



T.C.
SELÇUK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**KRONİK INFLAMATUVAR DEMİYELİNİZAN
POLİNÖROPATİ (CIDP) HASTALIĞININ
TEŞHİSİNDE MAKİNE ÖĞRENME
ALGORİTMALARI KULLANILARAK KARAR
DESTEK SİSTEMİ OLUŞTURMA**

Hüseyin AKBUDAK

YÜKSEK LİSANS TEZİ

Biyomedikal Anabilim Dalı

Eylül-2024
KONYA
Her Hakkı Saklıdır.

TEZ KABUL VE ONAYI

Hüseyin AKBUDAK tarafından hazırlanan “Kronik İnflamatuvar Demiyelinizan Polinöropati (CIDP) Hastalığının Teşhisinde Makine Öğrenme Algoritmaları Kullanılarak Karar Destek Sistemi Oluşturma” adlı tez çalışması 26/09/2024 tarihinde aşağıdaki jüri tarafından oy birliği ile Selçuk Üniversitesi Fen Bilimleri Enstitüsü Biyomedikal Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

Başkan

Doç.Dr. Adem GÖLCÜK

Danışman

Doç.Dr. Muhammet Serdar BAŞÇIL

Üye

Dr.Öğr.Üyesi Umut ÖZKAYA

İmza

.....

.....

.....

Yukarıdaki sonucu onaylarım.

Prof. Dr. Ömer Faruk YÜKSEL
FBE Müdürü

TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.

İmza

Hüseyin AKBUDAK

Tarih:

ÖZET

YÜKSEK LİSANS TEZİ

KRONİK İNFLAMATUVAR DEMİYELİNİZAN POLİNÖROPATİ (CIDP) HASTALIĞININ TEŞHİSİNDE MAKİNE ÖĞRENME ALGORİTMALARI KULLANILARAK KARAR DESTEK SİSTEMİ OLUŞTURMA

Hüseyin AKBUDAK

**SELÇUK ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ
BİYOMEDİKAL ANABİLİM DALI**

Danışman: Doç.Dr. Muhammet Serdar BAŞÇIL

2024, 68 Sayfa

Jüri

Doç.Dr. Adem GÖLCÜK

Doç.Dr. Muhammet Serdar BAŞÇIL

Dr.Öğr.Üyesi Umut ÖZKAYA

Bu çalışma, Kronik İnflamatuvar Demiyelinizan Poliradikülönöropati (CIDP) teşhisinde elektromiyografi (EMG) sinyal görüntülerinin yapay zeka tabanlı derin öğrenme yöntemleri ile sınıflandırılmasını hedeflemektedir. CIDP, periferik sinirlerin demiyelinizasyonu ile karakterize edilen ve hastaların motor ve duysal sinir fonksiyonlarında ciddi bozulmalara yol açan kronik bir nörolojik hastalıktır. CIDP teşhisi, benzer nöropatilerle semptomlarının örtüşmesi nedeniyle karmaşık bir süreçtir ve erken teşhis, tedavi sürecinin etkinliği açısından büyük önem taşır. Bu nedenle, EMG sinyallerinin sınıflandırılması, doğru teşhisin sağlanması ve benzer hastalıklarla karışma olasılığının azaltılması açısından kritik bir rol oynar. Çalışmada, Selçuk Üniversitesi Tıp Fakültesi Hastanesi'nden elde edilen EMG sinyal verilerinden oluşan bir veri seti kullanılmıştır. Bu veri seti, 13 CIDP hastası ve 13 sağlıklı bireyden alınan toplam 130 EMG sinyal görüntüsünü içermektedir. Veriler, Nihon Kohden MEB-200 model cihazla standardize edilmiş koşullarda toplanmış olup, yüksek çözünürlük ve renk derinliğine sahip PNG formatında saklanmıştır. Veri seti, CIDP ve sağlıklı bireyler arasında ayırım yapmak amacıyla iki sınıfa ayrılmış ve çeşitli CNN mimarileri ile analiz edilmiştir. Çalışmada kullanılan CNN modelleri arasında GoogLeNet, ResNet-50, EfficientNet-B0 ve DarkNet-53 gibi derin öğrenme algoritmaları yer almaktadır. Bu modeller, EMG sinyallerindeki ince farklılıkları yakalayarak hastalığın teşhisi için kullanılmıştır. Modellerin performansları doğruluk, duyarlılık, özgüllük ve F1 skoru gibi metriklerle değerlendirilmiş ve her bir modelin CIDP teşhisindeki başarısı analiz edilmiştir. Özellikle ResNet-50, EfficientNet-B0 ve DarkNet-53 modelleri, %100'e yakın doğruluk oranlarına ulaşarak CIDP teşhisinde yüksek bir performans sergilemiştir. GoogLeNet modeli ise diğer modellere kıyasla biraz daha düşük bir performans göstermiştir, ancak yine de teşhis sürecinde önemli katkılar sağlamıştır. Sonuç olarak, bu çalışma, derin öğrenme tekniklerinin CIDP gibi karmaşık nörolojik hastalıkların teşhisinde güçlü bir araç olarak kullanılabileceğini göstermektedir. EMG sinyallerinin derin öğrenme algoritmaları ile başarılı bir şekilde sınıflandırılması, klinik uygulamalarda yapay zeka tabanlı karar destek

sistemlerinin kullanılabilirliğini desteklemektedir. Bu sistemler, özellikle erken teşhis ve tedavi süreçlerinde doktorlara önemli bir rehberlik sağlayabilir. Ancak, çalışmada kullanılan veri setinin nispeten küçük olması, elde edilen sonuçların genellenebilirliği konusunda bazı sınırlamalar getirmektedir. Gelecekte daha geniş veri setleri ve farklı derin öğrenme tekniklerinin kullanılması, bu modellerin performansını daha kapsamlı bir şekilde değerlendirebilir ve CIDP teşhisinde yapay zeka uygulamalarının potansiyelini daha da artırabilir. Bu bağlamda, derin öğrenme modelleri nörolojik hastalıkların teşhis süreçlerini dönüştürebilecek güçlü bir araç olarak karşımıza çıkmaktadır.

Anahtar Kelimeler: Convolutional Neural Network (CNN), Elektromiyografi (EMG), Derin öğrenme, Kronik İnflamatuvar Demiyelinizan Poliradikülönöropati (CIDP), Teşhis, Yapay zeka



ABSTRACT

MS

DEVELOPING A DECISION SUPPORT SYSTEM FOR THE DIAGNOSIS OF CHRONIC INFLAMMATORY DEMYELINATING POLYNEUROPATHY (CIDP) USING MACHINE LEARNING ALGORITHMS

Hüseyin AKBUDAK

**THE GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCE
OF SELÇUK UNIVERSITY
THE DEGREE OF MASTER OF SCIENCE OF PHILOSOPHY
IN BIOMEDICAL ENGINEERING**

Advisor: Doç.Dr. Muhammet Serdar BAŞÇIL

2024, 68 Pages

Jury

Doç.Dr. Adem GÖLCÜK

Doç.Dr. Muhammet Serdar BAŞÇIL

Dr.Öğr.Üyesi Umut ÖZKAYA

This study aims to classify electromyography (EMG) signal images using artificial intelligence-based deep learning methods for the diagnosis of Chronic Inflammatory Demyelinating Polyneuropathy (CIDP). CIDP is a chronic neurological disease characterized by the demyelination of peripheral nerves, leading to significant impairments in both motor and sensory nerve functions. The diagnosis of CIDP is a complex process due to the overlap of its symptoms with other neuropathies, and early diagnosis is crucial for the effectiveness of treatment. Therefore, the classification of EMG signals plays a critical role in ensuring an accurate diagnosis and reducing the likelihood of confusion with similar diseases. In this study, a dataset of EMG signal data obtained from the Selçuk University Faculty of Medicine Hospital was used. This dataset includes a total of 130 EMG signal images, obtained from 13 CIDP patients and 13 healthy individuals. The data were collected under standardized conditions using the Nihon Kohden MEB-200 model device and were stored in PNG format with high resolution and color depth. The dataset was divided into two classes, distinguishing between CIDP patients and healthy individuals, and analyzed using various CNN architectures. The CNN models used in the study included deep learning algorithms such as GoogLeNet, ResNet-50, EfficientNet-B0, and DarkNet-53. These models were employed to capture subtle differences in EMG signals for diagnostic purposes. The models' performances were evaluated using metrics such as accuracy, sensitivity, specificity, and F1 score, and the success of each model in diagnosing CIDP was analyzed. Particularly, ResNet-50, EfficientNet-B0, and DarkNet-53 achieved high performance with near 100% accuracy in CIDP diagnosis. While GoogLeNet performed slightly lower than the other models, it still made significant contributions to the diagnostic process. In conclusion, this study demonstrates that deep learning techniques can be effectively used as a powerful tool in diagnosing complex neurological diseases like CIDP. The successful classification of EMG signals through deep learning algorithms

supports the potential use of AI-based decision support systems in clinical applications. These systems can provide valuable guidance to physicians, especially in early diagnosis and treatment processes. However, the relatively small size of the dataset used in this study poses some limitations on the generalizability of the results. In the future, using larger datasets and exploring different deep learning techniques can further evaluate the performance of these models and enhance the potential of AI applications in CIDP diagnosis. In this context, deep learning models present themselves as a powerful tool capable of transforming the diagnostic processes of neurological diseases.

Keywords: Artificial Intelligence (AI), Chronic Inflammatory Demyelinating Polyneuropathy (CIDP), Convolutional Neural Network (CNN), Deep Learning, Diagnosis, Electromyography (EMG)



ÖNSÖZ

Öncelikle, bu çalışmanın gerçekleştirilmesindeki destek ve katkılarından dolayı danışmanım Doç.Dr. Muhammet Serdar BAŞÇIL'a

Araştırmamın uygulama sürecinde tıbbi bilgi ve imkanlarından yararlandığım ve destek aldığım Selçuk Üniversitesi Tıp Fakültesi Hastanesi Nöroloji Bölümü'nün akademik ve idari personellerine, ve özellikle Nöroloji Anabilim Dalı Öğretim Üyesi Doç. Dr. Hakan Ekmekçi'ye,

Çalışma sürecinde veri toplamamda yardımcı olan Dr. Bayram Uysal'a

Tez çalışmam sürecinde yanımda olan aileme, özellikle sevgili anneme ve babama, yüksek motivasyon ile maddi ve manevi yanımda olan Biyomedikal Oryantasyon Derneği (MEDİKORYA) ailesine sonsuz teşekkür ederim.

Hüseyin AKBUDAK
KONYA-2024

İÇİNDEKİLER

ÖZET	iv
ABSTRACT.....	vi
ÖNSÖZ	viii
İÇİNDEKİLER	ix
ŞEKİLLER LİSTESİ	xi
SİMGELER VE KISALTMALAR	xiii
1. GİRİŞ	1
1.1. CIDP Teşhisinde Kullanılan Yöntemler	3
1.2. Yapay Zeka ve Nörolojik Hastalıkların Teşhisi	5
2. KAYNAK ARAŞTIRMASI	10
2.1. CIDP'nin Genel Tanımı ve Klinik Özellikleri	10
2.1.1. Klinik Özellikler	10
2.1.2. Patofizyoloji.....	11
2.1.3. Hastalığın Seyri ve Prognoz	11
2.2. CIDP Teşhisinde Kullanılan Yöntemler	12
2.2.1. Elektrofizyolojik Testler	13
2.2.2. Manyetik Rezonans Görüntüleme (MRI)	14
2.2.3. Beyin Omurilik Sıvısı (BOS) Analizi	14
2.2.4. Sinir Biyopsisi.....	14
2.2.5. Makine Öğrenimi ve Derin Öğrenme Algoritmalarının CIDP Teşhisinde Kullanımı	15
2.3. CNN'lerin Temelleri ve Avantajları.....	15
2.3.1. CIDP Teşhisinde CNN Modellerinin Kullanımı	15
2.4. Yapay Zeka Tabanlı Karar Destek Sistemleri	16
2.5. Gelecek Perspektifleri ve Araştırma Yönleri	16
2.6. CIDP'nin Diğer Nöropatilerle Karıştırılması ve Teşhis Zorlukları.....	17
2.7. Atipik CIDP ve Diğer Nöropatilerle Karışma Olasılığı.....	17
2.8. Teşhis Zorlukları ve Yanlış Teşhis	18
2.8.1. Elektrofizyolojik ve Görüntüleme Bulguları	18
2.8.2. Klinik Değerlendirme ve Ayırıcı Tanı	18
3. MATERYAL VE YÖNTEM.....	20
3.1. Veri Seti Kaynağı.....	20
3.1.1. Katılımcılar	20
3.1.2. Veri Toplama Yöntemi	21

3.1.3. Veri Setinin Yapısı.....	21
3.1.4. Veri Setinin Kullanımı.....	24
3.2. CNN MİMARİLERİ.....	25
3.2.1. GoogLeNet Mimarisi: Detaylı İnceleme	27
3.2.2. ResNet-50 Mimarisi Detaylı İnceleme	29
3.2.3. EfficientNet-B0 Mimarisi Detaylı İnceleme.....	31
3.2.4. Darknet-53 Mimarisi Detaylı İnceleme	33
4. ARAŞTIRMA SONUÇLARI.....	37
4.1.Eğitim ve Değerlendirme.....	37
5. SONUÇLAR VE ÖNERİLER	41
5.1. Sonuç	43
5.2. Öneri	43
KAYNAKLAR	44
EKLER	51
EK-1 Kullanılan EMG Cihazının Açıklama Rehberi	51
EK-1 (Devamı)	52
EK-2 Selçuk Üniversitesi Tıp Fakültesi Hastanesi Dekanlığı Yerel Etik Kurul Kararı	53
EK-2 (Devamı)	54
ÖZGEÇMİŞ	55

ŞEKİLLER LİSTESİ

Şekil 1.1 Sinir Hücresi Gösterimi; (a) Sağlıklı Bireyin Sinir Hücresi, (b) CIDP Hastasının Sinir Hücresi (Panzyga, 2023)	1
Şekil 1.2 Demiyenizel Hastalıkların Sinyal Gösterimi (Feldman ve ark., 2021)	2
Şekil 1.3 Elektromiyografi (EMG) Prosedürü: Sinir ve Kas Fonksiyonlarının Değerlendirilmesinde kullanılan Test Yöntemi (Cuesta-Vargas ve ark., 2020).....	4
Şekil 1.4 Epilepsi Hastalığını Teşhisinde Kullanılan EGG Sinyalleri (Amo ve ark., 2004)	7
Şekil 2.1 CIDP Hastalığının Tipik ve Varyantlarının Gösterimi (Björklund ve ark., 2023)	11
Şekil 2.2 CIDP Hastalığının Semptomlarının Gösterimi (Mathey ve ark., 2015).....	12
Şekil 2.3 NCS, Ölçüm Tekniğinin Gösterimi (Mathey ve ark., 2015)	13
Şekil 3.1 Nihon Kohden marka Neuropack S1 MEB-9400K	20
Şekil 3.2 Motor Conduction Study (MCS) Median Ölçüm Tekniği (Yamamoto ve ark., 2017)	22
Şekil 3.3 Sensory Conduction Study (SCS) Median Ölçüm Tekniği (Yamamoto ve ark., 2017)	23
Şekil 3.4 Motor Conduction Study (MCS) Tibial Ölçüm Tekniği (Yamamoto ve ark., 2017)	23
Şekil 3.5 Hasta Bireye ait SCS Median L Sinyal Görüntüsü.....	24
Şekil 3.6 CNN Yapısı ve Ağları	26
Şekil 3.7 GoogLeNet Mimarisi (Zhou ve ark., 2021).....	28
Şekil 3.8 ResNet-50 Mimarisi (Fayaz ve ark., 2024)	30
Şekil 3. 9 EfficientNet-B0 Mimarisi (Ahmed ve Sabab, 2022).....	32
Şekil 3.10 Darknet-53 Mimarisi (Xiong ve ark., 2023).....	34
Şekil 4.1 Resnet.50'ye Ait Karışıklık Matrisleri (a.%50-50, b.%60-40 c.%70-30).....	38
Şekil 4.2 GoogleNET'ye Ait Karışıklık Matrisleri (a.%50-50, b.%60-40 c.%70-30)	39
Şekil 4.3 EfficientNet-B0'e Ait Karışıklık Matrisleri (a.%50-50, b.%60-40 c.%70-30)40	
Şekil 4.4 Darnet-53'de Ait Karışıklık Matrisleri (a.%50-50, b.%60-40 c.%70-30).....	41

ÇİZELGELER LİSTESİ

Çizelge 4.1 CNN modellerine Ait Doğruluk Verileri	37
Çizelge 4.2 Resnet.50, EfficientNet-B0 ve Darnet-53 Performans Metrik Sonucu	41
Çizelge 4.3 GoogleNet Performans Metrik Sonucu	42



SİMGELER VE KISALTMALAR

Simgeler:

$P(k=y \mid x)$:	Koşullu Olasılık İfadesi
zk:	K-inci sınıfa ait logit (lineer çıktı).
e:	Euler sayısı (yaklaşık 2.718).
N:	Toplam sınıf sayısı


Kısaltmalar

CIDP:	Kronik İnflamatuvar Demiyelinizan Polinöropati
EMG:	Elektromiyografi
MCS:	Motor Conduction Study
SCS:	Sensory Conduction Study
MRI:	Manyetik Rezonans Görüntüleme
BOS:	Beyin Omurilik Sıvısı
TP:	True Positive
TN:	True Negative
FP:	False Positive
FN:	False Negative
TPR:	True Positive Rate (Duyarlılık)
FPR:	False Positive Rate (Yanlış Pozitif Oranı)
FNR:	False Negative Rate (Yanlış Negatif Oranı)
CNN:	Convolutional Neural Network
DL:	Deep Learning (Derin Öğrenme)
ML:	Machine Learning (Makine Öğrenimi)

1. GİRİŞ


Kronik İnflamatuvar Demiyelinizan Polinöropati (CIDP), periferik sinirlerin myelin kılıfında meydana gelen kronik inflamasyon sonucu ortaya çıkan yavaş ilerleyen bir nörolojik hastalıktır. CIDP, dünya genelinde nadir görülen bir hastalık olmasına rağmen etkilediği bireylerde ciddi nörolojik semptomlara ve fonksiyon kayıplarına neden olabilir. Hastalık genellikle simetrik olarak hem motor hem de duyuşal sinirleri etkiler, bu da hastaların hem hareket yeteneklerinde hem de duyuşal algılarında belirgin bozulmalara yol açar. CIDP'nin teşhisi bu semptomların diğer nörolojik hastalıklarla büyük ölçüde örtüşmesi nedeniyle oldukça karmaşıktır. Bu nedenle hastalığın erken dönemde doğru teşhis edilmesi tedavi sürecinin etkinliği ve hastalığın ilerlemesinin önlenmesi açısından kritik bir öneme sahiptir (Uncini ve Kuwabara, 2015).

CIDP'nin kesin nedeni tam olarak bilinmemekle birlikte genellikle bağışıklık sisteminin yanlışlıkla sinirlerin myelin kılıfına saldırması sonucu ortaya çıkar. Bu bağışıklık yanıtı sinirlerin düzgün bir şekilde işlev görmesini engelleyerek sinyal iletiminde gecikmelere ve bozulmalara neden olur. CIDP'nin tetiklenmesinde bazı enfeksiyonlar, otoimmün hastalıklar veya genetik yatkınlık gibi faktörlerin rol oynadığı düşünülmektedir (Kuwabara ve ark., 2006). Ayrıca, bazı durumlarda CIDP'nin tetiklenmesi, vücudun bağışıklık sisteminin anormal bir şekilde tepki vermesi sonucu ortaya çıkabilir. Örneğin, geçirilen bir enfeksiyon sonrasında vücutta gelişen anormal bağışıklık yanıtları CIDP'yi tetikleyebilir (Brun ve ark., 2022). Şekil 1.1'de görüldüğü gibi, CIDP'de bağışıklık hücreleri tarafından myelin kılıfına saldırı sonucu sinir hücrelerinin hasar görmesi sinir iletiminde kesintilere yol açar. Sağlıklı bir sinir hücresinde sinyaller düzgün bir şekilde iletilirken, hasarlı myelin kılıfı olan sinir hücresinde bu iletim kesintili ve bozuk hale gelir.



Şekil 1.1 Sinir Hücresi Gösterimi; (a) Sağlıklı Bireyin Sinir Hücresi, (b) CIDP Hastasının Sinir Hücresi (Panzyga, 2023)

CIDP'nin teşhis sürecinde karşılaşılan zorluklar, hastalığın farklı klinik formlarda ortaya çıkabilmesi ve benzer semptomlara sahip diğer nöropatilerle karıştırılabilmesi nedeniyle daha da artar. Örneğin, "atipik" CIDP vakaları, genellikle tipik CIDP belirtileri taşımayan, dolayısıyla teşhis edilmesi daha zor olan vakalardır. Bu tür vakalar, bazen distale yerleşik demiyelinizan simetrik nöropati (DADS) veya multifokal motor nöropati gibi diğer nöropatilerle karıştırılabilir(Chroni ve Kleopa, 2021). Şekil 1.2'de görüldüğü gibi, CIDP ve diğer nöropatiler arasındaki farklar, sinir iletim hızları ve klinik belirtilerle tanımlanabilir. Bu grafik, CIDP'nin atipik formlarının, distale yerleşik demiyelinizan simetrik nöropati (DADS) ve multifokal motor nöropati gibi diğer nöropatilerle karıştırılabileceğini görsel olarak göstermektedir.



Yanlış teşhis konulan hastalar, genellikle gereksiz ve potansiyel olarak zararlı tedavilere maruz kalmakta, aynı zamanda gerçek hastalıklarının tedavisi gecikmektedir. ABD'de yapılan bir çalışmada, CIDP tanısı konan hastaların neredeyse yarısının aslında bu hastalığa sahip olmadığı tespit edilmiştir(Allen, 2020). Bu durum, hem bireysel düzeyde sağlık sorunlarına hem de toplumsal düzeyde önemli ekonomik yüklerin doğmasına neden olmaktadır. CIDP, bireyler için olduğu kadar toplumlar için de ciddi ekonomik yükler doğurur. Yanlış teşhis konulan vakalarda, gereksiz tıbbi müdahaleler ve uzun süreli tedaviler, sağlık sistemi üzerindeki maliyetleri artırırken, hastaların iş gücü kaybı ve yaşam kalitesindeki düşüş gibi sosyal maliyetler de dikkate değerdir. CIDP'nin teşhis edilmesi ve uygun tedavi stratejilerinin belirlenmesi, bu ekonomik yükü hafifletmek için hayati önem taşır. Özellikle sağlık sistemlerinin bu hastalığın teşhisinde


daha dikkatli ve titiz olması, hem bireysel hem de toplumsal sağlık maliyetlerinin düşürülmesine katkı sağlayacaktır (Divino ve ark., 2018).

1.1. CIDP Teşhisinde Kullanılan Yöntemler

CIDP teşhisinde, doğru ve erken tanı konulması için çeşitli klinik ve laboratuvar yöntemleri kullanılmaktadır. Bu yöntemlerin kombinasyonu, hastalığın doğru bir şekilde tanımlanması ve benzer semptomlara sahip diğer nöropatilerden ayırt edilmesi açısından büyük önem taşır. CIDP teşhisi genellikle hastanın klinik öyküsünün ayrıntılı bir şekilde değerlendirilmesiyle başlar. Hastalığın tipik belirtileri arasında, özellikle proksimal ve distal kas güçsüzlüğü, duyuşsal kayıplar ve reflekslerde azalma veya kaybolma yer alır. Ancak, bu belirtilerin varlığı tek başına yeterli olmayabilir; bu nedenle, teşhisin doğrulanması için daha ileri testler yapılması gerekmektedir (Eftimov ve ark., 2020).

Elektrofizyolojik testler, CIDP teşhisinde en yaygın olarak kullanılan yöntemlerden biridir. Sinir iletim çalışmaları (NCS) ve elektromiyografi (EMG), periferik sinirlerin işlevselliğini değerlendirmek için kullanılır. NCS, sinirlerin elektriksel uyarılara verdiği yanıtı ölçerken, EMG, kasların elektriksel aktivitesini analiz eder. CIDP'de, NCS genellikle sinir iletim hızında belirgin bir yavaşlama ve distal latanslarda uzama gösterir. Bu bulgular, demiyelinizasyonun bir göstergesi olarak kabul edilir ve CIDP teşhisi için kritik öneme sahiptir (Eftimov ve ark., 2020). Ayrıca, sinir iletim çalışmaları sırasında tespit edilen temporal dispersiyon ve iletim blokları, CIDP'nin diğer nöropatilerden ayırt edilmesine yardımcı olabilir. Şekil 3'te, elektromiyografi (EMG) prosedürünün detayları gösterilmiştir. Bu test, CIDP teşhisinde sinir ve kas işlevlerinin değerlendirilmesinde önemli bir rol oynar. NCS, sinir iletim hızındaki yavaşlamaları ve distal latanslardaki uzamaları tespit ederken, EMG, kasların elektriksel aktivitesini analiz ederek demiyelinizasyonun varlığını doğrular. (Neligan ve ark., 2014)

Elektromiyografi (EMG)



Şekil 1.3 Elektromiyografi (EMG) Prosedürü: Sinir ve Kas Fonksiyonlarının Değerlendirilmesinde kullanılan Test Yöntemi (Cuesta-Vargas ve ark., 2020)

Bunların yanı sıra, beyin omurilik sıvısı (BOS) analizi de CIDP teşhisinde önemli bir rol oynar. BOS'da yüksek protein seviyeleri, özellikle hücre sayısında artış olmaksızın gözlemlendiğinde, CIDP için oldukça spesifik bir bulgu olarak kabul edilir. Ancak, bu bulgu tek başına tanı koymak için yeterli olmayabilir ve diğer klinik ve elektrofizyolojik bulgularla desteklenmelidir (Eftimov ve ark., 2020). Son yıllarda, manyetik rezonans görüntüleme (MRI) de teşhis sürecinde kullanılmaya başlanmıştır. MRI, omurilik ve sinir köklerindeki anormal kalınlaşmaları veya kontrast tutulumlarını tespit edebilir, bu da CIDP'nin tanısında yardımcı olabilir (Tanaka ve ark., 2013).

Bu yöntemlerin her biri, CIDP teşhisinin doğruluğunu artırmak için birlikte kullanılır ve hastalığın diğer benzer nöropatilerden ayrımını sağlamak için kritik öneme sahiptir. Ancak, bu yöntemlerin uygulanmasında dikkatli olunmalı ve her bir bulgunun klinik tablo ile uyumlu olup olmadığı titizlikle değerlendirilmelidir. Yanlış pozitif sonuçlar, hastaların gereksiz tedavilere maruz kalmasına neden olabileceği gibi, hastalığın yanlış tanınması durumunda da doğru tedavinin gecikmesine yol açabilir (Eftimov ve ark., 2020).

Yapay zeka (AI), hastalıkların teşhisinde giderek daha fazla kullanılan güçlü bir araç haline gelmiştir. AI, özellikle tıbbi görüntüleme, klinik veri analizi ve hasta risk

değerlendirmesi gibi alanlarda büyük bir etki yaratmaktadır.(Rehman ve ark., 2022). AI teknolojilerinin bir alt dalı olan makine öğrenimi (ML), hastalıkların teşhis edilmesi ve hatta bazı durumlarda hastalıkların prognozunun tahmin edilmesi için yaygın olarak kullanılmaktadır. Bu teknolojiler, büyük veri kümelerini analiz ederek, karmaşık örüntüleri tanıyabilir ve bu sayede doktorların karar verme süreçlerine destek olabilir (Nguyen ve ark., 2022).

AI, özellikle kanser, kalp hastalıkları ve nörolojik hastalıklar gibi karmaşık ve çok boyutlu hastalıkların teşhisinde etkin bir şekilde kullanılmaktadır. Örneğin, derin öğrenme (DL) algoritmaları, tıbbi görüntülerdeki karmaşık yapıların tanımlanmasında oldukça başarılıdır. Bu algoritmalar, doktorların gözden kaçırabileceği ince detayları tespit edebilir ve böylece teşhis doğruluğunu artırabilir(Battineni ve ark., 2020). Bir çalışmada, derin öğrenme tabanlı bir algoritmanın, normal sinus ritmi gösteren EKG kayıtlarından atriyal fibrilasyonu (AF) yüksek doğrulukla tespit edebildiği gösterilmiştir. Bu, AI'nın sadece mevcut hastalıkların teşhisinde değil, aynı zamanda gelecekteki hastalık risklerinin öngörülmesinde de önemli bir araç olabileceğini göstermektedir (Yuan ve ark., 2023).

AI'nın sağlık alanındaki bir diğer önemli uygulama alanı, kişiselleştirilmiş tıp ve hasta izlem sistemleridir. AI algoritmaları, hastaların tıbbi geçmişlerini, genetik bilgilerini ve yaşam tarzı verilerini analiz ederek, bireye özel tedavi planları oluşturabilir. Bu durum, tedavi süreçlerinin daha etkili ve hedefe yönelik olmasını sağlar. Ayrıca, AI tabanlı sistemler, hastaların günlük aktivitelerini ve çevresel faktörleri izleyerek, özellikle kronik hastalıkların yönetiminde büyük faydalar sağlar. Örneğin, yapay zeka destekli sistemler, diyabet gibi kronik hastalıkların erken aşamalarında hastalık belirtilerini tespit edebilir ve bu sayede erken müdahaleye olanak tanır (Raglio ve ark., 2020).

1.2. Yapay Zeka ve Nörolojik Hastalıkların Teşhisi

Yapay zeka (AI), nörolojik hastalıkların teşhisinde devrim niteliğinde yenilikler getirmiştir. Nörolojik hastalıklar, genellikle karmaşık ve çok yönlü belirtiler gösterir, bu da doğru tanı konulmasını zorlaştırır. Yapay zekanın bu alandaki en önemli katkılarından biri, büyük veri setlerini işleme yeteneğidir. Yapay zeka, klinik veriler, genetik bilgiler ve beyin görüntüleme sonuçları gibi farklı veri türlerini analiz edebilir ve böylece


doktorların hastalığın karmaşıklıklarını anlamalarına ve doğru tanı koymalarına yardımcı olabilir(Nenning ve Langs, 2022).

Özellikle, makine öğrenimi ve derin öğrenme algoritmaları, nörolojik hastalıkların teşhisinde yaygın olarak kullanılmaktadır. Bu teknolojiler, beyin görüntülerindeki ince yapısal değişiklikleri tespit ederek Alzheimer hastalığı gibi dejeneratif hastalıkların erken teşhisinde kritik bir rol oynar. Örneğin, Zhen ve arkadaşları, MRI görüntülerinden Alzheimer ve hafif bilişsel bozukluk (MCI) teşhisini gerçekleştiren derin öğrenme tabanlı bir özellik temsil algoritması geliştirmişlerdir. Bu algoritma, Alzheimer hastalığının erken evrelerinde bile beyin yapısındaki değişiklikleri tespit ederek, doğru tanı koyma oranını artırmıştır (Zhao ve ark., 2023) Benzer şekilde, Bron ve ekibi tarafından geliştirilen bir başka çalışmada, CADDementia adlı bilgisayar destekli teşhis sistemi, Alzheimer ve diğer demans türlerinin tanısında yüksek doğruluk oranları sunmuştur(Bron ve ark., 2015).

Yapay zeka ayrıca Parkinson hastalığı gibi hareket bozukluklarının teşhisinde de etkili bir araçtır. Parkinson hastalığının motor semptomları, geleneksel teşhis yöntemleriyle kolayca gözden kaçabilir. Ancak, yapay zeka tabanlı sistemler, hastaların motor aktivitelerini analiz ederek, Parkinson hastalığının erken belirtilerini tespit edebilir. Rizvi ve ekibi, Parkinson hastalığını tespit etmek için derin öğrenme ve uzun-kısa süreli bellek (LSTM) ağlarını birleştirerek otomatik bir teşhis sistemi geliştirmiştir. Bu sistem, hastaların yürüme paternlerini ve el titremesini analiz ederek, hastalığın erken teşhis edilmesini sağlamıştır (Rizvi ve ark., 2020). Jo ve meslektaşları ise derin öğrenme ve transfer öğrenme yöntemlerini kullanarak, Parkinson hastalığının tespitinde yüksek doğruluk oranları elde etmişlerdir (Jo ve ark., 2019). Bu çalışmalar, Yapay zekanın nörolojik hastalıkların teşhisinde nasıl kullanılabileceğine dair güçlü örnekler sunmaktadır.

Ek olarak, yapay zeka, epilepsi gibi diğer nörolojik hastalıkların teşhisinde de kullanılmaktadır. Örneğin, Poorani ve ekibi tarafından yapılan bir çalışmada, EEG sinyallerini analiz eden derin öğrenme tabanlı bir model kullanılarak epilepsi nöbetlerinin yüksek doğrulukla tespit edildiği gösterilmiştir. Bu sistem, epilepsi nöbetlerinin başlangıcını önceden tahmin ederek, hastaların nöbet geçirme olasılığını azaltmak için erken müdahalelere olanak tanır (Poorani ve Balasubramanie, 2023). Şekil 1.4'de

görüldüğü gibi EGG sinyalleri karmaşık olmakla beraber bir çok çıkarım yapılabilmektedir.



Şekil 1.4 Epilepsi Hastalığını Teşhisinde Kullanılan EGG Sinyalleri (Amo ve ark., 2004)

Başka bir çalışmada, Aslam ve ekibi, derin öğrenme kullanarak multiple sklerozun (MS) tespitinde etkili bir sistem geliştirmiştir. Bu sistem, hastaların beyin görüntülerini analiz ederek, MS lezyonlarını tespit etmiş ve doğru tanı koyma oranını artırmıştır (Aslam ve ark., 2022).

Yapay zekanın nörolojik hastalıkların teşhisinde sunduğu bu yenilikler, tıp alanında devrim niteliğinde değişiklikler yaratmaktadır. Yapay zeka, doktorların hastalıkların karmaşıklıklarını daha iyi anlamalarına ve daha doğru teşhisler koymalarına olanak tanıyarak, tıbbi bakımın kalitesini artırır. Örneğin, Klöppel ve ekibi tarafından yapılan bir çalışmada, MR görüntülerinin otomatik olarak sınıflandırılmasıyla Alzheimer hastalığının teşhisinde yüksek doğruluk oranları elde edilmiştir (Klöppel ve ark., 2008). Bu tür yenilikler, Yapay zekanın nörolojik hastalıkların teşhisinde daha da

yaygınlaşmasına ve bu alandaki gelişmelerin hızla artmasına neden olacaktır (Klöppel ve ark., 2008).

Yapay zeka, özellikle derin öğrenme ve Convolutional Neural Networks (CNN) gibi algoritmalar, nörolojik hastalıkların teşhisinde giderek daha fazla kullanılmaktadır. Bu teknolojiler, nörolojik hastalıkların tanısında büyük bir potansiyele sahiptir, çünkü beyin görüntülerindeki karmaşık yapıları tanımlayabilir ve hastalığın erken evrelerinde teşhis koyabilirler (Gezer ve ark., 2021). Örneğin, Parkinson hastalığının teşhisinde GoogLeNet, ResNet-50, EfficientNet-B0 ve DarkNet-53 gibi CNN modelleri başarılı bir şekilde kullanılmıştır. Dinlenme halindeki fMRI verilerini analiz eden bir çalışmada, GoogLeNet tabanlı derin öğrenme modeli, Parkinson hastalığının erken evrelerinde beyindeki fonksiyonel bağlantı desenlerini başarılı bir şekilde tespit etmiştir. Bu model, Parkinson hastalığının nörolojik etkilerini erken safhalarda belirleyebilmiş ve bu sayede tedaviye erken başlama imkanı sağlamıştır (Acharya ve ark., 2019).

Benzer şekilde, Alzheimer hastalığının teşhisinde de CNN'ler büyük başarı göstermiştir. Örneğin, ResNet-50 ve EfficientNet-B0 modelleri kullanılarak Alzheimer hastalığının erken teşhisi için MRI verileri analiz edilmiştir. ResNet-50, özellikle derin ve karmaşık yapısı sayesinde, Alzheimer hastalığının erken evrelerinde beyindeki yapısal değişiklikleri tespit ederek hastaların doğru teşhis almasını sağlamıştır. EfficientNet-B0 ise, optimize edilmiş mimarisiyle daha düşük hesaplama gücü gerektiren, ancak yüksek doğruluk oranlarına ulaşan bir model olarak öne çıkmıştır (Jain ve ark., 2020).

CNN'lerin nörolojik hastalıkların teşhisinde kullanıldığı bir diğer önemli alan ise tümörlerin ayırt edilmesidir. Özellikle DarkNet-53, MRI verileri kullanarak beyindeki tümörleri sınıflandırma konusunda üstün performans göstermiştir. Bir çalışmada, DarkNet-53 tabanlı bir model, uzman radyologlardan daha yüksek bir doğruluk oranıyla tümörleri sınıflandırabilmiştir. Bu tür modeller, özellikle deneyimsiz klinisyenlere tanısal süreçlerde önemli bir destek sağlayarak, yanlış tanı riskini azaltabilir ve tanı süreçlerini hızlandırabilir (Kurian ve Juliet, 2023).

Bu gelişmeler, GoogLeNet, ResNet-50, EfficientNet-B0 ve DarkNet-53 gibi CNN modellerinin nörolojik hastalıkların teşhisinde giderek daha kritik bir rol oynamasına yol açmaktadır. AI tabanlı bu yaklaşımlar, beyin görüntüleme verilerinin analizinde insan gözünün tespit edemeyeceği ince ayrıntıları ortaya çıkararak, hastalıkların daha erken ve

daha doğru teşhis edilmesine yardımcı olmaktadır. Gelecekte, bu teknolojilerin daha da gelişmesi ve yaygınlaşması beklenmektedir, bu da nörolojik hastalıkların tanı ve tedavi süreçlerini dönüştürecektir(Ahuja ve ark., 2022).



2. KAYNAK ARAŞTIRMASI


2.1. CIDP'nin Genel Tanımı ve Klinik Özellikleri

Kronik İnflamatuvar Demiyelinizan Poliradikülonöropati (CIDP), periferik sinirlerde demiyelinizasyon ile karakterize edilen, yavaş ilerleyen bir nörolojik hastalıktır. CIDP, sinirlerin myelin kılıfında kronik inflamasyonun meydana gelmesi sonucu ortaya çıkar ve genellikle hem motor hem de duysal sinirleri etkiler. Hastalık, akut inflamatuvar demiyelinizan poliradikülonöropati (AIDP) olarak da bilinen Guillain-Barré sendromunun kronik bir formu olarak kabul edilir. CIDP'nin tanımı, nöropatinin süresine, semptomların progresif doğasına ve elektrofizyolojik bulgulara dayanır (Bunschoten ve ark., 2019).

2.1.1. Klinik Özellikler

CIDP'nin klinik belirtileri, hastalığın doğası gereği oldukça geniş bir yelpazede ortaya çıkabilir. Genellikle, hastalar simetrik olarak distal ve proksimal kas güçsüzlüğü, duysal kayıplar ve derin tendon reflekslerinde azalma veya kaybolma gibi belirtilerle başvurur. CIDP'nin karakteristik belirtileri, yavaş ilerleyen bir zayıflık, dengesizlik ve yürüyüş bozukluğu içerir. Bu semptomlar genellikle bacaklarda başlar ve zamanla kollara yayılabilir (Ekladiou ve Jiang, 2022).

Bununla birlikte, CIDP'nin klinik spektrumu oldukça geniştir ve bazı hastalar atipik belirtiler gösterebilir. Örneğin, hastaların bir kısmı sadece motor sinirlerde veya sadece duysal sinirlerde etkilenme gösterebilir. Atipik CIDP vakalarında, hastalığın tanınması ve teşhis edilmesi daha zor olabilir. Multifokal motor nöropati veya distale yerleşik demiyelinizan nöropati gibi diğer nöropatilerle karıştırılma riski taşır. (van Doorn ve ark., 2024). CIDP varyantlarının gösterimi şekil 2.1'de gösterilmiştir.



Şekil 2.1 CIDP Hastalığının Tipik ve Varyantlarının Gösterimi (Björklund ve ark., 2023)

2.1.2. Patofizyoloji

CIDP'nin patofizyolojisi, esas olarak otoimmün bir süreç olarak kabul edilir. Hastalığın gelişiminde, bağışıklık sisteminin yanlışlıkla periferik sinirlerin myelin kılıfına saldırdığı düşünülmektedir. Bu saldırı, myelin kılıfının hasar görmesine, sinir iletiminin yavaşlamasına ve sonunda sinir hücrelerinin işlevlerini kaybetmesine yol açar. Myelin kılıfı, sinir sinyallerinin hızlı ve verimli bir şekilde iletilmesini sağlar; bu kılıfın hasar görmesi durumunda sinir sinyalleri kesintiye uğrar ve motor ve duysal işlevlerde bozulmalar meydana gelir (Wolbert ve ark., 2020).

Hastalığın otoimmün doğası, genetik yatkınlık, enfeksiyonlar veya diğer tetikleyici faktörlerle birleştiğinde ortaya çıkabilir. Bazı hastalarda CIDP, enfeksiyonlar veya diğer otoimmün hastalıklarla ilişkilendirilmiştir. Örneğin, geçirilmiş viral enfeksiyonlar, bağışıklık sisteminin anormal bir şekilde tepki vermesine ve sinirlerde demiyelinizasyona yol açabilir. CIDP'nin patofizyolojik süreci, sinir hücrelerinin kronik inflamasyonu ve bunun sonucunda sinir hasarı ile karakterize edilir (Dalakas, 2011).

2.1.3. Hastalığın Seyri ve Prognoz

CIDP, yavaş ilerleyen bir hastalıktır ve genellikle tekrarlayan ataklarla seyreder. Uzunlarda uyuşma, duyu kaybı, halsizlik sırt batın bölgelerinde ağrı ve sinir motor

harekelerinde kayıp gözlemlenir. Şekil 2.1’de semptomlar ilustrasyonu gösterilmiştir. Bu ataklar arasında belirgin iyileşme dönemleri olabilir, ancak hastalık kronik ve ilerleyici bir doğaya sahiptir. Tedavi edilmediğinde, CIDP hastalarında kalıcı nörolojik hasar gelişebilir ve bu da yaşam kalitesinde ciddi düşüslere yol açabilir. Tedaviye yanıt, hastalar arasında farklılık gösterebilir; bazı hastalar immün modölatör tedavilere iyi yanıt verirken, diğlerlerinde hastalık daha dirençli olabilir (Lehmann ve ark., 2019).



Şekil 2.2 CIDP Hastalığının Semptomlarının Gösterimi (Mathey ve ark., 2015)

Tedavi, genellikle bağışıklık sistemini baskılayan ilaçlar, intravenöz immünoglobulin (IVIg) veya plazmaferez gibi yöntemlerle yapılır. CIDP'nin erken teşhisi ve uygun tedavi stratejilerinin uygulanması, hastalığın ilerlemesini yavaşlatabilir ve semptomların kontrol altına alınmasına yardımcı olabilir. Bununla birlikte, hastalığın seyri bireyden bireye büyük ölçüde değişiklik gösterebilir ve tedaviye verilen yanıt, hastalığın uzun vadeli prognozunu belirlemede kritik bir faktördür (Hu ve ark., 2022).


2.2. CIDP Teşhisinde Kullanılan Yöntemler

CIDP'nin doğru ve erken teşhisi, hastalığın yönetimi ve tedavi sürecinin etkinliği açısından kritik öneme sahiptir. Bu nedenle, CIDP teşhisinde kullanılan çeşitli klinik ve laboratuvar yöntemlerinin bir kombinasyonu tercih edilmektedir. CIDP'nin teşhisinde en yaygın olarak kullanılan yöntemler arasında elektrofizyolojik testler, manyetik rezonans

görüntüleme (MRI), beyin omurilik sıvısı (BOS) analizi ve sinir biyopsisi yer almaktadır (Jongbloed ve ark., 2017).

2.2.1. Elektrofizyolojik Testler

Elektrofizyolojik testler, CIDP teşhisinde altın standart olarak kabul edilen yöntemlerden biridir. Sinir iletim çalışmaları (NCS) ve elektromiyografi (EMG), periferik sinirlerin elektriksel iletim özelliklerini değerlendirir. NCS, sinirlerin elektriksel uyarılara verdiği yanıtı ölçmektedir. Şekil 2.3. de gösterildiği gibidir. EMG, kasların elektriksel aktivitesini analiz eder. CIDP'de, NCS genellikle sinir iletim hızında belirgin bir yavaşlama, distal latanslarda uzama ve temporal dispersiyon gibi demiyelinizasyonun göstergelerini ortaya koyar. Ayrıca, iletim blokları da sıkça gözlemlenir ve bu bulgular CIDP'nin diğer nöropatilerden ayırt edilmesine yardımcı olur (Chichkova ve Katzin, 2010).



Şekil 2.3 NCS, Ölçüm Tekniğinin Gösterimi (Mathey ve ark., 2015)

Elektrofizyolojik testlerin yanı sıra, fokal anormalliklerin tespiti için ince iğne EMG'si de kullanılır. Bu test, motor ünit potansiyellerini analiz ederek, sinir hasarının derecesini ve yaygınlığını belirlemekte etkilidir. Elektrofizyolojik bulgular, CIDP'nin klinik tanısının doğrulanmasında ve hastalığın ilerleme hızının değerlendirilmesinde önemli bir rol oynar (Benoit ve ark., 2021).

2.2.2. Manyetik Rezonans Görüntüleme (MRI)

Manyetik rezonans görüntüleme (MRI), CIDP teşhisinde giderek daha fazla kullanılan bir başka önemli yöntemdir. MRI, özellikle spinal köklerde ve periferik sinirlerde görülen inflamatuvar değişiklikleri ve sinir kalınlaşmalarını tespit etmekte etkilidir. CIDP'li hastalarda, MRI'da genellikle spinal köklerin kontrast tutulumunda artış, sinir kalınlaşmaları ve bazen de omurilikte anormal sinyal yoğunlukları gözlemlenir.

MRI, ayrıca CIDP'nin diğer demiyelinizan nöropatilerden ayırt edilmesine de yardımcı olur. Özellikle multifokal motor nöropati (MMN) gibi CIDP ile karışabilecek diğer nöropatilerde farklı MRI bulguları mevcuttur. Bu nedenle, MRI, CIDP'nin doğru teşhisi ve ayırıcı tanısı için kritik bir görüntüleme aracıdır. Ayrıca, MRI, sinirlerin demiyelinizasyon ve remiyelinizasyon süreçlerini izlemek için de kullanılabilir (Lehmann ve ark., 2019).

2.2.3. Beyin Omurilik Sıvısı (BOS) Analizi

BOS analizi, CIDP'nin teşhisinde kullanılan invaziv olmayan bir diğer önemli yöntemdir. CIDP'de, BOS analizi genellikle hücre sayısında artış olmaksızın yüksek protein seviyeleri gösterir. Bu bulgu, demiyelinizasyonun varlığını gösteren bir diğer önemli parametredir ve genellikle CIDP'nin BOS protein seviyelerindeki artışa dayanan klinik tanısının doğrulanmasında kullanılır (Van den Bergh ve ark., 2010) .

Bununla birlikte, BOS'daki bu bulgu, tek başına CIDP teşhisini doğrulamak için yeterli olmayabilir ve diğer klinik ve elektrofizyolojik bulgularla desteklenmesi gereklidir. BOS analizi ayrıca, CIDP'nin diğer otoimmün nöropatilerden ayırt edilmesine yardımcı olabilir. Örneğin, Guillain-Barré sendromu gibi diğer nöropatilerde BOS'da hücre sayısında artış gözlemlenebilirken, CIDP'de bu genellikle görülmez (Matur ve ark., 2013).

2.2.4. Sinir Biyopsisi

Sinir biyopsisi, CIDP teşhisinde nadiren kullanılan, ancak spesifik durumlarda başvurulmuş invaziv bir yöntemdir. Biyopsi, sinir dokusunda demiyelinizasyon, remiyelinizasyon ve inflamatuvar hücre infiltrasyonunun doğrudan gözlemlenmesini sağlar. Sinir biyopsisi, özellikle atipik CIDP vakalarında, klinik ve elektrofizyolojik bulguların yetersiz kaldığı durumlarda kullanılabilir .

Biyopsi ile elde edilen bulgular, CIDP'nin yanı sıra vaskülitik nöropati gibi diğer inflamatuvar nöropatilerin ayırıcı tanısında da yardımcı olabilir. Ancak biyopsi, sinir hasarına neden olabileceği için sadece gerekli durumlarda tercih edilmelidir (Nathani ve ark., 2021).

2.2.5. Makine Öğrenimi ve Derin Öğrenme Algoritmalarının CIDP Teşhisinde Kullanımı

Makine öğrenimi (ML) ve derin öğrenme (DL) algoritmaları, tıbbi teşhis süreçlerinde devrim yaratan teknolojiler arasında yer almaktadır. Özellikle Convolutional Neural Networks (CNN) gibi derin öğrenme modelleri, tıbbi görüntüleme verilerinin analizinde büyük bir potansiyele sahiptir. CIDP teşhisinde de bu teknolojilerin kullanımı giderek artmakta ve doğru teşhis oranlarını önemli ölçüde artırmaktadır (Chang ve ark., 2022).

2.3. CNN'lerin Temelleri ve Avantajları

Convolutional Neural Networks (CNN), özellikle görsel veri analizi için tasarlanmış derin öğrenme modelleridir. CNN'ler, katmanlar arasında filtreler uygulayarak görüntülerdeki özellikleri otomatik olarak öğrenir ve sınıflandırma yapar. Bu özellikleri sayesinde, tıbbi görüntülerdeki ince ayrıntıları yakalayıp hastalıkların teşhisinde insan gözüyle kaçırılacak detayları tespit edebilirler (Li ve ark., 2021).

CNN'lerin en büyük avantajlarından biri, büyük veri setlerinde üstün performans göstermeleridir. Görüntü işleme, CIDP gibi nörolojik hastalıkların teşhisinde kritik öneme sahiptir. Özellikle elektromiyografi (EMG) sinyal görüntüleri gibi karmaşık verilerde, CNN'ler hastalıkla ilişkili belirgin özellikleri otomatik olarak tespit edebilir. Bu, CIDP teşhisinin daha hızlı ve doğru bir şekilde yapılmasını sağlar (Aloysius ve Geetha, 2017).

2.3.1. CIDP Teşhisinde CNN Modellerinin Kullanımı

CIDP teşhisinde CNN modellerinin kullanımı, EMG sinyal verilerinin analizi ve sınıflandırılması üzerine odaklanmıştır. CNN'ler, EMG sinyal verilerini işleyerek, CIDP ile sağlıklı bireyler arasındaki farklılıkları tespit etme yeteneğine sahiptir. Bu, EMG

verilerinin zaman içinde nasıl değiştiğini inceleyerek, hastalığın ilerleyişini izlemek için de kullanılabilir (Hostin ve ark., 2023).

Bir çalışmada, ResNet-50 ve GoogLeNet gibi derin öğrenme modelleri, CIDP teşhisinde kullanılmış ve yüksek doğruluk oranları elde edilmiştir. Bu modeller, EMG sinyal verilerindeki ince farklılıkları tespit ederek, hastalığın erken teşhisinde önemli bir rol oynamıştır. Özellikle ResNet-50, derin katman yapısı sayesinde sinyal gürültüsüne karşı dayanıklılık göstermiştir (Hu ve ark., 2022).

Diğer bir çalışmada, EfficientNet-B0 modeli, daha düşük hesaplama maliyetiyle benzer doğruluk oranlarına ulaşmıştır. Bu model, parametre verimliliği sayesinde, özellikle büyük veri kümeleri üzerinde hızlı ve etkili bir şekilde çalışabilir. Bu tür CNN modellerinin kullanımı, CIDP teşhisinde geleneksel yöntemlere kıyasla daha hızlı sonuçlar elde edilmesini sağlayarak, klinik karar verme süreçlerini desteklemektedir (Larson ve ark., 2023).

2.4. Yapay Zeka Tabanlı Karar Destek Sistemleri

Yapay zeka (AI) tabanlı karar destek sistemleri, CIDP gibi karmaşık nörolojik hastalıkların teşhisinde giderek daha fazla önem kazanmaktadır. AI algoritmaları, büyük veri kümelerini analiz ederek, doktorlara hastalıkların teşhisi ve tedavi planlarının belirlenmesinde yardımcı olabilir. Bu sistemler, tıbbi görüntüleme verilerini işleyerek, hastalığın evrelerini belirleyebilir ve tedaviye yanıtın izlenmesine olanak tanır (Litjens ve ark., 2017).

CNN'ler, bu tür AI tabanlı sistemlerin merkezinde yer alır. Derin öğrenme modelleri, tıbbi görüntülerin otomatik olarak sınıflandırılmasında kullanılır ve bu süreçte insan müdahalesine olan ihtiyacı azaltır. Bu, özellikle deneyimsiz klinisyenler için faydalı olabilir, çünkü AI tabanlı sistemler, doğru teşhis oranlarını artırabilir ve yanlış teşhis olasılığını azaltabilir (Shen ve ark., 2017).

2.5. Gelecek Perspektifleri ve Araştırma Yönleri

Gelecekte, CIDP teşhisinde kullanılan CNN modellerinin daha da gelişmesi beklenmektedir. Özellikle transfer öğrenme ve derinlemesine denetimsiz öğrenme gibi tekniklerin kullanılması, CIDP teşhisinde daha yenilikçi çözümler sunabilir. Ayrıca,

yapay zeka tabanlı sistemlerin klinik uygulamalarda daha yaygın hale gelmesi, hastalıkların teşhisinde devrim yaratabilir (Esteva ve ark., 2019).

Bu bağlamda, CIDP teşhisinde kullanılan yapay zeka tabanlı algoritmaların sürekli olarak güncellenmesi ve geliştirilmesi, hastalıkların daha erken ve daha doğru teşhis edilmesini sağlayacak önemli bir adımdır. Ayrıca, bu teknolojilerin yaygınlaşmasıyla, sağlık hizmetlerinin kalitesi artırılabilir ve hastaların yaşam kalitesi iyileştirilebilir (Alam ve ark., 2022).

2.6. CIDP'nin Diğer Nöropatilerle Karıştırılması ve Teşhis Zorlukları

Kronik İnflamatuvar Demiyelinizan Poliradikülonöropati (CIDP), karmaşık ve heterojen klinik tablosu nedeniyle diğer nöropatilerle karıştırılabilir. Bu durum, CIDP'nin doğru ve zamanında teşhis edilmesini zorlaştırmakta ve hastaların tedavi süreçlerini olumsuz etkileyebilmektedir. CIDP, özellikle benzer semptomlara sahip demiyelinizan ve aksonal nöropatilerle sıklıkla karışır. Bu nedenle, hastalığın teşhisinde karşılaşılan zorluklar, hem klinik bulguların dikkatli değerlendirilmesini hem de çeşitli tanısal yöntemlerin etkin bir şekilde kullanılmasını gerektirir (Vallat ve ark., 2010).

2.7. Atipik CIDP ve Diğer Nöropatilerle Karışma Olasılığı

CIDP'nin klinik spektrumu oldukça geniştir ve hastalar arasında önemli ölçüde değişiklik gösterebilir. CIDP'nin atipik formları, özellikle diğer nöropatilerle karıştırılma olasılığını artırır. Örneğin, distale yerleşik demiyelinizan simetrik nöropati (DADS) ve multifokal motor nöropati (MMN) gibi nöropatiler, CIDP ile benzer klinik özellikler sergileyebilir. Bu hastalıklar da demiyelinizasyon ile karakterizedir, ancak patofizyolojik mekanizmaları ve tedaviye yanıtları farklılık gösterir (Latov, 2014).

Atipik CIDP vakalarında, hastalığın yalnızca belirli sinir gruplarını etkileyebileceği veya yalnızca motor ya da duyuşal sinirlerde semptomlar gelişebileceği unutulmamalıdır. Bu durum, hastalığın teşhisini daha da karmaşık hale getirebilir ve yanlış teşhis olasılığını artırabilir. Örneğin, MMN, CIDP'ye çok benzeyen multifokal bir motor nöropati olup, genellikle anti-GM1 antikorlarının varlığı ile karakterizedir, bu da ayırıcı tanı için önemli bir ipucu sağlar (Van Schaik ve ark., 1994).

2.8. Teşhis Zorlukları ve Yanlış Teşhis

CIDP'nin teşhisinde karşılaşılan en büyük zorluklardan biri, hastalığın semptomlarının geniş bir nöropati yelpazesi ile örtüşmesidir. CIDP'nin klinik belirtileri, genellikle diğer demiyelinizan nöropatiler ve hatta bazı metabolik nöropatiler ile benzerdir. Özellikle diyabetik nöropati, CIDP ile karıştırılabilecek yaygın bir durumdur. Diyabetik nöropatide de distal simetrik polinöropati görülebilir, ancak bu durumun tedaviye yanıtı ve prognozu farklıdır (Stewart ve ark., 1996).

Yanlış teşhis, hastaların gereksiz ve potansiyel olarak zararlı tedavilere maruz kalmasına neden olabilir. Örneğin, CIDP tanısı konan bazı hastaların aslında bu hastalığa sahip olmadığı ve bu durumun hastalara yanlış tedavilerin uygulanmasına yol açtığı bildirilmiştir. Bu tür yanlış teşhisler, hastaların yaşam kalitesini olumsuz etkileyebilir ve sağlık sistemleri üzerinde gereksiz maliyetler yaratabilir (Tsfaye, 2007).

2.8.1. Elektrofizyolojik ve Görüntüleme Bulguları

CIDP'nin diğer nöropatilerden ayırt edilmesinde elektrofizyolojik testler önemli bir rol oynar. Sinir iletim çalışmaları (NCS) ve elektromiyografi (EMG) bulguları, CIDP'nin demiyelinizan bir nöropati olduğunu gösterebilir. Ancak, bu testler, aksonal nöropatiler veya diğer demiyelinizan nöropatiler ile benzer bulgular verebilir. Örneğin, multifokal motor nöropatide, EMG genellikle CIDP'de görülen fokal iletim bloklarını ve temporal dispersiyonu gösterebilir (Kotan ve Alemdar, 2016).

Manyetik rezonans görüntüleme (MRI), CIDP'nin teşhisinde yardımcı bir araç olabilir, ancak bu yöntem de diğer nöropatilerle karışıklıklara neden olabilir. Özellikle, spinal köklerin ve sinirlerin kalınlaşması gibi bulgular, hem CIDP'de hem de diğer inflamatuvar nöropatilerde görülebilir. Bu nedenle, MRI bulguları dikkatle yorumlanmalı ve diğer klinik ve elektrofizyolojik bulgularla birlikte değerlendirilmelidir (Pitarokoili ve ark., 2015).

2.8.2. Klinik Değerlendirme ve Ayırıcı Tanı

CIDP'nin diğer nöropatilerden ayırt edilmesinde klinik değerlendirme büyük önem taşır. Hastalığın seyri, semptomların başlangıç şekli ve ilerleyişi, hastanın geçmiş tıbbi öyküsü ve mevcut semptomları dikkatle değerlendirilmelidir. Ayırıcı tanıda,

hastanın yanıt verdiđi tedaviler de dikkate alınmalıdır. Örneđin, immünoglobulin tedavisine hızlı yanıt, CIDP lehine bir bulgu olarak değerdendirilirken, bu tür bir yanıtın eksikliđi, diđer nöropatilerin düşünölmesini gerektirebilir (Reynolds ve ark., 2016).



3. MATERYAL VE YÖNTEM

3.1. Veri Seti Kaynağı

Bu çalışmada kullanılan veri seti, Selçuk Üniversitesi Tıp Fakültesi Hastanesi Nöroloji Bölümü'ne başvuran hastalardan elde edilen elektromiyografi (EMG) cihazından elde edilen Nihon Kohden Neuropack S1 MEB-9400K görüntülerine dayanmaktadır. Veriler, hastanenin arşivinde bulunan Nihon Kohden Neuropack S1 MEB-9400K model cihaz ile toplanmıştır. Cihazın arşivinde 2008 ile 2024 yılları arasında kaydedilmiş toplam 14,034 hastaya ait EMG görüntüleri yer almaktadır. Bu geniş veri havuzundan yapılan incelemeler sonucunda, 35 hastaya CIDP tanısı konulmuş ancak bu hastalardan sadece 13'ünün görüntüleri, standart kaydedilme koşullarına uygun bulunmuştur. Bu seçili veriler, çalışmanın güvenilirliği açısından önemli bir kaynak oluşturmakta olup, hastalığın teşhisi ve sınıflandırılması için kritik bir rol oynamaktadır. Ayrıca, bu veri seti, hem hastaların EMG sinyal verilerini hem de sağlıklı bireylerden elde edilen kontrol verilerini içermektedir, böylece iki grup arasındaki farkların belirlenmesi ve CIDP'nin doğru teşhisi için sağlam bir temel sunulmaktadır.

3.1.1. Katılımcılar

Bu çalışmada kullanılan veri seti, 13 CIDP hastasından ve 13 sağlıklı bireyden elde edilen EMG görüntülerini içermektedir. CIDP hastaları, Selçuk Üniversitesi Tıp Fakültesi Hastanesi Nöroloji Bölümü'ne başvuran ve Nihon Kohden marka Neuropack S1 MEB-9400K model cihaz ile standardize koşullarda EMG görüntüleri kaydedilen hastalar arasından seçilmiştir. Cihazın görseli Şekil. 3.1'de gösterildiği gibidir. Sağlıklı bireyler ise, aynı cihaz ve protokoller kullanılarak veri toplanan kontrol grubunu oluşturmuştur.



Şekil 3.1 Nihon Kohden Marka Neuropack S1 MEB-9400K Model EMG Cihazı

Toplamda, her birey için beş adet farklı ölçüm ve farklı ölçüm tekniklerine ait sinyal görüntüsü kaydedilmiş ve bu doğrultuda veri seti, 65 hasta ve 65 sağlıklı birey görüntüsünden oluşan 130 adet EMG sinyal görüntüsünü içermektedir. Veri seti, hastalığın teşhis sürecinde karşılaşılan zorlukları ve sinyal verilerindeki farklılıkları analiz etmek için kullanılmış olup, CIDP'nin ayırıcı tanısında önemli bir rol oynamaktadır.

3.1.2. Veri Toplama Yöntemi

Veri toplama süreci, Selçuk Üniversitesi Tıp Fakültesi Hastanesi Nöroloji Bölümü'nde standardize edilmiş protokoller çerçevesinde gerçekleştirilmiştir. EMG görüntüleri, Nihon Kohden marka Neuropack S1 MEB-9400K model cihaz kullanılarak elde edilmiştir. Bu cihaz, spesifik formatta EMG kaydı yapabilen ve uluslararası sağlık standartlarını karşılayan, güvenilirliği FDA gibi kurumlardan onaylı bir yazılımdır. Her bir katılımcının EMG sinyal verileri, MEB-2000 yazılımı aracılığıyla toplanmış ve verilerin yüksek doğrulukta kaydedilmesi sağlanmıştır. Görüntüler, cihazın arayüzünden ekran alıntısı şeklinde alınmış olup, tüm kayıtlar aynı çözünürlük ve renk derinliği standartlarına uygun olarak gerçekleştirilmiştir. EMG sinyal görüntüleri, 2560x1600 piksel çözünürlüğe ve 24 bit renk derinliğine sahip PNG formatında kaydedilmiştir.

Veri toplama süreci boyunca, hastalığın teşhis edilmesi ve sınıflandırılması için gerekli olan tüm teknik detaylar titizlikle uygulanmış, verilerin doğruluğu ve güvenilirliği en üst düzeyde tutulmuştur. Ayrıca, veri toplama işlemi öncesinde Selçuk Üniversitesi Etik Kurulu'ndan gerekli onaylar alınmış ve tüm katılımcılardan bilgilendirilmiş onam formları imzalatılmıştır.

3.1.3. Veri Setinin Yapısı


Bu çalışmada kullanılan veri seti, iki ana sınıftan oluşmaktadır: CIDP hastaları ve sağlıklı bireyler. Veri seti, toplamda 130 adet EMG sinyal görüntüsünü içermekte olup, bu görüntülerin 65'i CIDP teşhisi konmuş hastalardan, diğer 65'i ise sağlıklı kontrol bireylerinden elde edilmiştir. Her bir katılımcıdan beş farklı ölçüm alınmıştır: MCS Median L, MCS Median R, SCS Median L, SCS Median R ve MCS Tibial L. MCS Tibial L ölçümü 5 ms zaman aralığında kaydedilmişken, diğer dört sinyal ölçümü 2 ms zaman aralığında kayıt altına alınmıştır. Veri setindeki her bir görüntü, 250x276 piksel boyutuna

dönüştürülmüş, 96 dpi çözünürlük ve 24 bit renk derinliğine sahip PNG formatında saklanmıştır. Veri seti, iki sınıf (CIDP hastaları için 0, sağlıklı bireyler için 1) olarak etiketlenmiştir, bu da sınıflandırma algoritmalarının performansını değerlendirmek için sağlam bir temel sunar. Veri setinin bu şekilde yapılandırılması, CIDP'nin sağlıklı bireylerden ayırt edilmesini kolaylaştırmakta ve sinyal verilerindeki farklılıkların belirginleştirilmesine olanak tanımaktadır.

MCS Median L, MCS Median R, SCS Median L, SCS Median R ve MCS Tibial L şeklinde sınıflandırılmıştır. MCS Median yönteminin örneği Şekil 3.2'de, SCS Median yönteminin örneği ise Şekil 2'de sunulmuştur. MCS Tibial yönteminin örneği ise Şekil 3.3'te gösterilmiştir. İlgili açıklamalar aşağıda yer almaktadır:

MCS Median L: Orta sinirin sol elin medyan sinir bölgesindeki EMG sinyalini temsil eder. Medyan sinir elin duysal ve motor işlevlerinde önemli rol oynar.


MCS Median R: Orta sinirin sağ elin medyan sinir bölgesindeki EMG sinyalini temsil eder. Sağ ve sol medyan sinir sinyalleri arasındaki farklar CIDP tanısında önemli olabilir .



Şekil 3.2 Motor Conduction Study (MCS) Median Ölçüm Tekniği (Yamamoto ve ark., 2017)


SCS Median L: Orta sinirin sol elin medyan sinir bölgesindeki sinyalinin daha geniş bir analizini ifade eder.

SCS Median R: Orta sinirin sağı elin medyan sinir bölgesindeki sinyalinin daha geniş bir analizini ifade eder. Bu sinyal CIDP'nin sağı el üzerindeki etkilerini değerlendirmek için kullanılır.




Şekil 3.3 Sensory Conduction Study (SCS) Median Ölçüm Tekniğı (Yamamoto ve ark., 2017)

MCS Tibial L: Tibial sinirin sol bacakta elde edilen EMG sinyalidir (Horiuchi ve ark., 2022).



Şekil 3.4 Motor Conduction Study (MCS) Tibial Ölçüm Tekniğı (Yamamoto ve ark., 2017)

Yukarda belirtildiğı gibi bir bireye ait 5 ayrı ölçüm yöntemi (MCS Median L, MCS Median R, SCS Median L, SCS Median R, MCS Tibial L) ile kayıtlanan EMG sinyal görüntülerine ait bir örnek (SCS Median L) şekil 3.4'de verilmiştir.



Şekil 3.5 Hasta Bireye ait SCS Median L Sinyal Görüntüsü

3.1.4. Veri Setinin Kullanımı

Bu çalışmada, kullanılan veri seti, derin öğrenme modellerinin eğitimi, doğrulaması ve test edilmesi amacıyla kullanılmıştır. Veri seti, başlangıçta %50 eğitim ve %50 test oranında bölünmüştür. Daha sonra, modelin performansını artırmak ve genel doğruluğunu optimize etmek amacıyla veri seti %60 eğitim ve %40 test olarak yeniden bölünmüş, son olarak ise %70 eğitim ve %30 test oranında nihai bir bölünme gerçekleştirilmiştir. Bu aşamalı veri bölme süreci, modellerin genelleme yeteneğini değerlendirmek ve olası aşırı uyum (overfitting) problemlerini minimize etmek için kritik bir rol oynamıştır. Her bir bölünmede, veri seti, sınıflar arasında dengeli bir dağılım sağlanarak, hem CIDP hastalarının hem de sağlıklı bireylerin sinyal görüntülerinin eşit temsil edilmesine özen gösterilmiştir. Bu veri seti, derin öğrenme modellerinin eğitiminde kullanılan temel girdi olarak işlev görmüş ve çeşitli model performans metrikleri (örneğin, doğruluk, hassasiyet, özgüllük) üzerinden değerlendirilmiştir. Elde edilen sonuçlar, CIDP'nin teşhisinde kullanılan CNN tabanlı modellerin etkinliğini ve veri setinin bu modellerin performansını değerlendirmede ne denli önemli olduğunu ortaya koymuştur.


3.2. CNN MİMARİLERİ

Convolutional Neural Network (CNN), özellikle görüntü tanıma, sınıflandırma ve nesne algılama gibi görsel verilerle ilgili görevlerde yaygın olarak kullanılan bir derin öğrenme modelidir. CNN, görüntülerdeki yerel özellikleri algılamak için farklı boyutlardaki filtreler kullanarak, verinin uzaysal hiyerarşisini öğrenir. Bu sayede, görüntülerdeki kenarlar, köşeler, dokular ve daha karmaşık yapılar gibi yerel özellikler belirlenir ve sonraki katmanlara iletilir. Her bir evrişim katmanı, önceki katmandan aldığı özellikleri daha soyut hale getirerek, görüntünün daha derin özelliklerini öğrenir. Böylece, düşük seviyeli özelliklerden başlayarak daha yüksek seviyeli kavramlara ulaşılır (Deng ve ark., 2022).

CNN'lerin temel yapı taşları arasında evrişim (convolution) ve havuzlama (pooling) katmanları bulunur. Evrişim katmanları, filtreler aracılığıyla görüntü üzerindeki belirli örüntüleri algılamak, havuzlama katmanları, özellik haritalarının boyutlarını küçülterek hesaplama yükünü azaltır ve modelin genel performansını artırır. Özellikle, maksimum havuzlama (max-pooling) gibi yöntemler, bir bölgede en baskın özellikleri seçerek verinin sıkıştırılmasını sağlar. Ayrıca, fully connected (tam bağlantılı) katmanlar, öğrenilen bu özellikleri daha soyut düzeyde bir sınıflandırmaya dönüştürür ve modelin çıktı katmanında sınıf tahminleri yapılır (Chen ve Qu, 2021).

CNN'ler, özellikle büyük veri kümeleri ile eğitildiklerinde yüksek doğruluk oranlarına ulaşabilir. Örneğin, Krizhevsky tarafından geliştirilen AlexNet, ImageNet veri kümesindeki milyonlarca görüntü üzerinde eğitilmiş ve bu sayede nesne tanıma görevlerinde devrim niteliğinde bir başarı elde etmiştir (Krizhevsky ve ark., 2012). CNN'ler, aynı zamanda tıbbi görüntüleme, yüz tanıma, sürücüsüz araçlar ve güvenlik sistemleri gibi geniş bir yelpazede kullanılır. Litjens CNN'lerin tıbbi görüntüleme uygulamalarında kanser teşhisi, beyin görüntüleme ve organ segmentasyonu gibi alanlarda önemli ilerlemeler sağladığını belirtmiştir (Litjens ve ark., 2017). Esteva da benzer şekilde, CNN'lerin dermatolojik görüntülerde cilt kanseri tespiti gibi zor görevlerde insan uzmanlarla karşılaştırılabilir sonuçlar verdiğini göstermiştir. (Esteva ve ark., 2017)

Bu özellikleri sayesinde, CNN mimarileri günümüzde biyomedikal uygulamalarda da geniş bir kullanım alanına sahiptir ve özellikle EMG sinyallerinin sınıflandırılması gibi biyomedikal verilerdeki örüntüleri belirlemek için güçlü bir araç olarak kullanılmaktadır. Bu çalışmada kullanılan CNN mimarileri, belirli biyomedikal sinyalleri sınıflandırmak için optimize edilmiş ve sinyal verisinin doğasına uygun filtreler ve katman yapılarıyla donatılmıştır.



Şekil 3.6 CNN Yapısı ve Ağları

Şekil 3.6’da görüldüğü gibi bu çalışmada ResNet-50, EfficientNet-B0, GoogleNet, DarkNet-53, DarkNet-19 uygulanmıştır.

3.2.1. GoogLeNet Mimarisi: Detaylı İnceleme

GoogLeNet, 2014 yılında Christian Szegedy ve ekibi tarafından geliştirilmiş olan bir derin öğrenme modeli olup, aynı yıl ImageNet yarışmasında en iyi sonuçları elde etmiştir (Szegedy ve ark., 2015). GoogLeNet, derin konvolüsyonel sinir ağlarının (CNN) bir versiyonudur ve Inception mimarisi adı verilen yenilikçi bir yapıyı kullanır. Bu model, derinlikte genişlemeye odaklanarak daha az parametre ile çok daha etkili sonuçlar elde etmeyi hedeflemiştir (Tang ve ark., 2017).


3.2.1.1. Inception Modülü

GoogLeNet'in temelini oluşturan Inception modülü, farklı boyutlardaki konvolüsyon filtrelerini aynı anda kullanarak ağın her katmanında çeşitli uzamsal boyutlarda özellikleri çıkarmasını sağlar (Szegedy ve ark., 2015). Standart CNN mimarilerinde, tek bir konvolüsyon katmanında genellikle sabit bir filtre boyutu kullanılırken, Inception modülü aynı anda 1x1, 3x3 ve 5x5 gibi farklı boyutlarda filtreleri uygular (Iandola ve ark., 2016). Ayrıca, bu modül, hesaplama maliyetini azaltmak için 1x1 konvolüsyonlar ile boyut indirgeme (dimensionality reduction) işlemi de kullanır .

Şekil 3.5'te gösterildiği gibi Inception modülünde kullanılan bileşenler:

1. **1x1 konvolüsyonlar:** Parametre sayısını azaltırken derin özellikler çıkarır.
2. **3x3 ve 5x5 konvolüsyonlar:** Farklı boyutlardaki uzamsal özellikleri yakalamak için kullanılır.
3. **Max-Pooling:** Daha büyük alanlardan önemli bilgileri çekerek çıktı boyutunu küçültür (Li ve ark., 2020).

Bu çoklu konvolüsyon filtrelerinin bir araya gelmesiyle elde edilen çıktı, kanal yönünde birleştirilir ve bir sonraki katmana iletilir. Bu sayede, model hem düşük maliyetli hem de güçlü bir temsili öğrenme kapasitesine sahip olur.



Şekil 3.7 GoogLeNet Mimarisi (Zhou ve ark., 2021)

3.2.1.2. Parametrelerin Azaltılması

GoogLeNet'in en büyük avantajlarından biri, daha az parametre kullanarak çok derin bir ağ yapısını verimli bir şekilde eğitebilmesidir. Örneğin, 22 katmandan oluşan GoogLeNet, o dönem popüler olan AlexNet'ten çok daha derin olmasına rağmen yaklaşık 12 kat daha az parametreye sahiptir (GoogLeNet'in yaklaşık 6,8 milyon parametresi varken AlexNet'in 60 milyondan fazla parametresi bulunur). Bu başarı, Inception modüllerindeki 1x1 konvolüsyonların boyut indirgeme yeteneği sayesinde elde edilmiştir (Szegedy ve ark., 2015).

3.2.1.3. Yardımcı Sınıflandırıcılar

Derin ağların eğitimi sırasında "vanishing gradient" (kaybolan gradyan) problemiyle karşılaşılabilir. GoogLeNet bu sorunu çözmek için ağın farklı katmanlarına yerleştirilen iki adet yardımcı sınıflandırıcı kullanır (Szegedy ve ark., 2015). Bu sınıflandırıcılar, ağın daha derin katmanlarına kadar ulaşmadan önce ara sonuçlar üreterek gradyan bilgisinin kaybolmasını önler. Yardımcı sınıflandırıcılar, eğitimin ortasında küçük kayıplar üretir ve bu sayede eğitim sürecinin stabilitesini artırır (Yang ve ark., 2023b).

3.2.1.4. GoogLeNet'in Genel Başarı Değerlendirmesi

GoogLeNet, mimarisi sayesinde çok daha az parametre ile çok daha derin bir yapıyı öğrenebilmiş ve ImageNet yarışmasında %6.67 hata oranı ile birinci olmuştur. Bu başarısı, Inception mimarisinin hem verimliliğini hem de derin öğrenme modellerindeki parametre verimliliğini kanıtlamıştır (Szegedy ve ark., 2015).

GoogleNet yapısında Konvolüsyon Katmanları: $9 * 6 + 3$ (giriş) = 57 konvolüsyon katmanı Pooling Katmanları: 5 (Maksimum) + 2 (Ortalama) = 7 pooling katmanı bulunur.

3.2.2. ResNet-50 Mimarisi Detaylı İnceleme

ResNet-50, derin öğrenme modelleri arasında oldukça popüler bir konvolüsyonel sinir ağı (CNN) modelidir. “Residual Network” yani “Kalıntı Ağı” anlamına gelen ResNet'in mimarisi, derin sinir ağlarının eğitilmesi sırasında ortaya çıkan temel bir soruna çözüm getirmeyi amaçlar: kaybolan gradyan problemi. Ağlar derinleştikçe, eğitim sırasında gradyanların sıfıra yaklaşması ve modelin öğrenme yeteneğinin azalması sorunu ortaya çıkar. ResNet, "residual" (kalıntı) bağlantıları kullanarak bu sorunu büyük ölçüde çözer (Huang ve ark., 2023).

3.2.2.1 Residual Bağlantılar

ResNet'in en belirgin özelliği, katmanlar arasında kullanılan skip connection (atlama bağlantıları) ya da residual bağlantılardır. Geleneksel bir CNN'de, her katman girdi verisini alır, işler ve çıktıyı bir sonraki katmana iletir. Ancak ResNet'te, belirli bir katmandan gelen çıktı, birkaç katman sonrası iletilen çıktıyla toplanır. Bu yapı, ağın daha derin katmanları öğrenme sırasında daha efektif bir şekilde kullanmasını sağlar (He ve ark., 2016). Böylece, hem çok derin ağların performansı artar hem de gradyanların kaybolma olasılığı azalır (Koonce ve Koonce, 2021).


3.2.2.2 ResNet-50'nin Yapısı

ResNet-50, toplamda 50 katmana sahiptir ve bu nedenle "50" ismini almıştır. Derinliği arttırılmış bu modelde, residual bloklar kullanılmasına rağmen hesaplama maliyetleri minimal tutulmaya çalışılmıştır. Modelin yapısı şu şekilde özetlenebilir:

Conv1 (1. Katman): 7x7 konvolüsyon filtresi, 64 adet çekirdek ve stride=2 bulunur. Max Pooling (2. Katman): 3x3 boyutunda filtre, stride=2 bulunur. Conv2_x (3-7. Katmanlar): 1x1, 3x3 ve 1x1 boyutlarında konvolüsyon filtreleri ve residual bağlantılar vardır. Conv3_x (8-16. Katmanlar): Yine 1x1, 3x3 ve 1x1 boyutlarında filtreler ile residual bağlantılar vardır. Conv4_x (17-31. Katmanlar): Aynı yapı, ancak filtre sayıları ve parametreler arttırılmıştır. Conv5_x (32-49. Katmanlar): Yine aynı yapı korunarak, filtre sayısı artırılır.

Son Katman (50. Katman): Fully connected (tam bağı) katman ile sınıflandırma yapılır.

Bu yapı, derinliği artırarak daha fazla özellik çıkarımı yapılmasını sağlar. Fakat residual bloklar sayesinde model, derin olmasına rağmen gradyanların kaybolmasını önler (Wen ve ark., 2020). ResNet-50 Mimarisi genel yapısı Şekil 3.6’da gösterilmiştir.



Şekil 3.8 ResNet-50 Mimarisi (Fayaz ve ark., 2024)

3.2.2.2. Avantajları ve Kullanım Alanları

ResNet-50'nin sunduğu en önemli avantajlardan biri, çok derin bir model olmasına rağmen kolayca eğitilebilmesidir (He ve ark., 2016). Bu da modelin farklı görüntü işleme problemleri ve çeşitli makine öğrenimi uygulamalarında kullanılmasını sağlar. ResNet-50, özellikle şu alanlarda yaygın olarak kullanılmaktadır:

Görüntü Sınıflandırma: ResNet-50, ImageNet gibi büyük veri setlerinde son derece yüksek doğruluk oranlarına ulaşmıştır (Russakovsky ve ark., 2015).

Nesne Tespiti: Modelin güçlü özellik çıkarma yeteneği, nesne tespiti ve tanıma gibi görevlerde etkili olmasını sağlar (Jongbloed ve ark., 2017).

Segmentasyon: Görüntüdeki belirli nesnelerin bölütlenmesi, ResNet-50'nin güçlü yapısından faydalanılarak yapılabilir (Battineni ve ark., 2020).

3.2.2.3. Performans ve Sonuçlar

ResNet-50, GoogleNet ve VGG gibi önceki derin öğrenme mimarileriyle kıyaslandığında hem daha derin hem de daha etkili bir modeldir. ImageNet gibi devasa veri setlerinde yapılan testlerde, ResNet-50'nin doğruluk oranlarının çok yüksek olduğu

gözlenmiştir. Ayrıca residual bağlantılar sayesinde, eğitim sırasında derinliğin artmasıyla performans kaybı yaşanmaması büyük bir avantaj olarak öne çıkar (Russakovsky ve ark., 2015).

Resnet.50 yapısı da toplam 53 katman bulunur Konvolüsyon Katmanları: 1 (giriş) + 4 (son) + 48 (16 residual blokta) = 53 konvolüsyon katmanı Pooling Katmanları: 1 (başlangıç) + 1 (sondaki average pooling) + 4 (residual bloklar içinde) = 6 pooling katmanı bulunur.

3.2.3. EfficientNet-B0 Mimarisi Detaylı İnceleme

EfficientNet-B0, derin öğrenme modelleri arasında verimlilik ve performans dengesini sağlayan bir mimari olarak dikkat çeker. Bu model, CNN tabanlı görüntü sınıflandırma problemlerinde daha az hesaplama gücüyle yüksek doğruluk elde etmek için tasarlanmıştır. EfficientNet'in temel amacı, derin öğrenme modellerinin performansını artırırken, model boyutunu ve hesaplama maliyetlerini en aza indirmektir. Bu nedenle, model tasarımında "model scaling" (model ölçekleme) adı verilen yeni bir yaklaşım benimsenmiştir (Tan, 2019).

3.2.3.1. Model Ölçekleme

EfficientNet, genişlik, derinlik ve çözünürlük olmak üzere üç temel boyutta ölçeklendirme kullanır. Genişlik, her katmandaki filtre sayısını ifade ederken; derinlik, modeldeki katman sayısını belirtir. Çözünürlük ise giriş görüntüsünün boyutlarını tanımlar. EfficientNet-B0 modelinin ölçeklendirilmesi, bu üç parametrenin dengeli bir şekilde artırılmasıyla gerçekleştirilir. EfficientNet-B0, bu parametreleri en verimli şekilde ayarlayarak hem daha küçük hem de daha hızlı bir model olmasına rağmen yüksek doğruluk sunar .

EfficientNet, compound scaling (bileşik ölçekleme) adı verilen bu yaklaşımı kullanarak daha verimli bir şekilde ölçeklendirilen modeller oluşturur. Geleneksel modellerde, genellikle sadece bir parametre artırılarak performans iyileştirilir. Ancak EfficientNet'te, bu üç parametre optimize edilerek modelin her yönü dengeli bir şekilde büyütülür. Bu sayede EfficientNet-B0, çok daha büyük modellerle kıyaslanabilir performans sergiler (Nayak ve ark., 2022).


3.2.3.2. EfficientNet-B0'nin Yapısı

EfficientNet-B0, MobileNetV2 temelli bir yapı üzerine inşa edilmiştir ve MBConv blokları kullanılarak derinleştirilmiştir (Tan ve Le, 2019). Bu bloklar, hem hesaplama verimliliğini artırır hem de daha az parametre kullanarak daha fazla özellik çıkarımını mümkün kılar. EfficientNet-B0'nin temel mimarisi şu şekildedir:

MBConv Blokları: Derinlik ayırık konvolüsyonlar ve genişletme işlemleri kullanılarak, verimli ve düşük maliyetli hesaplama sağlar.

Swish Aktivasyon Fonksiyonu: Bu aktivasyon fonksiyonu, ReLU gibi geleneksel fonksiyonlara kıyasla daha pürüzsüz bir doğrusal olmayanlık sunar, bu da modelin daha iyi performans göstermesine olanak tanır. EfficientNet-B0 Mimarisi genel akış diyagramı Şekil 3.7.'de gösterilmiştir.

Giriş Çözünürlüğü: EfficientNet-B0, 224x224 giriş boyutunda çalışacak şekilde optimize edilmiştir, bu da daha büyük modellere kıyasla hafif ve hızlı bir mimari sağlar (Konduri ve Rao, 2024).



Şekil 3. 9 EfficientNet-B0 Mimarisi (Ahmed ve Sabab, 2022)

3.2.3.2. Performans ve Verimlilik

EfficientNet-B0, hem doğruluk hem de verimlilik açısından dikkat çeker. ImageNet veri setinde, EfficientNet-B0, çok daha büyük modellerle kıyaslanabilir doğruluk oranlarına ulaşmıştır. Örneğin, VGG16 gibi daha büyük modellerin yaklaşık iki katı doğruluk sunarken, hesaplama maliyeti oldukça düşüktür(Theckedath ve Sedamkar, 2020). Bu özellikleri, EfficientNet-B0'yi mobil cihazlarda ve düşük güç tüketimi gerektiren uygulamalarda ideal bir çözüm haline getirir.

3.2.3.3. Kullanım Alanları

EfficientNet-B0, farklı alanlarda yaygın olarak kullanılmaktadır:

Görüntü Sınıflandırma: Yüksek doğruluğu ve verimliliği ile çeşitli görüntü sınıflandırma problemlerinde sıklıkla tercih edilmektedir.

Nesne Tespiti ve Segmentasyon: EfficientNet tabanlı modeller, nesne tespiti ve görüntü segmentasyonu gibi görevlerde başarılı sonuçlar elde etmektedir.

Mobil Uygulamalar: Düşük hesaplama gücü ve yüksek performansı sayesinde, EfficientNet-B0, mobil ve yerleşik sistemlerde kullanılmak üzere ideal bir modeldir (Li ve ark., 2020).


EfficientNet-B0'de konvolüsyon katmanları sayısı Konvolüsyon Katmanları: 49 (MBConv blokları) + 1 (giriş) = 50 konvolüsyon katmanı bulunur Pooling Katmanları: 1 adet average pooling katmanı toplamda 51 katman vardır.

3.2.4. Darknet-53 Mimarisi Detaylı İnceleme

Darknet-53, özellikle nesne tespiti ve görüntü işleme uygulamalarında kullanılan güçlü bir derin öğrenme modelidir. 53 katmandan oluşan derin bir sinir ağı yapısına sahip olan bu model, özellikle görüntü sınıflandırma ve nesne tespiti gibi zorlu görevlerde yüksek doğruluk ve hız sunmak için geliştirilmiştir. Darknet-53, hızlı ve verimli bir mimari olarak kabul edilmektedir (Valdez, 2020).

3.2.4.1. Darknet-53'ün Yapısı

Darknet-53, 53 katmandan oluşan derin bir konvolüsyonel sinir ağı (CNN) mimarisidir. Yapı, çoğunlukla 3x3 ve 1x1 konvolüsyon filtreleri ile oluşturulmuş katmanlardan meydana gelir. Bu filtreler, girdi verisinin daha derinlemesine işlenmesine ve özelliklerin daha yüksek doğrulukla çıkarılmasına olanak tanır (Mascarenhas ve Agarwal, 2021). Darknet-53 Mimarisi genel yapısı Şekil 3.8.'de gösterilmiştir.



Şekil 3.10 Darknet-53 Mimarisi (Xiong ve ark., 2023)

Modelin en önemli özelliklerinden biri, derin katmanlarda residual bağlantıların kullanılmasıdır. Residual bağlantılar, katmanlar arasındaki gradyan kaybını önleyerek modelin eğitim sırasında daha derin katmanları da öğrenmesine yardımcı olur. Bu bağlantılar, derin yapıya sahip ağlarda yaygın olarak karşılaşılan kaybolan gradyan sorununu çözerek modelin daha etkin bir şekilde eğitilmesini sağlar. Darknet-53'ün bu residual yapı ile donatılması, derin katmanlardan öğrenme sürecini kolaylaştırır ve ağın eğitilebilirliğini artırır (Wang ve ark., 2020).

3.1.4.1. Performans ve Verimlilik

Darknet-53, performans ve verimlilik açısından dikkat çeken bir modeldir. Yapısında kullanılan residual bağlantılar sayesinde daha derin katmanlar kullanılabilir hale gelirken, aynı zamanda hesaplama verimliliği de korunur. Model, hem büyük veri setlerinde hem de gerçek zamanlı uygulamalarda yüksek performans göstermektedir (Gordon ve ark., 2018).

Özellikle nesne tespiti gibi zaman hassasiyetine sahip görevlerde, Darknet-53 hızlı sonuçlar verebilme kapasitesine sahiptir. Modelin yapısındaki katmanlar, görüntülerdeki karmaşık özellikleri tanımlamak için derin öğrenme yapılarından faydalanır ve hızlı hesaplama yeteneği sayesinde gerçek zamanlı uygulamalarda sıkça kullanılır. Modelin bu verimliliği, özellikle büyük ölçekli görüntü veri setleriyle çalışırken önemli bir avantaj sağlar (Yang ve ark., 2023a).

3.2.4.2. Avantajları

Darknet-53'ün sunduğu en büyük avantajlardan biri, derinlik ve verimlilik dengesidir. 53 katmanlık derin bir yapıya sahip olmasına rağmen, residual bağlantılar

sayesinde hesaplama yükü ve eğitim süreci optimize edilmiştir. Bu yapı, modelin yüksek doğruluk oranlarına ulaşırken aynı zamanda hesaplama kaynaklarını verimli kullanmasını sağlar. Modelin residual bloklarla donatılması, eğitimin daha hızlı ve etkili bir şekilde gerçekleşmesine olanak tanır (Pathak ve Raju, 2023).

Modelin bir diğer önemli avantajı, özellik çıkarma kapasitesidir. Darknet-53, görüntülerdeki ince detayları yakalayarak daha karmaşık nesneleri bile doğru bir şekilde sınıflandırabilir ve tespit edebilir. Bu, özellikle karmaşık nesnelerin bulunduğu görüntü işleme görevlerinde büyük bir avantaj sağlar.

Eğitim verimliliği de Darknet-53'ün bir diğer güçlü yönüdür. Model, residual bağlantılar sayesinde derin yapısına rağmen kolayca eğitilebilir. Bu, büyük veri setleri ile çalışırken eğitim sürecini hızlandırır ve yüksek performans sağlar (Gongguo ve Junhao, 2021).

3.2.4.2. Kullanım Alanları

Darknet-53, özellikle nesne tespiti ve görüntü sınıflandırma gibi bilgisayarla görü uygulamalarında yaygın olarak kullanılmaktadır. Bu model, hızlı ve etkili sonuçlar üretebilmesi sayesinde güvenlik kameraları, otonom araçlar, medikal görüntüleme gibi gerçek zamanlı uygulamalarda kullanılmaktadır. Özellikle YOLOv3 (You Only Look Once) gibi nesne tespit sistemlerinde Darknet-53 mimarisi temel olarak kullanılır ve bu sayede nesnelerin hızlı bir şekilde tespit edilmesi sağlanır.

Ayrıca Darknet-53, büyük veri setlerinde yüksek doğruluk gerektiren görevler için de idealdir. Yapay zeka tabanlı görüntü işleme ve robotik uygulamalar gibi çeşitli alanlarda kullanılan model, güçlü yapısı sayesinde hem akademik çalışmalarda hem de endüstriyel projelerde yer bulmaktadır (Jiang ve ark., 2021).

Darknet-53'te $52 \text{ (residual bloklarda)} + 1 \text{ (giriş)} = 53$ konvolüsyon katmanı
Pooling Katmanları: Geleneksel pooling katmanı yok, stride 2 konvolüsyonlar kullanır.

Tüm modellere ait çıkış katmanı fonksiyonun katmanı aşağıda verildiği gibidir.

$$P(k = y|x) = \frac{e^{z_k}}{\sum_{j=1}^N e^{z_j}} \quad (3.1)$$

Burada:

- **zk:** k-inci sınıfa ait logit (lineer çıktı).
- **e:** Euler sayısı (yaklaşık 2.718).
- **N:** Toplam sınıf sayısı.
- **P(k=y | x):** K-inci sınıfa ait olasılık değeridir.



4. ARAŞTIRMA SONUÇLARI

4.1.Eğitim ve Değerlendirme

CNN modelleri, Matlab kullanılarak eğitilmiş ve test edilmiştir. Hastalardan alınan toplam 130 EMG görüntüsü kullanılmıştır. Bu görüntülerin sırasıyla %50, %60 ve %70'i eğitim amacıyla, kalan sırasıyla %30, %20 ve %10'u ise test amacıyla kullanılmıştır. Eğitim verisi olarak kullanılan CIDP teşhisine ait EMG görüntüleri, CNN mimarileri ile eğitilen modellerde sınıflandırılmış ve elde edilen doğruluk oranları hesaplanmıştır. Tüm modellerde öğrenme adımları 0.001 olacak şekilde elde edilmiştir. Aşağıdaki tabloda (Çizelge 4.1), her bir modele ait sınıflandırma sonuçları ve sırasıyla ilgili karışıklık matrisleri sırasıyla (Şekil 4.1, Şekil 4.2, Şekil 4.3, Şekil 4.4) verilmiştir.

Çizelge 4.1 CNN modellerine Ait Doğruluk Verileri

CNN Modeli	Doğruluk (%)		
	%50-50	%60-40	%70-30
“Resnet.50	100	100	100z
GoogleNet	90.6	100	94.7
EfficientNet-B0	100	100	100
Darknet-53	100	100	100

Performans metriklerinin hesaplamasını kullandığımız formüller aşağıda verildiği gibidir. Doğruluk formülü 4.1, Duyarlılık 4.2, Özgünlük 4.3 ve Yanlış Keşif Oranı 4.4 numaralı formüllerdir.


$$\text{Doğruluk} = \frac{TP+TN}{TP+TN+FP+FN} \times 100 \quad (4.1)$$

$$\text{Duyarlılık (TPR)} = \frac{TP}{TP+FN} \quad (4.2)$$


$$\text{Özgünlük (FPR)} = \frac{FP}{TN+FP} \quad (4.3)$$

$$\text{Yanlış Keşif Oranı (FNR)} = \frac{FN}{FN+TP} \quad (4.4)$$


- True Positive (TP): Modelin pozitif olarak doğru şekilde sınıflandırdığı örneklerdir.
- True Negative (TN): Modelin negatif olarak doğru şekilde sınıflandırdığı örneklerdir.
- False Positive (FP): Modelin pozitif olarak yanlış şekilde sınıflandırdığı örneklerdir.
- False Negative (FN): Modelin negatif olarak yanlış şekilde sınıflandırdığı örneklerdir.
- True Positive Rate (TPR): Pozitif olarak doğru sınıflandırılan örneklerin, toplam gerçek pozitif örnekler (TP + FN) içindeki oranıdır.
- False Positive Rate (FPR): Negatif olması gereken fakat pozitif olarak yanlış sınıflandırılan örneklerin, toplam negatif örnekler (TN + FP) içindeki oranıdır.
- False Negative Rate (FNR): Pozitif olması gereken fakat negatif olarak yanlış sınıflandırılan örneklerin, toplam gerçek pozitif örnekler (FN + TP) içindeki oranıdır.




Şekil 4.1 Resnet.50'ye Ait Karışıklık Matrisleri (a.%50-50, b.%60-40 c.%70-30)



Şekil 4.2 GoogleNET'ye Ait Karışıklık Matrisleri (a.%50-50, b.%60-40 c.%70-30)



Şekil 4.3 EfficientNet-B0'e Ait Karışıklık Matrisleri (a.%50-50, b.%60-40 c.%70-30)



Şekil 4.4 Darnet-53’de Ait Karışıklık Matrisleri (a.%50-50, b.%60-40 c.%70-30)

Karışıklık matrislerinde de görüldüğü gibi a,b,c şekillerinde sınıflandırma doğruluklarının %100’ze ulaştığı ve dolayısıyla hata oranlarının 0 olduğunu görmek mümkündür.

Çizelge 4.2 Resnet.50, EfficientNet-B0 ve Darnet-53 Performans Metrik Sonucu

Model	Doğruluk (%)	TPR	FPR	FNR
a	100	1	0	0
b	100	1	0	0
c	100	1	0	0

Çizelge 4.3 GoogleNet Performans Metrik Sonucu

Model	Accuracy (%)	TPR	FPR	FNR
a	90.0	0.90625	0.09375	0.09375
b	100.0	1.0	0.0	0.0
c	94.74	0.947	0.053	0.053

5. SONUÇLAR VE ÖNERİLER

5.1. Sonuç

Bu çalışma, Kronik İnflamatuvar Demyelinizan Poliradikülönöropati (CIDP) teşhisinde derin öğrenme tekniklerinin etkinliğini değerlendirmek amacıyla gerçekleştirilmiştir. EMG sinyal verileri kullanılarak yapılan analizler, ResNet-50, EfficientNet-B0 ve DarkNet-53 gibi Convolutional Neural Network (CNN) mimarilerinin CIDP teşhisinde yüksek doğruluk oranlarına ulaşabildiğini göstermiştir. Bu modellerin sağladığı sonuçlar, CIDP gibi karmaşık nörolojik hastalıkların teşhisinde derin öğrenme algoritmalarının güçlü birer araç olarak kullanılabileceğini ortaya koymaktadır.

Elde edilen bulgular, derin öğrenme tekniklerinin klinik uygulamalarda karar destek sistemi olarak kullanılma potansiyelini vurgulamaktadır. Ancak, bu çalışmada kullanılan veri setinin sınırlı büyüklüğü ve kullanılan modellerin optimizasyon süreçleri, sonuçların genellenebilirliği üzerinde etkili olabileceğinden, gelecekte daha geniş veri setleri ve farklı algoritmalarla yapılacak araştırmalara ihtiyaç duyulmaktadır. Sonuç olarak, bu çalışma, derin öğrenme modellerinin CIDP teşhisinde uygulanabilirliğini ve klinik pratikte kullanılabilirliğini destekleyen önemli bulgular sunmaktadır. Bu alandaki ilerlemeler, gelecekte nörolojik hastalıkların teşhis süreçlerini dönüştürebilir ve hastaların tedavi süreçlerini iyileştirebilir.

5.2. Öneri

Bu çalışma, Kronik İnflamatuvar Demyelinizan Poliradikülönöropati (CIDP) teşhisinde derin öğrenme algoritmalarının kullanımına dair önemli bulgular sunmakla birlikte, gelecekteki araştırmalar için bazı önerilerde bulunulması gerektiğini göstermektedir. İlk olarak, daha geniş ve çeşitli veri setlerinin kullanılması, derin öğrenme modellerinin güvenilebilirliğini artırabilir ve sonuçların doğruluğunu pekiştirebilir. Özellikle, farklı demografik gruplardan elde edilecek veriler, modellerin tüm hasta grupları için geçerliliğini değerlendirmede kritik bir rol oynayabilir.

KAYNAKLAR

- Acharya, U. R., Fernandes, S. L., WeiKoh, J. E., Ciaccio, E. J., Fabell, M. K. M., Tanik, U. J., Rajinikanth, V. ve Yeong, C. H., 2019, Automated Detection of Alzheimer's Disease Using Brain MRI Images- A Study with Various Feature Extraction Techniques, *J Med Syst*, 43 (9), 302.
- Ahmed, T. ve Sabab, N., 2022, Classification and Understanding of Cloud Structures via Satellite Images with EfficientUNet, *SN Computer Science*, 3.
- Ahuja, S., Panigrahi, B. K. ve Gandhi, T. K., 2022, Enhanced performance of Dark-Nets for brain tumor classification and segmentation using colormap-based superpixel techniques, *Machine Learning with Applications*, 7, 100212.
- Alam, U., Anson, M., Meng, Y., Preston, F., Kirthi, V., Jackson, T. L., Nderitu, P., Cuthbertson, D. J., Malik, R. A. ve Zheng, Y., 2022, Artificial intelligence and corneal confocal microscopy: the start of a beautiful relationship, *Journal of Clinical Medicine*, 11 (20), 6199.
- Allen, J. A., 2020, The Misdiagnosis of CIDP: A Review, *Neurology and Therapy*, 9 (1), 43-54.
- Aloysius, N. ve Geetha, M., 2017, A review on deep convolutional neural networks, *2017 international conference on communication and signal processing (ICCSP)*, 0588-0592.
- Amo, C., Santiuste, M., Maestú, F., Egatz, R., González-Hidalgo, M., Saldaña, C., Saiz, A. ve Ortiz, T., 2004, Temporal lobe seizure recorded by magnetoencephalography: Case report, *Archivos de neuro-psiquiatria*, 62, 737-740.
- Aslam, N., Khan, I. U., Bashamakh, A., Alghool, F. A., Aboulmour, M., Alsuwayan, N. M., Alturaif, R. a. K., Brahimi, S., Aljameel, S. S. ve Al Ghamdi, K., 2022, Multiple Sclerosis Diagnosis Using Machine Learning and Deep Learning: Challenges and Opportunities, *Sensors*, 22 (20), 7856.
- Battineni, G., Sagaro, G. G., Chinatalapudi, N. ve Amenta, F., 2020. Applications of Machine Learning Predictive Models in the Chronic Disease Diagnosis. *Journal of Personalized Medicine* 10, 2. Erişim Adresi.
- Benoit, C., Svahn, J., Debs, R., Vandendries, C., Lenglet, T., Zyss, J., Maisonobe, T. ve Viala, K., 2021, Focal chronic inflammatory demyelinating polyradiculoneuropathy: Onset, course, and distinct features, *Journal of the Peripheral Nervous System*, 26 (2), 193-201.
- Bjørklund, G., Đorđević, A. B., Hamdan, H., Wallace, D. R. ve Peana, M., 2023, Metal-induced autoimmunity in neurological disorders: A review of current understanding and future directions, *Autoimmunity Reviews*, 103509.
- Bron, E. E., Smits, M., van der Flier, W. M., Vrenken, H., Barkhof, F., Scheltens, P., Papma, J. M., Steketee, R. M. E., Méndez Orellana, C., Meijboom, R., Pinto, M., Meireles, J. R., Garrett, C., Bastos-Leite, A. J., Abdulkadir, A., Ronneberger, O., Amoroso, N., Bellotti, R., Cárdenas-Peña, D., Álvarez-Meza, A. M., Dolph, C. V., Iftekharuddin, K. M., Eskildsen, S. F., Coupé, P., Fonov, V. S., Franke, K., Gaser, C., Ledig, C., Guerrero, R., Tong, T., Gray, K. R., Moradi, E., Tohka, J., Routier, A., Durrleman, S., Sarica, A., Di Fatta, G., Sensi, F., Chincarini, A., Smith, G. M., Stoyanov, Z. V., Sørensen, L., Nielsen, M., Tangaro, S., Inglese, P., Wachinger, C., Reuter, M., van Swieten, J. C., Niessen, W. J. ve Klein, S., 2015, Standardized evaluation of algorithms for computer-aided diagnosis of dementia based on structural MRI: The CADDementia challenge, *NeuroImage*, 111, 562-579.

- Brun, S., de Sèze, J. ve Muller, S., 2022, CIDP: Current Treatments and Identification of Targets for Future Specific Therapeutic Intervention, *Immuno*, 2 (1), 118-131.
- Bunschoten, C., Jacobs, B. C., Van den Bergh, P. Y. K., Cornblath, D. R. ve van Doorn, P. A., 2019, Progress in diagnosis and treatment of chronic inflammatory demyelinating polyradiculoneuropathy, *The Lancet Neurology*, 18 (8), 784-794.
- Chang, C. W., Ro, L. S., Lyu, R. K., Kuo, H. C., Liao, M. F., Wu, Y. R., Chen, C. M., Chang, H. S., Weng, Y. C. ve Huang, C. C., 2022, Establishment of a new classification system for chronic inflammatory demyelinating polyneuropathy based on unsupervised machine learning, *Muscle & Nerve*, 66 (5), 603-611.
- Chen, Y. ve Qu, R., 2021, Study on infringement identification of art works based on CNN image recognition technology, *Journal of Physics: Conference Series*, 032084.
- Chichkova, R. I. ve Katzin, L., 2010, EMG and nerve conduction studies in clinical practice, *Pract Neurol*, 2010 (1), 32-38.
- Chroni, E. ve Kleopa, K. A., 2021, Editorial: Update on the Diagnosis and Management of CIDP Variants, *Frontiers in Neurology*, 12.
- Cuesta-Vargas, Á., Martín-Martín, J., Pérez-Cruzado, D., Cano-Herrera, C. L., Rodríguez, J. G., Merchán-Baeza, J. A. ve González-Sánchez, M., 2020, Muscle Activation and Distribution during Four Test/Functional Tasks: A Comparison between Dry-Land and Aquatic Environments for Healthy Older and Young Adults, *Int J Environ Res Public Health*, 17 (13).
- Dalakas, M. C., 2011, Advances in the diagnosis, pathogenesis and treatment of CIDP, *Nat Rev Neurol*, 7 (9), 507-517.
- Deng, Y., Chen, H., Liu, H. ve Li, Y., 2022, A voxel graph cnn for object classification with event cameras, *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 1172-1181.
- Divino, V., Mallick, R., DeKoven, M. ve Krishnarajah, G., 2018, The economic burden of CIDP in the United States: A case-control study, *PLOS ONE*, 13 (10), e0206205.
- Eftimov, F., Lucke, I. M., Querol, L. A., Rajabally, Y. A. ve Verhamme, C., 2020, Diagnostic challenges in chronic inflammatory demyelinating polyradiculoneuropathy, *Brain*, 143 (11), 3214-3224.
- Ekladios, A. ve Jiang, B., 2022, Motor neuron disease: to identify the mimics and chameleons at the early stage, *Int J Biomed Res Pract*, 2 (2).
- Esteva, A., Kuprel, B., Novoa, R. A., Ko, J., Swetter, S. M., Blau, H. M. ve Thrun, S., 2017, Dermatologist-level classification of skin cancer with deep neural networks, *nature*, 542 (7639), 115-118.
- Esteva, A., Robicquet, A., Ramsundar, B., Kuleshov, V., DePristo, M., Chou, K., Cui, C., Corrado, G., Thrun, S. ve Dean, J., 2019, A guide to deep learning in healthcare, *Nature Medicine*, 25 (1), 24-29.
- Fayaz, M., Nam, J., Dang, L. M., Song, H.-K. ve Moon, H., 2024, Land-Cover Classification Using Deep Learning with High-Resolution Remote-Sensing Imagery, *Applied Sciences*, 14 (5), 1844.
- Feldman, E. L., Russell, J. W., Löscher, W. N., Grisold, W. ve Meng, S., 2021, Polyneuropathies, In: *Atlas of Neuromuscular Diseases: A Practical Guideline*, Eds: Feldman, E. L., Russell, J. W., Löscher, W. N., Grisold, W. ve Meng, S., Cham: Springer International Publishing, p. 215-261.
- Gezer, M., Darıcı, M. ve Yıldırım, Ş., 2021, Brain Age Estimation from MRI Images using 2D-CNN instead of 3D-CNN, *ACTA INFOLOGICA*, 5 (2).

- Gongguo, Z. ve Junhao, W., 2021, An improved small target detection method based on Yolo V3, *2021 International Conference on Electronics, Circuits and Information Engineering (ECIE)*, 220-223.
- Gordon, D., Kembhavi, A., Rastegari, M., Redmon, J., Fox, D. ve Farhadi, A., 2018, Iqa: Visual question answering in interactive environments, *Proceedings of the IEEE conference on computer vision and pattern recognition*, 4089-4098.
- He, K., Zhang, X., Ren, S. ve Sun, J., 2016, Deep residual learning for image recognition, *Proceedings of the IEEE conference on computer vision and pattern recognition*, 770-778.
- Horiuchi, M., Hongo, Y., Yamazaki, K., Komuta, Y., Kadoya, M., Takazaki, H., Furuya, Y., Matsui, T., Sakamoto, N. ve Ikewaki, K., 2022, An atypical phenotype of chronic inflammatory demyelinating polyradiculoneuropathy associated with ocular palsy, IgM-anti ganglioside antibody, and fever-induced recurrence, *Internal Medicine*, 61 (8), 1247-1252.
- Hostin, M. A., Ogier, A. C., Michel, C. P., Le Fur, Y., Guye, M., Attarian, S., Fortanier, E., Bellemare, M. E. ve Bendahan, D., 2023, The impact of fatty infiltration on MRI segmentation of lower limb muscles in neuromuscular diseases: A comparative study of deep learning approaches, *Journal of Magnetic Resonance Imaging*, 58 (6), 1826-1835.
- Hu, J., Sun, C., Lu, J., Zhao, C. ve Lin, J., 2022, Efficacy of rituximab treatment in chronic inflammatory demyelinating polyradiculoneuropathy: a systematic review and meta-analysis, *Journal of neurology*, 269 (3), 1250-1263.
- Huang, Y., Lin, L., Cheng, P., Lyu, J., Tam, R. ve Tang, X., 2023, Identifying the key components in resnet-50 for diabetic retinopathy grading from fundus images: a systematic investigation, *Diagnostics*, 13 (10), 1664.
- Jain, M. C., Nadaraja, A. V., Vizcaino, B. M., Roberts, D. J. ve Zarifi, M. H., 2020, Differential Microwave Resonator Sensor Reveals Glucose-Dependent Growth Profile of E. coli on Solid Agar, *IEEE Microwave and Wireless Components Letters*, 30 (5), 531-534.
- Jiang, X., Gao, T., Zhu, Z. ve Zhao, Y., 2021, Real-time face mask detection method based on YOLOv3, *Electronics*, 10 (7), 837.
- Jo, T., Nho, K. ve Saykin, A. J., 2019, Deep Learning in Alzheimer's Disease: Diagnostic Classification and Prognostic Prediction Using Neuroimaging Data, *Frontiers in Aging Neuroscience*, 11.
- Jongbloed, B. A., Bos, J. W., Rutgers, D., van der Pol, W. L. ve van den Berg, L. H., 2017, Brachial plexus magnetic resonance imaging differentiates between inflammatory neuropathies and does not predict disease course, *Brain and Behavior*, 7 (5), e00632.
- Klöppel, S., Stonnington, C. M., Chu, C., Draganski, B., Scahill, R. I., Rohrer, J. D., Fox, N. C., Jack, C. R., Jr., Ashburner, J. ve Frackowiak, R. S. J., 2008, Automatic classification of MR scans in Alzheimer's disease, *Brain*, 131 (3), 681-689.
- Konduri, P. S. R. ve Rao, G. S. N., 2024, A transfer learning coupled framework for distortion classification in laparoscopic videos, *Multimedia Tools and Applications*, 83 (15), 45947-45968.
- Koonce, B. ve Koonce, B., 2021, ResNet 50, *Convolutional neural networks with swift for tensorflow: image recognition and dataset categorization*, 63-72.
- Kotan, D. ve Alemdar, M., 2016, Kronik inflamatuvar demiyelinizan nöropati ve meme kanseri: Ender bir birliktelik, *Uludağ Üniversitesi Tıp Fakültesi Dergisi*, 42 (2, 3), 99-101.

- Krizhevsky, A., Sutskever, I. ve Hinton, G. E., 2012, Imagenet classification with deep convolutional neural networks, *Advances in neural information processing systems*, 25.
- Kurian, S. M. ve Juliet, S., 2023, An automatic and intelligent brain tumor detection using Lee sigma filtered histogram segmentation model, *Soft Computing*, 27 (18), 13305-13319.
- Kuwabara, S., Misawa, S., Mori, M., Tamura, N., Kubota, M. ve Hattori, T., 2006, Long term prognosis of chronic inflammatory demyelinating polyneuropathy: a five year follow up of 38 cases, *J Neurol Neurosurg Psychiatry*, 77 (1), 66-70.
- Larson, S., Lim, G. ve Leach, K., 2023, On evaluation of document classification with rvl-cdip, *Proceedings of the 17th Conference of the European Chapter of the Association for Computational Linguistics*, 2665-2678.
- Latov, N., 2014, Diagnosis and treatment of chronic acquired demyelinating polyneuropathies, *Nature Reviews Neurology*, 10 (8), 435-446.
- Lehmann, H. C., Burke, D. ve Kuwabara, S., 2019, Chronic inflammatory demyelinating polyneuropathy: update on diagnosis, immunopathogenesis and treatment, *J Neurol Neurosurg Psychiatry*, 90 (9), 981-987.
- Li, S., Han, K., Costain, T. W., Howard-Jenkins, H. ve Prisacariu, V., 2020, Correspondence networks with adaptive neighbourhood consensus, *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 10196-10205.
- Li, Z., Liu, F., Yang, W., Peng, S. ve Zhou, J., 2021, A survey of convolutional neural networks: analysis, applications, and prospects, *IEEE transactions on neural networks and learning systems*, 33 (12), 6999-7019.
- Litjens, G., Kooi, T., Bejnordi, B. E., Setio, A. A. A., Ciompi, F., Ghafoorian, M., van der Laak, J. A. W. M., van Ginneken, B. ve Sánchez, C. I., 2017, A survey on deep learning in medical image analysis, *Medical Image Analysis*, 42, 60-88.
- Mascarenhas, S. ve Agarwal, M., 2021, A comparison between VGG16, VGG19 and ResNet50 architecture frameworks for Image Classification, *2021 International conference on disruptive technologies for multi-disciplinary research and applications (CENTCON)*, 96-99.
- Mathey, E. K., Park, S. B., Hughes, R. A., Pollard, J. D., Armati, P. J., Barnett, M. H., Taylor, B. V., Dyck, P. J., Kiernan, M. C. ve Lin, C. S., 2015, Chronic inflammatory demyelinating polyradiculoneuropathy: from pathology to phenotype, *J Neurol Neurosurg Psychiatry*, 86 (9), 973-985.
- Matur, Z., Kaymaz, A., Altunrende, B., Tunçer, S., Güngör-Tunçer, Ö., Demir-Akman, G. ve Öge, E., 2013, “Human immunodeficiency virus” enfeksiyonu ile ilişkili kronik inflamatuvar demiyelinizan poliradikülonöropati: Farklı klinik özellikler ve tanı sorunları.
- Nathani, D., Spies, J., Barnett, M. H., Pollard, J., Wang, M. X., Sommer, C. ve Kiernan, M. C., 2021, Nerve biopsy: Current indications and decision tools, *Muscle & Nerve*, 64 (2), 125-139.
- Nayak, D. R., Padhy, N., Mallick, P. K., Zymbler, M. ve Kumar, S., 2022, Brain tumor classification using dense efficient-net, *Axioms*, 11 (1), 34.
- Neligan, A., Reilly, M. M. ve Lunn, M. P., 2014, CIDP: mimics and chameleons, *Practical Neurology*, 14 (6), 399-408.
- Nenning, K.-H. ve Langs, G., 2022, Machine learning in neuroimaging: from research to clinical practice, *Die Radiologie*, 62 (1), 1-10.
- Nguyen, N. H., Picetti, D., Dulai, P. S., Jairath, V., Sandborn, W. J., Ohno-Machado, L., Chen, P. L. ve Singh, S., 2022, Machine Learning-based Prediction Models for

- Diagnosis and Prognosis in Inflammatory Bowel Diseases: A Systematic Review, *Journal of Crohn's and Colitis*, 16 (3), 398-413.
- Pathak, D. ve Raju, U., 2023, Shuffled-Xception-DarkNet-53: A content-based image retrieval model based on deep learning algorithm, *Computers and Electrical Engineering*, 107, 108647.
- Pitarokoili, K., Schlamann, M., Kerasnoudis, A., Gold, R. ve Yoon, M.-S., 2015, Comparison of clinical, electrophysiological, sonographic and MRI features in CIDP, *Journal of the Neurological Sciences*, 357 (1-2), 198-203.
- Poorani, S. ve Balasubramanie, P., 2023, Deep learning based epileptic seizure detection with EEG data, *International Journal of System Assurance Engineering and Management*.
- Raglio, A., Imbriani, M., Imbriani, C., Baiardi, P., Manzoni, S., Gianotti, M., Castelli, M., Vanneschi, L., Vico, F. ve Manzoni, L., 2020, Machine learning techniques to predict the effectiveness of music therapy: A randomized controlled trial, *Computer Methods and Programs in Biomedicine*, 185, 105160.
- Rehman, A., Naz, S. ve Razzak, I., 2022, Leveraging big data analytics in healthcare enhancement: trends, challenges and opportunities, *Multimedia Systems*, 28 (4), 1339-1371.
- Reynolds, J., George Sachs, M. ve Stavros, K., 2016, Chronic inflammatory demyelinating polyradiculoneuropathy (CIDP): clinical features, diagnosis, and current treatment strategies, *Rhode Island medical journal*, 99 (12), 32.
- Rizvi, D., Nissar, I., Masood, S., Ahmed, M. ve Ahmad, 2020, An LSTM based Deep learning model for voice-based detection of Parkinson's disease, 29, 337-343.
- Russakovsky, O., Deng, J., Su, H., Krause, J., Satheesh, S., Ma, S., Huang, Z., Karpathy, A., Khosla, A., Bernstein, M., Berg, A. C. ve Fei-Fei, L., 2015, ImageNet Large Scale Visual Recognition Challenge, *International Journal of Computer Vision*, 115 (3), 211-252.
- Shen, D., Wu, G. ve Suk, H.-I., 2017, Deep Learning in Medical Image Analysis, *Annual Review of Biomedical Engineering*, 19 (Volume 19, 2017), 221-248.
- Stewart, J. D., McKelvey, R., Durcan, L., Carpenter, S. ve Karpati, G., 1996, Chronic inflammatory demyelinating polyneuropathy (CIDP) in diabetics, *Journal of the Neurological Sciences*, 142 (1-2), 59-64.
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V. ve Rabinovich, A., 2015, Going deeper with convolutions, *Proceedings of the IEEE conference on computer vision and pattern recognition*, 1-9.
- Tan, M., 2019, Efficientnet: Rethinking model scaling for convolutional neural networks, *arXiv preprint arXiv:1905.11946*.
- Tanaka, K., Mori, N., Yokota, Y. ve Suenaga, T., 2013, MRI of the cervical nerve roots in the diagnosis of chronic inflammatory demyelinating polyradiculoneuropathy: a single-institution, retrospective case-control study, *BMJ Open*, 3 (8), e003443.
- Tang, P., Wang, H. ve Kwong, S., 2017, G-MS2F: GoogLeNet based multi-stage feature fusion of deep CNN for scene recognition, *Neurocomputing*, 225, 188-197.
- Tesfaye, S., 2007, Clinical features of diabetic polyneuropathy, *Diabetic neuropathy: clinical management*, 243-257.
- Theckedath, D. ve Sedamkar, R., 2020, Detecting affect states using VGG16, ResNet50 and SE-ResNet50 networks, *SN Computer Science*, 1 (2), 79.
- Uncini, A. ve Kuwabara, S., 2015, Nodopathies of the peripheral nerve: an emerging concept, *J Neurol Neurosurg Psychiatry*, 86 (11), 1186-1195.

- Valdez, P., 2020, Apple defect detection using deep learning based object detection for better post harvest handling, *arXiv preprint arXiv:2005.06089*.
- Vallat, J.-M., Sommer, C. ve Magy, L., 2010, Chronic inflammatory demyelinating polyradiculoneuropathy: diagnostic and therapeutic challenges for a treatable condition, *The Lancet Neurology*, 9 (4), 402-412.
- Van den Bergh, P. Y. K., Hadden, R. D. M., Bouche, P., Cornblath, D. R., Hahn, A., Illa, I., Koski, C. L., Léger, J. M., Nobile-Orazio, E., Pollard, J., Sommer, C., Van Doorn, P. A. ve Van Schaik, I. N., 2010, European Federation of Neurological Societies/Peripheral Nerve Society Guideline on management of chronic inflammatory demyelinating polyradiculoneuropathy: Report of a joint task force of the European Federation of Neurological Societies and the Peripheral Nerve Society — First Revision, *European Journal of Neurology*, 17 (3), 356-363.
- van Doorn, I. N., Eftimov, F., Wieske, L., van Schaik, I. N. ve Verhamme, C., 2024, Challenges in the Early Diagnosis and Treatment of Chronic Inflammatory Demyelinating Polyradiculoneuropathy in Adults: Current Perspectives, *Therapeutics and Clinical Risk Management*, 20 (null), 111-126.
- Van Schaik, I., Vermeulen, M., Van Doorn, P. ve Brand, A., 1994, Anti-GM1 antibodies in patients with chronic inflammatory demyelinating polyneuropathy (CIDP) treated with intravenous immunoglobulin (IVIg), *Journal of neuroimmunology*, 54 (1-2), 109-115.
- Wang, H., Zhang, F. ve Wang, L., 2020, Fruit classification model based on improved Darknet53 convolutional neural network, *2020 International Conference on Intelligent Transportation, Big Data & Smart City (ICITBS)*, 881-884.
- Wen, L., Li, X. ve Gao, L., 2020, A transfer convolutional neural network for fault diagnosis based on ResNet-50, *Neural Computing and Applications*, 32 (10), 6111-6124.
- Wolbert, J., Cheng, M. I., Meyer zu Horste, G. ve Su, M. A., 2020, Deciphering immune mechanisms in chronic inflammatory demyelinating polyneuropathies, *JCI Insight*, 5 (3).
- Xiong, Z., Wang, L., Zhao, Y. ve Lan, Y., 2023, Precision Detection of Dense Litchi Fruit in UAV Images Based on Improved YOLOv5 Model, *Remote Sensing*, 15, 4017.
- Yamamoto, T., Watanabe, M., Obuchi, T., Kobayashi, K., Oshima, H., Fukaya, C. ve Yoshino, A., 2017, Spinal Cord Stimulation for Vegetative State and Minimally Conscious State: Changes in Consciousness Level and Motor Function, *Trends in Reconstructive Neurosurgery*, Cham, 37-42.
- Yang, L., Chen, G. ve Ci, W., 2023a, Multiclass objects detection algorithm using DarkNet-53 and DenseNet for intelligent vehicles, *EURASIP Journal on Advances in Signal Processing*, 2023 (1), 85.
- Yang, L., Yu, X., Zhang, S., Long, H., Zhang, H., Xu, S. ve Liao, Y., 2023b, GoogLeNet based on residual network and attention mechanism identification of rice leaf diseases, *Computers and Electronics in Agriculture*, 204, 107543.
- Yuan, N., Duffy, G., Dhruva, S. S., Oesterle, A., Pellegrini, C. N., Theurer, J., Vali, M., Heidenreich, P. A., Keyhani, S. ve Ouyang, D., 2023, Deep Learning of Electrocardiograms in Sinus Rhythm From US Veterans to Predict Atrial Fibrillation, *JAMA Cardiology*, 8 (12), 1131-1139.
- Zhao, Z., Chuah, J. H., Lai, K. W., Chow, C. O., Gochoo, M., Dhanalakshmi, S., Wang, N., Bao, W. ve Wu, X., 2023, Conventional machine learning and deep learning

- in Alzheimer's disease diagnosis using neuroimaging: A review, *Front Comput Neurosci*, 17, 1038636.
- Zhou, F., Ma, Y., Wang, B. ve Lin, G., 2021, Dual-channel convolutional neural network for power edge image recognition, *Journal of Cloud Computing*, 10.



EKLER**EK-1** Kullanılan EMG Cihazının Açıklama Rehberi

Examination Guide

Neuropack *S3*
EMG/EP Measuring
System
MEB-9600



0614-007719C

 **NIHON KOHDEN**

EK-1 (Devamı)

About This Manual

In order to use this product safely and fully understand all its functions, read this manual before using the product.

Keep this manual near the instrument or in the reach of the operator and refer to it whenever the operation is unclear.

Accompanying Documentation

The MEB-9600 EMG/EP measuring system comes with the following manuals. Refer to the manual depending on your needs. Some of the manuals are only provided in PDF format. We recommend printing a copy of the electronic data for reference in case of emergency. If you require printed versions of the manuals, contact your Nihon Kohden representative.

Operator's Manual

Describes the operation and settings of the MEB-9600 EMG/EP measuring system. Read this manual before use.

Examination Guide (PDF only) (this manual)


Describes how to prepare, examine and handle data for EMG/EP measurement.

Service Manual

For qualified service personnel. Describes information on servicing the system.
Only qualified service personnel can service the system.

Trademark

The company name and model name are trademarks and registered trademarks of each company.



The mark printed on the SD card that is used in this instrument is a trademark.

Copyright Notice

The entire contents of this manual are copyrighted by Nihon Kohden. All rights are reserved. No part of this document may be reproduced, stored, or transmitted in any form or by any means (electronic, mechanical, photocopied, recorded, or otherwise) without the prior written permission of Nihon Kohden.

This product stores personal patient information. Manage the information appropriately.

Patient names on the screen shots and recording examples in this manual are fictional and any resemblance to any person living or dead is purely coincidental.

The contents of this manual are subject to change without notice.

If you have any comments or suggestions on this manual, please contact us at:
<https://www.nihonkohden.com/>

The CE mark applies to the MEB-9600 Op No. 00K and 00G EMG/EP measuring systems only.



EK-2 Selçuk Üniversitesi Tıp Fakültesi Hastanesi Dekanlığı Yerel Etik Kurul Kararı

Ek Tarih ve Sayısı: 15.02.2023-E.463572



T.C.
SELÇUK ÜNİVERSİTESİ REKTÖRLÜĞÜ
Yerel Etik Kurulu

Sayı : E-70632468-050.01.04-463572
Konu : Dr.Muhammet Serdar Başçıl (Etik Kurul Kararı)

15.02.2023

Sayın Doç. Dr. Muhammet Serdar BAŞÇIL

20.01.2023 tarihli "Kronik İnflamatuvar Demiyelinizan Polinöropati (CIDP) Hastalığının Teşhisinde Yapay Zeka Kullanımı" başlıklı araştırma projeniz, 14.02.2023 tarihli Yerel Etik Kurul Toplantısında görüşülmüş olup, kurulun konu ile ilgili 2023/94 sayılı kararı ekte sunulmuştur. Bilgilerinizi rica ederim.

Prof. Dr. Kamil Hakan DOĞAN
Etik Kurul Başkanı

Ek:Karar sureti (1 Sayfa)

Bu belge, güvenli elektronik imza ile imzalanmıştır.

Belge Doğrulama Kodu : *BSEARUNIR9* Pin Kodu : 98472

Belge Takip Adresi : <https://www.turkiye.gov.tr/selcuk-universitesi-ebys>

Adres : Akademi Mah. Yeni İstanbul Cad. No:313 Selçuk Üniversitesi Alaeddin Keykubad
Yerleşkesi Selçuklu - Konya 42250 Türkiye
Telefon : 3322412181 Faks : 3322412184
e-Posta:dekanliktip@selcuk.edu.tr Web:www.selcuk.edu.tr
Kep Adresi : selcukuniversitesi@hs01.kep.tr

Bilgi için : Burcu Tuğba ALDORA
Unvanı : Bölüm Sekreteri
Tel No : 3322243963



EK-2 (Devamı)

İh ve Sayısı: 15.02.2023-E.463572

T.C.
SELÇUK ÜNİVERSİTESİ
TIP FAKÜLTESİ DEKANLIĞI

YEREL ETİK KURULU KARARLARI

Toplantı Sayısı: 2023/04	Toplantı Tarihi :14.02.2023
--------------------------	-----------------------------

Karar Sayısı 2023/94 S.Ü. Teknoloji Fakültesi Biyomedikal Mühendisliği Anabilim Dalı Öğretim Üyesi Doç. Dr. Muhammet Serdar BAŞÇIL'ın "Kronik İnflamatuvar Demiyelinizan Polinöropati (CIDP) Hastalığının Teşhisinde Yapay Zeka Kullanımı" başlıklı araştırmasının değerlendirilme talebi ile ilgili 20.01.2023 tarihli dilekçesi ve ekleri görüşüldü.

Yapılan inceleme ve görüşmelerden sonra; Doç. Dr. Muhammet Serdar BAŞÇIL'ın "Kronik İnflamatuvar Demiyelinizan Polinöropati (CIDP) Hastalığının Teşhisinde Yapay Zeka Kullanımı" adlı araştırmasının kabulüne oy birliği ile karar verildi.

Yardımcı Araştırmacılar: Ahmet Hakan EKMEKÇİ, Hüseyin AKBUDAK.

NOT: 3359 sayılı Sağlık Hizmetleri Temel Kanunu Ek 10.madde hükümleri uyarınca; bazı çalışmalar için etik kurul onayı alındıktan sonra, Sağlık Bakanlığı veya bağlı kuruluşlarından (çalışmanın yapılacağı kurum) izin alınması zorunlu olduğundan araştırmacıların bu hususa dikkat etmeleri gerekmektedir.

ASLI GÜNDÜR
14.02.2023
Enfeksiyon Hastalıkları
Sekreteriye

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı : Hüseyin AKBUDAK
Uyruğu : T.C.

EĞİTİM

Derece	Okul Adı ve Bölüm	Bitirme Yılı	İlçe - İl
Lise	Konya M.T.A.L Biyomedikal C. Teknolojileri Alanı	2016	Meram - Konya
Üniversite	Ankara Üniversitesi Gama MYO Biyomedikal C. Teknolojileri Bölümü	2018	Keçiören - Ankara
Üniversite 2	Afyon Kocatepe Üniversitesi Biyomedikal Mühendisliği	2021	Merkez - Afyonkarahisar

İŞ DENEYİMLERİ

Yıl	Kurum Adı	Görev ve Pozisyon
2017-2019	Aser Biyomedikal Kalibrasyon LTD. ŞTİ.	Biyomedikal Kalibrasyon Personeli
2020-Halen	Yapılcan Sağlık Gereçleri LTD. ŞTİ.	Tıbbi Cihaz Aplikasyon Eğitim Satış Personeli

UZMANLIK ALANI

- Bilgisayar Bakım Onarım
- Tıbbi Cihaz Bakım Onarım
- Grafik Tasarım
- Tıbbi Bilişim Organizasyon
- Ultrason
- EMG/EGG

YABANCI DİLLER

BELİRTMEK İSTEĞİNİZ DİĞER ÖZELLİKLER

Biyomedikal Oryantasyon Derneği Kurucu Yönetim Kurulu Başkanı