Veri setinde yer alan görüntüler çeşitlilik göstermediğinden dolayı çapraz doğrulamaya ihtiyaç yoktur ve bundan dolayı uygulanmamıştır. Bunu onaylamak için, ağız açık pozisyonda Inception mimarisinde 5 kat çapraz doğrulama gerçekleştirilmiştir. Elde edilen doğruluk oranı, hassasiyet, duyarlılık ve f1-skor değerleri sırasıyla 0.65, 0.70, 0.66 ve 0.61 olup **Çizelge 4.2** ile benzerdir. Bundan dolayı zamandan tasarruf sağlamak için kalan hastalıklar ve mimarilere çapraz doğrulama uygulanmamıştır.

4.2 Deney Sonuçları

Tüm yürütmeler neticesinde ağız kapalı pozisyonda modellerin performansı, ağız açık pozisyonda modellerin performansı, sinoviyal sıvı için modellerin performansı ve kondil kemik için modellerin performansı sırasıyla **Çizelge 4.1, 4.2, 4.3** ve **4.4** te verilmiştir. Bu tablolarda doğruluk oranı Doğ., hassasiyet Has. duyarlılık Duy. ve özgüllük Özg. olarak kısaltılmıştır.

Çizelge 4.1 Ağız kapalı pozisyonda modellerin performansı

Model	Doğ.	Has.	Duy.	F1	NPV	Özg.	AUC	Kappa
CNN	0.48	0.48	0.48	0.48	0.48	0.48	0.48	0.05
Xception	0.88	0.88	0.88	0.87	0.89	0.82	0.85	0.72
ResNet-101	0.91	0.91	0.91	0.91	0.91	0.90	0.90	0.81
MobileNetV2	0.97	0.97	0.97	0.97	0.98	0.94	0.95	0.93
InceptionV3	0.84	0.84	0.84	0.84	0.84	0.83	0.84	0.68
DenseNet- 121	0.84	0.87	0.84	0.85	0.77	0.87	0.86	0.66
ConvNeXt	0.87	0.88	0.87	0.87	0.87	0.88	0.88	0.75

Çizelge 4.1’ deki çıktılar ele alındığında MobileNet’ten sonra en iyi sonucu veren model ResNet olmuştur. ResNet sadece kappa değeride 0.81 sonucu vermiştir, diğer başarı metriklerinde 0.91 çıktısını üretmiştir. ResNet’i takip eden mimariler sırasıyla Xception, ConvNeXt, DenseNet, Inception ve CNN ağıdır. Tüm değerler incelendiğinde sonuçların oldukça başarılı olduğu görülmektedir.

Çizelge 4.2 Ağız açık pozisyonda modellerin performansı

Model	Doğ.	Has.	Duy.	F1	NPV	Özg.	AUC	Kappa
CNN	0.68	0.60	0.68	0.64	0.46	0.34	0.51	0.03
Xception	0.81	0.85	0.81	0.79	0.92	0.64	0.72	0.52
ResNet-101	0.77	0.82	0.81	0.80	0.84	0.68	0.75	0.54
MobileNetV2	0.75	0.70	0.72	0.70	0.57	0.54	0.63	0.29
InceptionV3	0.66	0.69	0.66	0.60	0.71	0.52	0.59	0.20
DenseNet- 121	0.69	0.64	0.69	0.66	0.50	0.40	0.55	0.11
ConvNeXt	0.78	0.78	0.78	0.77	0.76	0.67	0.72	0.48

Ağız açık pozisyonda elde edilen sonuçları (**Çizelge 4.2**) incelediğimizde, ağız kapalı pozisyonda elde edilen değerler kadar iyi olmadığı görülmektedir. Burada en başarılı mimari Xception ve ResNet olurken, en başarısız model Inception olmuştur. ResNet ve Xception'dan sonra sırasıyla ConvNeXt, MobileNet ve DenseNet gelmektedir. Kendi oluşturduğumuz CNN ağı ağız kapalı pozisyonda ortaya koyduğu sonuçlardan daha iyi çıktılar üretmiştir.

Çizelge 4.3 Sinoviyal sıvı için modellerin performansı

Model	Doğ.	Has.	Duy.	F1	NPV	Özg.	AUC	Kappa
CNN	0.53	0.53	0.53	0.53	0.53	0.53	0.53	0.07
Xception	0.81	0.82	0.81	0.81	0.82	0.80	0.81	0.62
ResNet-101	0.84	0.86	0.84	0.84	0.84	0.86	0.85	0.69
MobileNetV2	0.75	0.78	0.75	0.75	0.72	0.78	0.77	0.5
InceptionV3	0.72	0.77	0.72	0.73	0.88	0.76	0.74	0.42
DenseNet- 121	0.81	0.82	0.81	0.81	0.80	0.82	0.82	0.62
ConvNeXt	0.69	0.69	0.69	0.69	0.66	0.66	0.68	0.35

Sinoviyal sıvıda artışı teşhis etmede modellerin başarısı gözlemlendiğinde tüm metriklerde en etkili sonucu ResNet vermiştir. ResNet'ten sonra sırasıyla Xception, DenseNet, MobileNet, Inception ve ConvNeXt gelmektedir. Burada da ağız açık pozisyondan daha düşük sonuçlar elde edilmiştir. Burada da CNN ağı kappa skoru hariç diğer metriklerde 0.5 üzeri çıktı vermiştir.

Çizelge 4.4 Kondil kemik için modellerin performansı

Model	Doğ.	Has.	Duy.	F1	NPV	Özg.	AUC	Kappa
CNN	0.51	0.51	0.51	0.51	0.51	0.51	0.51	0.02
Xception	0.8	0.89	0.88	0.88	0.77	0.89	0.88	0.73
ResNet-101	0.94	0.94	0.94	0.94	0.95	0.92	0.93	0.85
MobileNetV2	0.97	0.97	0.97	0.97	0.96	0.97	0.97	0.94
InceptionV3	0.78	0.78	0.78	0.78	0.77	0.78	0.78	0.56
DenseNet- 121	0.94	0.94	0.94	0.94	0.93	0.93	0.94	0.87
ConvNeXt	0.94	0.94	0.94	0.94	0.94	0.94	0.94	0.87

Kondil kemikte dejenerasyon tespitinde mimariler oldukça yüksek sonuçlar üretmiştir. Tüm metriklerde en başarılı mimari MobileNet olurken, DenseNet, ResNet ve ConvNeXt'in birbirine yakın çıktılar verdiği görülmektedir. Bu modelleri Xception takip etmektedir. Burada en başarısız mimari Inception olarak yorumlanmıştır. Bu hastalık genel anlamda ağların en başarılı olduğu sınıf çıkarımı yapılabilir.


Tüm tablolar incelendiğinde ağız kapalı pozisyonda ve kondil kemik için tüm metriklerde en iyi değerleri MobileNet'in, sinoviyal sıvıda ResNet mimarisinin verdiği görülmektedir. Ağız açık pozisyon için değerler incelendiğinde doğruluk oranı, hassasiyet, duyarlılık ve NPV için Xception mimarisi, F1-skor, özgüllük, AUC ve kappa'da ResNet modeli daha iyi sonuç vermiştir. Fakat, burada Xception mimarisinin F1-skor, özgüllük, AUC ve kappa değerleri çok düşük olmayıp ResNet'e yakındır. MobileNet mimarisi kısıtlı verilerin olduğu ortamlar için geliştirilmiş bir model olduğu için diğer ağlara göre daha etkili olması yorumu yapılabilir. Bu değerlendirmeler neticesinde, ağız kapalı konumda ve kondil kemik için MobileNet, ağız açık konum için Xception ve sinoviyal sıvı için ResNet ağları en etkili ağlar olarak seçilmiş olup, kayıp (loss), doğruluk (accuracy) ve Grad-CAM çıktıları alınmıştır. **Şekil 4.1, 4.2 ve 4.3**'de sırasıyla bu çıktılar sunulmuştur. Kayıp (4.1) ve doğruluk oranı (4.2) grafiklerinde, training eğitim, validation doğrulamaya karşılık gelmektedir. Ayrıca burada ağız kapalı için yürütmenin 50. iterasyonda sonlandığı görülmektedir. Bu

şekilde sonlandırma yapılmasının sebebi, bu iterasyondan sonra validation ve training için kayıp artış göstermekte, doğruluk oranı ise iyileşmemektedir. Bundan dolayı erken durdurma uygulanmıştır.


Önceki bölümlerde problem üzerinde ViT uygulandığına değinilmiştir. Görüntüler üzerinde ViT kullanılarak elde edilen sonuçlar 0.4 ve altı olup, çok düşük değerler olduğundan dolayı tabloya dahil edilmemiştir. Bunun temel sebebi ViT'nin yanlış noktaya odaklanmasıdır. Ağ hastalıkla ilgili bölgeyi dropout yapmaktadır. Yani bu kısımları önemsiz bölge olarak algılamaktadır. Bu durum ise yanlış sınıflandırma yapmaya, dolayısıyla sonuçların çok düşük olmasına neden olmuştur.

Grad-CAM (Şekil 4.3) sonuçlarında ilk satır hastalık ile ilgili diş hekimi tarafından işaretlenen çıktıları, ikinci satır ise en başarılı modeller ile elde edilen çıktıları göstermektedir. Mimariler tarafından ortaya konan çıktılar incelendiğinde diş hekimi ile benzer kısımlara odaklandığı görülmektedir. Burada çok kesin bir sınır çizilmesi hedeflenen bir durum değildir. Veri sayısı dikkate alındığında modellerin oldukça başarılı olduğu görülmektedir.


Mimariler arasındaki anlaşma ICC değeri ile gözlemlenmiştir. **Çizelge 4.5'**e göre sadece NPV değeri 0.5'in altında kalmıştır. Diğer metrikler için sonuçlar 0.5 ve üzeri olup kabul edilebilirdir. Buda modeller arasında metrikler bakımından bir uyum olduğunu göstermektedir.




(a)



(b)



(c)




(d)


Şekil 4.1 Kayıp(loss) grafikleri (a) Ağız kapalı MobileNet (b) Ağız açık Xception (c) Sinoviyal sıvı ResNet (d) Kondil kemik MobileNet



(a)



(b)




(c)



(d)

Şekil 4.2 Doğruluk (accuracy) grafikleri (a) Ağız kapalı MobileNet (b) Ağız açık Xception (c) Sinoviyal sıvı ResNet (d) Kondil kemik MobileNet



Şekil 4.3 Grad-CAM sonuçları. 1: Ağız kapalı MobileNet, 2: Ağız açık Xception, 3: Sinoviyal sıvı ResNet, 4: Kondil kemik MobileNet. (a) Diş hekimi tarafından yapılan işaretleme, (b) Model tarafından yapılan renklendirme

Çizelge 4.5 ICC değerleri

Metrik	ICC değerleri
Doğruluk	0,58
Hassasiyet	0,57
Duyarlılık	0,63
F1-skor	0,64
NPV	0,28
Özgüllük	0,79
AUC	0,74
Kappa	0,67

4.3 Tartışma

Temporomandibular eklem bozukluğu genel bir ifade ile çene eklemine ve çene kaslarının fonksiyon bozukluklarıdır. Bu bozukluklar, çenenin açılma, kapanma ve çiğneme gibi temel işlevlerini etkileyebilmektedir. TMD'nin belirtileri ve nedenleri kişiden kişiye değişebilir ve sık sık ağrı, rahatsızlık ve çene hareketlerinde kısıtlamalara neden olabilir. Günümüzde bu hastalığın teşhisi bir diş hekimi veya maksillofasiyal cerrah tarafından farklı görüntüleme yöntemleri kullanılarak ve muayene ile yürütülmektedir. Herhangi bir otomatik sistem kullanılmamaktadır. MR bu alanda altın standart olarak kabul edilen bir görüntüleme yöntemidir. Fakat, MR raporlarının çıkması bazen zaman almaktadır. Otomatik çıkarım yapacak bir sistemin olmaması teşhis ve tedavi süresinin uzamasına yol açabilmektedir.

Bu tez çalışmasında, kendi oluşturduğumuz MR görüntülerini içeren veri seti üzerinde TMD'nin otomatik teşhisi için derin öğrenme yaklaşımları uygulanmıştır. Literatürü incelediğimizde gerçekleştirdiğimiz çalışmaya en benzer yayının Kao ve arkadaşları tarafından yürütülen (Kao vd. 2023) makalesidir. Bu çalışmada, yazarlar 52 TME hastası ve 32 sağlıklı kişiye ait 300 MR görüntüsü üzerinde derin öğrenme mimarileri ile teşhis gerçekleştirmiştir. Bu görüntülerden 105'i normal, 195'inde ise hastalık olan görüntülerdir. Eklem boşluğu tespiti için U-Net mimarisi kullanılmıştır. U-Net modelinde kullanılan tarama sayısı 100 olarak alınmıştır. Sınıflandırma için InceptionResNetV2, InceptionV3, DenseNet169 ve VGG16 ağları kullanılmış olup, InceptionV3 ve DenseNet169 en başarılı mimari olmuştur. InceptionV3 için recall, precision, doğruluk ve F1 skoru sırasıyla 1, 0.81, 0.85 ve 0.9'dur. DenseNet169 için bu değerler sırasıyla 0.92, 0.86, 0.85 ve 0.89 olarak bulunmuştur.

Bu tez çalışmasında, 4 farklı hastalık (ağız açık disk önde, ağız kapalı disk önde, sinoviyal sıvıda artış var, kondil kemikte dejenerasyon var) için deneyler gerçekleştirilmiştir. Oluşturulan veri seti 200 hastaya ait 2576 MR taraması içermektedir. Her bir görüntü sadece bir hastalığı içermektedir. Bundan dolayı, görüntüler 4 farklı hastalık için ayrı ayrı gruplanmıştır. İlk olarak kendi

oluşturduğumuz ağ kullanılmıştır. Bu ağın sonuçları genel olarak çok düşük olmayıp ortalama bir başarı vermiştir. Bunun temel sebebi eldeki veri sayısının yeterli olmamasıdır. Etikten kaynaklı olarak medikal verilerin alınıp düzenlenmesi zaman gerektirmektedir. Bir ağın sıfırdan eğitilebilmesi için çok sayıda veriye ihtiyaç duyulmaktadır. Bundan dolayı, taramalar üzerinde popüler transfer öğrenme yaklaşımları (GoogleNet, VGG, Xception, ResNet, MobileNet, Inception, DenseNet, ConvNeXt) uygulanmıştır. Çıktılar daha iyi olup umut vadedicidir. Ayrıca, son zamanlarda oldukça popüler bir yöntem olan ViT’de kullanılmıştır. Fakat, sonuçlar beklenenden düşük çıkmıştır. Bunun temel sebebi ağın yanlış kısımları dropout yapmasıdır. Bundan dolayı ağ yanlış kısımlara odaklanarak çıkarım yapmaktadır. Hastalıkla ilgili olmayan bölgelere göre yapılan tahminde başarının düşmesine neden olmuştur. Başarı metriklerine ek olarak, ICC değeri ile modeller arasındaki uyuma gözlemlenmiş, Grad-CAM ile modellerin odaklandığı kısımlar incelenmiştir. Burada, sadece NPV metriği için kabul edilebilir bir ICC sonucu alınamamıştır. Grad-CAM görüntülerinden ise ağların genel olarak hekim ile aynı noktaya odaklandığının yorumu yapılmıştır.

Daha öncede değinildiği gibi çalışma kapsamında zorlanılan nokta verilerin alınıp düzenlenmesidir. Medikal veriler kişisel verilerin korunması durumundan dolayı hızlı bir şekilde toplanamamaktadır. Bundan dolayı hedeflenen sayıda veri edinilememiştir. Veri sayısının istenilen miktarda olmaması kendi oluşturduğumuz ağın başarısını olumsuz etkilemiştir. Aynı zamanda, her hastalık ayrı ayrı ele alınmış birden fazla hastalığın aynı olması durumu incelenememiştir. İleriki zamanlarda kalan verilerinde alınması durumunda yeni deneylerin yapılması amaçlanmaktadır. Böylece, kendi oluşturduğumuz ağında daha başarılı olması düşünülmektedir. Ayrıca, veri sayısının artması ile aynı anda birden fazla hastalığın teşhisi de mümkün olacaktır.

Bu tez çalışmasında tasarlanıp geliştirilen model TMD’ler için otomatik teşhis gerçekleştiren bir sistem önerisidir. İlgili sistemin zamanla yeni diş hekimlerine ve öğrencilere teşhiste yardımcı olurken zamandan da tasarruf sağlayacağı öngörülmüştür. Böylelikle doğru teşhisin çok daha kısa sürede konulması sağlanarak

bu alanda önemli bir katkının sağlanacağı düşünülmektedir. Geliştirilecek yeni yapay zekâ ve derin öğrenme sistemlerinin diş hekimliğinde kullanılmakta olan KIBT, MRG ve ultrasonografi gibi görüntüleme cihazlarına entegre edilmesi diş hekimlerine teşhis doğruluğu, zaman ve maliyet açısından önemli katkılar sağlayacaktır.



KAYNAKLAR

- Akan, A., Ergin, A., Yildirim, M., Öztaş, E. 2006. *Analysis of temporomandibular joint sounds in orthodontic patients*, Computers & Electrical Engineering, 32(4), 312-321.
- Akbulut, Y., Şengür, A., Guo, Y., & Polat, K. 2017. *KNCM: Kernel neutrosophic c-means clustering* Applied Soft Computing, 52, 714-724.
- Al Turkestani, N., Bianchi, J., Deleat-Besson, R., Le, C., Tengfei, L., Prieto, J.C., Gurgel, M., Ruellas, A.C., Massaro, C., Aliaga Del Castillo, A. vd. 2021. *Clinical decision support systems in orthodontics: a narrative review of data science approaches*, Orthodontics & craniofacial research, 24, 26-36.
- Almăsan, O., Leucut, a, D.C., Hedes, iu, M., Mures, anu, S., Popa, S, .L. 2023. *Temporomandibular Joint Osteoarthritis Diagnosis Employing Artificial Intelligence: Systematic Review and Meta-Analysis*, Journal of Clinical Medicine, 12(3), 942.
- Anonymous. 2021. *Web sitesi: <https://medium.com/@AnasBrital98/inception-v3-cnn-architecture-explained-691cfb7bba08>*, Erişim tarihi: 31.08.2023.
- Ashraf, J., Närhi, M., Suominen, A.N., Saxlin, T. 2022. *Association of temporomandibular disorder-related pain with severe headaches—a Bayesian view.*, Clinical Oral Investigations, 1-10.
- Bianchi, J., de Oliveira Ruellas, A.C., Goncalves, J.R., Paniagua, B., Prieto, J.C., Styner, M., Li, T., Zhu, H., Sugai, J., Giannobile, W. vd. 2020. *Osteoarthritis of the Temporomandibular Joint can be diagnosed earlier using biomarkers and machine learning*, Scientific reports, 10(1), 8012.
- Bianchi, J., Ruellas, A., Prieto, J.C., Li, T., Soroushmehr, R., Najarian, K., Gryak, J., Deleat-Besson, R., Le, C., Yatabe, M. vd. 2021. *Decision support systems in temporomandibular joint osteoarthritis: a review of data science and artificial intelligence applications*, Seminars in orthodontics, 27(2), 78-86.
- Brickley, M.R., Shepherd, J.P., Armstrong, R.A. 1998. *Neural networks: a new technique for development of decision support systems in dentistry*, Journal of dentistry, 26(4), 305-309.
- Brosset, S., Dumont, M., Cevidanes, L., Soroushmehr, R., Bianchi, J., Gurgel, M.L., Deleat-Besson, R., Le, C., Ruellas, A., Yatabe, M. vd. 2021. *Web infrastructure for data management, storage and computation*, Medical Imaging 2021: Biomedical Applications in Molecular, Structural, and Functional Imaging, 11600, 400-408.
- Brosset, S., Dumont, M., Bianchi, J., Ruellas, A., Cevidanes, L., Yatabe, M.,

- Goncalves, J., Benavides, E., Soki, F., Paniagua, B., vd. 2023. *3D auto-segmentation of mandibular condyles*, 2020 42nd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC), 1270-1273.
- Burget, R., Cika, P., Zukal, M., Masek, J. 2011. *Automated localization of temporomandibular joint disc in mri images*, 2011 34th International Conference on Telecommunications and Signal Processing (TSP), 413-416.
- Cardoneanu, A., Macovei, L.A., Burlui, A.M., Mihai, I.R., Bratoiu, I., Rezus, I.I., Richter, P., Tamba, B.I., Rezus, E. 2022. *Temporomandibular Joint Osteoarthritis: Pathogenic Mechanisms Involving the Cartilage and Subchondral Bone, and Potential Therapeutic Strategies for Joint Regeneration*, International Journal of Molecular Sciences, 24(1), 171, doi: 10.3390/ijms24010171. PMID: 36613615; PMCID: PMC9820477.
- Chen, Y., Stanley, K., Att, W. 2020. *Artificial intelligence in dentistry: current applications and future perspectives*, Quintessence Int, 51(3), 248-257.
- Cheng, H. D., Jiang, X. H., Sun, Y., & Wang, J. 2001. *Color image segmentation: advances and prospects*, Pattern recognition, 34(12), 2259-2281.
- Choi, E., Kim, D., Lee, J.Y., Park, H.K. 2021. *Artificial intelligence in detecting temporomandibular joint osteoarthritis on orthopantomogram*, Scientific Reports, 11(1), 10246.
- Chollet, F. 2017. *Xception: Deep learning with depthwise separable convolutions*, Proceedings of the IEEE conference on computer vision and pattern recognition, 1251-1258.
- Corbella, S., Srinivas, S., Cabitza, F. 2021. *Applications of deep learning in dentistry*, Oral Surgery, Oral Medicine, Oral Pathology and Oral Radiology, 132(2), 225-238.
- Cunha, S.C., Nogueira, R.V.B, Duarte, A.P., Vasconcelos, B.C.E., Almeidarac. 2007. *Análise dos índices de Helkimo e craniomandibular para diagnóstico de desordens temporomandibulares empacientes com artrite reumatoide*. Revista Brasileira de Otorrinolaringologia, 73(1), 19-26.
- de Dumast, P., Mirabel, C., Cevdanes, L., Ruellas, A., Yatabe, M., Ioshida, M., Ribera, N.T., Michoud, L., Gomes, L., Huang, C. vd. 2018. *A web-based system for neural network based classification in temporomandibular joint osteoarthritis*, Computerized Medical Imaging and Graphics, 67, 45-54.
- Detamore, M. S., Athanasiou, K.A. 2003. *Structure and function of the temporomandibular joint disc: implications for tissue engineering*, Journal of Oral and Maxillofacial Surgery, 61(4), 494-506.

- Detamore, M.S., Athanasiou, K.A., Mao, J. 2007. *A call to action for bioengineers and dental professionals: directives for the future of TMJ bioengineering*, Annals of biomedical engineering, 35, 1302-1311.
- Diagnostic Radiology. *Web sitesi:* <https://www.ohsu.edu/school-of-medicine/diagnostic-radiology/pet-mri-advancing-patient-care-and-accelerating-discovery>, Erişim tarihi: 26.10.2023.
- Diniz de Lima, E., Souza Paulino, J.A., Lira de Farias Freitas, A.P., Viana Ferreira, J.E., Barbosa, J.d.S., Bezerra Silva, D.F., Bento, P.M., Araújo Maia Amorim, A.M., Melo, D.P. 2022. *Artificial intelligence and infrared thermography as auxiliary tools in the diagnosis of temporomandibular disorder.*, Dentomaxillofacial Radiology, 51(2), 20210318.
- Djurđjanovic, D., Widmalm, S.E., Williams, W.J., Koh, C.K.H., Yang, K.P. 2000. *Computerized classification of temporomandibular joint sounds*, IEEE Transactions on Biomedical Engineering, 47(8), 977-984.
- Dosovitskiy, A., Beyer, L., Kolesnikov, A., Weissenborn, D., Zhai, X., Unterthiner, T., Dehghani, M., Minderer, M., Heigold, G., Gelly, S. and others. 2020. *An image is worth 16x16 words: Transformers for image recognition at scale*, arXiv preprint arXiv:2010.11929.
- Duchi, J., Hazan, E., Singer, Y. 2011. *Adaptive subgradient methods for online learning and stochastic optimization*, Journal of machine learning research, 12(7).
- Dworkin, S.F., Lereschei, L. 1992. *Research diagnostic criteria for temporomandibular disorders: review, criteria, examinations and specifications, critique*, J Craniomandib Disord, 6(4), 301–55.
- Ebadian, B., Abbasi, M., Nazarifar, A.M. 2020. *Frequency distribution of temporomandibular disorders according to occlusal factors: A cross-sectional study.*, Dental research journal, 17(3), 186.
- Elżbieta M.M., Szyszka-Sommerfeld, L., Vegh, A., Gedrange, T., Woźniak, K. 2020. *The ways of using machine learning in dentistry*, Advances in Clinical & Experimental Medicine, 29(3)
- Eng, S.W.M., Yeung, R.S.M., Morris, Q. 2021. *The promise of machine learning to inform the management of juvenile idiopathic arthritis*, Expert review of clinical immunology, 17(1), 1-3.
- Eşer, G., Duman, Ş.B., Bayrakdar, İ.Ş., Çelik, Ö. 2023. *Classification of Temporomandibular Joint Osteoarthritis on Cone-Beam Computed Tomography Images Using Artificial Intelligence System*, Journal of Oral Rehabilitation.

- Fan, Y., Beare, R., Matthews, H., Schneider, P., Kilpatrick, N., Clement, J., Claes, P., Penington, A., Adamson, C. 2019. *Marker-based watershed transform method for fully automatic mandibular segmentation from CBCT images*, *Dentomaxillofacial radiology*, 48(2), 20180261.
- Farook, T.H., Jamayet, N.B., Abdullah, J.Y., Alam, M.K. 2021. *Machine learning and intelligent diagnostics in dental and orofacial pain management: A systematic review*, *Pain Research and Management*, 2021, 1-9.
- Farook, T.H., Dudley, J. 2023. *Automation and deep (machine) learning in temporomandibular joint disorder radiomics: A systematic review*, *Journal of Oral Rehabilitation*, 50(6), 501-521.
- Fonseca, R.J., Marciani, RD., Turvey, TA., Heir, GM. 2009. *Assessing temporomandibular disorders.*, *Sensors*, 22, 3811.
- Ghodsi, M., Hassani, H., Sanei, S., Hicks, Y. 2009. *The use of noise information for detection of temporomandibular disorder*, *Biomedical Signal Processing and Control*, 4(2), 79-85.
- Grischke, J., Johannsmeier, L., Eich, L., Griga, L., Haddadin, S. 2020. *Dentronics: Towards robotics and artificial intelligence in dentistry*, *Dental Materials*, 36(6), 765-778.
- Grossmann, E., Januzzi, E., Iwaki Filho, L. 2013. *O uso do hialuronatode sódio no tratamento das disfunc,ões temporomandibularesarticulares*, *Revista Dor*, 14(4), 301-306.
- Guo, Y., & Sengur, A. 2013. *A novel color image segmentation approach based on neutrosophic set and modified fuzzy c-means*, *Circuits, Systems, and Signal Processing*, 32, 1699-1723.
- He, K., Zhang, X., Ren, S., Sun, J. 2016. *Deep residual learning for image recognition*, *Proceedings of the IEEE conference on computer vision and pattern recognition*, 770-778.
- Heshmati, A., Gholami, M., & Rashno, A. 2016. *Scheme for unsupervised colour–texture image segmentation using neutrosophic set and non-subsampled contourlet transform*, *IET Image Processing*, 10(6), 464-473.
- Hidaka, T., Tanaka, K., Mori, H. 2023. *An Artificial Intelligence-Based Cosmesis Evaluation for Temporomandibular Joint Reconstruction*, *The Laryngoscope*, 133(4), 841-848.
- Howard, A.G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., Andreetto, M., Adam, H. 2017. *Mobilenets: Efficient convolutional neural networks for mobile vision applications*, *arXiv preprint arXiv:1704.04861*.

- Huang, G., Liu, Z., Van Der Maaten, L., Weinberger, K.Q. 2017. *Densely Connected Convolutional Networks*, Proceedings of the IEEE conference on computer vision and pattern recognition 4700-4708.
- Hunter, A., Kalathingal, S. 2013. *Diagnostic Imaging for Temporomandibular Disorders and Orofacial Pain*, Dental Clinics, 57(3), 405–418.
- Ito, S., Mine, Y., Yoshimi, Y., Takeda, S., Tanaka, A., Onishi, A., Peng, T.Y., Nakamoto, T., Nagasaki, T., Kakimoto, N. vd. 2022. *Automated segmentation of articular disc of the temporomandibular joint on magnetic resonance images using deep learning*, Scientific Reports, 12(1), 221.
- Iwasaki H. 2015. *Bayesian belief network analysis applied to determine the progression of temporomandibular disorders using MRI.*, Dentomaxillofacial Radiology, 44(4), 20140279.
- Jeon K.J., Kim, Y.H., Ha, E.G., Choi, H.S., Ahn, H.J., Lee, J.R., Hwang, D., Han, S.S. 2022. *Quantitative analysis of the mouth opening movement of temporomandibular joint disorder patients according to disc position using computer vision: a pilot study.*, Quantitative Imaging in Medicine and Surgery, 12(3), 1909.
- Jha, N., Lee, K., Kim, Y.J. 2022. *Diagnosis of temporomandibular disorders using artificial intelligence technologies: A systematic review and meta-analysis*, Plos one, 17(8), e0272715.
- Jung, Y.W., Park, S.H., On, S.W., Song, S.I. 2015. *Correlation between clinical symptoms and magnetic resonance imaging findings in patients with temporomandibular joint internal derangement.*, Journal of the Korean Association of Oral and Maxillofacial Surgeons, 41(3), 125.
- Jung, W., Lee, K.E., Suh, B.J., Seok, H., Lee, D.W. 2021. *Deep learning for osteoarthritis classification in temporomandibular joint*, Oral Diseases, 29(3), 1050-1059.
- Kalladka, M., Quek, S., Heir, G., Eliav, E., Mupparapu, M., Viswanath, A. 2014 *Temporomandibular joint osteoarthritis: diagnosis and long-term conservative management: a topic review*, J Indian Prosthodont Soc, 14(1), 6-15. doi: 10.1007/s13191-013-0321-3. Epub 2013 Sep 22. PMID: 24604992; PMCID: PMC3935038.
- Kao, Z.K., Chiu, N.T., Wu, H.T.H., Chang, W.C., Wang, D.H., Kung, Y.Y., Tu, P.C., Lo, W.L., Wu, Y.T. 2023. *Classifying temporomandibular disorder with artificial intelligent architecture using magnetic resonance imaging*, Annals of Biomedical Engineering, 51(3), 517-526.
- Kaymak, D., Karakis, D., Dogan, A. 2019. *Evolutionary spectral analysis of temporomandibular joint sounds before and after anterior repositioning splint therapy*

- in patients with internal derangement*, Int J Prosthodont, 32(6), 475-481.
- Kim, D., Choi, E., Jeong, H.G., Chang, J., Youm, S. 2020. *Expert system for mandibular condyle detection and osteoarthritis classification in panoramic imaging using r-cnn and cnn*, Applied Sciences, 10(21), 7464.
- Kim, J.Y., Kim, D., Jeon, K.J., Kim, H., Huh, J.K. 2021. *Using deep learning to predict temporomandibular joint disc perforation based on magnetic resonance imaging.*, Scientific Reports, 11(1), 6680.
- Kim, Y.H., Shin, J.Y., Lee, A., Park, S., Han, S.S., Hwang, H.J. 2021. *Automated cortical thickness measurement of the mandibular condyle head on CBCT images using a deep learning method*, Annals of Scientific Reports, 11(1), 14852.
- Kingma, D.P., Ba, J. 2014. *Adam: A method for stochastic optimization*, arXiv preprint arXiv:1412.6980.
- Kreiner, M., Vilorio, J. 2022. *A novel artificial neural network for the diagnosis of orofacial pain and temporomandibular disorders*, Journal of Oral Rehabilitation, 49(9), 884-889.
- Kulesa, M., Barański, R., Kłaczyński, M. 2022. *sEMG and Vibration System Monitoring for Differential Diagnosis in Temporomandibular Joint Disorders.*, Sensors, 22(10), 3811.
- Kwak, G.H., Kwak, E.J., Song, J.M., Park, H.R., Jung, Y.H., Cho, B.H. Hui, P., Hwang, J.J. 2020. *Automatic mandibular canal detection using a deep convolutional neural network*, Scientific Reports, 10(1), 5711.
- Larheim, T., Doria, A.S., Kirkhus, E., Parra, D.A., Kellenberger, C.J., Arvidsson, L. Z. 2015. *TMJ imaging in JIA patients—an overview*, Seminars in Orthodontics, 21(2), 102-110.
- Le, C., Deleat-Besson, R., Al Turkestani, N., Cevidanes, L., Bianchi, J., Zhang, W., Gurgel, M., Shah, H., Prieto, J., Li, T. 2021. *TMJOAI: an artificial web-based intelligence tool for early diagnosis of the temporomandibular joint osteoarthritis*, Clinical Image-Based Procedures, Distributed and Collaborative Learning, Artificial Intelligence for Combating COVID-19 and Secure and Privacy- Preserving Machine Learning: 10th Workshop, CLIP 2021, Second Workshop, DCL 2021, First Workshop, LL-COVID19 2021, and First Workshop and Tutorial, PPML 2021, Held in Conjunction with MICCAI 2021, Strasbourg, France, September 27 and October 1, 2021, Proceedings 2, 78-87.
- Lee, K.S., Kwak, H.J., Oh, J.M., Jha, N., Kim, Y.J., Kim, W., Baik, U.B., Ryu, J.J. 2020. *Automated detection of TMJ osteoarthritis based on artificial intelligence*, Journal of dental research, 99(12), 1363-1367.

- Lee, K.S., Jha, N., Kim, Y.J. 2021. *Risk factor assessments of temporomandibular disorders via machine learning.*, Scientific Reports, 11(1), 19802.
- Lee, Y.H., Won, J.H., Kim, S., Auh, Q., Noh, Y.K. 2022. *Advantages of deep learning with convolutional neural network in detecting disc displacement of the temporomandibular joint in magnetic resonance imaging.*, Scientific Reports, 12(1), 11352
- Li K., Ramkumar S., Thimmiaraja J., Diwakaran S. 2020. *Optimized artificial neural network based performance analysis of wheelchair movement for ALS patients*, Artificial Intelligence in Medicine, 102, 101754.
- Li, M., Punithakumar, K., Major, P.W., Le, L.H., Nguyen, K.C.T., Pacheco-Pereira, C., Kaipatur, N.R., Nebbe, B., Jaremko, J.L., Almeida, F.T. 2022. *Temporomandibular joint segmentation in MRI images using deep learning*, Journal of Dentistry, 127, 104345.
- Li, X., Shen, X., Zhou, Y., Wang, X., Li, T.Q. 2020. *Classification of breast cancer histopathological images using interleaved DenseNet with SENet (IDS-Net)*, PloS one, 15(5), e0232127.
- Lin, B., Cheng, M., Wang, S., Li, F., Zhou, Q. 2021. *Automatic detection of anteriorly displaced temporomandibular joint discs on magnetic resonance images using a deep learning algorithm.*, Dentomaxillofacial Radiology, 51(3), 20210341.
- Liu, Y., Lu, Y., Fan, Y., Mao, L. 2021. *Tracking-based deep learning method for temporomandibular joint segmentation*, Annals of Translational Medicine, 9(6), 467.
- Lorencin I., Anđelić N., Španjol J., Car, Z. 2020. *Using multi-layer perceptron with Laplacian edge detector for bladder cancer diagnosis*, Artificial Intelligence in Medicine, 102, 101746.
- Magalhães, B.G., de-Sousa, S.T., de Mello, V.V.C., da-Silva-Barbosa A.C., de-Assis-Morais, M.P.L. Barbosa-Vasconcelos, M.M.V., Caldas-Júnior, A.F. 2014. *Risk factors for temporomandibular disorder: binary logistic regression analysis.*, Medicina oral, patologia oral y cirugia bucal, 19(3), e232.
- Mago, V.K., Bhatia, N., Bhatia, A., Mago, A. 2012. *Clinical decision support system for dental treatment*, Journal of Computational Science, 3(5), 254-261.
- Mahl, C.R.W., Silveira, M.W. 2002. *Diagnóstico por imagens da articulação temporomandibular: técnicas e indicações*, JBA, 2, 327-32.2.
- Maixner, W., Diatchenko, L., Dubner, R. 2011. *Orofacial pain prospective evaluation and risk assessment study – the OPPERA study*, The journal of Pain, 12(4), T4–T11.

- Maizlin, ZV., Nutiu, N., Dent, PB., Vos, PM., Fenton, DM., Kirby, JM., Vora, P., Gillies, JH., Clement, JJ. 2010. *Displacement of the temporomandibular joint disk: correlation between clinical findings and mri characteristics.*, Journal-Canadian Dental Association, 76(4), 233.
- McCulloch, W., Pitts, W. 1943. *A logical calculus of the ideas immanent in nervous activity*, The bulletin of mathematical biophysics, 5 115-133.
- Mendoca, E.A. 2004. *Clinical Decision Support Systems: perspective in Dentistry*, Journal of Dental Education, 6, 589-597.
- Nam, Y., Kim, H.G., Kho, H.S. 2018. *Differential diagnosis of jaw pain using informatics technology.*, Journal of Oral Rehabilitation, 45(8), 581-588.
- Nocera, L., Vistoso, A., Yoshida, Y., Abe, Y., Nwoji, C., Clark, G.T. 2020. *Building an automated orofacial pain, headache and temporomandibular disorder diagnosis system.*, AMIA Annual Symposium Proceedings, 2020, 943.
- Nozawa, M., Ito, H., Ariji, Y., Fukuda, M., Igarashi, C., Nishiyama, M., Ogi, N., Katsumata, A., Kobayashi, K., Ariji, E. 2022. *Automatic segmentation of the temporomandibular joint disc on magnetic resonance images using a deep learning technique*, Dentomaxillofacial Radiology, 51(1), 20210185.
- Ochoa G., Christie L.A., Brownlee A.E., Hoyle A. 2020. *Multi-objective evolutionary design of antibiotic treatments*, Artificial Intelligence in Medicine, 102, 101759.
- Oflas, S. 2020. *Web sitesi:* <https://www.saglikteknoloji.com/klinik-karar-destek-sistemleri-kkds-hbys/>, Erişim tarihi: 26.10.2023.
- Okeson, J.P. 2013. *Functional anatomy and biomechanics of masticatory system*, 7th ed. Management of Temporomandibular Disorders and Occlusion, 1-20.
- Orhan, K., Driesen, L., Shujaat, S., Jacobs, R., Chai, X.. 2021. *Development and Validation of a Magnetic Resonance Imaging-Based Machine Learning Model for TMJ Pathologies.*, BioMed Research International, 2021, 6656773.
- Peroz, I., Tai, S. 2002. *Masticatory performance in patients with anterior disk displacement without reduction in comparison with symptom-free volunteers*, European journal of oral sciences, 110(5), 341–344.
- Perpetuini, D., Trippetti, N., Cardone, D., Breda, L., D’Attilio, M., Merla, A. 2021. *Detection of temporomandibular joint dysfunction in juvenile idiopathic arthritis through infrared thermal imaging and a machine learning procedure*, 8th European Medical and Biological Engineering Conference: Proceedings of the EMBEC 2020, November 29–December 3, 2020 Portorož, Slovenia, 372-381.
- Polášková, A., Feberová, J., Dostálová, T., Kříž, P., Seydlová, M., vd. 2013. *Clinical*

- decision support system in dental implantology*, MEFANET Journal, 1(1), 11-14.
- Ribera, N.T., De Dumast, P., Yatabe, M., Ruellas, A., Ioshida, M., Paniagua, B., Styner, M., Gonçalves, J.R., Bianchi, J., Cevidanes, L., vd. 2019. *Shape variation analyzer: a classifier for temporomandibular joint damaged by osteoarthritis*, Medical Imaging 2019: Computer-Aided Diagnosis, 10950, 517-523.
- Rosenblatt, F. 1958. *The perceptron: a probabilistic model for information storage and organization in the brain*, Psychological review, 65(6) 386.
- Rumelhart, D.E., Hinton, G.E., Williams, R.J. 1986. *Learning representations by back-propagating errors*, Nature, 323(6088) 533-536.
- Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., Chen, L.C. 2018. *Mobilenetv2: Inverted residuals and linear bottlenecks*, Proceedings of the IEEE conference on computer vision and pattern recognition, 4510-4520.
- Sharma, N., Dar, I. G., Kim, Kumar, J., Khan, A., Thakur, A. 2019. *Temporomandibular joint syndrome prediction using neural network*, Engineering Vibration, Communication and Information Processing: ICoEVCI, India, 1-7.
- Shoukri, B., Prieto, J.C., Ruellas, A., Yatabe, M., Sugai, J., Styner, M., Zhu, H., Huang, C., Paniagua, B., Aronovich, S., vd. 2019. *Minimally invasive approach for diagnosing TMJ osteoarthritis*, Journal of Dental Research, 98(10), 1103-1111.
- Silveira, A.M., Feltrin, P.P., Zanetti, R.V., Mautoni, M.C. 2007. *Prevalência de portadores de DTM em pacientes avaliados no setor de otorrinolaringologia*, Revista Brasileira de Otorrinolaringologia, 73, 528-32.
- Simonyan, K., Zisserman, A. 2014. *Very deep convolutional networks for large-scale image recognition*, arXiv preprint arXiv:1409.1556.
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., Rabinovich, A. 2015. *Going deeper with convolutions*, Proceedings of the IEEE conference on computer vision and pattern recognition, 1-9.
- Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., Wojna, Z. 2016. *Rethinking the inception architecture for computer vision*, Proceedings of the IEEE conference on computer vision and pattern recognition, 2818-2826.
- Taşkıran, U., Çunkaş, M., Kim, Y.J. 2021. *A deep learning based decision support system for diagnosis of Temporomandibular joint disorder.*, Applied Acoustics, 182, 108292.

- Troka, M., Wojnicz, W., Szepietowska, K., Podlasiński, M., Walerzak, S., Walerzak, K., Lubowiecka, I. 2022. *Towards classification of patients based on surface EMG data of temporomandibular joint muscles using self-organising maps.*, Biomedical Signal Processing and Control, 72, 103322.
- Van Loon, J.P., De Bont, L.G.M., Stegenga, B., Spijkervet, F.K.L., Verkerke, G.J. 2002. *Groningen temporomandibular joint prosthesis. Development and first clinical application*, International journal of oral and maxillofacial surgery, 31(1), 44-52.
- Van Nieuwenhove, E., Lagou, V., Van Eyck, L., Dooley, J., Bodenhofer, U., Roca, C., Vandebergh, M., Goris, A., Humblet-Baron, S., Wouters, C. vd. 2019. *Machine learning identifies an immunological pattern associated with multiple juvenile idiopathic arthritis subtypes*, Annals of the rheumatic diseases, 78(5), 617-628.
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A.N., Kaiser, Ł., Polosukhin, I. 2017. *Attention is all you need*, Advances in neural information processing systems, 30.
- Vinayahalingam, S., Berends, B., Baan, F., Moin, D. A., van Luijn, R., Bergé, S., Xi, T. 2023. *Deep learning for automated segmentation of the temporomandibular joint*, Journal of Dentistry, 132, 104475.
- Waked, J.P., Canuto, Ma.P.A., Gueiros, M.C.S., Aroucha, J.M.C., Farias, C.G., Caldas J.A.F. 2020. *Model for predicting temporomandibular dysfunction: use of classification tree analysis*, Brazilian Dental Journal, 31, 360-367.
- Wang, X., Zhang, J.N., Gan, Y.H., Zhou, Y.H. 2015. *Current understanding of pathogenesis and treatment of TMJ osteoarthritis*, Journal of dental research, 94(5), 666-673.
- Warren, M.P., Fried, J.L. 2001. *Temporomandibular disorders and hormones in women*, Cells Tissues Organs, 169(3), 187-192.
- Whyte, AM., McNamara, D., Rosenberg, I., Whyte, AW. 2006. *Magnetic resonance imaging in the evaluation of temporomandibular joint disc displacement—a review of 144 cases*, International journal of oral and maxillofacial surgery, 35(8), 696–703.
- Xie, S., Girshick, R., Dollár, P., Tu, Z., He, K. 2017. *Aggregated Residual Transformations for Deep Neural Networks*, Proceedings of the IEEE conference on computer vision and pattern recognition, 1492-1500.
- Xu, G., Wang, S., Yang, T., & Jiang, W. 2018. *A neutrosophic approach based on TOPSIS method to image segmentation*, International Journal of Computers Communications & Control, 13(6), 1047-1061.
- Yang, C.H., Chuang, L.Y., Lin, Y.D. 2020. *An improved fuzzy set-based multifactor*

dimensionality reduction for detecting epistasis, Artificial Intelligence in Medicine, 102, 101768.

Yang, K.P., Djurdjanovic, D., Koh, K.H., Williams, W.J., Widmalm, S.E. 1998. *Automatic classification of the temporomandibular joint sounds using scale and time-shift invariant representation of their time-frequency distributions*, Proceedings of the IEEE-SP International Symposium on Time-Frequency and Time-Scale Analysis (Cat. No. 98TH8380), 265-268.

Young-Wook, J., Sung-Hoon, P., Sung-Woon, O., Seung-Il S. 2015. *Correlation between clinical symptoms and magnetic resonance imaging findings in patients with temporomandibular joint internal derangement*, J Korean Assoc Oral Maxillofac Surg, 41(3), 125–132.

Zhang N., Cai Y.X., Wang Y.Y., Tian Y.T., Wang X.L., Badami B. 2020. *Skin cancer diagnosis based on optimized convolutional neural network*, Artificial Intelligence in Medicine, 102, 101756.

EK 1 MR TARAMASINDA KULLANILAN CİHAZ



MR taraması cihazı (Diagnostic Radiology)