



TÜRKİYE CUMHURİYETİ
KARADENİZ TEKNİK ÜNİVERSİTESİ
SAĞLIK BİLİMLERİ ENSTİTÜSÜ

BİYOİSTATİSTİK ve TIP BİLİŞİMİ ANABİLİM DALI

**DERİN ÖĞRENME İLE MANYETİK
REZONANS GÖRÜNTÜLERDE
TEMPOROMANDİBULAR EKLEM DİSK
DEPLASMANLARININ DİAGNOZU**

Yusuf BAYKAL

YÜKSEK LİSANS TEZİ

Doç. Dr. Mehmet İTİK

TRABZON-2019



TÜRKİYE CUMHURİYETİ
KARADENİZ TEKNİK ÜNİVERSİTESİ
SAĞLIK BİLİMLERİ ENSTİTÜSÜ

BİYOİSTATİSTİK ve TIP BİLİŞİMİ ANABİLİM DALI

**DERİN ÖĞRENME İLE MANYETİK
REZONANS GÖRÜNTÜLERDE
TEMPOROMANDİBULAR EKLEM DİSK
DEPLASMANLARININ DİAGNOZU**

Yusuf BAYKAL

YÜKSEK LİSANS TEZİ

Doç. Dr. Mehmet İTİK

TRABZON-2019

ONAY

Bu tez Yüksek Lisans Tezi Standartlarına Uygun Bulunmuştur

Prof. Dr. Kemal TURHAN

Biyoistatistik ve Tıp Bilişimi Anabilim Dalı Başkanı

Karadeniz Teknik Üniversitesi Sağlık Bilimleri Enstitüsü Biyoistatistik ve Tıp Bilişimi Anabilim Dalı Yüksek Lisans/Doktora öğrenci Yusuf BAYKAL'ın hazırladığı “**Derin Öğrenme ile Manyetik Rezonans Görüntülerde Temporomandibular Eklem Disk Deplasmanlarının Diagnozu**” başlıklı tez KTÜ Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliğinin ilgili maddeleri uyarınca kapsam ve bilimsel kalite yönünden değerlendirilerek Yüksek Lisans Tezi olarak kabul edilmiştir.

Danışman: Doç. Dr. Mehmet İTİK

Yüksek Lisans Sınavı Jüri Üyeleri

Prof. Dr. Kemal TURHAN

Doç. Dr. Mehmet İTİK

Doç. Dr. Celal ÇANDIRLI

Tarih: 18/06/2019

Bu tez KTÜ Sağlık Bilimleri Enstitüsü Yönetim Kurulu'nun .../.../.... tarih ve ...sayılı kararıyla onaylanmıştır.

Prof. Dr. Ersan KALAY

Sağlık Bilimleri Enstitüsü Müdürü

BEYAN

Bu tez çalışmasının KTÜ Sağlık Bilimleri Enstitüsü tez yazım kılavuzu standartlarına uygun olarak yazıldığını, tezin akademik ve etik kurallara bağlı kalınarak gerçekleştirilmiş özgün bir bilimsel araştırma eserim olduğunu, tezde yer alan ve bu tez çalışmasıyla elde edilmeyen tüm bilgi ve yorumlara kaynak gösterdiğimi ve kaynakların kaynaklar listesinde yer aldığını, tezin çalışılması ve yazımı aşamalarında patent ve telif haklarını ihlal edici bir davranışımın olmadığını beyan ederim.

18/06/2019

Yusuf BAYKAL

TEŐEKKÖR

Bu tez alıřmasında yardımlarını esirgemeyen, bilgi ve tecrübelerini benimle paylaşan ve bana yol gösteren danışman hocam Do. Dr. Mehmet İTİK'e, ağız diř ene cerrahı Do. Dr. Celal ANDIRLI'ya ve radyoloji bölümünden Dr. Öğr. Üyesi İlker EYÜBOĞLU'na teşekkür ederim. Bu süreçte büyük bir sabırla beni destekleyen her zaman yanımda olan başta annem ve babam olmak üzere, gösterdikleri yardım ve fedakarlık için kardeşim Sena BAYKAL'a ayrıca tezimi bitirmemde büyük katkıları olan arkadaşım Dr. Yařar Faik İSKEFYELİ'ye ve bu tez süreci boyunca beni hiç yalnız bırakmayan tüm arkadaşlarıma sevgi, saygı ve teşekkürlerimi sunarım.

Yusuf BAYKAL

İÇİNDEKİLER

	Sayfa
ONAY	
BEYAN	
TEŞEKKÜR	
İÇİNDEKİLER	vi
ŞEKİLLER DİZİNİ	ix
TABLO DİZİNİ	xi
SİMGE ve KISALTMALAR	xii
1. ÖZET	1
2. SUMMARY	2
3. GİRİŞ ve AMAÇ	3
4. GENEL BİLGİLER	7
4.1. Temporomandibular Eklem Anatomisi ve Fonksiyonu	7
4.1.1. Temporomandibular Eklem Kemik Elemanları	8
4.1.1.1. Mandibular Kondil	8
4.1.1.2. Glenoid Fossa	8
4.1.2. Temporomandibular Eklemi Oluşturan Yumuşak Doku Elemanları	9
4.1.2.1. Eklem Diski (Discus Articularis)	9
4.1.2.2. Temporomandibular Eklem Ligamentleri	11
4.1.2.3. Retrodiskal Doku (Bilaminer Bölge)	12
4.1.2.4. TME'nin Arteriel Beslenmesi	12
4.1.3. TME'nin Sinir Yapısı	13
4.1.4. Mandibular Fonksiyondaki Kaslar	13
4.1.4.1. Massater Kası	13
4.1.4.2. Temporal Kas	13
4.1.4.3. M. Pterigoideus Medialis (İç)	14
4.1.4.4. M. Pteridoideus Lateralis	14
4.2. Temporomandibular Eklem Hastalıkları	15
4.2.1. Temporomandibular Bozuklukların Etyolojisi	15
4.2.2. Temporomandibular Bozuklukların Sınıflandırılması	16
4.2.3. Çiğneme Kası Rahatsızlıkları	17

4.2.4. Temporomandibular Eklem Düzensizlikleri	18
4.2.4.1. Disk Deplasmanları	18
4.2.5. TME'nin İltihapsal Hastalıkları	19
4.3. Temporomandibular Eklemde Görüntüleme	20
4.3.1. Direkt Radyografiler	20
4.3.2. Bilgisayarlı Tomografi (BT)	21
4.3.3. Manyetik Rezonans Görüntüleme (MRG)	22
4.4. Yapay Zeka	23
4.5. Makine Öğrenmesi	23
4.5.1. Danışmanlı Öğrenme	24
4.5.2. Danışmansız Öğrenme	24
4.5.3. Pekiştirmeli Öğrenme	24
4.6. Yapay Sinir Ağları	25
4.6.1. Yapay Sinir Ağlarının Genel Özellikleri	25
4.6.2. Yapay Sinir Ağlarının Kullanım Alanları	27
4.6.3. Yapay Sinir Ağlarının Yapısı ve Temel Elemanları	28
4.6.3.1. Biyolojik sinir hücresi	28
4.6.3.2. Yapay Sinir Hücreleri	29
4.6.4. Yapay Sinir Ağlarının Sınıflandırılması	32
4.6.4.1. İleri Beslemeli Yapay Sinir Ağları	34
4.6.4.2. Geri Beslemeli Yapay Sinir Ağları	35
4.7. Derin Öğrenme	35
4.7.1. Derin öğrenime giriş	35
4.7.2. Derin öğrenmenin tarihi	36
4.7.3. Derin Sinir Ağı (Deep Neural Network)	39
4.7.4. Derin Öğrenme	39
4.7.4.1. Vanishing Gradient (kaybolma gradyanı)	40
4.7.4.2. Overfitting (Aşırı Uygunluk)	41
4.7.4.3. Hesaplama Yüğü (Computational Load)	43
4.7.5. Konvolüsyonel Sinir Ağları (Convolution Neural Network)	43
4.7.5.1. Konvolüsyon (Evrişim) Katmanı	44
4.7.5.2. Pooling Layer (Havuzlama Katmanı)	45

4.7.5.3. Fully Connected Layer (Tam Bağlı Katman)	46
4.7.5.4. Hiper-Parametreler	47
5. GEREÇ ve YÖNTEM	50
5.1. Transfer Öğrenme ve Derin Öğrenme Modelleri	50
5.1.1. AlexNet	50
5.1.2. GoogLeNet	51
5.2. Verilerin Hazırlanması	53
5.3. Ağ Parametrelerinin Seçimi	55
5.4. Ağların Eğitilmesi ve Test	55
6. BULGULAR	56
6.1. Ağız Kapalı Veri Setinin Modellere Uygulanması	56
6.2. Ağız Açık Veri Setinin Modellere Uygulanması	59
7. TARTIŞMA ve SONUÇ	64
8. KAYNAKLAR	66
9. ETİK KURUL ONAYI	71
10. ÖZGEÇMİŞ	73

ŞEKİLLER DİZİNİ

Şekil	Sayfa
Şekil 1. Temporomandibular eklem	8
Şekil 2. Mandibular kondil	8
Şekil 3. Glenoid fossa	9
Şekil 4. Eklem diski	10
Şekil 5. Ağız kapalı (A) ve açık (B) pozisyonlarda, rediksal doku hacmindeki değişiklik	12
Şekil 6. Kaslara ait toplu görsel	13
Şekil 7. Çeneyi iki yana (laterale) hareket ettiren kaslar	14
Şekil 8. Diskin normal superior pozisyonu	18
Şekil 9. Ağız kapalı pozisyonda MR görüntüsü	22
Şekil 10. Makine öğrenme teknikleri	24
Şekil 11. Biyolojik sinir hücresi	28
Şekil 12. Yapay sinir hücresinin yapısı	29
Şekil 13. Yapay sinir ağları katmanları	32
Şekil 14. Yapay sinir ağı mimarileri	33
Şekil 15. Yapay sinir ağı modelleri	34
Şekil 16. İleri beslemeli yapay sinir ağı örneği	34
Şekil 17. Geri beslemeli yapay sinir ağı örneği	35
Şekil 18. Yapay zeka ile derin öğrenme arasındaki ilişki	36
Şekil 19. Derin sinir ağı	39
Şekil 20. Yeni giriş verilere yerleştirilir	41
Şekil 21. Doğrulama süreci için eğitim verilerinin bölünmesi	42
Şekil 22. Çapraz doğrulama	43
Şekil 23. Konvolüsyonel sinir ağı mimarisi	44
Şekil 24. Konvolüsyon katmanı süreci	45
Şekil 25. İki farklı yöntem kullanılarak yapılan havuzlama	46
Şekil 26. Aktivasyon fonksiyonları	48
Şekil 27. AlexNet yapısı	51
Şekil 28. Naif inception modülü	52
Şekil 29. Katagorize edilen veriler	53

Şekil 30. Ağzı kapalı bileteral MR görüntüsü ve TME kesiti	54
Şekil 31. Kesilmiş ve etiketlenmiş MR görüntüleri	54
Şekil 32. Ağzı kapalı veri seti AlexNET(adam) doğruluk grafiği	57
Şekil 33. Ağzı kapalı veri seti AlexNET(adam) hata grafiği	58
Şekil 34. Doğruluk setinin rasgele 4 kesit tahmini ve hata matrisi	59
Şekil 35. İki modelin aynı doğrulama seti için tahminleri	59
Şekil 36. Ağzı açık veri seti AlexNET(adam) doğruluk grafiği	61
Şekil 37. Ağzı açık veri seti AlexNET(adam) hata grafiği	61
Şekil 38. Modelin ağız açık rasgele 4 kesit tahmini ve doğruluk seti hata matrisi	62
Şekil 39. İki modelin aynı doğrulama seti için tahminleri	63

TABLÖLAR DİZİNİ

Tablo	Sayfa
Tablo 1. TME rahatsızlıklarının sınıflandırılması	17
Tablo 2. Toplama fonksiyonu türleri	30
Tablo 3. Aktivasyon fonksiyonu türleri	31
Tablo 4. GoogLeNet katmanları	52
Tablo 5. Veri seti örnek sayısı	55
Tablo 6. AlexNET ve GoogLeNET uygulama sonuçları	56
Tablo 7. Optimizasyon sonrası sonuçlar	57
Tablo 8. Ağız açık veri seti eğitim sonuçları	60
Tablo 9. Ağız açık veri setinin optimal sonuçları	60

KISALTMA, SİMGE ve FORMÜLLER DİZİNİ**Kısaltmalar**

ML	Makine öğrenimi
AI	Yapay zeka
TME	Temporomandibular eklem
MR	Manyetik rezonans
MRG	Manyetik rezonans görüntüleme
YSA	Yapay sinir ağları
RDD	Redüksiyonlu disk deplesmanı
BT	Bilgisayarlı tomografi
DNN	Derin sinir ağları
ANN	Yapay sinir ağı
GPU	Grafik işleme birimi
ReLU	Rectified linear unit
CNN	Konvolüsyonel sinir ağı
KTÜ	Karadeniz Teknik Üniversitesi

1. ÖZET

Derin Öğrenme ile Manyetik Rezonans Görüntülerde Temporomandibular Eklem Disk Deplasmanlarının Diagnozu

Derin öğrenme temelinde insanı taklit eden, önceden bilinen verilerden çok katmanlı sinir ağları kullanılarak özellik çıkartabilen, bilinmeyen veriler üzerinde sınıflandırma ve analiz yapabilen bir makine öğrenmesi çeşididir. Teknolojinin ilerlemesiyle yetersiz kalmaya başlayan öğrenme çeşitlerine alternatif olan derin öğrenme; son zamanlarda akademisyenler, araştırmacılar ve bilim insanlarının sıkça tercih etmeye başladığı bir öğrenme çeşididir. Yapay zeka çalışmalarının artmasıyla birlikte ortaya çıkan bu yöntem, imgelerin tanınma ve öğrenme sürecinin çok daha hızlı gerçekleşmesini sağlamaktadır. Manyetik rezonans görüntüleme (MRG), temporomandibular eklem (TME) disk deplasmanının tespit etmek için kullanılan en yaygın görüntüleme tekniğidir. MR görüntüleri TME disk deplasmanlarını tespit etmek için radyologlar tarafından elle analiz edilmektedir. Çok büyük görüntü hacminin manuel olarak yorumlanması zaman alıcı ve zor olmaktadır. Bu nedenle, bilgisayar tabanlı algılama, doğru ve hızlı tanılamada yardımcı olmaktadır. Bu çalışmada, normal ve disk deplasmanı olan MR görüntülerinin derin öğrenme yaklaşımının, konvolüsyonel sinir ağları (CNN) yöntemi ile sınıflandırılması amaçlanmıştır. Bu çalışma doğrultusunda CNN tabanlı AlexNET ve GoogLeNET derin öğrenme modelleri farklı hiper-parametreler kullanılarak test edilmiştir. Bu çalışma sonunda TME disk deplasmanı teşhisinde derin öğrenmenin başarılı sonuçlar verdiği görülmüştür.

Anahtar Kelimeler: Derin Öğrenme, Disk Deplasmanı, MRG, Temporomandibular Eklem

2. SUMMARY

Diagnosis of temporomandibular joint disc displacements on magnetic resonance images with deep learning

It is a kind of machine learning that simulates human being on the basis of deep learning, can extract features from previously known data using multi-layer neural networks, and can make classification and analysis on unknown data. Deep learning which is an alternative to the learning varieties that are beginning to be insufficient with the advancement of technology; is a type of learning that academicians, researchers and scientists have recently started to prefer. This method, which occurs with the increase of artificial intelligence studies, makes the recognition and learning process of images much faster. Magnetic resonance imaging (MRI) is the most common imaging technique used to detect temporomandibular joint (TMJ) disc displacement. MRI images are analyzed manually by radiologists to detect disc displacements. Manual interpretation of very large image volumes is time consuming and difficult. Therefore, computer-based detection helps in accurate and rapid diagnostics. In this study, it was aimed to classify the deep learning approach of normal and disk displacement MR images with convolutional neural network (CNN). In this study, CNN-based AlexNET and GoogLeNET deep learning models were tested using different hyper-parameters. At the end of this study, deep learning was found to be successful in diagnosing TMJ disc displacement.

Key Words: Deep Learning, Disc Displacement, MRI, Temporomandibular Joint

3. GİRİŞ ve AMAÇ

Günümüz teknolojisinde bilgisayar hayatımızın hemen her alanında yerini almaya başlamıştır. Akıllı cihazlar, klonlanan canlılar, robotlar ve insanın zekasından esinlenerek üretilen yapay zekalar teknolojiyle beraber aramıza katılmıştır.

Askeriden eğitime kadar birçok alanda teknoloji hızla ilerlemektedir. Sağlık alanı da teknoloji ve bilgisayarın bu denli hayatımızda olmasından faydalanan alanlardan bir tanesidir. Birçok tıbbi uzman; insan hatasından kaynaklanan sorunları en aza indirmek, hastalıklara alternatif çözümler üretmek ve tanı koyma sürecini hızlandırmak gibi amaçlarla yaptıkları çalışmalarında, geleneksel öğrenme metotları yerine, makine öğrenme tekniklerine, yapay zekaya ve derin öğrenmeye başvurmaktadır.

Makine Öğrenimi (ML) ve Yapay Zekâ (AI) teknikleri, tıbbi görüntü işleme, bilgisayar destekli tanı, görüntü yorumlama, görüntü birleştirme, görüntü kaydı, görüntü bölümleme, görüntü rehberli terapi, görüntü alma ve analiz gibi tıbbi alanlarda önemli bir rol oynamıştır. Bilgiyi etkili ve verimli bir biçimde görüntülemekte ve temsil etmektedirler. ML ve AI doktorlara, hastalık riskini doğru ve hızlı şekilde teşhis edip öngörebilmeleri, zaman içinde önleyebilmeleri ve araştırmacılara da hastalığa yol açacak olan genel varyasyonları nasıl analiz edeceklerini anlamalarında yardımcı olmaktadır.

Yapay zekâ farklı disiplinlerdeki problemlere sunduğu etkin çözümler ile günden güne önemini arttıran bir bilim dalıdır. Mantıksal ve matematiksel platformda ifade edilebilen problemlere çözüm sunabilmesi, yapay zekayı üzerinde çokça çalışma yapılan bir alan haline getirmiştir. Makine öğrenimi yapay sinir ağları da bu çalışmaların ulaştığı bir yapay zekâ terimidir.

Yapay sinir ağları kendisine verilen birçok bilgiyi kullanarak yeni bilgiler üretmektedir. Makine öğrenmesi gerçekleştirir ve bu öğrenme işinde kendisine verilen bilgilerden yani örneklerden yararlanırlar. Çalışma prensipleri biyolojik sinir sistemi model alınarak oluşturulmuştur. Sinir hücrelerinin sahip olduğu nöronlar gibi yapay sinir ağlarının da kendi yapay sinir hücreleri bulunmaktadır. Bu hücreler bilgileri birinden diğerine aktarmaktadır. Hücre içine giren bilgilere girdi, hücrenin girdileri kullanarak ürettiği sonuç bilgisine de çıktı adı verilmektedir. Yapay sinir ağı girdi ve

çıktı arasındaki süreçte, bilinmeyen bir fonksiyonun değerini tahmin etmeyi ya da yaklaşık değerini hesaplamayı hedeflemektedir.

Yapay zekâ yöntemlerinin doğru ve anlaşılır olmasını destekleyen diğer bir yöntemi ise derin öğrenmedir. Derin öğrenme, kendi kendine öğrenme yöntemlerini kullanarak içsel özellik çıkarımının avantajlarını sağlayan, çoklu işlem katmanları kullanarak verideki yüksek-düzeyleli soyutlamaları modellemeye yarayan bir dizi algoritmaya dayanan bir makine öğrenme yöntemidir (1). Son yıllarda görüntü ve ses işleme alanında büyük başarılar getirmesi ile öne çıkan derin öğrenme, sağlık alanında hastalıkları teşhis ederken ya da sınıflandırırken radyolojik bulgular üzerinden çıkarımlar sağlamaktadır. Bu teknoloji ile ilgili son zamanlarda yapılan çalışmalar arasında prostat kanserinin teşhisi (2), akciğer nodüllerinin diagnozu (3) ve beyin tümörünün sınıflandırılması ve segmentasyonu (4, 5) gibi birçok hastalığın teşhisinde uygulanarak iyi bir performans gösterme potansiyeline sahip olduğu ortaya koyulmuştur.

Temporomandibular eklem (TME) rahatsızlıkları her yaşta görülebilmesine rağmen en çok gençlerde rastlanan bir rahatsızlıktır. Çene hareketleri sırasında çenede ve çevre dokularda ağrı, çene hareketlerinde kısıtlılık, klik veya kreptasyon gibi seslerin gelmesi TME'nin bulguları arasındadır. Aynı zamanda baş, boyun, kulak ve diş ağrısı gibi semptomlar da bulgular arasında olabilmektedir. Toplumun %20'sinde TME rahatsızlıkları belirtileri görülebilmektedir. Yapılan araştırmalar sonucu ulaşılan verilere göre batı toplumlarında TME rahatsızlıklarının yaşam boyu prevalansı %3-15 arası değişkenlik göstermektedir (6).

Temporomandibular eklem alt çene kemiği ile kafatasının temporal kemiği arasındaki bağlantıdır. Normal bir Temporomandibular ekleminde (TME) ağız kapalı pozisyonda kondilin apeksi üstüne yerleşen, bikonkav yoğun fibröz dokudan oluşan eklem diski bulunmaktadır. TME rahatsızlıklarından biri olan disk deplasmanı, bu diskin hareket yol fonksiyonundaki değişiklikleri oluşturmaktadır. Disk deplasmanları, ağzın açık ve kapalı pozisyonuna bağlı olarak redüksiyonlu ve redüksiyonsuz disk deplasmanı şeklinde sınıflandırılmaktadır (7, 8).

TME disk deplasmanı teşhisinde birçok metot kullanılmaktadır. Görüntüleme metotlarından artrografi, ultrasonagrafi ve Manyetik Rezonans Görüntüleme (MRG)

teknikleri bulunmaktadır. Bu teknikler arasında literatürde en çok kabul gören ve klinisyenler tarafından da en yaygın olarak kullanılan MRG, disk deplasmanının teşhisinde yüksek hassasiyet, spesifite ve doğrulukla birlikte sabit muayenede oldukça detaylı anatomik bilgiler vermektedir (7, 8). Hatta MRG, TME yumuşak dokularının değerlendirilmesinde, disk kondil ilişkisinde ve disk deplasmanının saptanmasında en etkili görüntüleme aracı (altın standart) olarak kabul edilmektedir (9).

Geleneksel bilgisayar programları hesaplama yapmak ve kendisine verilen talimatları yerine getirmek üzerine tasarlanmıştır. Bu programların sorunları çözebilmeleri için ilk olarak sorunların açık ve net yani iyice belirlenmiş bir hale getirilmesi gerekmektedir. Bilgisayarın ağacın rengini kırmızıdan ayırması veya bir yazı içerisindeki harfler ile rakamları ayırt edebilmesi için öncelikle bununla ilgili kodlarının yazılması gerekmektedir. Aynı şekilde iki nokta arasındaki uzaklığın hesaplanma işleminin gerçekleşmesi için de öncesinde gerekli talimatlar bilgisayara verilmelidir. Bütün bu kodların yazılması aylar hatta yıllar sürebilmektedir. O yüzden geleneksel programlar bu tür sorunların çözümünde kullanılacak etkili bir yol değildir. Problemlerin makine diline çevrilmesi için uzmanlık gerektiren yollara başvurulmalıdır.

Derin öğrenme makine öğreniminin gelişmiş bir şeklini oluşturmaktadır. Derin öğrenme algoritması, biyolojik ve tıbbi veriler gibi oldukça karmaşık problemlerden saklı kalıpları çıkarmaktadır (10). Her bir nöron üstel biçimde büyüyen birçok katmana ve birime sahiptir. Sinir ağı bu şekilde genişlemektedir/büyümektedir. Çeşitli alanlarda (tıbbi, ilaç, endüstriyel...) özel derin öğrenme problemleri için birçok farklı algoritma geliştirilmiştir.

Yapay sinir ağları (YSA) kullanılarak son zamanlarda tıp biliminde ve biyomedikal araştırmalarda birçok farklı uygulama geliştirilmektedir. Ağız ve çene-yüz cerrahisinde literatür incelendiğinde sinir ağlarının kullanımı sınırlı sayıda olduğu görülmektedir. Bu alanda TME disk deplasmanı teşhisinde YSA kullanılarak sadece bir çalışma görülmektedir. Bas vd. (2012) tarafından gerçekleştirilen bu çalışmada hastaların klinik semptomları ve tanıları fonksiyon yaklaşımı (özellik çıkarma) kullanılarak bir yapay sinir ağı oluşturulmuş. Çalışmada karar verme algoritması olarak geri yayılım sinir ağı temel alınmıştır (11). Fakat TME disk deplasmanında derin

öğrenme metoduyla ile herhangi bir sınıflandırma ve segmentasyon çalışması medikal görüntülerle yapılmamıştır.

Bu çalışmada temporomandibular disk deplasmanının derin öğrenme yaklaşımının, konvolüsyonel sinir ağıları algoritması sınıflandırılması yapılacaktır. Çalışma kapsamında klinikçiler tarafından önceden teşhis edilmiş hastalıklı ve sağlıklı manyetik rezonans görüntüler kullanılarak danışmanlı bir öğrenme gerçekleştirilmesi amaçlanmıştır.




4. GENEL BİLGİLER

4.1. Temporomandibular Eklem Anatomisi ve Fonksiyonu

Gnglymus ve articulatio plana grubu eklemlerin karışımından oluşan temporomandibular eklem (TME) kafa kemikleri arasındaki tek hareketli eklemdir ve hem kayma hareketi yapan ginglimoid eklem hem de translasyon hareketini gerçekleştiren artroidal tip eklem birleşiminden oluşmaktadır. Eklem üst yüzünde os temporale'ye ait tuberculum articulare ve fossa mandibularis, alt yüzünde ise os mandibulare'ye ait mandibüler kondil bulunmaktadır. Bu iki kemik doku arasında hareketi kolaylaştıran ve fibro-elastik kıkırdaktan oluşan discus articularis bulunmaktadır. Eklem kapsülü içerisinde bulunan eklem diski, üst yüzünde os temporale'deki eklem yüzüne uyacak şekilde önde hafif konkav, arkada belirgin konveks, alt yüzünde mandibular kondile uyacak şekilde konkav şekil almaktadır. Eklem diski ayrıca, eklem boşluğunu da inferior ve superior olmak üzere iki bölüme ayırmaktadır. Bu disk kuvvetin uygun şekilde dağıtılmasını ve sürtünmenin azaltılmasını sağlamaktadır. Elastik yapısı sayesinde kuvvet ortadan kalktığında disk, kendi şekline geri dönmekte ve diskin normal pozisyonunun bozulması ise eklem hareketlerinde bozulmalara yol açabilmektedir (8).

Eklem dış çeperi eklem kapsülü tarafından oluşturulmaktadır. Eklem yüzleri hariç kapsülün iç tarafı sinovial membran ile sarılıdır. Capsula articularis, discus articularis, ligamentum laterale, ligamentum mediale, ligamentum sphenomandibulare ve ligamentum stylomandibulare bu eklem bağlarını oluşturmaktadır. Şekil 1'de temporomandibular eklem yeri gösterilmiştir.




Şekil 1. Temporomandibular eklem (12)

4.1.1. Temporomandibular Eklemin Kemik Elemanları

4.1.1.1. Mandibular Kondil

İnsanda şekil ve boyutu kişiden kişiye, hatta sağ-sol kondil olarak farklılık göstermekle birlikte yetişkinlerde kondil başı anteroposterior yönde 8-10 mm, mediolateral yönde 15-20 mm boyutlara sahiptir. Kondilin çeşitli bölgelerinde eklem diski ve ligamentler için pürüzlü yüzeyler bulunmakla birlikte asıl eklem yüzeyleri üst ve ön yüzleridir ve kondil başının ön yüzeyi daha fazla kuvvete dayanabilecek şekilde daha kalın bir yapıdan oluşmaktadır.



Şekil 2. Mandibular kondil (Staubesand'dan, 13)

4.1.1.2. Glenoid Fossa

Glenoidal fossa (mandibular fossa) TME'nin temporal kemikteki kısmını oluşturmakta ve kemiğin skuamoz kısmındaki konkav bir boşluğundan meydana

gelmektedir. Buraya mandibular kemiğin kondili oturmaktadır. Boşluğun ön duvarında temporal kemiğe ait eminentia articularis, dış duvarını ise dış kulak yolunun ön duvarı yani timpanik tabaka yer almaktadır. Timpanik tabakaya geçişte skuamotimpanik, petrotimpanik ve petroskuamoz adında üç yarık bulunmaktadır ve disk deplasmanlarında bu yarıklarda ossifikasyon, oldukça sık görülen bir bulguyu oluşturmaktadır. Mandibular fossa'nın üst ve arka kısımları damardan zengin fibröz bağ doku ile sarılı olup, eklem hareketine katılmamakta ve uygulanan kuvveti ön duvara doğru yönlendirmektedir. Glenoid fossanın eklem açısından ön tarafında bulunan asıl fonksiyonel kısmına artiküler fossa denilmektedir.

Glenoid fossanın ön yüzeyini oluşturan artiküler eminens, arcus zigomaticus'un posteriyor kökünü oluşturmaktadır ve TME'nin hareketlerinde asıl yükü taşıyan kısımdır. Yaptığı işe yönelik kalın ve sert bir fibröz doku ile kaplıdır. Üzerinde, eklem yüzeylerinden bağımsız olarak artiküler tüberkül bulunmaktadır ve temporomandibular ligament buraya tutunmaktadır.



Şekil 3.Glenoid fossa (Staubesand'dan, 13)


4.1.2. Temporomandibular Eklemi Oluşturan Yumuşak Doku Elemanları

4.1.2.1. Eklem Diski (Discus Articularis)

Eklem diski, primer görevi eklem yüzeyleri arasındaki kuvvetleri dağıtmak, kayganlığı sağlayarak sürtünmeyi azaltmak olan fibröz bir plaktır. Yapısındaki tip 1 ve tip 2 kollajen lifler basınç karşısında sağlamlık sağlarken; elastik lifler, kuvvet kalktığında eski yapısına kavuşmasını sağlamaktadır. Ayrıca içeriğindeki kondroitin

sülfat, dermatan sülfat, keratin sülfat ve hyalüronik asit içerikli glikozaminoglikanlar sayesinde osmotik basıncı da yeterli seviyede tutulmaktadır. Bu birliktelikler sayesinde discus articularis, kuvvet altında dayanıklı bir biçimde gerekli şekli almakta ve ortadan kalktığında da hasarsız bir biçimde eski şekline dönebilmektedir.

Eklem diski, fonksiyonel açıdan anterior, intermediate ve posterior olmak üzere üç kısımda incelenmektedir. Kalınlıkları 2:1:3 oranlarındadır. Önde eklem kapsülü ve musculus pterigoideus lateralis'e, arkada retrodiskal dokuya bağlı iken yanlardan kondil başına tutunmaktadır. Kondil başına olan bağları sayesinde hareket sırasında kondil ile birlikte hareket etmekte ve iki kemik arası yüzey uyumunun devamlılığını sağlamaktadır. Disk ve bağları, eklem kapsülünü süperior ve inferior olmak üzere iki alana ayırmaktadır. Bu alanlar sinovyal membran'dan salgılanan sinovyal sıvı ile dolu olmakla birlikte ve bu sıvı, gerek doku beslenmesi gerekse eklem hareketlerindeki sürtünmenin azaltılması adına önemli görevler yapmaktadır. Şekil 4'te eklem diski ve diğer yapılar gösterilmektedir.



Şekil 4. Eklem diski (1.Kondil başı, 2.Pterigoid fovea, 3.Eklem Diski, 4.Eklem kapsülü, 5.Retrodiskal doku, 6.Alt eklem boşluğu, 7.Üst eklem boşluğu, 8. Artiküler eminens, 9.Zigomatik ark, 10.Dış kulak yolu, 11.Superior lateral pterigoid, 12.İnferior lateral pterigoid kası) (14).

4.1.2.2. Temporomandibular Eklem Ligamentleri

TME’de 3’ü fonksiyonel 2’si aksesuar olmak üzere 5 adet ligament bulunmaktadır. Aktif harekete katılmasalar da, hareket kısıtlamasında görev yapmaktadırlar. Esneme özellikleri yoktur ancak büyük ya da uzun süreli kuvvet maruziyeti sonucunda uzayabilmektedirler.

4.1.2.2.1. Fonksiyonel Ligamentler

Kollateral Ligament(Diskal Lig.)

Diskin medial ve lateral kenarlarını kondil ucuna bağlamakta ve özellikle rotasyon sırasında diskın kondille beraber hareket etmesini sağlamaktadır.

Eklem Kapsülü(Kapsüler Lig.)

Üstte temporal kemiğin eklem yüzüne, altta da kondilin boynuna tutunan lifleriyle TME’yi tüm yönlerden sarmaktadır. Bütünlüğü sayesinde eklem içindeki sinovial sıvıya kese görevi görmekte ve devamlılığını sağlamaktadır. Ekleme gelebilecek medial, lateral ve inferior kuvvetlere karşı koruma sağlamakla birlikte güçlendirilmiş lateral kısmı temporomandibular ligamenti oluşturmaktadır (14).

Temporomandibular Ligament(Lateral Lig.)

Lateral ligament içte horizontal, dışta oblik şekilde iki kısımdan oluşur ve TME’lerin lateralinde bulunmaktadır. Oblik kısım, rotasyonel ağız açmayı, kondilin aşırı öne hareketini engelleyerek kısıtlar. Horizontal kısmı retrodiskal dokunun travmadan korunmasını, kondil ve diskın posterior hareketine engel olarak sağlamaktadır (14).

4.1.2.2.2. Aksesuar Ligamentler

Sfenomandibular Ligament

Sfenoid kemiğin spina sphenoidale’sinden bağlayıp dışa aşağı uzanarak, mandibula’nın lingula mandibulare’sinde sonlanan bu kasın mandibular hareketlerde herhangi bir görevi bulunmamaktadır. Çene hareketleri sırasında, gerilime karşı yapıları koruma özelliğine sahiptir.


Stylomandibular Ligament

Processus styloideus'tan başlayıp ramus mandibulare'nin arkasına ve angulus mandibulare'ye yapışmaktadır. Mandibulanın protrüziv hareketini sınırlandırmaktadır.

4.1.2.3. Retrodiskal Doku (Bilaminer Bölge)

Retrodiskal alan, üst ve alt stratum olarak iki bölgeye ayrılmaktadır. Bu ikisi arasında da damar-sinir ağları ve yağ dokunun bulunduğu intermediate tabaka yer almaktadır. Üst stratum gevşek yapıda iken, alt stratum sıkı kollajen fibrillerden oluşmaktadır. Alt stratum disk deplasmanları açısından önem arz etmektedir, zira diskin kondil üzerinde sabit kalmasını sağlamakta ve anterior disk deplasmanı sadece alt stratum fazla gerilirse gerçekleşmektedir.

Eklem hareketleri sırasında bu alanda negatif basınç ortaya çıkmakta akabinde bu bölgeye kan dolmaktadır. Bu kan, eklem elemanlarının beslenmesi ve kayganlığın devamı açısından önemlidir. Şekil 5'te ağız kapalı ve ağız açık pozisyonda eklem diskinin lokasyonu ve diğer yapılar gösterilmektedir.



Şekil 5. Ağız kapalı (A) ve açık (B) pozisyonlarda, rediksal doku hacmindeki değişiklik (1. Kondil başı, 2. Pterigoid fovea, 3. Eklem diski, 4. Eklem kapsülü, 5. Alt eklem boşluğu, 6. Üst eklem boşluğu, 7. Artiküler eminens, 8. Zigomatik ark, 9. Dış kulak yolu, 10. Superior lateral pterigoid kas, 11. İnferior lateral pterigoid kas) (14).

4.1.2.4. TME'nin Arteriel Beslenmesi

Posteriorda arteria maksillaris ve arteria temporalis superficialis ve posteriorda masseterik arter TME'yi besleyen ana arterlerdir. Ayrıca kondil çevresindeki arter ağı

ve arteria alveolaris inferior da kanlanmaya katkı sağlamaktadır. Pterigoid pleksus, maksiller pleksus ve vena temporalis superficialis de venöz boşaltımın gerçekleştiği venleri oluşturmaktadır.

4.1.3. TME'nin Sinir Yapısı

Aurikulotemporal sinirin dallarından gelen TME'nin, motor ve sensitif inervasyonuna massater ve derin posterior temporal sinir yardımcı olmaktadır.

4.1.4. Mandibular Fonksiyondaki Kaslar

Mandibula fonksiyonel hareketlerini 4 çift çiğneme kasıyla yapmaktadır. Şekil 6'da bu kaslara ait toplu bir görsel verilmektedir.



Şekil 6. Kaslara ait toplu görsel (Tillman'dan, 15)

4.1.4.1. Massater Kası

Dikdörtgen şekilli bu kas, zigomatik arkta başlayıp aşağı doğru uzanarak mandibulanın alt sınırının lateral kısmında son bulmaktadır. Yüzeysel ve derin olmak üzere iki dalı vardır. Derin dalı vertikal liflerden oluşurken; yüzeysel dalı aşağı ve hafifçe geriye doğru uzanmaktadır. Massater kasıldığında mandibulayı yukarı doğru çekerek dişleri birbirine temas ettiren, güçlü bir çiğneme kasıdır.


4.1.4.2. Temporal Kas

Temporal fossa ve kafatasının lateral yüzünden başlayan lifleriyle yelpaze şeklindeki bu büyük kasın lifleri birleşerek arcus zygomaticus'un içinden geçmekte ve

tendonuyla koronoide ve mandibular ramusun anterior sınırına yapışmaktadır. Ön, orta ve arka lifleri farklı doğrultularda yerleştikleri için farklı görevlere sahiptir. Ön lifler dik inmekte ve kasıldıklarında alt çeneyi yukarı doğru çekmektedirler. Orta lifler oblik olarak uzanmakta ve kasıldıklarında alt çeneyi yukarı ve geriye doğru çekmektedirler. Arka lifler ise daha horizontal yerleşimlidirler ve kasıldıklarında alt çeneyi geriye çekmektedirler. Tüm lif grupları aynı anda kasıldıklarında ise alt çeneyi kapatmaktadır ve en güçlü çiğneme kası temporal kastır.

4.1.4.3. M. Pterigoideus Medialis(İç)

Sfenoid kemiğin pterigoid fossasından başlayıp aşağı, geri ve dışa doğru ilerleyip angulus mandibularisin iç yüzeyinde son bulmaktadır. Asıl olarak alt çenenin kapanmasında görev alsa da çeneyi ileri oynatabilme özelliğine de sahiptir. Tek taraflı kasıldığında mandibulayı mediotrüzyona getirmektedir (14). Şekil 7’de çeneyi hareket ettiren kaslar gösterilmektedir.



Şekil 7. Çeneyi iki yana (laterale) hareket ettiren kaslar (Tillman’dan, 15)

4.1.4.4. M. Pteridoideus Lateralis

İnferior ve süperior olmak üzere farklı görevde iki bölümden oluşmaktadır.

İnferior Lateral Ptreigoid Kas: Dışa, yukarı ve geriye uzanarak lateral pterigoid plağın dış yüzü ile kondil boynuna yapışmaktadır. Mandibula protrüzyonun, bilateral inferior lateral kas ile kasılıp kondiller artiküler tüberküle doğru çekilme yapmaktadır. Tek taraflı kasıldığında ise, mandibula karşı tarafa doğru hareket etmektedir.

Mandibular depresör kaslarla beraber kasıldığında kondillerin ileri ve aşağıya hareketi oluşmaktadır (14).

Superior Lateral Pterigoid Kas: Ala sphenoidalis major'un infratemporal yüzünden başlayıp geri ve dışa doğru yatay olarak uzanarak eklem kapsülüne, kondile ve artiküler diske yapışmaktadır. Bu kas kasıldığında disk, anteromediale doğru çekilmektedir. Çene açma hareketinde görevi yoktur ancak yükseltici kaslar işlev görürken çalışmaktadır. Superior lateral pterigoid kas, ağız kapatılırken, retrüzyonda ve laterotrüzyonda aktif hale gelmekte, bu hareketler sırasında kondil-disk kompleksini devamlı olarak eminensin eğimine karşı tutmaya çalışmaktadır (8, 16).

4.2. TME Hastalıkları

Diş hekimlerinin ilgi alanına, 1934'te dış kulak semptomları ile diş dizilimindeki değişikliklerin birbiri ile bağlantı olduğu Costen tarafından ileri sürülmektedir. Temporomandibular rahatsızlığı değişik bulguların birleşmesiyle oluşan semptomlar topluluğu olarak değerlendirmiştir. Bu durum oklüzal dikey boyutun düşmesi, posterior diş destek kaybı ve maloklüzyonların TME eklem düzensizliği ve değişmiş anatomik ilişkinin sebebiyet verdiği aurikulotemporal ve chordatympanic sinirlerdeki iritasyondan olan refleksler olduğunu düşünmüştür. Bulgular, baş ağrısı, sinüs ağrısı, kulak ağrısı ve çınlaması, kulak tıkanıklığı hissi, dil yanması, metalik tad ve duyma bozukluğudur ve "*Costen Sendromu*" olarak isimlendirilmiştir. Tedaviye yönelik olarak da Costen, oklüzyonu(dişlerin ağız içinde birbirine göre duruşu) yükseltmeyi denemiştir (14). Bruksizm, maloklüzyon, travma, kondil-disk kompleks düzensizlikleri ve TME'nin dejeneratif-iltihapsal hastalıkları etyoloji açısından bazıları olsa da sonuçlarında görülen semptomlar birbirine çok benzerdir. Bu benzerlik sebebiyle tanının doğru konması ve doğru tedavi planı önemli hale gelmiştir.

4.2.1. Temporomandibular Bozuklukların Etyolojisi

TM bozukluklarına sebep olabilecek birçok etyolojik faktör bulunmaktadır. Disk deplasmanları için diski sabitleyen ligamentlerde fonksiyon kaybı bulunması gerekmektedir. Bu kayıp, genellikle diskin bağ dokusu proliferasyonuna bağlı plastik deformasyon sonucu gelişmektedir.

Travma: TMB'de en sık karşılaşılan etyolojik faktör travmadır. Eklem elemanlarında yaralanmaya sebep olan travmalara ilk yanıt, travmatik artritis ve

efüzyondur. Travma karşısında vücudun bu doğal seyri içerisinde fibrozis ya intraartiküler hiperplastik doku oluşumu görülebilmektedir. Bu da, ağrı ve hareket kısıtlılığına sebep olabilmektedir.

Eklem Laksisitesi (Gevşekliği): Disk düzensizlikler ile eklem ligamentlerindeki gevşeklikler arasında sıkı bir bağlantı olduğu düşünülmektedir. TME disk düzensizliği olan hastalarda, diğer eklem rahatsızlığı olan ya da asemptomatik gruba göre sistemik eklem laksisitesinin anlamlı derecede fazla olduğu bulunmuştur (14).

Bruksizm: Bruksizm, eklemden aşırı yüklemeye neden olmakta ve bunun sonucunda sinovial sıvı elemanlarına zarar verebilecek oksidatif radikaller oluşmaktadır. Ayrıca oklüzyonu bozabilecek kuvvet uygulamasına da sebep olabilmektedir. Bruksizm çoğu zaman, stres ve emosyonel etmenler nedeniyle ortaya çıkmaktadır.

4.2.2. Temporomandibular Bozuklukların Sınıflandırılması

Günümüze kadar birçok sınıflandırma yapılmıştır. 1998 yılında Okeson tarafından yapılan sınıflandırmada bozukluklar, ortak özelliklerine göre dört ana başlık altında toplanmıştır: Çiğneme kası rahatsızlıkları, TME düzensizlikleri, kronik mandibular hipomobilité ve büyüme bozuklukları. Hastalıkların doğru tanımlanması, doğru tedavi açısından önemlidir zira hastalıkların ortak semptomlarının oldukça fazla olduğu görülmektedir. Aşağıdaki Tablo 1'de Okeson'a göre temporomandibular bozuklukların sınıflandırılması verilmiştir.

Tablo 1. TME rahatsızlıklarının sınıflandırılması (Gezer'den, 6)

Çiğneme Kaslarına Ait Rahatsızlıklar	TME Rahatsızlıkları	Kronik Mandibular Hipomobilité	Gelişim Bozuklukları
Koruyucu ko-kontraksiyon	Kondil-disk kompleksinde düzensizlik	Ankiloz	Konjenital ve gelişimsel kemik rahatsızlıkları
Lokal kas ağrısı	1.Disk deplasmanı	1.Fibröz	1.Agenezi
Miyofasiyal ağrı	2. Redüksiyonlu disk dislokasyonu	2.Kemiksel	2.Hipoplazi
Miyospazm	3.Redüksiyonsuz disk dislokasyonu	Kas kontraktürleri	3.Hiperplazi
Miyozit ve diğerleri	Eklem yüzeylerinin yapısal uyumsuzluğu	1.Miyostatik	4.Neoplazi
	1.Şekil değişiklikleri	2.Miyofibrotik	Konjenital ve gelişimsel kas rahatsızlıkları
	2.Adezyonlar	Koronoid impedans	1.Hipotrofi
	TME'nin inflamatuvar hastalıkları		2.Hipertrofi
	1.Sinovit/kapsülit		3.Neoplazi
	2.Retrodiskit		
	3.Artritler		
	a.Osteoartrit		
	b.Poliartrit		

4.2.3. Çiğneme Kası Rahatsızlıkları

Miyofasiyal Ağrı: En sık rastlanan çiğneme kası rahatsızlığıdır (14). Kaslardaki hassas noktalardan(tetik noktası) başlamaktadır. En belirgin semptom tek taraflı sürekli ağrı iken, çift taraflı da görülebilmektedir. Çiğneme kaslarındaki hassasiyet ve mandibular hareketlerdeki kısıtlama, miyofasiyal ağrının diğer önde gelen semptomlarını oluşturmaktadır.

Miyozit: Enfeksiyon ya da travma gibi bir sebepten dolayı kaslarda oluşan primer enflamasyondur. Devamlı ve akut bir ağrı olarak tariflenebilmektedir. Genelde miyozite, şişlik, kızarıklık ve ateş eşlik etmektedir.


Miyospazm: Santral sinir sistemi kaynaklı istemsiz kas kasılmasıdır ve kramp olarak da bilinmektedir. Ağız hareketlerinde ciddi sınırlama mevcuttur.

Lokal Kas Ağrısı: Kas yorgunluğu, egzersiz sonrası geç dönem ağrıları, iskemik ağrılar gibi ağrılar bu grupta yer almaktadır. Patolojisi ve etyolojisi tam olarak bilinmeyen akut kas ağrılarına, lokal kas ağrıları denmektedir.

4.2.4. Temporomandibular Eklem Düzensizlikleri

4.2.4.1. Disk Deplasmanları

Disk deplasmanı diskin normal süperior pozisyonu olan ağız kapalı durumda iken diskin posterior bandının kondil üzerinde saat 12 pozisyonundaki durumunun artı veya eksi 30 derecelik sapması olarak adlandırılmaktadır. Diskin anteriorda bulunduğu varyasyonlar durumudur. Kondilin anterior çıkıntısı ve diskin orta kısmının inferior konkavitesi ile temastaysa, kondilin anterior çıkıntısı diskin bikonkav kısmında bulunması durumunda normal pozisyon olarak kabul edilmektedir. Eğer iki yüze 2mm'in üstünde uzaklaşırsa deplase olarak kabul edilmektedir. Kondilin anterior çıkıntısı disk ataşmanı üzerindeyse yani diskin posterior bandıyla ya da kenarıyla karşı karşıyaysa disk deplasmanı mevcut denilmektedir (14, 17). Şekil 8'de diskin normal süperior pozisyonu ve saat açısı gösterilmiştir.



Şekil 8. Diskin normal superior pozisyonu (Yalçın ve Aktaş'tan, 14)

Disk deplasmanlarının ikinci basamağını redüksiyonlu disk deplasmanları (RDD) oluşturmaktadır. RDD ağız açılması ile tekrar kapatılması esnasında diskin anteriorda kalması durumu olarak adlandırılmaktadır (7, 14, 17). RDD hastalarında deplasmanın olduğu tarafa doğru kısıtlama yaşanmazken, kontralateral yönde çene hareketlerinde kısıtlılık yaşanmaktadır. RDD hastalarında ağız kapanırken resiprokal klik adı verilen ikinci bir klik sesi alınabilmektedir. Bu ses diskin posterior bandı kondilden geçerken geçerken ortaya çıkmaktadır. Çeşitli müdahaleler ve palpasyonla disk, normal pozisyonuna döndürülebilmektedir.

Deplasmanların üçüncü aşaması olan redüksiyonsuz disk deplasmanlarında disk, RDD'den daha da öne kaymıştır ve yerine oturması daha zordur. Bu noktada klik sesi duyulmaz ancak eklemde kilitlenme gerçekleşir. Kondil rotasyon gerçekleştirir ancak translasyon yapamaz.

Akut ve kronik versiyonları bulunmaktadır. Akut redüksiyonsuz disk deplasmanında kilitlenme ani gelişmekte ve yardımsız ağız açıklığı maksimum 35mm'nin altında kalmaktadır. Kronik versiyonunda ise klinik semptomlar ortadan kalkmıştır. Geçmişte yaşanmış klik sesi ve zamanla bunun kaybolmasıyla birlikte ağız açıklığında kısıtlılık ve zamanla düzelen alt çene hareket kabiliyeti, bizi bu tanıya yönlendirmektedir.

TME düzensizliklerinin dördüncü alt başlığı disk deplasmanı değildir. Disk normal pozisyonundadır ancak adezyonlarla eminense bağlanmıştır. Bu yüzden sadece kondiler rotasyon oluşabilmektedir. Disk anatomik pozisyonunda yer aldığından, yüksek inervasyona sahip retrodiskal dokuda gerilim olmamaktadır. Hasta ağzını, kapsülü gelecek kadar çok açmadığı sürece ağrı hissedilmemektedir (14, 17).

4.2.5. TME'nin İltihapsal Hastalıkları

- **Artralji:** TME kapsül veya sinoviyal membranda hissedilen ağrıdır. Travma ve enfeksiyon gibi sebeplerden dolayı oluşmaktadır.
- **Sinovit:** TME'nin iç yüzeyini kaplayan sinovial membranın iltihabıdır.
- **Kapsülit:** kapsüler ligamentin gerilmesine bağlı olarak kapsülde oluşan iltihabı ifade etmektedir (14).
- **TME Osteoartriti:** Eklem yapılarının dejenerasyonudur. Yavaş ilerlemektedir ve sürtünme sesi tanıda bize yol göstermektedir.

- **TME Osteoartrozu:** Eklem formunun ve yapılarının bozulduğu eklemde dejeneratif rahatsızlıktır. Oluşumu sinsidir ve sistemik rahatsızlıklarla ilgili değildir (14). Osteoartroza sebep, eklemde uygulanan kuvvetin doğru şekilde dağıtılamaması sonucu ortaya çıkan dengesizlik olarak gösterilmektedir. Eklem kartilajında aşınma, kemikte remodelling olarak ortaya çıkmaktadır. Hasta ağrı hissetmemektedir.

4.3. Temporomandibular Eklemde Görüntüleme

TME rahatsızlıklarında görüntüleme önemli yer tutmaktadır ve günümüzde görüntüleme yöntemleri oldukça gelişmiştir. Her TME hastalığına klinik olarak tanı konulamayacağından görüntüleme yöntemlerine sıklıkla başvurulmaktadır. Doğru tanı ve tedavi açısından görüntüleme yöntemlerinin pozitif ve negatif yönlerinin bilinmesi, karar vermede kolaylık sağlayacaktır. Günümüzde en çok başvurulanan görüntüleme yöntemleri direkt radyografi, bilgisayarlı tomografi (BT) ve manyetik rezonans görüntüleme (MRG) olup diğer yöntemlere daha ender başvurulmaktadır.

4.3.1. Direkt Radyografiler

Kemik dokunun değerlendirilmesinde önemli bir yeri vardır. Kullanım kolaylığı, düşük radyasyon dozu, maliyet etkin tarafı düşünüldüğünde ilk başvurulanan yöntemlerden biridir. Yumuşak dokular görüntü kirliliği oluşturabilse de kemiğin kalsifiye kısımlarının görüntülenmesinde etkindir. Yumuşak doku süperpoze görüntüsünden etkilenmemek adına en az iki farklı projeksiyonda alınması faydalıdır.

TME görüntülemesinde sıkça kullanılan direkt grafi projeksiyonları aşağıdaki gibidir ve buradakiler haricinde: ağız açık transfarengeal projeksiyon, lateral sefalogram veya ters Towne projeksiyon da daha seyrek olmakla birlikte gerekli durumlarda kullanılmaktadır.

Transkranyal Projeksiyon

Eklemde lateralini değerlendirmede etkindir. Dislokasyonlu kırıklar ve ileri artritlerde bu projeksiyon tercih edilebilir. Minimal değişimleri göstermemektedir.

Transmaksiller Projeksiyon

Transkranyal projeksiyonla 90 derecelik açı yapan bu özel anteroposterior projeksiyon birlikte kullanıldıklarında üç boyutlu değerlendirmeye imkan sağlamaktadır. Medial dislokasyonların görüntülenmesinde faydalıdır.

Submentovertikal Projeksiyon

Uygulama yönü, alt çeneden mandibula ramusuna paralel olarak kafa kaidesine doğrudur. Ramuslar arası asimetri ve genel fasial asimetrijelerin değerlendirilmesinin yanında, travma veya düzeltici çene cerrahisi sonrasında kondil deplasman ve rotasyonlarının tespitinde yararlanılmaktadır (14).

Panoramik Radyografiler

Her iki temporomandibular eklemi kıyaslama, dişlerin yapısı ve duruşu ile birlikte alt üst çene kemik yapısını inceleme imkanı sunan bir yöntemdir. Panoramik görüntülemelerde boyut ve konum bire bir saptanamasa da ileri tetkiklere yönelme açısından önemli bir başlangıç görüntüleme yöntemini oluşturmaktadır.

4.3.2. Bilgisayarlı Tomografi (BT)


Günümüzde pek çok merkezde kullanılmaya başlanan multidedektör BT cihazları, geniş vücut bölgelerinin çok kısa süreler içinde mükemmel görüntü detayı ve multiplanar ve üç boyutlu rekonstrüksiyon seçeneğiyle incelenmesi imkanı sunan radyografik bir yöntemdir (14). Tek bir görüntüleme sonucunda üç boyutlu ve her yönden yorum yapılabilir. BT'nin kemik ve yumuşak doku görüntülemesindeki yüksek başarısına rağmen, yumuşak doku görüntülemesinde MRG'nın BT'den daha üstün olduğu unutulmamalıdır. MRG'ye göre daha hızlı ve ucuzdur. Bununla birlikte MRG'nın kontraendike olduğu birçok hastada kullanılabilmektedir. Direkt radyografilere göre çok daha net ve hassas bir görüntüleme yöntemidir. Direkt grafilerde görülenemeyen daha küçük değişiklikler BT'de ortaya konmaktadır. Ayrıca BT, yumuşak doku yorumlanması imkanı da sunmaktadır. Gerekğinde eklem boşluğuna kontrast madde enjeksiyonu ardından çekilen BT ile BT-artrografi elde edilebilmektedir. Ağız açık ve kapalı pozisyonlarda çekilen iki ayrı BT ile eklem kemiklerinin işlevsel durumu da değerlendirilebilmektedir. BT bizlere, neoplastik ve infeksiyöz gibi anormal oluşumlar ve içerikleri hakkında da yorum imkânı sunmaktadır.

4.3.3. Manyetik Rezonans Görüntüleme (MRG)

Güçlü magnetler kullanılarak iyonize olmayan radyofrekans dalgalarının kullanıldığı bu yöntemde, dokulardaki hidrojen atomu miktarına göre görüntü alınmaktadır. TME’de disk deplasmanlarında altın standart yöntemdir. Yumuşak dokulardaki yüksek sensitivite ve spesifite MRG’ye bu özelliğini kazandırmıştır.

Sagittal ve koronal düzlemlerden alınan görüntüler, kombine edilerek dixin eklem içerisindeki 3 boyutlu konumu ortaya konabilmektedir. Disk deplasmanları MRG’de, T1 ağırlıklı SE sekans kullanılarak saptanmaktadır. Ağız açık ve kapalı şekilde iki görüntüleme, farklı deplasman türlerini saptamak açısından önemlidir. Sağlıklı bir disk MRG’de hipointens görüntülenirken bilaminer bölge daha yoğun görüntülenmektedir.

Normal diskin posterior bandı, ağız kapalı durumdayken kondil başının üstünde bulunmaktadır. Artiküler eminensin posteroinferior durumuyla kondilin anterosuperior kısmı arasında ince intermediate zone yer almaktadır. Kronik disk deplasmlarında oluşan bilaminar zonun doku sinyali ile posterior band birbirine yaklaşması halinde posterior bandın doğru belirlenmesi imkansızlaşmaktadır. Kronik disk deplasmlarında , ince intermediate zone’nun pozisyonunu değerlendirmek gerekmektedir. Mediolateral deplasmanlar için en doğru görüntülerin koroner oblik düzlem çekimleridir. Şekil 9’da ağız kapalı pozisyonunda bir hastanın MR görüntüsü gösterilmiştir.



Şekil 9. Ağız kapalı pozisyonunda MR görüntüsü

4.4. Yapay Zeka


Yapay zeka terimi ilk kez 1956 yılında Stanford üniversitesinde ortaya çıkmıştır. İnsan beyninin öğrenme özelliklerinden esinlenilerek geliştirilmiştir. İnsanların akıl yürütme, bilgiyi öğrenme planlama, algı ve nesneleri işleme yeteneklerini gösterebilen sayısal bir akıl oluşturulmak amaçlanmıştır. Günümüzde sağlık alanından askeriye kadar birçok alanda yapay zekâ kullanılmaktadır. Daha da geliştirmek için birçok çalışma yapılmaktadır. Gelecekte günlük işlerimize yardım edecek kadar hayatımıza gireceği öngörülmektedir.

4.5. Makine Öğrenmesi

Yapay zekanın bir alt dalı olan makine öğrenmesi, verilerin kalıplarını otomatik olarak algılayan ve daha sonra belirsiz koşullar altında gelecek verileri analiz eden ve bu verilerden anlamlı tahminler veya kararlar çıkarabilen modelleme ve algoritmalarından oluşmaktadır. Kısacası, Makine Öğrenmesi veri içeren bir modelleme tekniğidir. Makine öğrenmesi, “veri”den “model”i belirleyen bir tekniktir. Burada, veriler tam anlamıyla belgeler, ses, görüntüler vb. anlamına gelmekte olup model ise makine öğreniminin son ürününü oluşturmaktadır.

Makine öğrenmesi tekniği, verileri analiz ederek ve modeli kendi başına oluşturan bir tekniktir. Buna “öğrenme tekniği” diyoruz çünkü süreç model bulma problemini çözmek için verilerle eğitime benzemektedir. Bu nedenle, Makine Öğreniminin modelleme sürecinde kullandığı verilere “eğitim” verileri denilmektedir.

Çeşitli alanlardaki sorunları çözmek için pek çok farklı Makine Öğrenme tekniği geliştirilmiştir. Bu Makine Öğrenme teknikleri, eğitim yöntemine bağlı olarak üç tipe ayrılabilir. Şekil 10’da bu teknikler görülmektedir.



Şekil 10. Makine öğrenme teknikleri

4.5.1. Danışmanlı Öğrenme

Danışmanlı öğrenme bir insanın bir şeyleri öğrenme sürecine çok benzerdir. Öğrenme süreci etiketli veriler üzerinden gerçekleştirilmektedir. Danışmanlı öğrenmede, her bir eğitim veri seti girdi ve doğru çıktı çiftlerinden oluşmalıdır. Doğru çıktı, modelin verilen girdi için üretmesi gereken şeydir. Danışmanlı öğrenmede öğrenme, bir modelin aynı girdi için doğru çıktı ile modelin çıktısı arasındaki farkı azaltmak için yapılan bir revizyon dizisidir. Bir model mükemmel şekilde eğitilirse, eğitim verisinden gelen girdiye karşılık gelen doğru bir çıktı üretmektedir.

4.5.2. Danışmansız Öğrenme

Denetimsiz öğrenmede veri etiketleri mevcut olmayan girdi verilerini içermektedir. Doğru çıktıları bilinmemektedir. Denetimsiz öğrenme genellikle verilerin özelliklerini araştırmak ve veriyi ön işleme koymak için kullanılmaktadır. Bu öğrenme yöntemiyle, sınıfları bilinmeyen girdi verilerinin gruplandırılması veya kümelenmesi yapılmaktadır.

4.5.3. Pekiştirmeli Öğrenme

Pekiştirmeli öğrenme ön bilgi yerine gözlem ve seçim üzerine kurulu bir öğrenme şeklidir. Neden sonuç ilişkisinin nasıl kurulduğu bilgisi, yapay zekaya verilmez. Ancak çok az verildiği durumlara da rastlanılmaktadır. Sistemin amacı yapay zekayı bir sonuca koşullandırmaktır. Bu sonuç her zaman en yüksek ödül değerindedir. Bu ödülün daha az, daha farklı bir ödül olması ya da hiçbir ödülün olmaması durumu yapay zeka için bir ceza olarak görülmektedir. Dolayısıyla yapay zeka motivasyonun her zaman tek yönde işlediği söylenebilmektedir.

4.6. Yapay Sinir Ağları

Yapay sinir ağları, yapay zekâ tekniklerinden birisi olup; insan beyninin bilgiye ulaşma, bilgiyi üretme veya türetme gibi yeteneklerini yardım almaksızın gerçekleştirilmesini amaçlayan bilgisayar sistemleridir. Bu sistemler programlanırken geleneksel yöntemler genellikle yeterli olmamaktadır.

Esas olarak yapay sinir ağları; insan ve hayvandaki biyolojik sinir ağından esinlenilmiş bir taklittir. Örneğin biyolojik sinir ağında nöronlar, tek başına depolama görevini yapamazlar. Bu yüzden sinyalleri birinden diğerine ileterek beyne ulaştırırlar. Yani bilgisayarın depolama işlemi için kullandığı bellek, biyolojik sistemdeki beyni taklit etmektedir. Amaçlar aynıdır fakat kullanılan mekanizma farklılık göstermektedir.

Kısaca; YSA programlanması zor olan olaylar için geliştirilmiş, veri işleme ile ilgilenen bilgisayar kaynaklı bir bilim dalı olduğu kabul edilmektedir (18).

4.6.1. Yapay Sinir Ağlarının Genel Özellikleri

YSA'nın özellikleri kullanılan algoritmalar ve modellere göre farklılık göstermektedir. Genel olarak aşağıdaki gibi sıralanabilmektedir.

Uyarlanabilirlik (Adaptasyon)

Yapay sinir ağında bilgi, ağın bağlantılarındaki ağırlıklarda saklanmaktadır. Ağırlıkların daima en iyi, en verimli değeri hesaplanmaktadır. Bu değer her durum için sabit bir değer değildir. Yapay sinir ağı oluşabilecek ters durumlara karşı kendisini yeniden yapılandırabilme özelliğine sahiptir.

Paralellik (Doğrusal Olmama)

Yapay sinir ağlarında işlemler doğrusal değildir. Bunun yerine paralellik söz konusudur. Tıpkı devrede paralel bağlı bir direncin akımının kesilmesinin, diğer dirençlere akım gitmesine engel olmaması gibi yapay sinir ağlarında da bazı bağlantıların ya da hücrelerin zarar görmesi veya etkisiz hale gelmesi doğru bilgi üretimine çok fazla etki etmemektedir.

Hata Toleransı

Yapay sinir ağlarında bilgi, ağın bütününe yayılmış durumdadır. Yani dağınık bir bellek vardır. Bilgi sadece bir kısımda değil ağın tamamında depo edilmektedir. Bu da

oluşabilecek bir hatanın bütün ağı etkilemesinin önüne geçmektedir. Hataya gösterilen tolerans, geleneksel metotlara göre çok daha fazladır.

Dereceli Bozukluk

Yapay sinir ağları hatalara karşı toleranslı oldukları için sistemin bozulması da dereceli olmaktadır (19). Hata olması durumunda klasik sistemlerde olduğu gibi tamamen çalışamaz duruma geçmemekte, sağlam olan birimler işleme devam etmektedir.

Öğrenme- Örneklem- Genelleme

Yapay sinir ağları makine öğrenmesi gerçekleştirmektedir (20). Bu öğrenme işini gerçekleştirmek için örneklerden yararlanmaktadır. Kendisine öğretilen örneklerden kullanarak, olay hakkında genelleme yapabilecek yeteneğe sahip olmaktadır (Diğer bir adı adaptif öğrenme).

Örnekler gerçekleşmiş olaylardır. Yapay sinir ağları (YSA), daha önce gerçekleşmiş bir olaydan öğrendikleri ve kendisine verilen yeni olay arasındaki benzerlikleri araştırıp, doğru bilgiye ulaşmayı hedeflemektedir. Bilgiye ulaştıktan sonra YSA, bu sefer de genelleme yoluyla birbirine benzettiği örneklerin veya olayların farklılıklarından yola çıkarak yeni bilgiler üretebilmektedir. Yine şekilleri birbirleriyle ilişkilendirip, sınıflandırıp sonrasında karşılırlarına çıkabilecek eksik şekilleri de tamamlayabilmektedirler.

Nümerik Bilgi ile Çalışma

Yapay sinir ağlarının çalışabilmeleri için bilgilerin nümerik yani sayısal olmaları gerekmektedir. Nümerik olmayan bilgiler önce nümerik ifadelere dönüştürüldükten sonra ağı tanıtılmaktadır (19).

Gerçek Zamanlı Çalışma (Donanım ve Hız)

Yapay sinir ağları, paralel bir çalışma düzenine sahiptir. Bu, aynı anda birçok işlem yapabilmelerini sağlamaktadır. Gerçek zamanlı çalışrlar ve birim zamanda çok daha fazla veriyi işleyebilmektedirler (19).

4.6.2. Yapay Sinir Ağlarının Kullanım Alanları

Yapay Sinir Ağları, insan beyninden ilham alan hesaplmalı modellerdir. Yapay Sinir Ağları sürekli öğrenerek bilgi edinmektedirler. İnsanlarda olduğu gibi, edinilen bilgiler YSA içerisinde tasarlanan yapay nöronlarda depolanmakta ve gerekli görevi yerine getirmek için kullanılmaktadır.

YSA literatürde tarandığında, yapay sinir ağları ile farklı alanlarda binlerce uygulamanın yapıldığı ve başarılı sonuçlar alındığı söylenebilmektedir. Yapay sinir ağı uygulamaları, ev aletlerinden cep telefonlarına kadar birçok alanda bulunabilir. YSA uygulamalarının bazıları aşağıda verilmiştir.


- *Tıp Alanında:* Yapay sinir ağları, tıbbi sinyallerin analizi, kanser hücrelerinin tespiti, protez tasarımı, nakil zamanlarının optimizasyonu, hastane masrafları, medikal görüntülerin sınıflandırılması ve segmentasyonu gibi alanlarda uygulanmaktadır.
- *Savunma Sanayi:* Silahların optimizasyonu ve hedef izleme, roket teknolojisinde yöringe takibi ve optimizasyonu, nesneleri veya görüntüleri ayırma ve tespit edilmesi, sensor sonar sistemleri gibi alanlarda sıklıkla kullanılmaktadır.
- *Haberleşme:* Görüntü ve data sıkıştırma, otomatik bilgi işleme hizmetleri, filtreleme, eko ve gürültü baskılanması, konuşmanın gerçek zamanlı çevirisinin yapılması, trafik yoğunluğunun kontrolü gibi konularda uygulanmaktadır.
- *Üretim:* Üretim sistemlerinin optimizasyonu, ürün analizi ve dizaynı, kalite analizi ve ürünlerin kontrolü, planlama ve yönetim analizi, makine bozulmalarının tespiti gibi alanlarda kullanılmaktadır.
- *Otomasyon ve Kontrol:* Uçaklarda otomatik pilot sistemi, ulaşım araçlarında sinyalizasyon ve otomatik yol gösterme veya bulma, non-lineer modelleme ve kontrolü gibi alanlarda yaygın bir şekilde kullanılmaktadır.
- *İstatistik:* Regresyon ve kümeleme analizleri gibi konularda yaygın olarak kullanılmaktadır.
- *Finans:* Kredi uygulamaları geliştirilmesi, müşteri analizi, kredi değerlendirilmesi, borsa endeks tahmini, enflasyon tahmini gibi birçok finansal alanda uygulanmaktadır.

Uygulama alanlarından anlaşılacağı üzere yapay sinir ağı tekniği gerçek hayatta karşılaşılan problemlerde de geniş bir uygulama alanı kazanmıştır. Günlük yaşamda birçok sahada başarılı bir şekilde kullanılmaktadır. Uygulama alanları gün geçtikçe genişlemekte ve gelişmektedir.

4.6.3. Yapay Sinir Ağlarının Yapısı ve Temel Elemanları

4.6.3.1. Biyolojik sinir hücresi

Yapay sinir ağı biyolojik sinir sisteminden esinlenerek geliştirilmiştir. Ne zaman bir şeyler öğrenirsek, beynimiz bu bilgiyi depolamaktadır. Bilgisayar ise bilgi depolamak için bellek kullanmaktadır. Her ikisi de bilgi depolamasına rağmen, mekanizmaları çok farklıdır. Beynin nöronların birleşimini değiştirirken, bilgisayar bilgi hafızasında belirtilen yerlere depolama işlemini gerçekleştirmektedir. Nöronun kendisinde depolama kapasitesi yoktur; sinyalleri bir nörondan diğerine iletir. Beyin, bu nöronların devasa bir ağını oluşturmakta ve nöronların birleşmesi özel bilgileri meydana getirmektedir. Nöronlar; dendritler, çekirdek, hücre gövdesi, akson ve sinapslardan oluşmaktadır. Şekil 11’de biyolojik sinir hücresi yer almaktadır.




Şekil 11. Biyolojik sinir hücresi (Karpathy'den, 21)

Nöronlar, sinir sistemi içindeki bilgileri diğer sinir hücrelerine, kas veya salgı hücrelerine ileten hücrelerdir. Çoğu nöronun bir hücre gövdesi, bir akson ve dendritleri vardır. Hücre gövdesi çekirdeği ve sitoplazmayı içermektedir. Akson hücre gövdesinden uzanmakta ve sıklıkla sinir terminallerinde bitmeden önce birçok küçük dallara ayrılmaktadır. Dendritler, nöron hücre gövdesinden uzanmakta ve diğer nöronlardan mesaj almaktadır. Sinapslar, bir nöronun diğeriyle iletişim kurduğu temas noktalarını

oluşturmaktadır. Dendritler, diğer nöronlardan aksonların uçları tarafından oluşturulan sinapslarla kaplı durumda bulunmaktadır (22).

4.6.3.2. Yapay Sinir Hücreleri

Yapay sinir ağıları biyolojik sinir sisteminden esinlenerek oluşturulmuş ağlardır. Tıpkı biyolojik sistemin sinir hücreleri gibi, yapay sinir ağlarının da kendi yapay sinir hücreleri bulunmaktadır. Biyolojik sistem hücrelerinde olduğu gibi yapay sinir hücreleri de elemanlara sahiptir. Beş temel elemanı vardır. Bunlar: girdiler, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve hücrenin çıktısıdır. Şekil 12’de bir yapay sinir hücresinin yapısı gösterilmektedir.



Şekil 12. Yapay sinir hücresinin yapısı

Girdi Değerleri: Girdiler hücreye gelen bilgilerdir. Bu bilgiler dış dünyadan, başka bir hücreden ve dahi hücrenin kendisinden gelebilmektedir. Girdiler giriş konumundadırlar. Görevleri bilgiyi iletmekle sınırlıdır, matematiksel işlem yapamazlar. Gelen bilgiler ağırlık öğrenmesi istenen örnekler tarafından belirlenmektedirler (23). Yapay sinir ağlarının algılayıcıları olarak nitelendirilebilirler (24).

Ağırlıklar: Ağırlıklar bir yapay hücreye gelen bilginin önemini ve hücre üzerindeki etkisini göstermektedirler (18). Her girdinin ağırlık değeri aynı olmak zorunda değildir. Ağırlık değerleri matematiksel anlamda artı değerler veya eksi değerler alabilmekle beraber sabit de kalabilmektedir. Bir girdinin pozitif ya da negatif değere sahip olması, bilginin hücre için de aynı oranda önemli olması anlamına gelmemektedir (Pozitifse

önemlidir veya negatifse değildir gibi). Bilginin ağırlık değeri sıfırken, bunun yapay sinir hücresi için önemi çok yüksek olabilmektedir.

Eşik Değeri: Eğitilecek ağırlık ezberlemesini önlemek için kullanılan değerdir (25).

Toplama Fonksiyonu: Hücreye giren net girdiyi hesaplamak için toplama fonksiyonu kullanılabilir. Her hücre için farklı toplama fonksiyonu uygulanabilmekle beraber en yaygın kullanılan fonksiyon formülünde her girdi değeri kendi ağırlığıyla çarpılmakta ve tüm girdiler için bulunan değerler toplanmaktadır (19).

$$NET = \sum_i^n G_i A_i$$

G: Girdileri; A: Ağırlıkları; n: Hücreye gelen toplam girdi sayısını göstermektedir. Tablo 2’de toplama fonksiyonu türleri gösterilmiştir.





Tablo 2. Toplama fonksiyonun türleri (Sarı’dan, 19)

Net Giriş	Açıklama
<i>Çarpım</i> $Net\ Girdi = \prod_i G_i A_i$	Ağırlık değerleri ile girdi değerlerinin birbirleriyle çarpılması elde edilir.
<i>Maksimum</i> $Net\ Girdi = \max(G_i A_i), i = 1 \dots N$	Ağırlıklar ile girdiler çarpılır, en büyük olan değer sistemin net girdisi olur.
<i>Minimum</i> $Net\ Girdi = \min(G_i A_i), i = 1 \dots N$	Ağırlıklar ile girdiler çarpılır, en küçük olan değer sistemin net girdisi olur.
<i>Çoğunluk</i> $Net\ Girdi = \sum_i \text{sgn}(G_i A_i)$	Ağırlıklarla çarpılan girdilerin işaret fonksiyonu alınarak değerlerin toplamı sisteme net girdi olarak sokulur.
<i>Kümülatif Toplam</i> $NET\ Girdi = Net(eski) + \sum_i^n (G_i A_i)$	Hücreye gelen bilgiler ağırlıklı olarak toplanır ve daha önce gelen bilgilere eklenerek hücrenin net girdisi hesaplanır.

Aktivasyon Fonksiyonu: Aktivasyon fonksiyonu, toplama fonksiyonunun ulaştığı net girdi bilgisini işleyerek hücrenin üreteceği çıktıyı belirlemektedir. Tıpkı toplama fonksiyonu gibi her hücre için farklı bir aktivasyon formülü kullanılabilir.

Problem için uygulanacak en uygun formülü tasarımcı belirlemektedir. Literatürde en sık karşılaşılan aktivasyon fonksiyonları Tablo 3'te gösterilmiştir.


Tablo 3. Aktivasyon Fonksiyonu Türleri (Çayıroğlu'dan, 26)

Doğrusal (Lineer) Aktivasyon Fonksiyonu		$F(Net) = A * Net$ (A sabit bir sayı)	Doğrusal problemler çözmek amacıyla aktivasyon fonksiyonu doğrusal bir fonksiyon olarak seçilebilir. Toplama fonksiyonundan çıkan sonuç, belli bir katsayı ile çarpılarak hücrenin çıktısı olarak hesaplanır.
Adım (Step) Aktivasyon Fonksiyonu		$F(Net) = \begin{cases} 1 & \text{if } Net > \text{Eşik Değer} \\ 0 & \text{if } Net \leq \text{Eşik Değer} \end{cases}$	Gelen Net girdinin belirlenen bir eşik değerin altında veya üstünde olmasına göre hücrenin çıktısı 1 veya 0 değerini alır.
Sigmoid Aktivasyon Fonksiyonu		$F(Net) = \frac{1}{1 + e^{-Net}}$	Sigmoid aktivasyon fonksiyonu sürekli ve türevi alınabilir bir fonksiyondur. Doğrusal olmayışı dolayısıyla yapay sinir ağı uygulamalarında en sık kullanılan fonksiyondur. Bu fonksiyon girdi değerlerinin her biri için 0 ile 1 arasında bir değer üretir.
Tanjant Hiperbolik Aktivasyon Fonksiyonu		$F(Net) = \frac{e^{Net} + e^{-Net}}{e^{Net} - e^{-Net}}$	Tanjant hiperbolik fonksiyonu, sigmoid fonksiyonuna benzer bir fonksiyondur. Sigmoid fonksiyonunda çıkış değerleri 0 ile 1 arasında değişirken hiperbolik tanjant fonksiyonunun çıkış değerleri -1 ile 1 arasında değişmektedir.
Eşik Değer Fonksiyonu		$F(Net) = \begin{cases} 0 & \text{if } Net \leq 0 \\ Net & \text{if } 0 < Net < 1 \\ 1 & \text{if } Net \geq 1 \end{cases}$	Gelen bilgilerin 0 dan küçük-eşit olduğunda 0 çıktısı, 1 den büyük-eşit olduğunda 1 çıktısı, 0 ile 1 arasında olduğunda ise yine kendisini veren çıktılar üretilebilir.
Sinüs Aktivasyon Fonksiyonu		$F(Net) = \sin(Net)$	Öğrenilmesi düşünülen olayların sinüs fonksiyonuna uygun dağılım gösterdiği durumlarda kullanılır.

Çıktı: Aktivasyon fonksiyon tarafından belirlenen değerlerdir. Girdiler birden fazla olsa dahi, hücrenin yalnız bir tane çıktısı olabilmektedir. Hücrenin ürettiği çıktılar daha sonrasında dış ortama bırakılmaktadır. Diğer hücreler veya çıktıyı üreten hücrenin kendisi de, bu çıktı bilgilerini, girdi olarak tekrar hücre içine alabilmektedir.

4.6.4. Yapay Sinir Ağlarının Sınıflandırılması

Beyin, çok sayıdaki nöronların bir ağı olduğundan, sinir ağı beyin nöronlarına karşılık gelen elemanlar olan düğümlerin bağlantılarıyla oluşturulmuştur. Şekil 13'te gösterildiği gibi katmanlı bir yapıya sahiptir.




Şekil 13. Yapay sinir ağları katmanları

Yapay bir sinir ağının üç ana katmanı vardır:

Giriş Katmanı: Dış dünyadan gelen bilgilerin alındığı ve gizli katmanlara iletildiği katmandır. Ağlar genellikle birden fazla giriş katmanına sahip olabilmektedir.

Gizli Katman(lar): Giriş katmanından alınan bilgilerin çeşitli işlemlere sokulduğu ve çıkış katmanına iletildiği katmandır. Ağın yapısına bağlı olarak, birden çok gizli katman olabilmektedir.

Çıktı Katmanı: Gizli katmanlardan alınan bilgileri dış ortama sunan katmandır. Çıktı katmanı beyindeki diğer sinir ağlarının da girdileri olan çıktı sinyallerini üretmektedir. Düğümlerin nasıl bağlandığına bağlı olarak çeşitli sinir ağları oluşturulabilir. Bu sinir ağlarından en yaygın kullanılanları aşağıda şekil 14'te gösterilmiştir.




Şekil 14. Yapay sinir ağı mimarileri (Kim'den, 27)

Şekil 14'te görüldüğü üzere, ağlar tek katmanlı ve çok katmanlı olmak üzere (derin sinir ağı çok katmanlı bir yapıya sahiptir) birbirinden ayrılmaktadır.

Katmanlı yapının özellikleri aşağıdaki gibi özetlenebilmektedir:

- Katman içinde bağlantı yoktur.
- Giriş ve çıkış katmanları arasında doğrudan bağlantı yoktur.
- Katmanlar arasında tamamen bağlanmıştır.
- Genellikle 3 kattan fazladır.
- Çıkış birimlerinin sayısı eşit sayıda giriş birimine ihtiyaç duymaz.
- Katman başına gizli birim sayısı giriş veya çıkış birimlerinden daha fazla veya daha az olabilir.

Yapay sinir ağları, sinirler veya düğümler adı verilen işlem elemanlarının bir kombinasyonundan oluşmaktadır. Yapay sinir ağı modelleri, sinirler arasındaki bağıntıların yönüne veya ağdaki akış yönüne göre ayrılabilir. Bu modellerden en yaygın kullanılanlar Şekil 15'te gösterilmiştir.




Şekil 15. Yapay sinir ağı modelleri (Ballı'dan, 24)

Bu ağlar yapılarına göre ileri beslemeli ve geri beslemeli olarak sınıflandırılabilir.

4.6.4.1. İleri Beslemeli Yapay Sinir Ağları


İleri beslemeli yapay sinir ağı, basit tasarımlı bir ağ türüdür. İleri beslemeli ağlarda, bilgi giriş ve çıkış arasındaki gizli düğümler yardımıyla yalnızca tek bir yönde (ileri) hareket etmektedir. Ağ üzerinde herhangi bir döngünün varlığından söz edilememektedir. Şekil 16'da ileri beslemeli yapay sinir ağının örneği gösterilmiştir.



Şekil 16. İleri beslemeli yapay sinir ağı örneği

4.6.4.2. Geri Beslemeli Yapay Sinir Ağları

Geri beslemeli ağlarda yapay sinir hücresinin ürettiği çıktı bilgisi, hücrenin kendisine veya diğer hücrelere tekrar girdi olarak girebilmektedir. Bu işlem için gizli katmanlar kullanılmaktadır. İleri beslemeli ağlardan farklı olarak döngüsel bir düzen vardır. Bilgi tek taraflı hareket etmemektedir. Bu sayede ağ daha etkin ve öğrenme kabiliyeti daha yüksek bir hale gelmektedir.



Şekil 17. Geri beslemeli yapay sinir ağı örneği (Öztemel'den, 18)


4.7. Derin Öğrenme

4.7.1. Derin öğrenime giriş

İnsan zihni öğrenme, problemi tespit etme ve çözüm üretme gibi bilişsel yetilere sahiptir. Yapay zekâ insanın bu işlevlerini makineyi kullanarak taklit etmeyi esas alan bir alandır. Makine öğrenme metotlarıyla insan, insan olmanın getirdiği yanılgıları en aza indirmek ve mükemmel doğruya ulaşmayı hedefleyen bir araç üretmek istemiş bunun için de yapay zekâ çözümünü bulmuştur. Özellikle bir amaç için programlanmadan öngörülerde bulunup, karar verme veya çözüm bulma gibi eylemleri uygulayabilmek, aynı zamanda kendine verilen görevi yerine getirmek için matematiksel veriler üretmek üzere makine öğrenimine yönelmiştir. Bu verilere "eğitim verileri" denir. Amaçları doğrultusunda insan yapay zekâ üretme yoluna bir alt kümesi olan makine öğreniminden başlamıştır.

Yine bu yolda göreve özgü programlamama olmadan, algoritmaların öğrenme verilerini temsil etmeye çalıştığı makine öğrenmesine ise derin öğrenme denir. Derin

öğrenme, hiyerarşik öğrenme veya derin yapılandırılmış öğrenme şeklinde de adlandırılabilir.



Şekil 18. Yapay zeka ile derin öğrenme arasındaki ilişki

Derin Öğrenme, derin sinir ağını kullanan bir Makine Öğrenme tekniğidir. Bildiğiniz gibi, derin sinir ağı iki veya daha fazla gizli katman içeren çok katmanlı sinir ağıdır.

Derin sinir ağları (DNN) ve tekrarlayan sinir ağları sayesinde oluşturan yapay zekalar; görüntü işleme, konuşma tanımlama, sosyal ağ filtreleme, tıbbi görüntü analizleri, ilaç tasarımları, masa oyunları gibi alanlarda insan uzmanlara yakın hatta bazı durumlarda daha iyi sonuçlar üretmeyi başarmıştır (28, 29).

4.7.2. Derin öğrenmenin tarihi

Derin Öğrenme terimi, Rina Dechter tarafından 1986'da makine öğrenme topluluğuna tanıtılmış ve 2000 yılında Igor Aizenberg ve meslektaşları tarafından yapay sinir ağlarıyla buluşturulmuştur. 1965 yılında Alexey Ivakhnenko ve Lapa tarafından denetimli derin beslemeli çok katmanlı algılayıcılar için ilk genel, çalışma öğrenme algoritması yayınlanmıştır (30). Diğer derin öğrenme çalışma mimarileri, özellikle bilgisayar vizyonu için inşa edilenler, 1980 yılında Kunihiro Fukushima tarafından tanıtılan Neocognitron ile başlamıştır (31).

1989'da Yann LeCun ve ark. 1970'den beri otomatik farklılaşmanın ters modu olan standart posta yayma algoritmasını, postadaki el yazısı ZIP kodlarını tanımak amacıyla derin bir sinir ağına uygulamıştır (32-35).

1991 yılına kadar, bu tür sistemler izole edilmiş 2 boyutlu elle yazılmış basamakları tanımak için kullanılırken, 3 boyutlu nesneleri tanımak, 2 boyutlu görüntüleri el yapımı 3 boyutlu nesne modeliyle eşleştirmek suretiyle yapılmıştır. Weng ve diğerleri bir insan beyninin monolitik bir 3B nesne modeli kullanmadığını öner sürerek 1992 yılında, dağınık haldeki sahnelerde 3 boyutlu nesne tanımlamayı gerçekleştirecek olan Cresception'ı yayınlamışlardır. Doğrudan doğal görüntüleri kullandığından, Cresceptron doğal 3D dünyalar için genel amaçlı görsel öğrenmenin başlangıcına vesile olmuştur. Cresceptron, Neocognitron'a benzer katmanlar dizisidir. Fakat Neocognitron, özellikleri birleştirmek için bir insan programcısına ihtiyaç duysa da, Cresceptron, her bir özelliğin, bir konvüsyon çekirdeği tarafından temsil edildiği, her katmanda, denetimsiz bir şekilde çok sayıda özellik öğrenmiştir. Cresceptron, öğrenilen her nesneyi dağınık haldeki bir sahneden ağ üzerinden geriye doğru analiz yoluyla bölümlendirmiştir. Günümüzde genellikle derin sinir ağları tarafından benimsenen Max Pooling ilk kez Cresceptron'da pozisyon çözünürlüğünü daha iyi genellemek için kademeli olarak (2x2)'ye 1 kadarlık bir faktörle azaltmak için kullanılmıştır (36-38).

1994 yılında, André de Carvalho, Mike Fairhurst ve David Bisset ile birlikte, 3 katmanlı bir kendi kendini düzenleyen özellikli sinir ağı modülünden oluşan, ağırlıksız bir sinir ağı olarak da bilinen çok katmanlı bir boolean sinir ağının (SOFT) deneysel sonuçlarını yayınlamıştır ve ardından bağımsız olarak eğitilmiş çok katmanlı bir sınıflandırma sinir ağı modülü (GSN) takip etmiştir. Özellik çıkarma modülündeki her katman, önceki katmana göre artan bir karmaşıklıkta özellikler çıkarmıştır (39).

1995 yılında Brendan Frey, Peter Dayan ve Hinton ile birlikte geliştirilen uyandırma-uyku algoritmasını kullanarak, tamamen birbirine bağlı altı katman ve birkaç yüz gizli ünite içeren bir ağ kurmanın (iki günden fazla) mümkün olduğunu göstermiştir (40).

Hesaplama maliyeti ve beynin biyolojik ağlarını nasıl bağladığının anlaşılması sebebiyle, Gabor filtreleri ve destek vektör makineleri gibi göreve özel el

yapımı özellikler kullanan daha basit modeller 1990'lar 2000'lerin popüler seçimleri olmuştur. Çoğu konuşma tanıma araştırmacısı, sinirsel ağlardan uzaklaşarak, üretken modellemeyi sürdürmüştür. Bir istisna 1990'ların sonlarında SRI International'dadır. ABD hükümetinin NSA ve DARPA tarafından finanse edilen SRI, konuşma ve konuşmacı tanıma konusunda derin sinir ağları üzerinde çalışır. Heck'in konuşmacı tanıma ekibi, 1998 Ulusal Standartlar Enstitüsü ve Teknoloji Konuşmacı Tanıma değerlendirmesinde konuşma işleminde derin sinir ağları ile ilk önemli başarıya imza atmıştır. SRI, konuşmacı tanımada derin sinir ağları ile başarı yaşamasına rağmen, konuşma tanımada benzer bir başarı göstermemiştir (41). Konuşma tanımının birçok yönü, Hochreiter ve Schmidhuber tarafından 1997'de yayınlanan tekrarlayan bir sinir ağı olan uzun kısa süreli bellek, LSTM adı verilen derin bir öğrenme yöntemi ile ele alınmıştır. LSTM tekrarlanan sinir ağları, kaybolan gradyan probleminden kaçınır ve konuşma için önemli olan binlerce ayrı zaman aşaması olan olayların anılarını gerektiren "Çok Derin Öğrenme" görevlerini öğrenebilmiştir.

2003 yılında, LSTM, belirli görevlerde geleneksel konuşma tanıyıcılarla rekabet etmeye başlamıştır (42).

Donanımdaki gelişmeler, ilginin yenilenmesini sağlamıştır. 2009'da Nvidia, derin öğrenimin sinir ağları Nvidia grafik işlem birimleriyle (GPU'lar) eğitilmiştir. Özellikle, GPU'lar makine öğrenmesine katılan matris/vektör matematiği için çok uygundur (1, 43). GPU'lar, çalışma algoritmalarını, büyüklük sırasına göre hızlandırarak haftalardan günlere kadar çalışma sürelerini azaltmaktadır. Verimli işlem için özel donanım ve algoritma optimizasyonları kullanılabilmektedir (27, 44).


2012 yılında, Dahl liderliğindeki bir ekip, bir ilacın biyomoleküler hedefini tahmin etmek için çok görevli derin sinir ağlarını kullanarak "Merck Moleküler Aktivite Mücadelesi" ni kazanmıştır (45).

2014 yılında, Hochreiter grubu çevre kimyasallarının besinlerde, ev ürünlerinde ve ilaçlarda hedef dışı ve toksik etkilerini tespit etmek için derin öğrenme kullanmış ve NIH, FDA ve NCATS'ın "Tox21 Veri Mücadelesi" ni kazanmıştır.

Görüntü veya nesne tanımadaki önemli ek etkiler 2011'den 2012'ye kadar hissedilmiştir. Birçok farklı kategorideki yarışma derin öğrenme ile kazanılmıştır.

4.7.3. Derin Sinir Ağı (Deep Neural Network)

Derin sinir ağı (DNN), giriş ve çıkış katmanları arasında çoklu katmanlara sahip yapay bir sinir ağıdır (ANN) (46). Derin sinir ağı, girdiyi çıktıya dönüştürmek için doğru matematiksel etkileşimin doğrusal mı yoksa doğrusal olmayan bir ilişki mi olduğunu bulur. Ağ, her çıktının olasılığını hesaplayan katmanlar arasında hareket eder.



Şekil 19. Derin sinir ağı (Kim'den, 27)

4.7.4. Derin Öğrenme

Derin öğrenme, özellikleri ve görevleri doğrudan veriden öğrenen bir makine öğrenme tekniğidir. Ardışık her katman, önceki katmandaki çıktıyı girdi olarak kullanır (47). Denetlenen (ör. sınıflandırma) ve/veya denetlenmeyen (ör. kalıp analizi) davranışları öğrenir. Farklı soyutlama seviyelerine karşılık gelen çoklu temsil seviyelerini öğrenir ve seviyeler bir kavram hiyerarşisi oluşturur (48).

Derin öğrenmede, her seviye girdi verilerini biraz daha soyut ve bileşik bir gösterime dönüştürmeyi öğrenir. Bir görüntü tanıma uygulamasında, ham girdi bir piksel matrisi olabilir; birinci temsil katmanı pikselleri soyutlayabilir ve kenarları kodlayabilir; ikinci katman kenar düzenlemelerini oluşturabilir ve kodlayabilir; üçüncü katman bir burnu ve gözleri kodlayabilir; dördüncü katman, görüntünün bir yüz

içerdiğini kabul edebilir. Daha da önemlisi, derinlemesine bir öğrenme süreci hangi özellikleri hangi seviyeye kendi başına getirebileceğini öğrenebilir (49).

Sinir ağının ilk nesli olan tek katmanlı sinir ağı, makine öğreniminin karşılaştığı uygulamalı sorunları çözerken, temel kısıtlamaların ortaya çıkarması çok uzun sürmemiştir. Ancak, tek katmanlı sinir ağına başka bir katman eklenmesi yaklaşık 30 yıl sürmüştür. Bunun nedeni, çok katmanlı sinir ağı için uygun bir öğrenme kuralının (geri yayılma algoritması) bulunamamasıdır.

Daha derin katmanlara sahip olan sinir ağının düşük performans vermesinin nedeni, ağına uygun şekilde eğitilmemesiydi. Geri yayılım algoritması, derin sinir ağının eğitim sürecinde şu üç ana güçlüklerle karşılaşır:

- Vanishing gradient (kaybolma gradyanı)
- Overfitting (Aşırı uygunluk, Ezberleme)
- Computational load (Hesaplama yükü)

4.7.4.1. Vanishing Gradient (kaybolma gradyanı)

Bu gradyan, geri yayılım algoritmasının deltasına benzer bir kavram olarak düşünülebilir. Kaybolma gradyanı, geri-yayılım algoritması ile öğrenme sürecinde, çıkış hatası uzaktaki düğümlere erişmenin başarısız olması olasılığı yüksek olduğunda ortaya çıkar. Geri yayılma algoritması, sinir ağını, çıktı hatasını geriye doğru gizli katmanlara yayarak eğitir. Ancak hatalar ilk katmana kadar nadiren geri geldiğinden, girdi katmanına yakın gizli katmanlar tam anlamıyla eğitilmiş olamazlar.

Kaybolma gradyanına temsili çözüm, Rectified Linear Unit (ReLU) fonksiyonunu aktivasyon işlevi olarak kullanılmasıdır. Hatayı sigmoid fonksiyonundan daha iyi ilettiği bilinmektedir. ReLU işlevi aşağıdaki gibi tanımlanır:


$$\varphi(x) = \begin{cases} x, & x > 0 \\ 0, & x \leq 0 \end{cases}$$
$$= \max(0, x)$$

Negatif girdiler için sıfır üretir ve pozitif girdiler için girdiyi iletir.

4.7.4.2. Overfitting (Aşırı Uygunluk)

Makine Öğrenmesinin başarısı, genelleme sürecinin ne kadar iyi uygulandığına büyük ölçüde bağlıdır. Eğitim verileri ile gerçek giriş verileri arasındaki farklılıklardan dolayı performans düşüşünü önlemek için, yeterli miktarda tarafsız eğitim verisine ihtiyacımız var.

Veri noktalarına bir göz attığımızda bazı aykırı veriler diğer grubun alanına girer ve sınırı bozar. Başka bir deyişle, bu veri çok gürültü içerir. Makine öğrenmesinin bu sorunu ayırt etmesinin bir yolu yoktur. Makine Öğrenimi, tüm verileri, hatta gürültüyü de dikkate aldığından, uygunsuz bir model üretir (bu durumda bir eğri). Burada fark edebileceğiniz gibi, eğitim verileri mükemmel değildir ve çeşitli miktarda gürültü içerebilir. Eğitim verilerinin her ögesinin doğru olduğuna ve modelin tamına uyduğuna inanıyorsanız, genelleştirilebilirliği daha düşük bir model elde edersiniz. Buna aşırı uygunluk denir.




Şekil 20. Yeni giriş verilere yerleştirilir (Kim'den, 27)

Aşırı uyumsuzluk, Makine öğreniminin performans seviyesini önemli ölçüde etkiler. Derin sinir ağının özellikle fazladan overfitting'e (aşırı uygunluk) karşı savunmasız olmasının nedeni, modelin karmaşıklıkça daha fazla gizli katman ve dolayısıyla daha fazla ağırlık içermesindendir. Karmaşık bir model overfitting'e karşı daha dayanıksızdır. Daha yüksek performans için katmanları derinleştirilmesi, sinir ağını makine öğrenimi güçlükleriyle yüzleşmeye zorlar.

Aşırı uyumla mücadele için kullanılan iki tipik yöntem vardır. Bunlar normalleştirme ve doğrulamadır.

Normalleştirme: Normalleştirme, mümkün olduğunca basit bir model yapısı kurmaya çalışan sayısal bir yöntemdir. Basitleştirilmiş model, küçük performans maliyetinde aşırı uygunluğun etkilerini önleyebilir. Eğitim verilerinin basit olduğu ve modelin kolayca görselleştirilebileceği için gruplama modelinin çok iyi olduğunu söyleyebiliriz. Ancak, veriler daha yüksek boyutlara sahip olduğundan, çoğu durumda durum böyle değildir. Modeli çizemeyiz ve bu tür veriler için aşırı uygunluk etkilerini sezgisel olarak değerlendiremeyiz. Bu nedenle, eğitilmiş modelin fazla takılıp takılmadığını belirlemek için doğrulama yöntemine ihtiyaç duyarız.


Doğrulama: Doğrulama, eğitim verilerinin bir bölümünü ayıran ve performansı izlemek için kullandığı bir işlemdir. Eğitim süreci için doğrulama kümesi kullanılmaz. Eğitim verisinin modelleme hatası gereğinden fazla olduğunu göstermediğinden, modelin gereğinden fazla olup olmadığını kontrol etmek için bazı eğitim verilerini kullanırız. Eğitilmiş model, ayrılmış veri girişine düşük bir performans düzeyi verdiğinde modelin aşırı olduğunu söyleyebiliriz. Bu durumda, aşırı uyumsuzluğu önlemek için modeli değiştiririz. Şekil 21 doğrulama işlemi için eğitim verilerinin bölünmesini göstermektedir.



Şekil 21. Doğrulama süreci için eğitim verilerinin bölünmesi (Kim'den, 27)

Eğitim verilerini (training data) iki gruba ayırırız. Bir grup eğitim için diğer grup doğrulama için kullanılır. Genellikle eğitim setinin (training set) doğrulama kümesine (validation set) oranı 8:2'dir. Model eğitim seti kullanılarak eğitilir. Doğrulama seti kullanarak modelin performansı değerlendirilir.

Farklı doğrulama işlemleri de vardır. Çapraz doğrulama, doğrulama işleminin ufak bir varyasyonudur. Eğitim verilerini eğitim ve doğrulama için gruplara ayırır, ancak veri kümelerini değiştirmeye devam eder. Başlangıçta bölünmüş kümeleri koruyarak yerine çapraz doğrulama, verilerin bölünmesini yineler. Çapraz doğrulama, doğrulama veri kümesinin rasgeleliğini korurken, modelin aşırı uygunluğunu daha iyi tespit edebilir. Şekil 22 çapraz doğrulama kavramını tanımlamaktadır. Koyu tonlar, eğitim süreci boyunca rasgele seçilen doğrulama verilerini gösterir.




4.7.4.3. Computational load (Hesaplama yükü)

Eğitimi tamamlamak için geçen süre hesaplama yüküdür. Ağırlıkların sayısı, gizli katmanların sayısı ile geometrik olarak artar, bu nedenle daha fazla eğitim verisi gerektirir. Bu sonuçta daha fazla hesaplama yapılması gerektirir. Yapay sinir ağı ne kadar çok hesaplama yaparsa, eğitim o kadar uzun sürer. Bu problem sinir ağının pratik gelişiminde ciddi bir sorundur. Derin bir sinir ağının eğitilmesi bir ay gibi bir zaman gerekiyorsa bu durumda faydalı bir araştırma çalışması pek mümkün olmayabilir. Bu sorun, GPU gibi yüksek performanslı donanımın ve toplu normalleştirme gibi algoritmaların geliştirilmesiyle büyük ölçüde giderilmiştir.

4.7.5. Konvolüsyonel Sinir Ağları (Convolution Neural Network- ConvNet-CNN)

Konvolüsyonel Sinir Ağları (CNN) çok katmanlı algılayıcıların (Multi Layer Perception-MLP) özel bir türüdür. Maymun görsel korteksindeki mikrobiyolojik sinyal işleme mekanizmasının modellenmesinden ilham almıştır. Beynin görsel korteksinin

görüntüleri nasıl işlediğini ve tanıdığını taklit eden derin bir ağıdır (35). CNN algoritmalarıyla nesne tanıma, sınıflandırma, takip etme, doğal dil işleme (Neuro Linguistic Programming-NLP), biyomedikal, tahmin problemleri gibi birçok farklı alanlarda uygulanmaktadır. Özellikle görüntü işleme alanında MNIST veri seti üzerinde çalışan Cişeran ve arkadaşlarının yaptığı çalışmada CNN ile hata oranını %2'lere kadar düşürmüşlerdir (45). 2012 yılından beri dramatik bir şekilde yeniden canlandırılan konvolüsyonel sinir ağı, GPU'ların gelişmesiyle birlikte yaygın olarak kullanılmaya başlanmıştır. Şekil 23'te konvolüsyon sinir ağının yapısının görseli verilmiştir.



Şekil 23. Konvolüsyonel sinir ağı mimarisi


4.7.5.1. Konvolüsyon (Evrişim) Katmanı:

Evrişim katmanı, özellik haritaları adı verilen yeni görüntüler oluşturur. Özellik haritası, orijinal görüntünün benzersiz özelliklerini vurgular. Evrişim katmanı, diğer sinir ağı katmanlarına kıyasla çok farklı bir şekilde çalışır. Bu katman bağlantı ağırlıkları ve ağırlıklı toplam kullanmaz. Bunun yerine, görüntüleri dönüştüren filtreler içerir. Bu filtreler evrişim filtreleri denir. Görüntünün evrişim filtreleri yoluyla girilmesi işlemi, özellik haritasını verir. Aşağıdaki formülde I giriş verisi (resim), K kernel olmak üzere konvolüsyon işlemi aşağıda gösterilmiştir.

$$S(i, j) = (I * K)(i, j) = \sum_m \sum_n I(m, n) K(i - m, j - n).$$

Şekil 24, daire içine alınmış $*$ işaretinin evrişim işlemi ifade ettiği ve ϕ işaretinin etkinleştirme işlevi olduğu, evrişim katmanı işlemini göstermektedir. Bu operatörler

arasındaki gri renkli kare simgeler, evrişim filtrelerini göstermektedir. Evrişim katmanı evrişim filtreleriyle aynı sayıda özellik haritası oluşturur. Bu nedenle, örneğin, evrişim katmanı dört filtre içeriyorsa, dört özellik haritası oluşturur.




Şekil 24. Konvolüsyon katmanı süreci (Kim'den, 27)

4.7.5.2. Pooling Layer (Havuzlama Katmanı)

Havuzlama katmanı, görüntünün belirli bir alanındaki birbirine komşu pikselleri tek bir temsilci değerde birleştirerek görüntünün boyutunu küçültülmesini sağlar. Bu teknik birçok görüntü işleme metodunda da yaygın kullanılan yöntemdir. Havuz katmanında yürütülecek işlemler için görüntüdeki havuz piksellerinin (pooling pixels) nasıl seçileceği ve temsilci değerinin (representative value) nasıl ayarlanacağı önceden belirlenmelidir. Komşu pikseller genellikle kare matristen seçilir ve birleştirilen piksellerin sayısı probleme göre farklılık göstermektedir. Temsilci değeri genellikle seçilen piksellerin ortalaması veya maksimumu olarak ayarlanır. Şekil 25' te 4x4'lük bir

giriş görüntüsünün ortalama havuzlama ve maksimum havuzlama sonrası 2x2'lik görüntüye küçülür.



Şekil 25. İki farklı yöntem kullanılarak yapılan havuzlama

Sonuç olarak matematiksel anlamda havuzlama işlemi bir tür evrişim (konvolüsyon) işlemidir. Evrişim katmanından farkı, evrişim filtresinin sabit olması ve evrişim bölgelerinin üst üste binmemesidir. Ek olarak, havuzlama işlemi görüntünün boyutunu düşürdüğü için, hesaplama yükünü hafifletmek ve aşırı uyumluluğu önlemek için oldukça faydalıdır.

4.7.5.3. Fully Connected Layer (Tam Bağlı Katman)

Konvolüsyon ve pooling katmanlarının ardından gelen katmandır. Bu katman konvolüsyon sinir ağlarının son ve en önemli katmanıdır. Tam bağlı katmanlardan önceki konvolüsyon katmanları, girdideki (input) kenarlar, lekeler, şekiller vb. gibi girdi hakkındaki ilgili bilgileri tutar. Her bir konvolüsyon katmanı yerel özelliklerden birini temsil eden birkaç filtre içerir. Tam bağlı katmanda tüm bu konvolüsyon katmanlarından gelen bileşik ve toplanmış bilgileri tutar. Önceki katmanlar tarafından ayıklanan özelliklere göre sınıflandırma yapar. Sonuç olarak tam bağlı katman, modelin tahmin etmeye çalıştığı sınıflandırma etiketlerinin her biri için bir olasılık (0-1 arasında bir sayı) veren bir aktivasyon fonksiyonu içeren geleneksel bir yapay sinir ağıdır.


4.7.5.4. Hiper-Parametreler

Makine öğrenme algoritmalarının birçoğu modelin parametrelerini optimize etmeden önce ayarlanması gereken birtakım değişkenleri (hiper-parametreleri) içerir. Hiper parametrelerin değerlerinin ayarlanması bir model seçim aşaması olarak görülebilir. Başka bir ifadeyle varsayımsal olarak olası modellerden hangi modelin kullanılacağı seçilir. Genellikle hiper-parametreler modeli tasarlayan kişi tarafından belirlenir, bazen de arama algoritmaları veya bazı hiper öğrenenler (hyper-learner) yardımıyla model seçimi ve optimizasyonu yapılır (49).

Yapay sinir ağlarında ağın yapısını ve ağın nasıl eğitileceğini belirleyen iki hiper-parametre grubu bulunmaktadır. Bunlar model hiper parametreler ve iyileştirici(optimizer) hiper parametrelerdir. Model hiper parametreler arasında en çok kullanılan aktivasyon fonksiyonları ve seyreltme katmanı (dropout layer) hiper parametreleridir. Mini-batch boyutu, öğrenme hızı (learning rate) ve epoch (eğitim tur sayısı) ise iyileştirici (optimizer) hiper-parametreler arasında yaygın kullanılanlardır (28, 51).

Aktivasyon Fonksiyonu

Aktivasyon fonksiyonu, bir nöronun ağırlıklı toplamını hesaplayarak ve bias ekleyerek aktive edilip edilmeyeceğine karar verir. Aktivasyon fonksiyonunun amacı, bir nöron çıkışına doğrusal olmayan (non-linear) bir özellik kazandırmaktır. Eğer bir Aktivasyon fonksiyonu uygulamazsak, çıktı (output) basit bir lineer fonksiyon olacaktır. Doğrusal bir denklemin çözülmesi kolaydır ancak karmaşıklıkları sınırlıdır ve verilerden karmaşık işlevsel özellikleri öğrenme konusunda daha az güce sahiptirler. Aktivasyon fonksiyonu olmayan bir yapay sinir ağı, sınırlı limite sahip olan ve çoğu zaman iyi performans göstermeyen bir lineer regresyon modeli olacaktır. Sinir ağımızın sadece doğrusal bir işlevi öğrenmesi ve hesaplamasını değil, daha karmaşık yapıları öğrenmesi ve çözümlemesi amaçlanmaktadır. Şekil 26'da yaygın olarak kullanılan aktivasyon fonksiyonları görülmektedir.



Şekil 26. Aktivasyon fonksiyonları

Seyreltme (Dropout) Katmanı

Çok sayıda parametreye sahip derin sinir ağları çok güçlü makine öğrenme sistemleridir. Ancak, aşırı uygunluk (overfitting) bu tür ağlarda ciddi bir sorundur. Seyreltme katmanı, bu sorunu gidermek için kullanılan bir tekniktir. Eğitim sırasında rastgele seçilen nöronların (ağları ile birlikte) sinir ağından rastgele düşürmektir. Bu, aşırı uyumluluğu önemli ölçüde azaltır ve diğer düzenleme yöntemlerine kıyasla önemli iyileştirmeler sağlar. Çok katmanlı derin sinir ağlarında belli eşik değerin altındaki düğümlerin seyreltilmesinin performansı iyileştirdiğini gösterilmiştir. Özetle zayıf bilgilerin seyreltilmesi öğrenmede başarıyı arttırdığı gözlenmiştir (52,53).

Mini-Batch boyutu

Yapay sinir ağlarında bütün veriler için aynı anda işlem yapmak gerek bellek açısından gerekse zaman açısından son derece maliyetli ve zordur. Öğrenme işleminin her tekrarında yapılan geriyayılım (backpropagation) ve ağ üstünde geriye yönelik gradyan (gradient descent) hesaplama işlemleri kullanılarak nöronun ağırlık değerleri yenilenir/hesaplanır. Yapılan hesaplama işleminde (gradyan) veriler ne kadar fazlaysa işlem süresi de o kadar uzun olur. Bu süreyi azaltmak, en aza indirmek ve ağın performansını en üst düzeye taşımak için veriler küçük gruplara ayrılıp öğrenme işlemi bu gruplar üzerinden devam eder.

Girdileri parçalayarak küçük gruplar haline getiren işleme mini-batch adı verilir. Mini-batch işlemi tasarlanan modelin aynı anda kaç veriyi işleyeceğini bulmamızı sağlar. Model önce mini-batch üzerinde ileri besleme ve hata değeri hesaplama işlemi

yapar. Sonrasında geriyayılım ve gradyan hesaplamayla yeni ağırlık değerlerini hesaplar (51, 52).

Genel olarak mini-batch boyutları hepsi aynı olup %1-%5 arasında ideal olarak seçilmektedir. %1'den küçük seçilirse gürültü çok fazla olmakta, %5'ten fazla seçilirse modelin eğitim değerleri düşmektedir.

Öğrenme Hızı (Learning Rate)

Geriyayılım işlemi derin öğrenmede ağırlık parametrelerinin/değerlerinin güncellenmesini sağlar. Bu işlem yapılırken önce geriye doğru türev alınarak fark bulunur. Sonrasında bulunan fark değeri learning rate parametresiyle çarpılır ve elde edilen değer ağırlık değerinden çıkarılır, yeni ağırlık değeri elde edilmiş olur. İşlem yapılırken kullanılan learning rate değeri sabit bir değer olabileceği gibi 0.1 ile 0.000001 arasında artan veya azalan bir değer olabilir. Öğrenim hızı için seçilen değerin çok büyük ya da çok küçük olmasının model üzerinde, eğitim verisinden çok etkilenme veya öğrenme süresinin çok uzun olması gibi sonuçları olabilir. Bu yüzden önce büyük değerler kullanılıp eğitim hızı artırılır sonrasında hata değerine yaklaştıkça kullanılan değerler küçültülerek öğrenme işlemi yavaşlatılır.

Eğitim Tur (Epoch) Sayısı

Model üzerinde eğitme işlemi yapılırken bütün veriler aynı anda eğitime katılamaz bu yüzden veriler küçük gruplara ayrılır. Her bir parça sırasıyla eğitilir, test edilir, test sonucu başarı durumuna göre geri yayılım (backpropagation) işlemiyle yeni ağırlık değerleri hesaplanır. Bütün parçaları bu işlemlerden geçirmekteki amaç model için en uygun ağırlık değerini bulmaktır. Bu süreçteki her bir eğitim basamağına "epoch" adı verilir (51, 52).

Epoch'ların başarı oranı ilk başlarda düşük olup sonradan artış gösterir. Bunun nedeni problemi çözmek için gereken ağırlık değerinin adım adım hesaplanmasıdır. Bir noktadan sonra modelin öğrenimi oldukça yavaşlar bu noktada genellikle öğrenme işlemi durdurulur. Bütün bu öğrenme süreci günler hatta aylar sürecektir bir zamanı kapsayabilir. Derin öğrenme için bu zaman dilimleri son derece normaldir.

5. GEREÇ ve YÖNTEM


5.1. Transfer Öğrenme ve Derin Öğrenme Modelleri

Derin öğrenme de yeni bir model oluşturmak için büyük bir hesaplama gücü ve büyük veri setlerine ihtiyacımız vardır. Gelişen grafik işleme birimleriyle bu problemler aşılsa da donanım maliyeti çok yüksektir. Bu problemlerle başa çıkmanın bir başka yolu transfer öğreniminin kullanılmasıdır. Önceden eğitilmiş bir ağın kullanılması, derin öğrenme alanında oldukça etkili bir yöntemdir. Önceden eğitilmiş modelden daha önce büyük ölçekli verilerle eğitilmiş olan bilgiler yeni bir modelde kullanılabilir. Transfer öğrenmesi önceki bir model tarafından öğrenilen özellikleri kullanır ve bu bilgiyi başka bir alana uygular. Küçük bir veri setiyle kendi modelimizi oluşturduğumuzda model birkaç eğitim turundan sonra aşırı uygunluk sorunu vermeye başlar. Veri seti yeterince büyük ve genel bir eğitilmiş model kullandığımızda öğrenilen özellikler orijinal veri setimizde bulunmayan farklı sınıfları sınıflandırabilir. Transfer öğreniminin bir diğer avantajı, büyük bir hesaplama gücüne ihtiyacımız olmamasıdır. Model, önceden eğitilmiş modelden konvolüsyonel katmanların ağırlıklarını kullanır ve sadece son katmanı eğitir (53, 54). Bu çalışmamızda kullandığımız modeller aşağıda anlatılmıştır.

5.1.1. AlexNet

AlexNet, ImageNet veritabanından bir milyondan fazla resim üzerinde eğitilmiş bir konvolüsyonel sinir ağıdır. 2012 yılında ILSRVRC yarışmasında sınıflandırma doğruluk oranını %74,3'ten %83,6'ya çıkararak derin öğrenmenin tekrar popüler olmasını sağlamıştır. Alex Krizhevsky, Ilya Sutskever ve Geoffrey Hinton tarafından geliştirilmiştir (47).

İlk 5'i konvolüsyon katmanlar, son 3'ü tam bağlı katmanlar olmak üzere 8 katmadan oluşmaktadır. Aktivasyon fonksiyonu olarak ReLU, son katmanda Softmax fonksiyonu kullanılmaktadır. Havuzlama (pooling) katmanında max-pooling kullanılmaktadır. Giriş katmanı 227x227x3 boyutuna sahip ve çıkış katmanı görüntüleri 1000 nesne kategorisine ayırabilir. Modelin yapısı şekil 27'de gösterilmiştir.




Şekil 27. AlexNet yapısı (Krizhevsky'dan, 47)

5.1.2. GoogLeNet

Konvolüsyonlar ile daha derine gitme düşüncesiyle Google tarafından geliştirilen, ILSVRC 2014 yarışmasını % 6.67 top-5 hata oranı ile kazanan bir derin öğrenme mimarisidir. LeNet modeline atıfta bulunarak 2015 yılında GoogLeNet ismiyle hem daha derin hem de daha geniş bir model olarak tasarlanmıştır. Başlangıç modülü olarak adlandırılan inception adını verdikleri modüllerle bu genişliği sağlamıştır. Her bir modül, farklı boyutlu konvolüsyon ve max-pooling işlemlerinden meydana gelmektedir.

Inception modüllerinde genişleme etkisi konvolüsyon katmanlarında meydana gelmektedir. İşlem; 1x1, 3x3, 5x5 konvolüsyon ve 3x3 maksimum havuzlama işlemlerinin birlikte ve birbirleriyle uyumlu (paralel) çalışmalarıyla gerçekleşmektedir. Bu yapıya "Naif Inception Modülü (Naive Inception Module)" adı verilmektedir. İşlemin oldukça komplike olması ve paralel çalışma yüzünden parametre sayısında oluşan büyüme, bu noktada önemli sorunlara sebep olabilmektedir. Bu sorunun çözümü için birbirlerine paralel olan Naif Inception konvolüsyon katmanlarının öncesine, 1x1 konvolüsyon katmanları eklenmektedir. Bu sayede boyut azaltma işlemi gerçekleşmekte ve sorun çözülmektedir. Şekil 28'de Naif Inception Modülü ve boyut küçültmeli başlangıç modülü gösterilmektedir (55).



(a) Inception modül, naif versiyon

(b) Boyut küçültmeli başlangıç modülü

Şekil 28. Naif Inception modülü (Szegedy'den, 55)


GoogLeNet 22 katmanlı bir CNN'den oluşmaktadır. AlexNet'in 60 milyon parametre kullanmasına karşı GoogLeNet 5 milyon parametre kullanmaktadır. Aşağıdaki tablo 4'te modelin katmanları hakkında bilgi verilmektedir. Sütunlardaki bilgiler sırasıyla: Katmanda yapılan işlem tipi (type), filtre boyutu/adım kaydırma büyüklüğü (patch size/stride), çıkış boyutu (output size), derinlik filtre boyutu (depth), boyut azaltma için filtre boyutu (reduce), hesaplanan parametre sayısı (params), işlem yükü (ops) olarak gösterilmiştir. Tablo 4'te GoogleNet katmanları gösterilmiştir.

Tablo 4. GoogLeNet katmanları (Szegedy'den, 56)

type	patch size/ stride	output size	depth	#1×1	#3×3 reduce	#3×3	#5×5 reduce	#5×5	pool proj	params	ops
convolution	7×7/2	112×112×64	1							2.7K	34M
max pool	3×3/2	56×56×64	0								
convolution	3×3/1	56×56×192	2		64	192				112K	360M
max pool	3×3/2	28×28×192	0								
inception (3a)		28×28×256	2	64	96	128	16	32	32	159K	128M
inception (3b)		28×28×480	2	128	128	192	32	96	64	380K	304M
max pool	3×3/2	14×14×480	0								
inception (4a)		14×14×512	2	192	96	208	16	48	64	364K	73M
inception (4b)		14×14×512	2	160	112	224	24	64	64	437K	88M
inception (4c)		14×14×512	2	128	128	256	24	64	64	463K	100M
inception (4d)		14×14×528	2	112	144	288	32	64	64	580K	119M
inception (4e)		14×14×832	2	256	160	320	32	128	128	840K	170M
max pool	3×3/2	7×7×832	0								
inception (5a)		7×7×832	2	256	160	320	32	128	128	1072K	54M
inception (5b)		7×7×1024	2	384	192	384	48	128	128	1388K	71M
avg pool	7×7/1	1×1×1024	0								
dropout (40%)		1×1×1024	0								
linear		1×1×1000	1							1000K	1M
softmax		1×1×1000	0								


5.2. Verilerin Hazırlanması

Bu çalışmada kullanılan veriler Karadeniz Teknik Üniversitesi Farabi Hastanesi Radyoloji Bölümü'nden alınmıştır. Veriler 2015-2018 yılları arasındaki teşhisi konulmuş 341 hastanın T2 ağırlıklı manyetik rezonans (MR) görüntüleridir. Görüntüler 384x384 boyutlarında TIFF formatında alınmıştır. MR görüntüleri ağız açık ve kapalı olmak üzere her bir grup için normal, redüksiyonlu disk deplasmanı (RDD) ve redüksiyonsuz disk deplasmanı şeklinde katagorize edilmiştir. Şekil 29'da katagorize edilen veriler gösterilmektedir.




Şekil 29. Katagorize edilen veriler

Eğitim verileri hazırlanırken MR görüntüsünde hasta ve normal TME disk lokasyonları radyolog hekim danışmanlığında işaretlenmiş ve sınıflandırılmıştır. İşaretlenen MR görüntülerinden TME diski kroplanmıştır. Şekil 30'da MR görüntüsünü ve kroplanmış kısmı gösterilmektedir.



Şekil 30. Ağız Kapalı bileteral MR görüntüsü ve TME kesiti

341 hastanın 12276 adet T2 kontrastlı MR görüntüsünden 3088 adet tiff formatında kesilmiş veri elde edilmiştir. Elde edilen kesilmiş veriler hasta (disk deplasmanı var) ve normal (disk deplasmanı yok) şeklinde iki sınıfa ayrılmıştır. Hasta sınıfında olan veriler kendi içinde redüksiyonlu ve redüksiyonsuz disk deplasmanı şeklinde iki sınıfa bölünmüştür. Ağız kapalı ve ağız açık olmak üzere 2 grup veri seti elde edilmiştir. Şekil 31’de etiketlenmiş veriler ve Tablo 5’te bu verilerin sayıları gösterilmiştir.



Şekil 31. Kesilmiş ve etiketlenmiş MR görüntüleri

Tablo 5. Veri seti örnek sayısı

MR Tipi	Normal	Redüksiyonlu	Redüksiyonsuz	Toplam
Ağız Kapalı	456	653	436	1545
Ağız Açık	462	639	442	1543

5.3. Ağ Parametrelerinin Seçimi

Hiper parametrelerin seçiminde modellerin varsayılan başlangıç değerleri üzerinden perfomansa bağlı olarak değişiklikler yapılmıştır. Önceden eğitilmiş derin öğrenme modelleri olarak Alexnet ve GoogLeNet kullanılmıştır. Modellerde optimize yöntemi olarak SGDM (Stochastic Gradient Descent with Momentum) ve ADAM (Adaptive Moment Estimation) seçilmiştir. Mini-batch boyutu %1-%5 arasında kalarak 16, 32, 64, 128 olarak ayarlanmıştır. Eğitim tur sayısı (Epoch) 10, 20, 50, 100 ve öğrenme hızı (Learning Rate) 10^{-2} , 10^{-3} , 10^{-4} seçilerek eğitimde uygulanmıştır.

5.4. Ağların Eğitilmesi ve Test

Veri seti eğitim (train set) ve doğrulama (validation set) olmak üzere iki klasörden oluşmuştur. Verilerin yüzde 20'lik kısmını doğrulama için yüzde 80'lik kısmını da eğitim için rasgele bir şekilde ayrılmıştır.

Disk deplasmanı rahatsızlığının teşhisinde hastanın ağız kapalı MR görüntüsünde TME diskin lokasyonuna bakılmaktadır. Hastanın disk deplasmanı rahatsızlığı teşhisi konulduktan sonra ağız açık lokasyonda TME diskin pozisyonuna göre hastanın redüksiyonlu ya da redüksiyonsuz disk deplasmanı tanısı konulmaktadır. Bundan hareketle ağımızı ilk aşamada ağız kapalı verilerle eğiterek hasta ve normal şekilde iki sınıfta inceledik. İkinci aşamada ağız açık verilerle disk deplasmanı rahatsızlığı olanların redüksiyonlu ya da redüksiyonsuz disk deplasmanı sınıfları altında olasılıklarını araştırdık.

6. BULGULAR

6.1. Ağız Kapalı Veri Setinin Modellere Uygulanması

Hasta (disk deplasmanı var) ve normal (disk deplasmanı yok) şeklinde iki sınıfa ayrılan veri setini AlexNET ve GoogLeNET ağ modelleri ile farklı hiper-parametrelerle eğitilmiştir. Tablo 6’da alınan sonuçların bir kısmı gösterilmiştir.

Tablo 6. AlexNET ve GoogLeNET uygulama sonuçları

Model Adı	Optimize Yöntemi	Öğrenme Oranı	Mini-Batch Boyutu	Epoch	Son Doğruluk (%)	Hata Oranı (%)
AlexNET	SGDM	0.001	128	100	81.9	0.8465
AlexNET	ADAM	0.001	64	50	83.62	0.5704
AlexNET	ADAM	0.0001	32	50	83.62	0.5659
AlexNET	ADAM	0.0001	128	100	84.48	1.0414
GoogLeNET	SGDM	0.001	128	100	77.59	1.2715
GoogLeNET	ADAM	0.001	128	100	68.1	0.6262
GoogLeNET	SGDM	0.0001	64	100	75	0.5967
GoogLeNET	ADAM	0.0001	128	100	79.31	1.5543

Öğrenme hızının küçülmesiyle başarının arttığı ancak eğitim süresinin arttırdığı, Mini-Batch boyutunun doğruluk oranını değiştirmedeği fakat eğitim süresini değiştirdiği, optimize yöntemi olarak ADAM (Adaptive Moment Estimation)’ın daha iyi performans gözlemlenmiştir.


Farklı hiper-parametrelerle ağlar kendini eğitirken 30 epoch’tan itibaren eğitim setinin başarısının artmasına karşı doğruluk setinin başarısı sabit kalmıştır. Bu nedenle aşırı uyumu (overfitting) engellemek için eğitim durdurulmuştur. Aldığımız veriler

doğrultusunda öğrenme oranı 0,0001, epoch sayısını 30 alarak 2 farklı optimize yöntemiyle ağıımız tekrar eğittikten sonra başarı oranları Tablo 7’de gösterilmiştir.

Tablo 7. Ağız kapalı veri setinde optimal sonuçları


Model Adı	Son Doğruluk (%)	En İyi Doğruluk (%)	Ortalama Doğruluk (%)	Standart Sapma	Hata Oranı (%)	Epoch
AlexNET(Adam)	80.26	84.48	76.21	5.0629	0.6687	30
AlexNET(Sgdm)	75	80.17	72.94	3.5578	0.5149	30
GoogLeNET(Adam)	73.28	83.62	73.32	4.313	2.0568	30
GoogLeNET(Sgdm)	69.83	75.86	68.47	2.2142	0.5644	30

Aşağıdaki şekillerde en iyi sonucu veren AlexNET(adam)’in eğitim sırasında doğruluk ve hata grafikleri, doğrulama setindeki hata matrisi verilmiştir.




Şekil 32. Ağız kapalı veri seti AlexNET(adam) doğruluk grafiği

Şekil 32 ve 33'ten görüleceği üzere derin öğrenme algoritması eğitim setinde yaklaşık 125. iterasyondan (~15, epoch) sonra görüntülerin sınıflandırılmasında önemli bir kırılma göstererek ağ yapısını optimize etmektedir. Bunun sonucunda doğruluk oranı lineer bir artış, aynı şekilde hata oranı ise lineer bir düşüş sergilemektedir.




Şekil 33. Ağz kapalı veri seti AlexNET(adam) hata grafiği

Doğrulama seti için elde edilen karışıklık matrisi ve doğruluk setindeki rasgele 4 kesitin tahmini Şekil 34'te gösterilmiştir. Matrislerdeki köşegenler, doğru sınıflandırılmış doğrulama verilerini göstermekte, köşegen dışındaki değerler yanlış kategorilere atanan sınıfları göstermektedir. Matris incelendiğinde, modelin hasta sınıfındaki 28 görüntü ve normal sınıfındaki 34 görüntüyü yanlış sınıflandırarak %86.79 duyarlılık, %64.94 özgüllük ve %80.26 doğruluk oranına ulaştığı gözlemlenmiştir.



Şekil 34. Modelin ağız kapalı rasgele 4 kesit tahmini ve doğruluk seti hata matrisi

Şekil 35’te AlexNET ve GoogLeNET’in ağız kapalı durumda disk deplasmanı tahmininde doğruluk oranının en yüksek olduğu hiper-parametrelerde aynı doğrulama setindeki tahminleri gösterilmiştir.



Şekil 35. İki modelin aynı doğrulama seti için tahminleri

6.2. Ağız Açık Veri Setinin Modellere Uygulanması

Ağız kapalı veri setine yapılan işlemler ağız açık veri setine de uygulanmıştır. Redüksiyonlu ve Redüksiyonsuz şeklinde iki sınıfa ayrılan veri setini birinci grup veri

setine yapılan işlemlerin aynıları tekrarlanmıştır. Farklı hiper-parametrelerle eğitilen veri setinden alınan sonuçlar birinci gruptan alınan sonuçlarla paralellik göstermiştir. Tablo 8’de 0.0001 öğrenme oranı ile 100 Epoch sonucundaki alınan değerler gösterilmiştir.

Tablo 8. Ağız Açık Veri Seti Eğitim Sonuçları


Model Adı	Son Doğruluk (%)	En İyi Doğruluk (%)	Ortalama Doğruluk (%)	Standart Sapma	Hata Oranı (%)	Epoch
AlexNET(Adam)	92.44	97.48	90.7	5.1315	0.2731	100
AlexNET(Sgdm)	87.39	90.76	83.12	4.8387	0.2547	100
GoogLeNET(Sgdm)	83.19	84.03	78.31	2.6764	0.5644	100
GoogLeNET(Adam)	88.24	94.12	88.51	3.8799	0.7631	100

Birinci grup veri setinde olduğu gibi 30 epoch’tan itibaren eğitim setinin başarısının artmasına karşı doğruluk setinin başarısı sabit kalmıştır. Bu sebeple modellerimizin aşırı uyuma takılmadan gerçek sonuçlarını öğrenebilmek adına öğrenme oranı 0.0001, epoch sayısını 30 alarak 2 farklı optimize yöntemi ve 2 farklı modelle ağız tekrar eğitilmiştir. Başarı oranları Tablo 9’da gösterilmiştir.

Tablo 9. Ağız Açık Veri Setinin Optimal Sonuçları


Model Adı	Son Doğruluk (%)	En İyi Doğruluk (%)	Ortalama Doğruluk (%)	Standart Sapma	Hata Oranı (%)	Epoch
AlexNET(Adam)	92.23	95.8	86.42	5.1315	0.1927	30
AlexNET(Sgdm)	84.03	84.87	77.27	4.0433	0.3669	30
GoogLeNET(Sgdm)	79.83	82.35	76.3	3.0655	0.4746	30
GoogLeNET(Adam)	89.08	94.12	86.76	6.3409	0.4371	30

Aşağıdaki şekillerde en iyi sonucu veren AlexNET(adam)’in eğitim sırasında doğruluk ve hata grafikleri, doğrulama setindeki hata matrisi verilmiştir.




Şekil 36. Ağz açık veri seti AlexNET(adam) doğruluk grafiği

Şekil 36 ve 37’de derin öğrenme algoritması eğitim seti ve validasyon seti üzerinde doğruluk ve hata oranlarını birbirlerine yakın tutacak biçimde öğrenme ağını optimize ettiği görülmektedir.




Şekil 37. Ağz açık veri seti AlexNET(adam) hata grafiği

Doğrulama seti için elde edilen karışıklık matrisi ve doğruluk setindeki rasgele 4 kesitin tahmini Şekil 38'de gösterilmiştir. Matrislerdeki köşegenler, doğru sınıflandırılmış doğrulama verilerini göstermekte, köşegen dışındaki değerler yanlış kategorilere atanan sınıfları göstermektedir. Matris incelendiğinde, modelin redüksiyonlu sınıfındaki 11 görüntü ve redüksiyonsuz sınıfındaki 13 görüntüyü yanlış sınıflandırarak %94.95 duyarlılık, %85.71 özgüllük ve %92.23 doğruluk oranına ulaştığı gözlemlenmiştir.



Şekil 38. Modelin ağız açık rasgele 4 kesit tahmini ve doğruluk seti hata matrisi

Şekil 39'da AlexNET ve GoogLeNET'in ağız açık durumda redüksiyonlu ve redüksiyonsuz disk deplasmanı tahmininde doğruluk oranının en yüksek olduğu hiperparametrelerde aynı doğrulama setindeki tahminleri gösterilmiştir.



Şekil 39. İki modelin aynı doğrulama seti için tahminleri

Sonuçlar değerlendirildiğinde her iki grup veri seti için model olarak AlexNET'in, optimize yöntemi olarak ADAM'ın 10^{-4} öğrenme oranı ile daha iyi sonuçlar verdiği gözlemlenmiştir.

7. TARTIŞMA ve SONUÇ

Son zamanlarda teknolojiadaki gelişmeler ile birlikte yapay zekâ hayatımızda büyük bir yer edinmiştir. Yapay zekâ metotları medikal verilerin analizinde kullanılarak klinisyenlere hastalıkların diağnozunda karar vermede önemli bir araç haline gelmiştir. Bu metotlar arasında medikal görüntülerin incelenmesinde derin öğrenmenin kullanımı artmaya başlamıştır. Derin öğrenme, kendi kendine öğrenme yöntemlerini kullanarak içsel özellik çıkarımının avantajlarını sağlayan, çoklu işlem katmanları kullanarak verideki yüksek-düzeyli soyutlamaları modellemeye yarayan bir dizi algoritmaya dayanan bir makine öğrenme yöntemidir (1). Son yıllarda görüntü ve ses işleme alanında büyük başarılar getirmesi ile öne çıkan derin öğrenme, sağlık alanında hastalıkları teşhis ederken ya da sınıflandırırken radyolojik bulgular üzerinden çıkarımlar sağlar. Bu teknoloji ile ilgili son zamanlarda yapılan çalışmalar arasında prostat kanserinin teşhisi (2), akciğer nodüllerinin diağnozu (3) ve beyin tümörünün sınıflandırılması ve segmentasyonu (4) gibi birçok hastalığın teşhisinde uygulanmış ve iyi performans gösterme potansiyelini ortaya koymuştur.

TME disk deplasmanı teşhisinde birçok metot kullanılmaktadır. Görüntüleme metotlarından artrografi, ultrasonagrafi ve Manyetik Rezonans Görüntüleme (MRG) teknikleri bulunmaktadır. Bu teknikler arasında literatürde en çok kabul gören ve klinisyenler tarafından da en yaygın olarak kullanılan MRG, disk deplasmanının teşhisinde yüksek hassasiyet, spesifikite ve doğrulukla birlikte sabit muayenede oldukça detaylı anatomik bilgiler vermektedir (6, 7). Ağız ve çene-yüz cerrahisinde literatür incelendiğinde sinir ağlarının kullanımı sınırlı sayıda olduğu görülmektedir. Bu alanda TME disk deplasmanı teşhisinde YSA kullanılarak sadece bir çalışma görülmektedir. Bas vd. (2012) tarafından gerçekleştirilen bu çalışmada hastaların klinik semptomları ve tanıları fonksiyon yaklaşımı (özellik çıkarma) kullanılarak bir yapay sinir ağı oluşturulmuş (11). Fakat TME disk deplasmanında derin öğrenme yöntemi ile herhangi bir sınıflandırma çalışması medikal görüntüler üzerinde yapılmamıştır.

Bu çalışmada, normal ve disk deplasmanı olan MR görüntülerinin alt tiplerinin teşhisinde derin öğrenme yaklaşımının, konvolüsyonel sinir ağları (CNN) yöntemi ile sınıflandırılması yapılmıştır. Ağız kapalı ve ağız açık veri setlerine, iki adet derin öğrenme modeli ve farklı hiper-parametreler uygulanmıştır. Bu çalışma doğrultusunda

CNN tabanlı AlexNET ve GoogLeNET derin öğrenme modelleri farklı hiper-parametreler kullanılarak test edilmiştir. Bu çalışma sonunda AlexNET yöntemlerinin ve Adam aktivasyon fonksiyonunun temporomandibular eklem MR görüntülerinde daha başarılı sonuçlar verdiği görülmüştür. Ağız açık veri setinde %95 üzerinde doğruluk oranı elde edilmiştir. Ağız kapalı veri setindeki karmaşıklığa bağlı olarak en yüksek %84 doğruluk oranı elde edilmiştir. Bu karmaşıklığı düzeltebilmek için T2 ağırlıklı MR görüntüleri yerine daha yüksek çözünürlüklü Proton Density (PD) ağırlıklı MR görüntüleri kullanılarak daha yüksek doğruluk oranı elde edilebilir.

Bu tez çalışması sonucunda temporomandibular eklem MR görüntülerinin derin öğrenme yöntemiyle sınıflandırılmasında başarılı sonuçlar verdiği görülmüştür. TME hastalıklarının teşhisinde yapay zekaların uygulanması diş hekimleri için yararlı bir destekleyici teşhis yöntemi olabilir. Aynı zamanda radyografik görüntüler kullanılarak teşhis edilen hastalıklar için farklı çalışmalar yapılabilir.

Gelecekteki çalışmalar adına mevcut modelin hastane görüntü veri tabanına entegre edilerek kendini otomatik olarak eğitebilen ve başarısını arttıran gelişmiş bir karar destek sistemi oluşturmak hedeflenmektedir.

8. KAYNAKLAR

1. Bengio Y (2009). Learning deep architectures for AI. Foundations and Trends in Machine Learning 2(1): 1-127.
2. Le MH, Chen J, Wang L, Wang Z, Liu W, Cheng KTT, Yang X (2017). Automated diagnosis of prostate cancer in multi-parametric MRI based on multimodal convolutional neural networks. Physics in Medicine & Biology 62(16): 6497.
3. Song Q, Zhao L, Luo X, Dou X (2017). Using deep learning for classification of lung nodules on computed tomography images. Journal of Healthcare Engineering, Volume 2017, Article ID: 8314740.
4. Gao XW, Hui R (2016). A Deep learning based approach to classification of CT brain images. In 2016 SAI Computing Conference, London, United Kingdom, 13-15 July 2016, 28-31.
5. Pereira S, Pinto A, Alves V, Silva CA (2016). Brain tumor segmentation using convolutional neural networks in MRI images. IEEE Transactions on Medical Imaging 35(5): 1240-1251.
6. Gezer İA, Levendoğlu F (2016). Temporomandibular eklem rahatsızlıklarının sınıflandırılması, tanı ve tedavisi. Genel Tıp Dergisi 26(1): 34-40.
7. Aksoy S, Orhan K (2010). Temporomandibular eklemin disk deplasmanları. Gazi Üniversitesi Diş Hekimliği Fakültesi Dergisi 27(1): 65-73.
8. Dönmez H (2012). Temporomandibular eklem hastalıklarında teşhis ve tedavi, Doktora Tezi, Ege Üniversitesi, Sağlık Bilimleri Enstitüsü, Ağız, Diş ve Çene Hastalıkları Cerrahisi Anabilim Dalı, İzmir.
9. Shaefer JR, Riley CJ, Caruso P, Keith D (2012). Analysis of criteria for MRI diagnosis of TMJ disc displacement and arthralgia. International Journal of Dentistry 2012: 283163.
10. Ching T, Himmelstein DS, Beaulieu-Jones BK, Kalinin AA, Do BT, Way GP, Xie W (2018). Opportunities and obstacles for deep learning in biology and medicine. Journal of the Royal Society Interface 15(141): 20170387.

11. Bas B, Ozgonenel O, Ozden B, Bekcioglu B, Bulut E, Kurt M (2012). Use of artificial neural network in differentiation of subgroups of temporomandibular internal derangements: preliminary study. *Journal of Oral and Maxillofacial Surgery* 70(1): 51-59.
12. Mayo Foundation for Medical Education and Research (2019). TMJ disorders. Available from: <https://www.mayoclinic.org/diseases-conditions/tmj/symptoms-causes/syc-20350941>. [Accessed 3 April 2019].
13. Staubesand J (1990). Sobotta insan anatomisi atlası 1. cilt baş boyun üst ekstremiteler ve deri. Türkçe 3. Baskı. Çeviren: Arıncı K, BETA Basım Yayım Dağıtım A.Ş., Münih, 34-35.
14. Yalçın S, Aktaş İ (2010). Dişhekimliğinde temporomandibular eklem hastalarına yaklaşım. *Vestiye Yayın Grubu, İstanbul*.
15. Tillmann BN (2018). Atlas der Anatomie. İnsan anatomisi atlası. 1. Baskı. Çeviren: Yurttaş C, İstanbul Medikal Sağlık ve Yayıncılık Hiz. Tic. Ltd. Şti., İstanbul, 42-45.
16. Görür Dİ (2009). Temporomandibuler eklemde (TME) disk deplasmanlarının Düşük enerji seviyeli laser ile tedavisinin subjektif ve objektif olarak değerlendirilmesi, Doktora Tezi, Ankara Üniversitesi, Sağlık Bilimleri Enstitüsü, Ağız, Diş ve Çene Hastalıkları Cerrahisi Anabilim Dalı, Ankara.
17. Kıpçak ÖA (2011). Temporomandibular eklem rahatsızlıklarının klinik tanı yöntemlerine genel bakış. *Ondokuz Mayıs Üniversitesi Diş Hekimliği Fakültesi Dergisi* 12(3): 133-143.
18. Öztemel E (2003). Yapay sinir ağları. Papatya Yayıncılık, İstanbul.
19. Sarı M (2016). Yapay sinir ağları ve bir otomotiv firmasında satış talep tahmini uygulaması, Yüksek Lisans Tezi, Sakarya Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Anabilim Dalı, Sakarya
20. Karahan M (2011). İstatistiksel tahmin yöntemleri: yapay sinir ağları metodu ile ürün talep tahmini uygulaması, Doktora Tezi, Selçuk Üniversitesi, Sosyal Bilimler Enstitüsü, İşletme Anabilim Dalı, Konya.
21. Karpathy A (2018). Stanford University CS231n: Convolutional neural networks for Visual Recognition. Available from: <http://cs231n.stanford.edu/syllabus.html>. [Accessed 3 April 2019].
22. Alpaydın E (2011). Yapay Öğrenme, Boğaziçi Üniversitesi Yayınevi, İstanbul.

23. Yazıcı ÜH (2010). Yapay sinir ağları ile banka müşterisi bekleme süresi tahmini, Yüksek Lisans Tezi, Atatürk Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Anabilim Dalı, Erzurum.
24. Ballı MT (2014). Yapay sinir ağları ile talep tahmini ve gıda sektöründe uygulanması, Yüksek Lisans Tezi, Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Anabilim Dalı, İstanbul.
25. Dülger E (2016). Ekonomide öncü göstergeler ile büyüme tahmini uygulaması, Yüksek Lisans Tezi, Ankara Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Anabilim Dalı, Ankara.
26. Çayiroğlu İ (2019). İleri Algoritma Analizi Ders Notları. Çevrimiçi: <http://www.ibrahimcayiroglu.com/Dokumanlar/IleriAlgoritmaAnalizi/IleriAlgoritmaAnalizi-5.Hafta-YapaySinirAglari.pdf>. [Erişildi: 6 Mayıs 2019].
27. Kim P (2017). Matlab deep learning. In With Machine Learning, Neural Networks and Artificial Intelligence. Apress, New York, ABD.
28. Cireşan DC, Meier U, Schmidhuber J (2012). Multi-column deep neural networks for image classification. 2012 IEEE Conference on Computer Vision and Pattern Recognition, 3642-3649.
29. LeCun Y, Bengio Y, Hinton G (2015). Deep learning. Nature 521(7553): 436.
30. Ivakhnenko AG, Lapa VG (1965). Cybernetic predicting devices. CCM Information Corporation, New York, United States.
31. Fukushima K (1980). Neocognitron: a self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position. Biological Cybernetics 36(4): 193-202.
32. Linnainmaa S (1970). The Representation of the cumulative rounding error of an algorithm as a taylor expansion of the local rounding errors. Master's Thesis (in Finnish), University of Helsinki, Finland.
33. Griewank A (2012). Who invented the reverse mode of differentiation. Documenta Mathematica, Extra Volume ISMP: 389-400.
34. Werbos P (1974). Beyond regression: new tools for prediction and analysis in the behavioral sciences, PhD dissertation, Harvard University, ABD.

35. Werbos PJ (1982). Applications of advances in nonlinear sensitivity analysis. In: Drenick RF, Kozin F (eds) System Modeling and Optimization. Lecture Notes in Control and Information Sciences, vol 38. Springer, Berlin, Heidelberg, 762-770.
36. Weng J, Ahuja N, Huang TS (1992). Cresceptron: a self-organizing neural network which grows adaptively. In IJCNN International Joint Conference on Neural Networks 1:576-581.
37. Weng JJ, Ahuja N Huang TS (1993). Learning recognition and segmentation of 3-d objects from 2-d images. 4th International Conference on Computer Vision :121-128.
38. Weng JJ, Ahuja N, Huang TS (1997). Learning recognition and segmentation using the cresceptron. International Journal of Computer Vision 25(2): 109-143.
39. De Carvalho A, Fairhurst MC, Bisset DL (1994). An Integrated boolean neural network for pattern classification. Pattern Recognition Letters 15(8): 807-813.
40. Hinton GE, Dayan P, Frey BJ, Neal RM (1995). The Wake-sleep algorithm for unsupervised neural networks. Science 268(5214): 1158-1161.
41. Heck LP, König Y, Sönmez MK, Weintraub M (2000). Robustness to telephone handset distortion in speaker recognition by discriminative feature design. Speech Communication 31(2-3): 181-192.
42. Hochreiter S, Schmidhuber J (1997). Long short-term memory. Neural Computation 9(8): 1735-1780.
43. Oh KS, Jung K (2004). GPU implementation of neural networks. Pattern Recognition 37(6): 1311-1314.
44. Chellapilla K, Puri S, Simard P (2006). High performance convolutional neural networks for document processing. In Tenth International Workshop on Frontiers in Handwriting Recognition, Universite de Rennes, France.
45. Cireşan DC, Meier U, Gambardella LM, Schmidhuber J (2010). Deep, big, simple neural nets for handwritten digit recognition. Neural Computation 22(12): 3207-3220.
46. Raina R, Madhavan A, Ng AY (2009). Large-scale deep unsupervised learning using graphics processors. In Proceedings of the 26th Annual International Conference on Machine Learning, Montreal, Quebec, Canada, 14-18 June 2009, 873-880.

47. Krizhevsky A, Sutskever I, Hinton GE (2012). Imagenet classification with deep convolutional neural networks. In *Advances in Neural Information Processing Systems*: 1097-1105.
48. Deng L, Yu D (2014). Deep learning: methods and applications. *Foundations and Trends in Signal Processing* 7(3-4):197-387.
49. Hubel DH, Wiesel TN (1968). Receptive fields and functional architecture of monkey striate cortex. *The Journal of Physiology* 195(1): 215-243.
50. Dahl GE, Jaitly N, Salakhutdinov R (2014). Multi-task neural networks for QSAR Predictions. *ArXiv*, 1406.1231.
51. Srivastava N, Hinton G, Krizhevsky A, Sutskever I, Salakhutdinov R (2014). Dropout: a simple way to prevent neural networks from overfitting. *The Journal of Machine Learning Research* 15(1): 1929-1958.
52. Bengio Y (2012). Practical recommendations for gradient-based training of deep architectures. In *Neural Networks: Tricks of the trade* : 437-478.
53. Goodfellow I, Bengio Y, Courville A (2016). *Deep learning*. MIT press, Cambridge, United Kingdom.
54. Talo M, Baloglu UB, Yıldırım Ö, Acharya UR (2019). Application of deep transfer learning for automated brain abnormality classification using MR images. *Cognitive Systems Research* 54: 176-188.
55. Szegedy C, Liu W, Jia Y, Sermanet P, Reed S, Anguelov D, Rabinovich A (2015). Going deeper with convolutions. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*: 1-9.

9.ETİK KURUL ONAYI

KTÜ TIP FAKÜLTESİ BİLİMSEL ARAŞTIRMALAR ETİK KURULU KARAR FORMU

BAŞVURU BİLGİLERİ	ARAŞTIRMANIN AÇIK ADI	“Derin Öğrenme ile Manyetik Rezonans Görüntülerde Temporomandibular Eklem Disk Deplasmanlarının Diağnozu”		
	ARAŞTIRMANIN PROTOKOL/PLAN KODU	2018 / 263		
	KOORDİNATÖR/SORUMLU ARAŞTIRMACI UNVANI/ADI/SOYADI	Doç. Dr. Mehmet İTİK		
	KOORDİNATÖR/SORUMLU ARAŞTIRMACININ UZMANLIK ALANI	Makine Teorisi ve Dinamiği		
	TEZ SAHİBİ/DİĞER ARAŞTIRICILAR, UNVANI/ADI/SOYADI	Arş.Gör.Yusuf BAYKAL, Dr.Öğr.Üyesi İlker EYÜBOĞLU		
	DESTEKLEYİCİ			
	ARAŞTIRMANIN NİTELİĞİ			
	ARAŞTIRMANIN TÜRÜ	TEZ ☒ AKADEMİK AMAÇLI ☐		
	ARAŞTIRMAYA KATILAN MERKEZLER	TEK MERKEZ ☒	ÇOK MERKEZLİ ☐	ULUSAL ☐

DEĞERLENDİRİLEN BELGELER	Belge Adı	Tarihi	Versiyon Numarası	Dili
	ARAŞTIRMA PROTOKOLÜ/PLANI			Türkçe ☒ İngilizce ☐ Diğer ☐
	BİLGİLENDİRİLMİŞ GÖNÜLLÜ OLUR FORMU			Türkçe ☐ İngilizce ☐ Diğer ☐
	OLGU RAPOR FORMU			Türkçe ☐ İngilizce ☐ Diğer ☐
DEĞERLENDİRİLEN DİĞER BELGELER	Belge Adı		Açıklama	
	TÜRKÇE ETİKET ÖRNEĞİ	☐		
	SIGORTA	☐		
	ARAŞTIRMA BÜTÇESİ	☐		
	BİYolojik MATERYEL TRANSFER FORMU	☐		
	İLAN	☐		
	YILLIK BİLDİRİM	☐		
	SONUÇ RAPORU	☐		
	GÜVENLİLİK BİLDİRİMLERİ	☐		
DİĞER:	☐			

**KTÜ TIP FAKÜLTESİ BİLİMSEL ARAŞTIRMALAR
ETİK KURULU KARAR FORMU**

KARAR BİLGİLERİ	Karar No: 7	Tarih: 07.01.2019
	Doç.Dr.Mehmet İTİK'in sorumluluğunda yürütülmesi planlanan Arş.Gör.Yusuf BAYKAL'a ait "Derin Öğrenme ile Manyetik Rezonans Görüntülerde Temporomandibular Eklem Disk Deplasmanlarının Diağnozu" başlıklı 2018/263 no.lu ve yukarıda başvuru bilgileri verilen araştırma/tez başvuru dosyası ile ilgili belgeler araştırmanın gerekçe, amaç, yaklaşım ve yöntemleri dikkate alınarak incelenmiş, gerçekleştirilmesinde etik sakınca bulunmadığına; toplantıya katılan etik kurul üyelerinin oy birliği ile karar verilmiştir.	

KTÜ TIP FAKÜLTESİ BİLİMSEL ARAŞTIRMALAR ETİK KURULU KARAR FORMU	
ÇALIŞMA ESASI	Klinik Araştırmalar Hakkında Yönetmelik, İyi Klinik Uygulamaları Kılavuzu
BAŞKANIN UNVANI / ADI / SOYADI:	Prof. Dr. Faruk AYDIN

Unvanı/Adı/Soyadı	Uzmanlık Alanı	Kurumu	Cinsiyet		İlişki *		Katılım **		İmza
Prof. Dr. Faruk AYDIN Başkan:	Tıbbi Mikrobiyoloji	KTÜ Tıp Fakültesi	E ☒	K ☐	E ☐	H ☒	E ☒	H ☐	
Prof. Dr. Gamze ÇAN Başkan Yrd.	Halk Sağlığı	KTÜ Tıp Fakültesi	E ☐	K ☒	E ☐	H ☒	E ☒	H ☐	
Prof. Dr. Murat LİVAOĞLU Üye:	Plastik, Rekons. ve Estetik Cer.	KTÜ Tıp Fakültesi	E ☒	K ☐	E ☐	H ☒	E ☒	H ☐	
Prof. Dr. S. Murat KESİM Raportör:	Tıbbi Farmakoloji	KTÜ Tıp Fakültesi	E ☒	K ☐	E ☐	H ☒	E ☒	H ☐	
Prof. Dr. Yılmaz BÜLBÜL Üye:	Göğüs Hastalıkları	KTÜ Tıp Fakültesi	E ☒	K ☐	E ☐	H ☒	E ☒	H ☐	
Prof. Dr. Murat ÇAKIR Üye:	Çocuk Sağlığı ve Hastalıkları	KTÜ Tıp Fakültesi	E ☒	K ☐	E ☐	H ☒	E ☒	H ☐	
Prof. Dr. Şafak ERSÖZ Üye:	Tıbbi Patoloji	KTÜ Tıp Fakültesi	E ☐	K ☒	E ☐	H ☒	E ☒	H ☐	
Dr. Öğr. Üyesi Demet SAĞLAM AYKUT Üye:	Ruh Sağlığı ve Hastalıkları	KTÜ Tıp Fakültesi	E ☐	K ☒	E ☐	H ☒	E ☒	H ☐	
Dr. Öğr. Üyesi Hüseyin YAMAN Üye:	Tıbbi Biyokimya	KTÜ Tıp Fakültesi	E ☒	K ☐	E ☐	H ☒	E ☒	H ☐	

* :Araştırma ile İlişki
** :Toplantıda Bulunma

10. ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Soyadı, Adı : BAYKAL, Yusuf
Uyruğu : T.C.
Doğum tarihi ve yeri : 18/02/1992 - TRABZON
Medeni hali : Bekar
E-Posta : yusufbaykal@yahoo.com
Yazışma adresi : KTÜ Tıp Fakültesi Biyoistatistik ve Tıp Bilişimi ABD

EĞİTİM BİLGİLERİ

Derece	Mezun Olduğu Kurum	Mezuniyet Yılı
Yüksek Lisans	KTÜ/Biyoistatistik ve Tıp Bilişimi	2016-
Lisans	Anadolu Üniveristesi / Bilgisayar Müh.	2009-2015
Lise	Trabzon Yomra Fen Lisesi	2005-2009

AKADEMİK / MESLEKİ DENEYİM

Görevi	Kurum	Süre (Yıl-Yıl)
1. Bursiyer	TÜBİTAK Projesi : 114E634	2016-2018
2. Araştırma Görevlisi	KTÜ Biyoistatistik ve Tıp Bilişimi ABD	2018-

YABANCI DİL

İngilizce