



T.C.

**AFYONKARAHİSAR SAĞLIK BİLİMLERİ
ÜNİVERSİTESİ TIP FAKÜLTESİ
NÖROLOJİ ANABİLİM DALI**

**KARPAL TÜNEL ÖN TANILI HASTALARIN
YAPAY ZEKA KULLANILARAK
EMG ANALİZİ**

**Arş. Gör. Dr. Furkan YILMAZ
TIPTA UZMANLIK TEZİ**

**Danışman
Dr. Öğr. Üyesi Abdullah GÜZEL**

NÖROLOJİ ANABİLİM DALI

AFYONKARAHİSAR 2025

T.C
AFYONKARAHİSAR SAĞLIK BİLİMLERİ ÜNİVERSİTESİ
TIP FAKÜLTESİ

Nöroloji Anabilim Dalı

KARPAL TÜNEL ÖN TANILI HASTALARIN YAPAY
ZEKA KULLANILARAK EMG ANALİZİ

Arş. Gör. Dr. Furkan YILMAZ

TIPTA UZMANLIK TEZİ

Danışman

Dr. Öğr. Üyesi Abdullah GÜZEL

AFYONKARAHİSAR 2025

BİLİMSEL ETİĞE UYGUNLUK BEYANI

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

Dr. Furkan YILMAZ



KABUL ONAY SAYFASI

T.C

AFYONKARAHİSAR SAĞLIK BİLİMLERİ ÜNİVERSİTESİ

TIP FAKÜLTESİ

NÖROLOJİ ANABİLİM DALI

Tez başlığı: Karpal Tünel Ön Tanılı Hastaların Yapay Zeka Kullanılarak
EMG Analizi

Tezi Hazırlayan: Arş. Grv. Dr. Furkan YILMAZ

Tez Savunma Tarihi: 28.01.2025

Tez Kabul Tarihi: 28.01.2025

Tez Danışmanı: Dr. Öğr. Üyesi Üyesi Abdullah GÜZEL

İş bu çalışma jürimiz tarafından NÖROLOJİ ANABİLİM

DALI'nda TIPTA UZMANLIK TEZİ olarak kabul edilmiştir.

Başkan

Prof. Dr. Ülkü TÜRK BÖRÜ

Nöroloji AD

Üye

Dr. Öğr. Üyesi Elif Simin ISSI

Nöroloji AD

Üye

Dr. Öğr. Üyesi Abdullah GÜZEL

Nöroloji AD

ONAY

DEKAN

Prof. Dr. Necip BECİT

TEŞEKKÜR

Asistanlığa başladığım ilk günden bugüne kadar benden ilgisini ve tecrübelerini esirgemeyen çok değerli hocam Dr. Öğr. Üyesi Abdullah Güzel'e, kodlama ve yapay zeka konusunda bana bildiğim her şeyi öğreten Dr. Adem Gencer'e bizi bir aile gibi hissettiren ve desteklerini esirgemeyen değerli AFSÜ Nöroloji Bölümü hocalarıma, uzmanlık eğitimim süresince birlikte çalıştığım asistan arkadaşlarıma, rotasyonlarım sırasında bilgi ve tecrübelerinden yararlandığım tüm hocalarıma ve asistan arkadaşlarıma, benden desteklerini hiçbir zaman esirgemeyen ve benim bugünlere gelmem için çaba gösteren değerli eşime, kızıma anneme, babama sonsuz teşekkürlerimi sunarım.

Dr.Furkan YILMAZ
Afyonkarahisar, Ocak 2025

KARPAL TÜNEL ÖN TANILI HASTALARIN YAPAY ZEKA KULLANILARAK EMG ANALİZİ

Furkan YILMAZ

Afyonkarahisar Sağlık Bilimleri Üniversitesi

Tıp Fakültesi Nöroloji Anabilim Dalı Tıpta Uzmanlık Tezi

Ocak 2025

Danışman: Dr. Öğr. Üyesi, Abdullah GÜZEL

ÖZET

Amaç: Karpal tünel sendromu (KTS), genel popülasyonda en sık görülen kompresyon nöropatisidir ve tanısında EMG testi altın standarttır. Yapay zeka (YZ) ise sağlık hizmetlerinde devrim meydana getirerek daha doğru teşhis ve sınıflandırma sağlamıştır. Bu çalışmada, EMG parametrelerini YZ algoritmaları ile değerlendirerek YZ'nin sağlık sektöründeki kullanımını geliştirmeyi hedefliyoruz.

Gereç ve Yöntem: Çalışmada kullanılan veriler, 01.10.2011- 30.06.2023 tarihleri arasında hastanemizdeki Dahili Tıp Bilimleri Nöroloji Anabilim Dalı Elektronörofizyoloji Laboratuvarı'ndan toplanmıştır. Araştırmaya toplamda 1.649 hastaya ait her el için birer tane olmak üzere toplamda 3298 EMG verisi dahil edilmiştir. Toplanan ve ön işleme tabi tutulan EMG verileri, makine öğrenimi algoritmaları ile analiz edilmiştir. Bu çalışmada kullanılan makine öğrenimi algoritmaları arasında; “Decision Tree”, “K-Nearest Neighbour”, “Suport Vector Machine”, “Random Forest”, “Naive Bayes”, “CatBoost”, “Xgboost”, “Light GBM” yer almaktadır.

Bulgular: Tüm modellerin doğruluk oranları (accuracy) yüksek olmakla birlikte, özellikle CatBoost, Random Forest ve XGBoost modelleri en yüksek doğruluk oranlarını elde etmiştir (%90, %90, %89 sırasıyla). KNN ve Naive Bayes modelleri, doğruluk oranı açısından diğerlerine göre daha düşük performans sergilemiştir (%77, %79 sırasıyla).

Sonuç: Tezimizde kullanılan makine öğrenmesi metotları genel olarak karpal tünel tanısı ve derecesi tahmininde yüksek başarı göstermekle beraber özellikle “hafif KTS” ve “ağır KTS” grupları tahmininde bazı sınırlamalar olduğunu gösteriyor.

Anahtar Kelimeler: Derin Öğrenme, Elektromiyografi, Karpal Tünel Sendromu, Makine Öğrenmesi, Yapay Zeka

EMG ANALYSIS OF PATIENTS WITH PRELIMINARY DIAGNOSIS OF CARPAL TUNNEL SYNDROME USING ARTIFICIAL INTELLIGENCE

Furkan YILMAZ

Afyonkarahisar University of Health Sciences
Faculty of Medicine, Department of Neurology Thesis
January 2025
Advisor: Asst. Prof. Dr. Abdullah GÜZEL

ABSTRACT

Objective: Carpal tunnel syndrome (CTS) is the most common compression neuropathy, with electromyography (EMG) remaining the gold standard for diagnosis. Advances in artificial intelligence (AI) have revolutionized healthcare, enhancing disease classification, diagnosis, treatment, and prognosis. AI models have shown high accuracy in analyzing EMG signals. This study aims to evaluate EMG parameters using AI algorithms to advance their application in healthcare.

Materials and Methods: The data used in this study were collected from the Electroneurophysiology Laboratory of the Neurology Department of Internal Medicine at our hospital between October 1, 2011, and June 30, 2023. A total of 3,298 EMG records from 1,649 patients (one for each hand) were included in the study. The collected EMG data were preprocessed and analyzed using machine learning algorithms. The machine learning algorithms employed in this study include "Decision Tree," "K-Nearest Neighbour," "Support Vector Machine," "Random Forest," "Naive Bayes," "CatBoost," "XGBoost," and "Light GBM."

Results: Although the accuracy rates of all models were high, CatBoost, Random Forest, and XGBoost achieved the highest accuracy rates (90%, 90%, and 89%, respectively). KNN and Naive Bayes performed comparatively lower in terms of accuracy (77% and 79%, respectively).

Conclusion: The machine learning methods used in this thesis generally demonstrated high success in predicting CTS diagnosis and severity. However, the study highlights some limitations in predicting the "mild CTS" and "severe CTS" groups

Keywords: Deep Learning, Electromyography, Carpal Tunnel Syndrome, Machine Learning, Artificial Intelligence

İÇİNDEKİLER

BİLİMSEL ETİĞE UYGUNLUK BEYANI.....	ii
KABUL ONAY SAYFASI.....	iii
TEŞEKKÜR.....	iv
ÖZET.....	v
ABSTRACT.....	vi
İÇİNDEKİLER	vii
KISALTMALAR	x
TABLolar DİZİNİ	xi
ŞEKİLLER DİZİNİ.....	xii
1. GİRİŞ VE AMAÇ	1
2. GENEL BİLGİLER	2
2.1 Elektromiyografi (EMG).....	2
2.1.1 EMG Tanımı:.....	2
2.2.2 EMG Amaçları:.....	2
2.2.3 EMG Tarihçesi.....	2
2.2.4 Risk ve komplikasyonları	4
2.2.5- Teknik.....	7
2.2.3 EMG Raporu Hazırlama	19
2.2- Karpal Tünel Sendromu	20
2.2.1- Tarihçe.....	20
2.2.2- Tanım.....	21
2.2.3- Patofizyoloji	21
2.2.4- Etiyoloji	22
2.2.4- Tanı.....	22
2.2.4- Ayırıcı Tanılar	22

2.2.5- Klinik ve muayene.....	24
2.2.6- Görüntüleme	27
2.2.5- KTS Sınıflama	36
2.2.6- KTS için EMG sonuçlarının yorumlanması	40
2.2.6- KTS Tedavisi.....	41
2.3 Yapay Zeka (Artificial Intelligence, YZ, AI).....	45
2.3.1- Tanım.....	45
2.3.2- Makine Öğrenmesi (Machine Learning, ML)	46
2.3.3-Makine Öğrenimi (Machine Learning, ML) Algoritmaları.....	50
2.3.2- Derin öğrenme (deep learning, DL)	63
3. GEREÇ VE YÖNTEM	65
3.1- Çalışma grubu.....	65
3.2- Veri Toplama.....	65
3.3-Veri ön işleme	66
3.4- Eksik verilerin yönetimi.....	66
3.5- Veri Analizi.....	66
3.6- Performans ölçütleri:	67
3.7- Kullanılan Yazılımlar ve Araçlar	68
3.8- Güçlükler ve Sınırlamalar	68
3.9- Etik ve Yasal Uygulamalar	68
4. BULGULAR	69
4.1- XgBoost:	72
4.2- SVM:.....	72
4.3- Random Forest:	72
4.4- Naive Bayes:	73
4.5- LightGBM:.....	73
4.6- K-Nearest Neighbors (KNN):	73

4.7- Decision Tree:	73
4.8- CatBoost:.....	74
4.9- Confusion Matrix (Karmaşıklık Matrisi) değeriendirmesi:.....	74
4.10- Genel Doğruluk (Accuracy) Değeriendirmesi:	74
5. TARTIŞMA	75
6. SONUÇLAR	82
7. KAYNAKÇA.....	84



KISALTMALAR

EMG: Elektromiyografi

KTS: Karpal Tünel Sendromu

ML: (Makine Öğrenimi) Machine Learning

NCS: Sinir İletim Çalışması

AI: Yapay Zeka (Artificial Intellingence)

DT: Karar ağacı (Decision Tree)

RF: Karışık orman (Random Forest)

SVM: Destek vektör makine (Support Vector Machine)

SENIAM: Surface ElectroMyoGraphy for the Non-Invasive Assessment of Muscles

sEMG: Yüzeysel Elektromiyografi(Surface Electromiyography)

SNAP: Duyusal Sinir Aksiyon Potansiyeli

PS: Pronator Sendrom

MN: Median Sinir

CSA: Median Sinir Kesit Alanı (cross sectional area)

WFR: El Bileği- Ön Kol Oranı

MUR: Median Sinir-Ulnar Sinir oranı

FR: Düzleşme Oranı

AAN: Amerikan Nöroloji Akademisi

AANEM: Amerikan Nöromusküler ve Elektrodiagnostik Tıp Derneği

AAPMR: Amerikan Fiziksel Tıp ve Rehabilitasyon Akademisi

SNCS: Duyusal Sinir İletim Çalışması

APB: Abductor Pollicis Breves

TABLÖLAR DİZİNİ

Tablo 1- Hafif Derece KTS Grubu ML Algoritmaları Başarı Durumları	69
Tablo 2- Orta Derece KTS Grubu ML Algoritmaları Başarı Durumları	70
Tablo 3- Ağır Derece KTS Grubu ML Algoritmaları Başarı Durumları	70
Tablo 4- Normal Grup ML Algoritmaları Başarı Durumları	71
Tablo 5- ML Algoritmaları Accuracy Ve Cost Function Karşılaştırması.....	71



ŞEKİLLER DİZİNİ

Şekil 1- EMG cihazı bileşenleri (30)	8
Şekil 2- EMG cihazı dijital bileşenleri (30)	9
Şekil 3- Elektromiyografi elde etme akış diyagramı (32).....	10
Şekil 4- Amplifikasyon artışı ile DML (Distal motor latans) artışının gösterimi (28).....	11
Şekil 5- Farklı durumlara göre süpürme hızının revize edilmesi sonucu oluşan veri farkları (A. Morvan sendromu olan bir hastada, rutin tarama hızında (5 ms/D) kaydedilen F dalgası çalışmaları. B. Tarama hızı 20 ms/D'ye ayarlandığında, sonrasındaki deşarjlar tespit edilmiştir) (28).....	12
Şekil 6- Farklı band genişliklerinin oluşan EMG sinyali üzerine etkisi(28).....	16
Şekil 7- Örnekleme frekansının elde edilen emg dalgası üzerine etkisi	17
Şekil 8- EMG Rapor Örneği	19
Şekil 9- Karpal Tünel Anatomisi (41).....	21
Şekil 10- Falen ve Tinel Testi (51)	26
Şekil 11- Karpal Tünel ve Median Sinir USG Kesiti (53).....	28
Şekil 12- Median-Ulnar Yüzük Parmağı Antidromik Duyusal Latans Farkı Çekim Tekniği (45).....	33
Şekil 13- Median-Radial Başparmak Antidromik Duyusal Latans Farkı Çekim Tekniği(45).....	34
Şekil 14- Örnek KTS Sınıflaması-1(62)	38
Şekil 15- Farklı İletim Çalışmaları Referans Değerleri(60).....	38
Şekil 16-Örnek KTS Sınıflaması-2 (63)	39
Şekil 17- Örnek KTS Sınıflaması-3 (64)	39
Şekil 18- Örnek KTS Sınıflaması-4 (65)	40
Şekil 20- SVM Algoritması Hiper Düzlem Oluşturma Yöntemi (103)	55

1. GİRİŞ VE AMAÇ

Bu tez çalışmamız, hastanemizde karpal tünel sendromu ön tanısı almış hastaların elektromiyografi verilerini, makine öğrenimi teknikleriyle inceleyerek, bu alanda daha objektif, tutarlı ve maliyet-etkin yol haritaları oluşturmayı hedefliyor. EMG testlerini, nörolojik rahatsızlıkların teşhisinde oldukça yaygın bir biçimde kullanıyoruz ancak süreç hem hasta hem doktor için oldukça karmaşıklıklar ve belirsizlikler barındırıyor. Sonuçların değerlendirilmesi hastanın klinik durumu, testin uygulandığı merkez, kullanılan cihaz ve hatta doktorun deneyimi gibi pek çok faktörden etkilenebiliyor. Bu da sonuçları değerlendirme sürecinde subjektif yorumların ortaya çıkmasına neden oluyor.

Bu çalışma ile makine öğrenimi algoritmasının faydalarını öne çıkararak ve bu tür bir sistemin değerlendirme sürecinde kullanılmasının daha dikkatli ve doğru sonuçlar elde etmemizi sağlayacağını savunuyoruz. Bu sayede, hastaların tedavi süreçlerinin optimizasyonu ve memnuniyetlerinde bir artış oluşmasını hedeflemekteyiz.

Bunun yanı sıra makine öğrenimi destekli bir değerlendirme sistemi, EMG testlerinin maliyet-etkinliğini önemli ölçüde artırma kapasitesine sahiptir. Klasik EMG değerlendirmeleri, doktorların zaman ve dikkatini gerektiren bir süreç olup, uzun vadede, ek olarak randevu sistemi nedeniyle geciken tedavi sürelerini de hesap ettiğimizde, yüksek maliyetlere yol açabilmektedir. Ancak yapay zeka destekli bir sistem, süreci otomatikleştirerek hem zaman tasarrufu sağlar hem de maliyetleri düşürür. Bu tez çerçevesinde karpal tünel sendromu ön tanısı almış hastaların EMG verilerini kullanarak, çeşitli makine öğrenimi modelleri oluşturacağız ve bu modellerin doğruluk oranı ile klinik uygulamaya uygunluklarını değerlendireceğiz. Makine öğrenimi algoritmalarının performansını karşılaştırarak en etkili modeli belirleyip ve bu modelin klinik uygulamalarda nasıl kullanılabileceği ile ilgili çalışacağız. Bu tür bir sistemin uygulama olanakları ve maliyet analizi, hasta sonuçları üzerindeki etkisi gibi konular da tezimizde incelenecektir.

2. GENEL BİLGİLER

2.1 Elektromiyografi (EMG)

2.1.1 EMG Tanımı:

Elektrodiagnostik değerlendirme, motor nöron bozuklukları, radikülopatiler, mononöropatiler, periferik nöropatiler, nöromüsküler kavşak bozuklukları ve miyopatiler dahil olmak üzere nöromüsküler bozuklukların tanı ve tedavisinin değerlendirilmesinde kullanılan bir nörodiagnostik çalışmadır.

Bir elektromiyografi çalışması 2 bölümden oluşur:

- 1- Motor veya duyuşal sinir tepkilerini kaydetmek için yüzey elektrik stimülasyonunu kullanan sinir iletim çalışması.
- 2- Kaslara yerleştirilen bir iğne elektrot aracılığıyla kas aktivitesinin değerlendirilmesini içeren iğne elektromiyografisi.

2.2.2 EMG Amaçları:

Nöromüsküler hastalık düşünülen bir hastada EMG, aşağıdaki amaçlar için kullanılmalıdır;

- 1-Klinik tanıyı doğrulamak
- 2-Alternatif tanıları dışlamak
- 3- Etkilenen anatomik bölgeyi belirlemek
- 4- Hastalığın şiddet derecesini göstermek
- 5-Patofizyoloji hakkında fikir vermek
- 6-Patolojinin olduğu lokasyonu belirlemek
- 7- Hastalığın zamana bağlı progresyon/regresyon durumu veya tedaviye verilen cevabı incelemek (1).

2.2.3 EMG Tarihçesi

Elektromiyogramın gelişimi 1666 yılında Francesco Redi'nin araştırması ile başladı. 1773 yılına gelindiğinde ise Walsh yılan balığı kas dokusunun elektrik

üretebileceğini göstermiştir. A. Galvani tarafından yazılan 'De Viribus Electricitatis in Motu Musculari Commentarius' adlı yayın ise 1792 yılında elektriğin kas kasılmalarını başlatabileceğini göstermiştir. 1890 yılında da Marey ilk kas aktivitesi kaydını yapmayı başarmıştır.

Cram ve arkadaşları elektromiyografi terimini ortaya atmış ve pektoralis majör kasının aktivasyonunu bipolar derivasyonda klasik yüzey elektromiyografisi (sEMG) kullanarak klaviküler ve sternokostal bölgelerden elde etmiştir. 1922 ise yılında Gasser ve Erlanger, kas elektrik potansiyellerini osiloskop yardımı ile göstermeyi başarmıştır.

Miyoelektrik sinyalin değişken yapısı, bu sinyallerden sadece kaba bilgiler elde edilebilmesine neden olmuştur ama kas sinyallerini ölçüm teknikleri ilerleyen yıllarda gelişim kaydetmeye devam ederek ilerlemesini sürdürmüştür. Daha belirgin bozuklukların tedavisi için 1960'larda yüzey elektromiyogramının klinik kullanımı başlamıştır. sEMG ilk olarak 1966 yılında Hardyck ve araştırmacıları tarafından kullanılmıştır. Cram ve Steger 1980'lerin başında elektromiyogram cihazı kullanarak çeşitli kasların taranması için klinik bir yöntem geliştirmiştir. EMG cihazlarının daha küçük ve taşınabilir olması ve seri üretimine geçmek için 1980'lerin ortalarına kadar elektrotlardaki entegrasyon teknikleri gelişmeye devam etmiştir. Bugün ise yeterli sayıda amplifikatör cihazı ticari olarak mevcuttur. 1980'lerin başında, istenen mikrovolt aralığında artefakt üretebilen kablolar ortaya çıkmıştır. Son 15 yılda yapılan çalışmalar ise EMG cihazlarının çalışma prensibinin ve kayıt özelliklerinin daha iyi anlaşılabilmesine olanak sağlamıştır.

Elektromiyogramın kullanımı için birçok uygulama vardır. Elektromiyogram klinik olarak nörolojik ve nöromusküler tanı aracı olarak kullanılır. Yürüme laboratuvarları, biofeedback veya ergonomik değerlendirme ile eğitilmiş klinisyenler tarafından tanısal olarak kullanılır. Konunun başında şu duruma da değinmek gerek ki EMG çekim tekniği diğer birçok tetkikteki zıt olarak çoğu merkezde halen net bir standardizasyona ulaşamamıştır. Bu durumun oluşmasında, kullanılan ekipmanların etkisi olduğu gibi çekim tekniklerinin farklılıklarının da etkisi bulunmaktadır. Standardizasyona dair bazı çalışmalar olsa bile bunların tamamlanması pek mümkün görünmemektedir (2-7).

Sinir iletimi ve elektromiyografi çalışmaları genellikle komplikasyonsuz seyreder. Bununla birlikte, bazı hastalar ve belirli incelemeler daha yüksek

komplikasyon potansiyeli taşımaktadır. Hastaları her türlü risk, bunların potansiyel ciddiyeti ve göreceli sıklığı hakkında bilgilendirmek, EMG öncesi yapılması gerekli olan bir uygulamadır. Bilgilendirilmiş onam almak için çalışmaların niteliği, amacı ve etkileri hakkında hasta ile yüz yüze konuşma gerçekleştirilmelidir, böylece hastalar işlemin artı ve eksi yönlerini kendi iradeleri ile değerlendirerek önerilen araştırmaya girmek isteyip istemediklerine karar verebilirler. Ayrıca, elektrik çarpması tehlikesini önlemek için ekipmanın uygun şekilde bakımının yapılması ve güvenlik testinden geçirilmesi, aynı şekilde teknisyenlerin elektrodagnostik çalışmaları yürütmek için uygun şekilde eğitilmesi ve yetkinliklerinin kanıtlanması gibi durumlarda sorun yaşanması, potansiyel yanlış yorumlama veya tanıya yol açabilir. Bu durum da hastalar için önemli riskler taşır, ancak bu konulara bu bölümde değinilmeyecektir (8,9).

2.2.4 Risk ve komplikasyonları

2.2.4.1- Temel Hususlar

Elektrodagnostik çalışmaların genellikle iyi tolere edilebildiği literatür çalışmalarında yaygın bir şekilde görülmektedir. En sık yan etki ağrı, rahatsızlık ve kanama olarak bildirilmiştir ama öte yandan bu durumların tedavisiz düzelmesi ve işlem sonrası kalıcı etki bırakmaması yüz güldürücüdür.

2020 yılında yapılan bir çalışmada en sık yan etkiler iğneye bağlı olarak görülmüştür. Kendini sınırlayan hafif hassasiyet ve/veya morarma gibi advers olaylar genellikle standart bir iğne elektromiyografi (EMG) incelemesinden sonra sıkça görülmektedir. Özellikle daha önce duyarlılaşmış olan bazı hastalar supramaksimal elektrik stimülasyonunu veya iğne EMG'yi tolere edemeyebilir. Hastaya EMG incelemesinin ön tanıları azaltarak tanı konusunda yardımcı olabileceği anlatılmakla birlikte, mesela radikulopati tanısında manyetik rezonans görüntüleme kullanımı gibi alternatif tanı yöntemleri hakkında da bilgilendirme yapılmalıdır. Presenkop ve senkop, nispeten nadir de olsa elektronörofizyologlar tarafından yan etki olarak görülmektedir (9-12).

2.2.4.1- Enfeksiyonlar

Tarihte iğne EMG'ye bağlı yumuşak doku enfeksiyonları sporadik olarak bildirilmiştir ancak çok nadirdir. Tanımlanan enfeksiyöz patojenler arasında *Staphylococcus epidermidis* ve yeniden kullanılabilen iğnelerle meydana gelen *Mycobacterium fortuitum* salgını bulunmaktadır ama bu enfeksiyonlar hafif ve kendini

sınırlayan şekilde seyretmiştir. Zaten yeniden kullanılabilir iğneler, tek kullanımlık iğnelerin tek lif EMG'nin sınırlı bant aralığındaki jitter çalışmaları için efektif kullanımının gösterilmesinden sonra popülerliğini yitirmiştir. Tek kullanımlık iğne elektrodu, iğne EMG testi sırasında aynı hastada birden fazla kasa giriş yapmak için kullanılır bununla birlikte aynı hastaya tek bir iğne elektrodu ile birden fazla giriş yapmanın enfeksiyon riskini artırdığını gösteren hiçbir kanıt yoktur. İğne yerleştirilmeden önce cildin dezenfeksiyon ajanları ile tedavi edilmesinin enfeksiyon riskini azaltıp azaltmadığı bilinmemektedir. Bağışıklık sistemi zayıf hastalarda enfeksiyon riski ve profilaktik antibiyotiklerin rolü ve endokardit riski henüz bilinmemektedir. Cildin aşınması ve kendinden yapışkanlı elektrotlar, özellikle çok genç, yaşlı veya hassas hastalarda cilde zarar verebilir ve teorik olarak lokal cilt enfeksiyonuna yol açabilir veya duyarlı bir hastada bir enfeksiyon giriş kapısı olarak işlev görebilir. Yapıştırıcı yüzey elektrotları hassas cilde uygulandığında daha sonra çıkarılmaları cilt yarası oluşturabilir. Kırık ve potansiyel olarak enfekte olmuş cilde (örn. dekübit ülseri) uygulama yapmaktan kaçınılması tavsiye edilir (13,14).

2.2.4.2- Lenfödem

Ciddi lenfödemi olan ekstremitelerde iğne EMG yapılmasının teorik olarak enfeksiyon riskini artırabileceği düşünülmüştür. Bedenin herhangi bir yerinde ciddi ödem olan hastalarda iğne elektrotlarla cildin ponksiyonu seröz sıvının sızmasına yol açabilmektedir. Bununla birlikte, lenfödem durumunda veya bölgesel lenf nodu rezeksiyonu sonrasında yapılan EMG ile ilgili selülit, enfeksiyon veya diğer komplikasyonlara ilişkin yayınlanmış bir rapora rastlanmamıştır (15).

2.2.4.3- Pnömotoraks

EMG'nin potansiyel olarak ciddi bir komplikasyonu, plevral boşluk içinde hava girmesi olarak bilinen pnömotoraktır. EMG sonrası gelişen pnömotoraksın insidansı bilinmemektedir, ancak yayınlanmış raporların azlığına dayanarak nadir olduğu düşünülmektedir. Pnömotoraks önlenebilir bir komplikasyondur ve sağlık hizmeti maliyetlerinin artması ve hastanede yatış süresinin uzamasına sebep olur. Pnömotoraks riski ileri yaşlarda, solunum yolu hastalığı olanlarda ve kortikosteroid tedavisi alan hastalarda artmaktadır (16, 17).

2.2.4.4- Kanama, hematoma ve kompartman sendromları

EMG iğnelerinin kaslara yerleştirilmesi çoğunlukla iyi tolere edilir ve belirgin bir kanama görülmez ya da çok azdır. Eş zamanlı olarak ortaya çıkan çok çeşitli tıbbi durumlar arasında trombositopeni (trombositlerin 50.000/mm³'ün altında olması), kronik böbrek yetmezliği ve koagülopatiler (edinsel veya kalıtsal) invaziv prosedürler sırasında kanama riskinin artmasıyla daha sık ilişkilidir. Aynı şekilde antikoagülasyon, anti-trombosit ajanlar ve diğer bazı ilaçlar (örn. non-steroid anti-inflamatuar ilaçlar ve reçetesiz bitkisel ilaçlar) kullanan kişilerde de iğne EMG ardından anlamlı miktarda kanama görülebilir. Literatürde ciddi hematoma ve sekonder ileri derecede kompartman sendromlarına ilişkin çok az sayıda vaka raporu bulunmaktadır; bunların çoğu da edinilmiş kanama bozuklukları olan hastalardır (18).

2.2.4.5- Gebe hastada EMG yönetimi

Gebe hastalarla ilgili yapılan çalışmalarda gerek yüzeysel EMG veya iğne EMG gerekse uyarılmış potansiyel çalışmalarında gebelik kaynaklı herhangi bir komplikasyon bildirilmemiştir (16).

2.2.4.6- Elektriksel duyarlılığı bulunan hastalar

Yoğun bakım hastalarının elektrikle hassasiyet kazanmasının en sık rastlanan sebepleri derinin normal koruyucu tabakasının kateterler tarafından delinerek kateter bölgesinden sızıntı olması ve kalbi çevreleyen koruyucu perikardit tabakasının kalp içi kateterler ve harici kalp pili kabloları tarafından bypass edilmesi ve böylece normalde zararsız olan akımların kalbe doğrudan iletilerek potansiyel olarak ölümcül hale gelmesidir. Cilt bariyerinin bozulduğu durumlarda hastalar, sağlam bir cilt bariyerine sahip hastalarda zararsız olan küçük akım kaçaklarına duyarlı hale gelebilirler. İmplant kalp pilleri (ICP) ve implant kalp defibrilatörleri (ICD) hem algılama hem de stimülasyon işlevine sahiptir. Teorik olarak, iletim çalışması sırasında stimülasyon anormal bir kardiyak ritim olarak algılanabilir ve bu da kalp pillerinin gereksiz şok vermesine neden olabilir. Yirmi hasta üzerinde yapılan küçük bir çalışma, antekübital fossa veya el bileğinden rutin iletim çalışması yapıldığında kardiyak iletim anormallikleri, kalp pilleri veya kardiyak defibrilatörlerin arızalanması riski olmadığını öne sürmüştür (19-23).

2.2.5- Teknik

2.2.5.1- Sinir İletim çalışmaları (Nerve Conduction Studies, NCS) tekniği

Periferik sinirler, duyuşal ve motor bilgileri omurilik, deri ve ekstremite kasları arasında çift yönlü olarak iletir. Herhangi bir periferik sinir hasarı meydana geldiğinde, nöronal hücre gövdesine iletilen ilk hasar belirtisi, proksimale doğru yayılan intra-aksonal kalsiyum akımıdır. Daha sonraki sinyal oluşumuna nörotrofinlerin ve sitokinler gibi bazı proteinlerin, özellikle de aksonal hasar bölgesinden hücre gövdesine retrograd taşınması neden olur. Bu iki sinyal birlikte, nöronların rejeneratif bir fenotipe geçmesini tetikler ve gen ekspresyonundaki değişiklikler nöron büyümesini uyaran bir dizi moleküler değişikliklerle sonuçlanır. Sinirlerin direkt elektrik uyarımına ilişkin ilk çalışmalar, yüksek miktarda akson filizlenmesinin, daha hızlı kas reinnervasyonu ve daha hızlı fonksiyonel iyileşme ile korele olduğunu göstermiştir (24-27).

Altta yatan mekanizmalar şunlardır;

1. Akson yöneliminin doğruluğu ve motor ve duyuşal hedeflerin birbirleri ile karışmadan reinnervasyonu
2. Aksonların cerrahi uygulama bölgesini daha hızlı sürede geçmesi ve bu bölgede akson uzama hızında değişiklik olmaması
3. Anahtar nörotrofik faktörlerin up-regulasyonu

NCS, tek bir sinirin, sinir içindeki tüm aksonları depolarize etmek için yeterli miktarda elektrik akımı ile uyarıldığı bir tekniktir. Sinirlerin direk elektrik uyarımına ilişkin ilk çalışmalar, akson filizlenme miktarında artış, daha hızlı kas yenilenmesi ve daha hızlı fonksiyonel iyileşme etkisi göstermiştir. Elektriksel stimülasyonun aksonal yenilenme üzerine hızlı bir başlangıç etkisi olduğu gösterilmiş ama uyarım süresini 1 saatten 2 haftaya çıkarmak şeklinde yapılan deneyler, ilk durumun aksine, iyileşme açısından negatif etkide bulunmuştur.


Bilgisayar teknolojisi ve veri analitiğindeki son gelişmeler, büyük boyutlarda veri kaydı ve makine öğrenimi alanını da ortaya çıkarmıştır. Bu yeni alan, genomik ve diğer omik verilerin (biyolojik çalışma verileri) yanı sıra elektronik sağlık verilerini bir araya getirme ve kombine etme potansiyeline sahiptir (28).

Hazırlık: Enstrümantasyon ve teknik konular elektromiyografi pratiğinde önemli bir rol oynar. Genellikle çoğu tıbbi tetkikte mevcut olan artefakt konusu, EMG alanında da kendine yer bulmuştur. Her incelemede olduğu gibi, artefaktan arındırılmış yüksek kaliteli sonuçlar EMG incelemesinde de önemlidir. Buna ek olarak, enstrümantasyon ve kayıt standardizasyonunun, EMG çalışmaları sonuçlarının laboratuvarlar arasında da karşılaştırılmasını sağlayacağı düşünülmektedir. Bu tarz standartlar tek tip bir uygulama sağlayacak ve araştırma çalışmaları için hasta seçimini iyileştirecektir.

Günümüzde elektrodiagnostik inceleme için tek bir standardizasyon sunan kılavuz sayısı çok az miktardadır. EMG kılavuzu açısından şu an kabul edilen mevcut uzlaşma raporu, “Klinik Nörofizyoloji Uygulaması için Öneriler: Uluslararası Klinik Nörofizyoloji Federasyonu Kılavuzu”nda yer alan son raporun güncellenmiş halidir. Bu raporda, 1999 tarihli raporda olduğu gibi amplifikatörler, filtreler ve enstrümantasyon gibi teknik konular ayrıntılı olarak ele alınmıştır. Ancak, bu bölümler son on yılda teknolojiye kaydedilen gelişmelere paralel olarak güncellenmiştir.


Ekipmanlar: Günümüz EMG cihazlarında amplifikatör, stimülatör, kontrol paneli ve bir bilgisayar içeren özel bir donanım birimi bulunmaktadır ve bu yerleşim EMG cihazını sabit tutarken bilgisayar sisteminin taşınma veya güncellenmesine olanak sağlamaktadır (28,29).

A.



Şekil 1- EMG cihazı bileşenleri (30)


B.



Şekil 2- EMG cihazı dijital bileşenleri (30)

EMG cihazlarında en önemli parçayı amplifikatörler ve stimulatörler oluşturmaktadır. Bazı EMG cihazları ek olarak ultrasonografi özelliği de içermektedir. Herhangi bir makinenin genellikle göz ardı edilen, ancak önemli bir yönü, ayak ve el kontrollerini de içeren ergonomisi ve kontrol paneli işlevleridir. Yeni bir EMG sistemi kurulurken cihaz ayarlamaları, doktor, teknikerler, hastane teknik servisinden oluşan bir heyet tarafından tayin edilmelidir.

Yeni cihaz satın alınırken ise öncelikli olarak tetkik doğruluğu için cihaz kalitesi, kullanım kolaylığı ve maliyet göz önüne alınarak uzun yıllar kullanılabilir bir cihaz alınması heyet tarafından da değerlendirilerek göz önünde bulundurulmalıdır.



Şekil 3- Elektromiyografi elde etme akış diyagramı (32)

Bilgisayar Donanımı: Çoklu ekranlar EMG sinyallerinin ve verilerinin radyolojik görüntülemeler gibi diğer verilerle eş zamanlı olarak incelenmesine izin verir.

İşlemci hızı ve RAM kapasitesi: Minimum sistem gereksinimleri EMG üreticisi firma tarafından belirtilecektir.

Harddisk boyutu: Bu miktar da üretici firma tarafından belirtilecek olup eğer veriler yerel olarak depolanacaksa, tahmini hasta sayısına göre boyut belirlenmelidir. Genellikle bir süre sonra daha fazla depolama alanına ihtiyaç duyulur, bu durumda disk değişimi gerekebilir.


Hoparlör: Kaliteli inceleme için EMG donanım birimi olmadan EMG sinyallerinin sese dönüştüren bir hoparlör kullanılması gereklidir. İyi bir ses kalitesi özellikle iğneli incelemeler için şarttır.

Yazıcı: Bağımsız veya ağa bağlı şekilde kullanılabilir.


Bilgisayar Yazılımı: Analiz yazılımı yapılması planlanan tetkikler, yerel uygulama ve referans limitleriyle uyumlu olmalıdır ve sinyal kalite kontrolü gibi yardımcı işlevleri içermelidir. Kullanılan algoritmalarla uyumlu şekilde görselleştirilmiş referans limitleri, sonuç tabloları, sinyaller, metin, renk ayarlaması

gibi ayarlamaları yaparak sonuç verebilmelidir, şart olmamakla birlikte sesli kontrol bazı işlevler için kullanılabilir. Uzaktan görüntüleyici, canlı kayıtların başka bir bilgisayardan uzaktan görüntülenmesi planlanıyorsa kullanılabilir. EMG ekipmanı tarafından kullanılan veritabanı motorunun kullanılacak sunucuyla uyumlu olduğu mutlaka kontrol edilmelidir. İşletim sistemi de üretici firma tarafından belirtilecektir.

EMG makinesi ayarı, kontrol verilerinin laboratuvar tarafından alındığı zamanki ayarlarla aynı olacak şekilde ayarlanmalıdır. Sinyal büyütme oranı ve sinyal süpürme hızı, dalga formlarının ekranda birbirlerinin üstüne binmeden ve net olarak seçilebilir şekilde görüntülenmesini sağlamak için uygulama sırasında ayarlanmalıdır.



Şekil 4- Amplifikasyon artışı ile DML (Distal motor latans) artışının gösterimi (28)



Şekil 5- Farklı durumlara göre süpürme hızının yenilenmesi sonucu oluşan veri farkları (A. Morvan sendromu olan bir hastada, rutin tarama hızında (5 ms/D) kaydedilen F dalgası çalışmaları. B. Tarama hızı 20 ms/D'ye ayarlandığında, sonrasındaki deşarjlar tespit edilmiştir) (28)

Emg donanım ve yazılımı: Elektrodiagnostik sistemin birincil işlevi, çeşitli biyolojik sinyalleri doğru bir şekilde kaydetmek ve analiz etmektir. Optimal bir sinyal/gürültü oranına sahip olmak, yani geri plandaki gürültüyü azaltırken nörofizyolojik sinyal voltajını yükseltmek doğru sonuç için önem arz etmektedir. Bu işlem analog ve dijital sinyal işleme teknikleri kullanılarak yapılmaktadır. Sinyal ve gürültü, yüzey veya iğne elektrotları aracılığıyla kaydedilir; elektrot uçları ve kablo aracılığıyla amplifikatör girişine taşınır. Ama maalesef bu bileşenler bir anten gibi davranarak daha fazla gürültü oluşmasına neden olabilir.

Bir diferansiyel amplifikatörün görevi de analog filtrelerin yardımıyla istenmeyen gürültüyü azaltırken sinyali büyütmesidir. Yükseltilemeyen sinyal bir analogdan dijital dönüştürücü (ADC) kullanılarak ölçülür ve voltaj değerleri bir dizi sayı olarak saklanır bu şekilde elektriksel veri sayısal değere dönüştürülerek dijital ortamda kayıt tutulabilmesi sağlanır.

Dijital filtreler, ortalama, yumuşatma gibi bazı işlemler artefaktı azaltır. Başka diğer işlemler ise NCS'de gecikme, genlik ve alan gibi ölçümler yapar. Daha karmaşık algoritmalar iğne EMG'sindeki MUP'ları tespit edebilir. Sinyal özellikleri, analog donanımla veya dijital teknoloji kullanılarak üretilen sinyal sesinden de değerlendirilir.

EMG cihazı ayrıca sinirleri ve kasları uyarmak için stimölasyon parçalarına da sahiptir. Uyarı elektriksel, görsel veya işitsel biçimde olabilir. Manyetik alan, temas ısısı gibi diğör uyarım biçimlerini sağlayan triggers adı verilen harici cihazlar, sinyalleri EMG cihazına aktarması için uygun zamanlama ile cihaz ile koordine edilebilir. Bunun için cihazlar dijital sinyalleri analog forma dönüştürmek için bir dijital-analog dönüştürücü (DAC) kullanır. Bu elde edilen veriler araştırmacının analog sinyalleri yeniden örnekleme ve kendi analizleri için algoritmalar geliştirmek istediğı araştırmalarda kullanılabilir. EMG ekranı sinyalleri, ölçüm sonuçlarını ve amplifikatör ve stimölator ayarlarını gösterir. Amplifikatör ve stimölator ayarları, kontrol paneli üzerinden fare veya bilgisayar klavyesi aracılığıyla yazılım komutları kullanılarak değıştirilebilir. Bazı cihazlarda ayak pedalı kullanılarak ölçüm başlatılabilir.

Yazılım, sinyal işleme ve sinyallerin sonucunu sayısal değör olarak içeren rapor oluşturma işlemlerinden sorumludur. Elde edilen veriler kullanılarak veri tabanları oluşturulabilir ve sonrasında incelemek için kullanılabilir fakat kişisel verilerin korunmasına ilişkin yönetmeliklerdeki yapılan sürekli değışiklikler ilerleyen zamanlarda bu konu açısından yasal bir sorun teşkil edebilir (28).

Verilerde elektrofizyolojik olmayan veriler de kaydedilmelidir, mesela hastanın vücut sıcaklık derecesi olası yanlış sonuçlar açısından veriler arasında yer almalıdır, video kamera, bilişsel işlev değörlendirme test sonucu gibi değörlerin test sonuç verilerinde yer alması gerekse de bu girdiler elektrofizyolojik değör taşımadıkları için konumuz dışında yer almaktadır.

Amplifikatör: Amplifikatörlerin ve filtrelerin özellikleri EMG sinyallerinin kalitesini belirler. Bu nedenle amplifikatörler, EMG sisteminin en kritik parçası olarak düşünölebilir. Amplifikatörlerin görevi E1 veya E2 girişlerindeki gerilimi yükseltmek değöl, iki giriş arasında oluşan gerilim farklarını büyüterek aradaki farkı belirginleştirmektir.

Bir amplifikatörü kaliteli yapan birkaç önemli özellik vardır:

1. Yüksek 'ortak mod' reddetme oranı
2. Yüksek giriş empedansı olması
3. Sinyal kaynağına kısa mesafede bulunması
4. Güçlü DC sinyal bastırma özelliğı olması

Elektrot: Kas kasılması nedeniyle oluşan biyolojik potansiyeli tespit etmek için elektrotlar kullanılır. EMG sinyalleri bağımsız olarak veya kas hareketinin daha iyi anlaşılması için yararlı olan diğer biyolojik sinyallerle birlikte analiz edilebilir.

Elektrot sayısı tercih edilen EMG türüne göre değişmektedir. Elektrot malzemesi, konfigürasyon ve boyut gibi özellikler, her bir uygulamada dikkate alınması gereken değişkenlerdir. Elektrotlar “aktif” “referans” ve “toprak” olarak isimlendirilir. Aralarında sadece 'toprak' terimi net olarak zihinde canlanmamaktadır. Toprak elektrot, voltaj ölçümü için referans noktası olarak kullanılan amplifikatör devresindeki bir noktayı ifade eder. Referans elektrodun elektriksel olarak sessiz olduğu varsayılır ancak elektrokardiyogram gibi büyük hacimli iletken potansiyelleri kaydederek oluşması muhtemel bir artefaktın önüne geçer. Referans elektrot elektriksel olarak sessiz olduğu düşünülen bir alana konulur. Terimlerin karışıklığı ve kökenleri göz önüne alındığında, amplifikatöre yapılan üç bağlantı için 'E10, 'E20 ve 'E00 terimleri önerilmektedir. Çoğu sistemde bu girişler siyah (E1), kırmızı (E2) ve yeşil (E0) renk kodludur. SENIAM (Surface ElectroMyoGraphy for the Non-Invasive Assessment of Muscles) kılavuzları yüzey elektrotlarının yerleştirilmesi için altın standart olarak kabul edilmektedir ve aynı tür incelemeler için birden fazla standardize edilmiş yöntem mevcuttur.

Yapılan bazı çalışmalar yapılan aynı tür incelemelerdeki farklı elektrot yerleşim yerlerini karşılaştırmış ve anlamlı fark bulamamış fakat çalışma grubunun sayısının arttırıldığı yeni çalışmaların yapılmasını da önermişlerdir. Son uzlaş raporu göre, eğer amaç tek MUP'ların hem merkezi hem de çevresel özelliklerini araştırmaksa, sEMG sinyali izometrik kasılmalar sırasında küçük çaplı (0,5- 3 mm) yakın aralıklı (2,5-10 mm) yoğun miktarda kayıt alabilen elektrotlar tarafından kaydedilmelidir. Ek olarak, kayıt elektrotlarının sayısı ve dağılımı, MUP'ların kas lifleri boyunca yayılımını doğru bir şekilde yansıtabilmesi için yeterli olmalıdır (28,34- 36). Daha ayrıntılı EMG elektrot yerleşimi ve teknikleri, 'Karpal tünel sendromu' başlığında incelenecektir.

Filtreler: Genel olarak artefakt azaltma yöntemleri sonuca etki ederek yanlış yönlendirmelere neden olabilen istem dışı oluşan artefaktların mümkün olabildiğince azaltılmasını hedefler.

Tipik bir sEMG sinyalinin genliđi 10 ila 500 Hz; frekans aralıđı ise 0 ila 10 mV arasındadır. Artefakt oluřturabilen her bir faktör kendine özđü genlik ve frekans özelliklerine sahip olduđu için, her bir faktörü azaltmak için kullanılan yöntemler bu duruma göre deđişkenlik gösterecektir.


Geleneksel dijital filtreler: Band geçiren (band pass) filtreler, alçak geçiren (low pass) filtreler ve yüksek geçiren (high pass) filtrelerdir.

Alçak geçiren (low pass) filtreler: sEMG spektrumu 500 Hz'e kadar olan dalgalardan oluşur. Bu nedenle, frekansı 500 Hz'den büyük olan herhangi bir sinyal gürültü olarak kabul edilir. Genellikle bu gürültü beyaz Gauss gürültüsü özelliklerine sahiptir. Bu gürültüyü gidermek için neredeyse her zaman 400 ila 500 Hz arasında kesme frekansına sahip alçak geçiren filtre kullanılır. Alçak kesme frekansının değeri çok kritik deđildir hatta EMG sinyallerinin maksimum frekansından çok ařađı bir değerde olabilir çünkü 350 Hz üzerindeki artefakt miktarı çok düşüktür.

Yüksek geçiren (high pass) filtreler: Yüksek geçiřli filtrenin kesme frekansı alçak filtrelere göre daha önemlidir çünkü bazı artefaktlar EMG sinyalleri ile ortak frekanslara sahiptir. Örneđin, vücudun hareketinden kaynaklı hareket artefaktları 20 Hz'ye kadar çıkabilirken, kablolardan kaynaklı artefaktlar 50 Hz'ye kadar çıkabilir. Bu tür artefaktları filtrelemek için arařtırmacılar birkaç farklı kesme frekansı (5-30 Hz arası) önermiřlerdir. Ama maalesef optimal değeri aralıđının yapılan işleme göre deđiřmesi nedeniyle ortak bir filtreleme aralıđı oluřturulamamıřtır. En son yapılan çalışmalar 2010 yılında sEMG sinyallerinden hareket artefaktlarını ve arka plan gürültüsünü filtrelemek için kullanılan üç kesme frekansını (10-20-30 Hz) karřılařtırmıřtır ve kullanılan kesme frekansının hem uygulamaya hem de çalışılan kasa göre belirlenmesi gerektiđi sonucuna varmıřlardır. Bununla birlikte, 20 Hz'nin altındaki kesme frekanslarında EMG sinyalinin artefakta oranla çok geri planda kaldıđını savunarak 20 Hz'den daha düşük kesme frekanslarının önerilmediđini de belirtmiřlerdir ve genel prosedürlerce de en az iki filtre kullanımının uygun olduđuna da değinilmiřtir. Ayrıca repetitif testler için de 20 Hz üzeri kesme frekansları uygun bulunmamıřtır.

Band kesen (band stop) filtreler: PLI (Powerline interference, enerji hattı giriřimi), EMG cihazının harici güç kaynađının elektromanyetik dalgalanması nedeniyle oluşan sEMG'nin başlıca artefaktıdır. PLI'yı kaldırmanın en ulařılabilir ve kolay yolu belirli bir merkez frekans ve yayılım miktarının belirlendiđi (genellikle 60 Hz merkez

frekans) band kesen filtre kullanımıdır. Bu tür bir filtre sinyalin spektrumunda bir "çentik" oluşturur. PLI kaynaklı oluşan harmonik artefaktlarını temizlemek için birden fazla band kesen filtre veya her harmonik frekansta dar aralıkta filtreleme bantları oluşturabilen tarak filtresi (comb filter) kullanılır ama literatürde tarak filtrelerinin kullanımına dair çalışma bulunmamaktadır. Ayrıca band kesen filtrelerin 20-40 Hz bandında kardiyak artefaktları önlemek için kullanıldığına dair çalışmalar da bulunmaktadır; fakat bazı çalışmalar 20 Hz band kesen filtrelerin kardiyak artefaktı engelleme konusunda uygun olmadığını ortaya koymuştur (37,38).




Şekil 6- Farklı band genişliklerinin oluşan EMG sinyali üzerine etkisi (28)

Dijital ekipmanlar: EMG cihazı, veri örnekleme, depolama ve sinyal işleme için bilgisayar kullanır. Analog sinyal yükseltildikten sonra, analogdan dijitale dönüştürücü cihaz(ADC), sinyali hem zaman hem de amplitüd olarak ayrıştırır ve tanımlanan noktalarda amplitüde dijital bir değer atar. Sonsuz sayıda olan zaman ve amplitüd değerlerinin belirli bir zaman ve sayı aralığında ekrana yansıtılabilmesi, sonsuz sayıda dijital genlik değerinin değerlendirilmesi ile gerçekleştirilebilir, böyle

bir durum mümkün olmadığı için de sadece belirli zamanlardaki sinyal değeri dijital ortama aktarılabilir. Bu dönüştürme işleminde iki önemli ölçüt karşılanmalıdır; ilk olarak örnekleme frekansı orijinal analog sinyali güvenli bir şekilde yansıtması için yeterince yüksek olmalıdır, ikincisi ise genliğin sayısallaştırılması, asıl sinyalin genliğini dijital alanda doğru bir şekilde yansıtmak için yeterince hassas olmalıdır. Bu durum aşağıdaki örnekte gösterilmiştir. 1 Hz ve 1 mV değerlerine sahip 'A şeklinde' gösterilen dalga, dalgadan daha düşük bir örnekleme frekansı ile 'B şeklinde' oluşturulmaya çalışılmış ama örnekleme frekansının yetersiz olması sonucu elde edilen dalganın frekansı, gerçek dalgadan daha düşük elde edilmiştir. Bu duruma 'aliasing' adı verilir.

Bu nedenli kural olarak örnekleme frekansı, gerçek dalganın tespit edilen en yüksek frekansının en az iki katından fazla olmalıdır, genellikle 2-5 kat arası tercih edilir. Sinyalin en yüksek frekansını tespit etmek için genelde analog bir 'Anti-aliasing' filtresi kullanılır (33).



Şekil 7- Örnekleme frekansının elde edilen emg dalgası üzerine etkisi

(Panel A: Frekansı 1 Hz ve genliği 1 mV olan analog sinüs sinyali

Panel B: 0.9 Hz ile örnekleme, aliasing'e yol açar ve elde edilen analog sinyal 0.1 Hz'lik bir sinüs dalgasıdır.

Panel C: 100 Hz frekansla örnekleme, ancak 3 bitlik bir AD dönüştürücü ile yapılır, bu da 5 dijital genlik değeri üretir. Bu durum sinyalin temsil edilmesini önemli ölçüde bozar.

Panel D: 100 Hz ile örneklenen dijital sinyal, 8 bitlik bir AD dönüştürücü ile alınmıştır, burada analog sinyal artık dijital ortamda güvenilir bir şekilde temsil edilebilmektedir.) (33)

Dijital sinyal analizi: EMG'nin görsel analizini tamamlamak için çeşitli nicel araçlar kullanılabilir. Bununla birlikte, deneyimli bir nörofizyoloğun dikkatli bir görsel veya işitsel değerlendirme ile sonuçları yorumlayabilmesi de mümkündür.

Spektral analiz (sıklık analiz) yöntemi: Yüzey EMG'si spektral analiz için kullanılabilir. Hasta sabit bir güç uyguladığında, gücün yoğun olarak uygulandığı dalganın spektral analizi yapılır, süre devam ettikçe elde edilen dalganın ortalama ve median frekansları tipik olarak azalmaya başlar. İğne EMG ise sabit kuvvet altında MUP'ların frekans analizinde frekans dağılımının, miyopatilerde daha yüksek frekanslara; nörojenik bozuklukları olan hastalarda ise daha düşük değerlere doğru kaydığını göstermiştir.

Tur- amplitüd analiz yöntemi: Bu teknikte, sinyalin amplitüdü, farklı kasılma seviyeleri için 'tur' sayısının karşılığına gelen değerde belirlenir. Bir "tur" >1001 V'luk voltajın tersine dönmesi olarak tanımlanır ve eğer girişim paterni çok sayıda dönüşe sahipse dikenli görünecek ve anormal sesler çıkaracaktır. Buradaki dağılım da normal değerlerle karşılaştırılarak miyopatik ve nörojenik paternler ayırt edilebilir.

Geciktirme hattı: Tek bir aksiyon potansiyelinin diğer aksiyon potansiyellerinden izole edilmesini ve böylece şeklin daha net bir şekilde analiz edilmesini ve onaylanmasını sağlar. Her bir aksiyon potansiyeli taramayı tetikledikten sonra geciktirilerek, o üniteye her deşarj olduğunda ekranda aynı konumda görünmesi sağlanır.

Sinyal averajlama ve artefakt engelleme: 1970'lerde sinyal averajlama yani tek bir sinyal yerine birden fazla sinyal alıp bu sinyallerin ortalamasını alma yönteminin yaygın olarak benimsenmesi, sinir iletim çalışmalarında, sinyal/artefakt oranında önemli bir ilerleme kaydedilmesini sağlamıştır. Averajlama öncesi ise birden fazla dalga örneği alındıktan sonra dalgalar üst üste konularak inceleme yapılıyordu. Bu yöntem günümüzde iletim çalışmalarından daha ziyade 'uyarılmış potansiyeller' alanında kullanıldığı için bu konuya ayrıntılı olarak bu bölümde yer verilmemiştir.

2.2.3 EMG Raporu Hazırlama

Standart bir EMG raporu sinir iletim çalışmaları ve iğne EMG'nin tüm bulgularını özetlemek durumundadır.

EMG Raporu			
BAŞVURU SAHİBİNİN			
Adı Soyadı		Cinsiyet - Yaş	Kadın 53
Hasta No	4866549	T.C. Kimlik No	
İsteyen Bölüm	Nöroloji	Uygulayan Bölüm	Nöroloji
İsteyen Doktor	Prof.Dr. ÜLKÜ TÜRK BÖRÜ	Onaylayan Doktor	Dr. Öğr. Üyesi Abdullah Güzel
İstek Tarihi	12/12/2024 09:41:00	Onay Tarihi	

Klinik bulgu: Sağ el median sinir dermatomu ile uyumlu gece artan uyuşukluk ve ağrı hissi. 36,5 °C

NC Data

MNCS					
Nerve	Lat	Amp		CV	F-M
	ms	mV	%	m/s	Ms
Medianus Motor Sol					
Wrist - APB APB	3.03	8.3			
Elbow-Wrist APB	6.19	7.9	-4.8	63.3	
Medianus Motor Sağ					
Wrist - APB APB	3.77	10.6			
Elbow-Wrist APB	7.06	10.2	-3.8	66.9	
Ulnaris Motor Sol					
Wrist - ADM ADM	1.98	9.2			
Bl. elbow-Wrist ADM	4.83	8.7	-5.4	52.6	
Ab. elbow-Bl. elbow ADM	5.98	8.5	-2.3	69.6	
Ulnaris Motor Sağ					
Wrist - ADM ADM	2.21	8.0			
Bl. elbow-Wrist ADM	5.36	7.4	-7.5	57.1	
Ab. elbow-Bl. elbow ADM	6.40	7.2	-2.7	67.3	

Sensory Nerve Conduction Studies

SNCS						
Nerve	Lat		Amp		CV	
	PLat	Lat	NAmp	PPAmp	m/s	mm
Medianus Duyusal Sol						
Wrist - Dig II	3.19	2.02	35.2	48.7	59.4	120
Medianus Duyusal Sağ						
Wrist - Dig II	3.92	2.92	26.7	39.4	41.1	120
Ulnaris Duyusal Sol						
Wrist - Dig IV	2.51	1.84	44.2	47.4	51.6	95.0
Ulnaris Duyusal Sağ						
Wrist - Dig IV	2.38	1.72	30.1	32.4	58.1	100

Bulgular

Bu incelemede sağda median sinir distal latansında uzama kaydedilmiştir. Sağda median sinir DSAP iletim hızında yavaşlama kaydedilmiştir.

Sonuç:

Mevcut bulgular sağ elde orta düzeyde karpal tünel sendromu ile uyumlu değerlendirildi.

Raporlayan
Teknisyen Dilek Karakuvvet

Onaylayan
Dr. Öğr. Üyesi Abdullah Güzel

Şekil 8- EMG Rapor Örneği

EMG raporu iki temel üzerine hazırlanır;

1. İğne EMG ve NCS sonuçlarına ilişkin hangi bilgiler raporda yer edinmelidir?
2. Bu bilgileri sunmanın en iyi yolu nedir?

EMG raporu aşağıda yer alan bilgileri ihtiva etmelidir;(1)

- 1- Klinik özet: Rapor, EMG çalışması için sevk nedenini açıklamalıdır. Bazı raporlar kısa bir klinik öykü ve muayene bulguları içerir, bazıları ise eski EMG rapor sonuçlarını belirtebilir. Ayrıca elektrofizyolog da çalışma yapılmadan önce her zaman kısa bir öykü ve muayene gerçekleştirmelidir.
- 2- Sinir iletim tablosu: Bu tablo, çalışılan her sinir için sinirin adı, kayıt bölgesi ve elde edilen verilerin sayısal değerleri dahil olmak üzere ayrıntıları listeler.
- 3- Sıcaklık: Soğuk uzuv EMG sonuçlarını etkileyebileceği için uygun bir rapor cilt sıcaklığını da içermelidir.
- 4- İğne elektromiyografi tablosu: Bu tabloda incelenen her bir kas ve o kasla ilgili bulgular listelenir. Genelde kullanılan sütunlar; giriş aktivitesini, fibrilasyon ve fasikülasyon potansiyellerinin varlığını ve derecesini ve istemli MUP parametrelerini içerir.
- 5- Bulguların özeti: Bu bölümde ilgili anormallikler veya anormalliklerin yokluğu klinik yorumu destekleyecek şekilde özetlenir. Ve bölüm genellikle, kısa segment stimülasyonu sırasında fokal yavaşlama varlığı veya eğer varsa iletim bloğu ve bölgesi veya repetitif sinir uyarımı sırasında dekrement varlığı ve derecesi gibi tablolarda yakalanamayan spesifik bilgileri içerir.
- 6- Klinik yorum: Bu bölüm, elektromiyografi uzmanının EMG çalışmasındaki bulgularını klinik senaryo bağlamında yorumladığı ve hastanın durumuna ilişkin görüşlerini sunduğu raporun kilit bölümüdür.


2.2- Karpal Tünel Sendromu

2.2.1- Tarihçe

Karpal tünel sendromu (KTS) ilk olarak 1854 yılında Paget tarafından el bileği ekleminde travma sonrası tuzak nöropatisi olarak bildirilmiştir. 1960'larda Phalen, idiyopatik KTS'yi gündeme getirmiş ve bu sendromun tanınırlığını arttırmıştır. Günümüzde KTS en sık görülen periferik nöropati olarak kabul edilmektedir ve prevalansının genel popülasyonda %0,2-4 arasında değiştiği bildirilmektedir (39).

2.2.2- Tanım

KTS, median sinirin karpal tünel içinde dar bir osteofibröz kanaldan geçerken el bileğinde sıkışması nedeniyle elin median sinir inervasyon alanında oluşan ağrı, uyuşukluk şikayetleri ve median sinir aracılığı ile inerve edilen kaslarda fonksiyon kaybı ile seyreden bir periferik nöropatik hastalıktır. KTS, birinci parmağın palmar tarafı, ikinci, üçüncü parmak ve dördüncü parmağın radyal yarısı dahil olmak üzere median sinir dağılımlarında ağrı ve parestezi ile karakterize bir hastalıktır. Ayrıca hassasiyet, el becerisi ve işlevsellik kaybı da semptomlar arasındadır. Bununla birlikte, belirti ve semptomlar değişkenlik göstermekte ve hastalığın ciddiyet düzeyi ile korelasyon göstermemektedir. KTS'nin genel nüfustaki yaygınlık oranı yetişkinler arasında %7-16 arasında değişmekte olup, en sık 40-60 yaş arasındaki kadınlar etkilenmektedir ve beyaz ırkta siyah ırka göre daha fazla müşahade edilmektedir (40).



Şekil 9- Karpal Tünel Anatomisi (41)

2.2.3- Patofizyoloji

KTS'nin altında yatan patofizyolojik mekanizmalar henüz tam olarak belirlenememiştir, ancak karpal tünel içindeki interstisyel sıvı basıncı ve komşu dokulardan median sinir üzerinde devamlı bir temasın rol oynadığı bilinmektedir.

Yumuşak bağ dokularının kalınlığının artması ve iltihaplanma, karpal tünel içinde median sinirin sıkışmasına ve KTS'ye neden olabilir. Karpal tünel içindeki hiper-interstisyel basıncın, periferik median sinirin el bileğinde karpal tünel içindeki seyri boyunca sıkışıp çekilmesini ve miyelin kılıfta mekanik hasar oluşturduğu tahmin edilmektedir. KTS'de eğer aksonal kayıp saptanırsa bu durum geri dönüşümsüz olarak kabul edilir ve cerrahi operasyon için bir endikasyon oluşturur (42).

2.2.4- Etiyoloji

KTS vakalarının çoğunluğu idiyopatik olmakla birlikte, çeşitli etiyolojileri araştırmak için kapsamlı araştırmalar yapılmıştır. Potansiyel risk faktörleri arasında travma, radyokarpal artrit ve tekrarlayan el hareketleri yer almaktadır. Ayrıca sıklıkla obezite, yaş ve kadın cinsiyet de etiyolojiler arasında yer bulmaktadır, bunun dışında inflamatuvar tenosinovit (inflamatuvar romatizma, lupus ve enfeksiyon, metabolik tenosinovit), primer veya sekonder amiloidoz, gut ve kondrokalsinoz, sıvı dağılımı anormallikleri, gebelik, hipotiroidizm ve kronik böbrek yetmezliği (arteriovenöz fistül), karpal tünel içi tümör varlığı, hematoma (hemofili, antikoagülan kullanımına bağlı kanama, el bileği travması), oral kontraseptifler, artrit, kollajen-vasküler hastalıklar, diyabet, hipotiroidizm ve el bileğinin tekrarlayan hareketlerinin uygulandığı mesleklerden birine mensup olmak KTS etiyolojisinde sayılabilir.(43)

2.2.4- Tanı

KTS tanısı için mükemmel bir tanı yöntemi yoktur. Semptomlar ve sinir iletim çalışması bulgularının kombinasyonu şu anda en doğru tanıyı sağlamaktadır. USG ve MR genellikle KTS'nin sekonder nedenlerini dışlamak için kullanılır. Klinik ve elektrofizyolojik testlerle yapılan değerlendirmede net bir sonuç elde edilemediğinde radyolojik tetkikler yol gösterici olabilmektedir (44).

2.2.4- Ayırıcı Tanılar

2.2.4.1- Martin -Gruber anastomozu

İlk olarak Martin tarafından 1763 ve Gruber tarafından 1870'te tanımlanmıştır. Martin-Gruber anastomozu ön kolda median ve ulnar sinirler arasında nöral bir bağlantıdır. Median ve ulnar sinirler arasında motor veya duysal lifler taşıdığı düşünülmektedir. Sinir liflerindeki anastomozun prenatal dönemde oluşan sinyal

bozukluğu ile korele şekilde oluşmuş ve bu bozukluğun doğum sonrasında da devam etmiş olduğu düşünülmektedir. Median sinirin ana dalı, ulnar sinirle birleşmeden önce yüzeysel olarak fleksör digitorum superficialis veya fleksör digitorum profundus kaslarının yüzeyinden geçer. Median sinirin bu dalı daha sonra ulnar sinirle birlikte ele gider ve ulnar kasları tenar bölgede (birinci dorsal interosseöz, fleksör pollicis brevis ve/veya adduktor pollicis) veya hipotenar eminensde ya da her ikisinde birden innerve eder. Bazı çalışmalarda insidansı %15,7 olarak bildirilmiştir. Bu varyasyonların bilinmesi, median ve ulnar sinir lezyonlarından şüphelenilen vakalarda iğne elektromiyografi ve sinir iletim çalışmalarının doğru yorumlanması için büyük önem taşımaktadır aksi takdirde bu durum yanlış yorumlara kapı açabilir.

EMG de Martin -Gruber anastomozunu tanımanın en temel bulgusu proksimal median motor iletim amplitüdünün, distal median motor iletim amplitüdünden daha yüksek saptanmasıdır. Bu durum ortaya çıkarsa, öncelikle proksimal median motor bölgesinin doğrudan ulnar sinire yayılan akımla aşırı uyarılması veya distal median uyarım bölgesinde yetersiz uyarım (yani supramaksimal olmayan uyarı) dışlanmalıdır.

EMG'de anastomozu gösteren başka bir bulgu da proksimal median motor yanıtın distal yanıtın daha yüksek amplitüdü olması yanı sıra, bu ileti cevabının alınmasından öncesinde de yüksek amplitüdü bir yanıt saptanmasıdır. Bu durum, karma motor iletim yanıtına katkıda bulunan median liflerin karpal tünel boyunca önemli ölçüde yavaşladığı, ancak çapraz liflerin bu yavaşlamayı atladığı ve karpal tünel boyunca median liflerden önce tenar eminense ulaşması nedeni ile oluşur. Bu çaprazlaşan lifler doğrudan APB G1 kayıt elektrodunun altında olmayan tenar fibrilleri aktive edebileceğinden, median karma motor iletimden önce büyük bir pozitif dalga oluşturur (45).

2.2.4.2- Pronator Sendrom (PS)

Hem PS hem de KTS median sinirin (MN) sıkışması ile ilişkili patolojilerdir. Etiyolojileri arasındaki temel fark, kompresyonun lokalizasyonunda yatmaktadır: PS, MN'nin ön kolun anatomik yapılarından geçerken sıkışmasından kaynaklanabilir, KTS ise karpal tüneldeki sıkışmadan kaynaklanır.

PS, proksimal ön kolda sinsi başlayan belirsiz ağrı, MN dağılımında parestezi ve aktivite ile başlayan ağrı semptomları ile seyredabilen, proksimal ön kolda MN'nin çeşitli anatomik yapılar tarafından sıkıştırılmasından kaynaklanan nadir bir kompresif

nöropatidir. Buna karşılık KTS, karpal tünel basıncının artması sonucu el bileğinde MN sıkışması ile ilgili bir grup semptomdan oluşur. Fizik muayene hala her iki hastalığın tanısı için altın standart olarak kabul edilmektedir. PS'li hastalar en sık olarak MN tarafından innerve edilen bölgelerde paretezilerle birlikte önkolun proksimalinde ağrı şikayetlerinden yakınırırlar. Sürekli dirsek fleksiyonu ve ön kol supinasyonu; ön kol pronasyonu ve tekrarlayan kavrama, pronator teres ve lacertus'u gererek MN'ye karşı itebilir ve böylece semptomlara neden olabilir. Bazı çalışmalar, hastaların bazen volar radial üç buçuk parmak ve tenar eminensde uyuşma bildirdiklerini göstermiştir (46).

2.2.5- Klinik ve muayene

KTS de duysal muayenenin genellikle normal olduğu unutulmamalıdır. Anatomik varyasyonlar nedenli duysal şikayetler her zaman median dermatom sınırlarında olmayabilir. Duyusal etkilenme bölgesini haritalamak için iğne muayenesi yapılabilir. İleri seviye ağır kayıplarda ise iki nokta diskriminasyonu muayenesinde kayıp mevcuttur.

Tenar eminens duyusu, karpal tünelin proksimalinden ayrılan median sinirin palmar kutanöz dalı tarafından alınır ve saf duysal bir daldır. İleri seviye KTS'de, başparmak abduksiyonu ve opozisyonunda zayıflık ve tenar eminens atrofi görülebilir. Median sinir dağılımında hafif dokunma hissinde azalma, tenar kaslarında güçsüzlük ve atrofi görülür. Uyuşma, başparmak ve ilk 2-3 parmak (ve 4. parmağın yan tarafı) bölgelerinde öncelikle ventral alanlarda görülür. Karıncalanma da uyuşma ile aynı dağılıma sahiptir. Bunun haricinde zayıflık, nesneleri düşürme veya tutma sorunları şeklinde kendini gösterebilir. Ağrı ventral bilek ve el tarafında görülebilir, sıcaklık veya renk değişiklikleri, kuru cilt, şişme gibi otonomik özellikler de görülebilir. Şikayetlerin gece saatlerinde kötüleşmesi, tekrarlayan el aktivitesi ile şikayetlerde şiddetlenme olabilir. Hastalar median innervasyonlu parmaklardan sadece bazılarının tutulduğunu ama diğerlerinin tutulmadığını bildirebilir veya median innervasyonlu olmayan parmakların veya elin ya da kolun bazı kısımlarının tutulduğu hissini bildirebilir (47).

El bileği seviyesinin üzerindeki ağrı, servikal radikülopati gibi alternatif bir tanıyı akla getirebilir ancak proksimal patolojisi saptanmayan KTS vakaları da yaygın

olarak görülebilmektedir (%20-%40). KTS'li hastalar tipik olarak median sinir dağılımında uyuşma, karıncalanma ve daha az sıklıkla ağrı ile başvururlar.

KTS için temel tanı kriteri hastanın gece yatarken şu 3 bulgudan en az birini içermesi şeklindedir (48).

1- Median sinir dermatom alanında oluşan duyuşal değışiklikler

2- Pozitif falen testi

3- Pozitif tinel testi

Lakin günümüzde bu yöntemler tanı yerine klinik şüphe yönünde kullanılmakta ve tanı için hasta elektronörofizyolojik testlere yönlendirilmektedir.

KTS'nin klinik tanısı;


1. 1 ay boyunca duyuşal semptomlar elin ilk 4 parmağından en az 2 tanesinde görülmelidir; aralıklı seyretmesi veya sürekli ise daha önceki zamanda aralıklı seyretmiş olması gerekmektedir. Eşlik eden ağrı olabilir, ancak tek başına ağrı yeterli değildir.
2. Ağırlaştırıcı faktörler (3 tanesinden birisi): Uyku, sık sık el veya kol hareketi, tekrarlayan el hareketleri.
3. Duyuşal semptomların şu hareketlerden birisi ile rahatlaması: El pozisyonu değıştirme, el sallama, bilek ateli kullanımı.
4. Ağrının, eğer mevcutsa, el ve parmaklarda; proksimal kol/ön kol ve servikal taraftakinden daha ağır olması.
5. Alternatif bir tanıyı düşündüren öykü veya muayene bulgusu olmaması (49).

Tinel ve Falen Testi: Her iki test de median sinir sıkışmasını provoke ederek belirlenen dermatom alanında sendroma ait şikayetlerin artmasını hedefleyen testlerdir.

Tinel İşareti 1950'lerin başında sinir sıkışması olan bölgeleri tespit etmek için kullanılmaya başlanmıştır. Fakat yapılan çalışmalar tinel testi açısından objektif muayene kriterleri olmadığını göstermektedir. 1915 yılında Fransız nörolog Jules Tinel, sinirin yaralanmadan sonra gövdesine bir kez hafifçe vurulduğunda "karıncalanma hissi" oluştuğunu tanımlamıştır.

Phalen 1957'de KTS hastalarında bir tanı testi olarak, el bileği fleksiyon testi (Falen manevrası) önermiş ve muayene ile ortaya çıkan parestezinin uygun anatomik dağılımını göstermiştir. Yapılan çalışmalarda, Falen testinin duyarlılığı %42 ile %91 arasında ve Tinel testinin duyarlılığı %38 ile %100 arasında değişirken, özgüllük Falen testi için %55 ile %98 arasında ve Tinel testi için %55 ile %80 arasında değerlere sahiptir.

Yapılan çalışmalarda Falen Testi'nin KTS tanısında yararlı olduğu ve tanısal değerinin sinir iletim çalışmalarına yaklaştığını göstermektedir. Bununla birlikte Tinel Testi'nin tanısal değeri daha azdır ve uzun süreli sendromlarda (>10 yıl) her iki testin de kullanışsız olduğu bildirilmiştir (50).



Şekil 10- Falen ve Tinel Testi (51)

2.2.6- Görüntüleme

2.2.6.1- MRG (Manyetik Rezonans Görüntüleme):

Manyetik rezonans görüntüleme (MRG) de donanım ve çözünürlükteki ilerlemeler nedeniyle son yıllarda giderek daha fazla kullanılmaktadır. Anatominin ve patolojik durumların ayrıntılı bir şekilde gösterilmesi, tünel sendromlarının teşhisinde ve ayrıca KTS'nin nedenleri olarak kistler, ganglionlar ve anormal damar yapısı gibi oluşumların tespit edilmesinde yardımcı olur ve tedavi yöntemini belirleyebilir. Ancak USG veya MRG'de hangi anatomik parametrenin tanısal açıdan en önemli olduğu henüz netleştirilememiştir. Ayrıca, median sinir boyu ölçümü için en uygun seviye hala standardize değildir. Yapısal veya yer kaplayan bir lezyondan şüpheleniliyorsa manyetik rezonans görüntüleme yararlı olabilir, ancak median nöropati için bildirilen spesifik bir korelasyon yoktur ve ekonomik açıdan net bir fayda sağlamaması nedeni rutin tetkikler arasında yer bulmamıştır (52).

2.2.6.2- USG (Ultrasonografi)

Yapılan bazı çalışmalar ultrasonografinin sinir iletim çalışmaları ile karşılaştırıldığında ek maliyet ve elektriksel uyarımlar olmadan benzer tanısal doğruluk sunabileceğini göstermiştir, günümüzde sinir iletim çalışmalarının bir alternatifi olarak kullanılmaktadır ama bazı çalışmalarda ileri seviye KTS tanısında USG tetkiki daha az güvenilir bulunmuştur. Son çalışmalarda ise USG ve sinir iletim çalışmalarının kombine şekilde kullanımının, tek başına herhangi bir testi kullanmaktan tanısal doğruluk açısından daha değerli olduğu belirtilmiştir.

Statik USG: 1990'larda, statik ultrason görüntülemenin fleksör tendonlarda ve fleksör retinakulumda kalınlaşma, ekojenite değişikliği, sinovyal proliferasyon, karpal tünelin proksimalinde median sinirin çap artışı ve karpal tünelde median sinirin düzleşmesi gibi patolojileri tespit edebileceği ortaya konmuştur. KTS'de çevredeki yapıların median siniri sıkıştırması nedeniyle median sinirde morfolojik değişiklikler beklenir. Bu etki, baskı bölgesinde sinir hacminin azalmasına ve kompresyonun proksimalinde veya bazen distalinde, sinir uzunluğunun artmasına neden olur.


Median sinir ön kol ve el bileği seyri boyunca farklı konumlarda USG cihazı ile değerlendirilebilir. Bu yüzden KTS tanısı koymak için USG'de en sık uygulanan kriter, median sinir kesit alanıdır (cross sectional area, CSA). Bazı çalışmalar distal bilek kıvrımında ölçülen median sinir CSA miktarı ile deneklerin boyu, kilosu ve bilek

çevresi arasında orta düzeyde korelasyonlar bulmuştur. Sinir CSA ölçüsünü etkileyebilecek vücut antropometrik varyasyonlarını hesaba katmak için, bazı oranlar öne sürülmüştür. Bunlar;

1. Distal bölgedeki, genellikle pisiform veya distal bilek kıvrımı seviyesindeki, median sinir CSA'sı ile ön koldaki sinir CSA'sı arasındaki oran olarak tanımlanan el bileği-ön kol oranı (WFR);
2. Median sinir-ulnar sinir oranı (MUR) veya el bileğinde ölçülen median sinir CSA'sının ulnar sinir CSA'sına oranı
3. Transvers radyal-ulnar sinir çapının (uzun eksen) anterior-posterior sinir çapına (kısa eksen) bölünmesiyle belirlenen düzleşme oranı (FR).

CSA dolaylı yoldan median sinirdeki enflamasyonu gösteren bir parametredir. USG yaşlı hastalarda, bu yaş grubunda median sinirler genellikle genç hastalardaki kadar genişlememiş olması nedeni, daha düşük hassasiyet gösterir. Birkaç sayıda yapılan çalışmalarda azalmış ekojenite gibi USG bulguları görülmüştür.

Diğer çalışmalarda da KTS hastalarında median sinirin normal bal peteği eko-strüktürünün kaybolduğu gösterilmiştir. USG'de görüntü analiz edilirken, ekojenitenin azalması parlaklık azalmasını ifade eder, sinir görüntüsünün bulanıklaşmasına neden olan eko-strüktür kaybı kontrast azalmasını ve diğer doku değişikliklerini ifade eder. Kesitsel ultrason görüntülemeye median sinir, hiperekoik epinörium ile çevrili bir bal peteği yapısı şeklinde gözlemlenir (53).



Şekil 11- Karpal Tünel ve Median Sinir USG Kesiti (53)

Dinamik USG: Dinamik ultrasonografi, özellikle elektrofizyolojik bulguların normal olduğu durumlarda, KTS tanı ve değerlendirilmesinde umut verici bir araçtır.

Semptomatik ultrasonografi, hasta belirli bir manevrayı gerçekleştirirken görüntü dizisinin elde edilmesi ve tendonlar ve sinirler gibi yumuşak dokuların hareketinin gerçek zamanlı olarak görüntülenmesidir. Normal elektrofizyolojik bulgulara ve statik ultrasonografide gösterilen normal median sinir morfolojisine sahip semptomatik hastalarda, parmak fleksiyonu ve ekstansiyonu sırasında sinirin fleksör pollicis longus ve parmak fleksör tendonları arasında sıkışmasının gösterilmesi gibi olağandışı KTS etiyolojilerini tespit etmede özellikle değerlidir. Ayrıca, KTS'li hastalarda median sinirin farklı parmak hareketleri ve bilek pozisyonlarında hareketinin kısıtlandığı da gösterilmiştir. Bunlara ek olarak, USG tetkikinin doğruluğu, incelemeyi yapan kişinin deneyim seviyesine önemli ölçüde bağlıdır ve veriler farklı radyologlar tarafından değerlendirildiğinde veriler farklı şekilde değerlendirilebilir. Son yıllarda yapılan bazı çalışmalarda deep learning algoritmaları görüntü analizi USG tetkikinde KTS saptaması için kullanılmış, yüksek duyarlılık ve özgüllük değerleri elde edilmiştir.

Yapay zeka çalışmalarının USG tetkikinde ilerlemesi, farklı klinisyenler tarafından değerlendirildiğinde farklı yorumlanan sonuçların tutarlılığında önemli ölçüde artış sağlayacaktır (54).

2.2.6.3- EMG

Karpal tünel sendromunda elektrodiagnostik çalışmalar için uygulama parametresi, Amerikan Nöromüsküler ve elektrodiagnostik Tıp Derneği (AANEM), Amerikan Nöroloji Akademisi (AAN) ve Amerikan Fiziksel Tıp ve Rehabilitasyon Akademisi (AAPMR) tarafından onaylandıktan sonra 2002 yılında yayınlanmıştır.

Sinir iletim çalışmalarının KTS tanısı için yeterliliği tartışma konusu olmaya devam etmektedir. Bu testlerin rutin KTS vakaları için faydası olduğunu düşünen hekimler arasında görüş ayrılıkları bulunmaktadır. NCS'nin rutin kullanımını savunanlar, literatürde bildirilen yüksek duyarlılık ve özgüllük değerlerine güvenmektedir. Rutin kullanımını reddedenler ise nispeten yüksek yanlış negatif ve yanlış pozitif test oranları gösteren çalışmalara atıfta bulunmaktadır.

Her ne kadar KTS tanısı hususunda net kriterler belirtilmemiş olsa da EMG, halen tanı konusunda altın standart olarak kabul edilmektedir. Birçok çalışma ise bir hastada birden fazla duysal sinir yanıtlarının karşılaştırılmasının, ortak tek bir eşik değer kullanmaktan daha etkili olduğunu bildirmiştir.

EMG'nin KTS tanısındaki amacı;

1. Median sinir anormalliğinin karpal tünelde olduğunu göstermek
2. KTS'yi taklit eden alternatif tanıları dışlamak
3. KTS tedavi edilse bile semptomların devam etmesine neden olabilecek üst üste binmiş bozuklukları teşhis etmek (servikal radikülopati, periferik nöropati vb.)
4. Nörojenik hasarın ciddiyetini tanımlamak
5. Ameliyat öncesi sinirin bazal sağlık durumunu belirlemek

Üst ekstremitelerde nöropatik şikayetleri olan ve nöropati ön tanısı (KTS veya diğer nedenler) ile elektromiyografi için sevk edilen hastaları değerlendiren bir seride, elektromiyografi sonucunun ön tanıyı %42 oranında değiştirdiği bulunmuştur.

Günümüzde elektrofizyolojik testler, %56 ila %85 arasında değişen duyarlılık ve %94'e varan özgüllük ile periferik sinir bozukluklarının değerlendirilmesinde standart yöntem olmaya devam etmektedir lakin rahatsız edici bir tetkik olmasının yanı sıra, sinir sıkışmasının net lokasyonu, kapsamı veya olası etiyolojisi hakkında sınırlı miktarda bilgi sağlayabilmektedir. Multidisipliner gruplardan gelen çeşitli fikir birliği bildirileri, klinik uygulamada ve özellikle invaziv tedavi değerlendirmelerinden önce tek başına elektrodiagnostik testler veya tek başına klinik değerlendirmeden ziyade, bu ikisinin kombinasyonu şeklinde tanıya ulaşılmaya çalışılmasının daha doğru olduğu yönündedir. (55,56)

Teknik: İkinci parmak üzerinden antidromik duysal kayıt tekniği incelendiğinde bu teknik, median sinir çalışmalarında tüm laboratuvarlarda rutin olarak kullanılmaktadır. KTS için klinik şüphesi olan hasta popülasyonunda duyarlılığı %65'tir ancak yüksek bir özgüllüğe (%98) sahiptir. AANEM/AAN/AAPMR, ilk ileti çalışması olarak kullanılmasını önermektedir.

Kayıt halka elektrotları, G1 proksimal falanks üzerine ve G2 orta falanksın distal kısmı üzerine gelecek şekilde ikinci parmak (işaret parmağı) üzerine yerleştirilir. Median sinir G1 elektrodunun 13 cm proksimalinden uyarılır. Ön kol üzerindeki iletim hızını hesaplamak için antekübital fossadaki median sinir üzerinde, brakiyal arterin üzerinde biceps tendonunun medialinde proksimal stimülasyon gerçekleştirilebilir. Median sinir bilek seviyesinde uyarıldığında sadece duysal lifler değil aynı zamanda motor lifler de uyarılır, bu durum tenar kasların kasılmasına bağlı olarak duysal yanıtta artefakt ortaya çıkarabilir. Antidromik ileti, ortodromik iletiye göre daha

yüksek amplitüdlüdür ve morfolojik özellikleri daha iyi belirlenmiştir. Eğer gerekli olursa kayıt elektrodunu distale doğru hareket ettirerek bu artefakt ayrımı anlaşılabilir, bu şekilde yapıldığında duyuşal yanıtın latans değeri artacak; motor yanıt ise sabit kalacaktır.

Uzamış distal latans süresi karpal tünel sendromu bulgusudur ama amplitüd azalması latans değeri göre daha değışken durumları ifade edebilir, özellikle distal latans normalken amplitüd azalması genellikle altta yatan KTS dışı bir durumu göstermektedir. Eğer yüksek şüpheli hastalarda distal latans uzaması saptanmaz ise testin daha dikkatli yapılması tavsiye edilir. Median motor sinir iletim çalışması ise daha düşük önceliklidir ve daha sonra gerçekleştirilir.


Median antidromik ileti aynı zamanda üçüncü parmakdan kaydedilebilir. KTS tanısı açısından ikinci veya üçüncü parmakdan kayıt arasında fark yoktur fakat seçilen yöntem için uygun referans değerlerinin kullanılması gereklidir. Ayrıca provokatif manevraların, iletim çalışmalarının duyarlılığını arttırdığı konusunda da bazı çalışmalar yapılmıştır. Bir çalışmada klinik olarak KTS tanısı alan lakin elektrofizyolojik testleri normal saptanan olgulara 5 dk boyunca falen manevrası uygulanmış ve sonuç olarak kontrol grup ve median motor iletilere göre anlamlı derecede KTS tanısı açısından belirleyici median duyuşal ileti farklılıkları oluşmuştur.

Ortodromik avuç uyarım: Bu teknikte median ve ulnar duyuşal yanıtların aynı ekstremitede çalışılması gerekir. Median sinir G1 kayıt elektrodu bilek kıvrımının proksimaline ve stimülatörün de 8 cm proksimalinde, fleksör karpi radialis ve palmaris longus tendonları arasında, median sinirin üzerinde olacak şekilde yerleştirilir. Ulnar sinir G1 kayıt elektrodu, fleksör karpi ulnaris tendonunun hemen medialindeki bilek kıvrımının proksimaline, yine stimülatörün 8 cm proksimaline yerleştirilir. G2 elektrotları ise her bir G1 elektrodunun 3,5 ila 4,0 cm proksimaline yerleştirilir. Ayrıca, her bir sinirin iletim hızını hesaplamak için dirsekteki antekübital fossada median sinir üzerine ve medial epikondilin yaklaşık 5 cm proksimaline, ulnar sinir üzerine kayıt elektrotları yerleştirilebilir. Median stimülasyon için; katot, ikinci metakarpalın üstündeki tenar kıvrıma yerleştirilir. Ulnar stimülasyon için katot, dördüncü ve beşinci metakarplar arasındaki palmar kıvrıma yerleştirilir. Her ikisi için de anot yerleşim yeri katodun biraz distalidir. Avuç içi uyarım temelde motor ve duyuşal iletileri içeren mikst bir uyarım türüdür ama bilekten elde edilen kayıt daha çok sensoriyel

ağırlıklıdır. Stimulatör ve G1 kayıt elektrodu arasının 8 cm'den kısa olması şok artefaktının oluşmasına sebebiyet verebilir, bu duruma engel olmak için minimal sayıda deneme yanılma yolu ile stimulatörü sinirin tam hizasına getirmek gerekir. Anodu kendi etrafında çevirme manevrası veya daha küçük bir stimulatör başlık kullanmak da bu etkiyi azaltmaya yardımcı olur. Amplitüdler antidromik çalışmalara göre daha yüksek düzeyde değişkenlik gösterir ve yine burada da izole düşük amplitüdlü palmar yanıt genelde KTS ye işaret etmediği için dikkatli olunmalıdır.


Median sinir ve ulnar sinir, benzer miyelinizasyon özellikleri, derinlik miktarı ve sıcaklığa sahip olması nedeni birbirini ile karşılaştırılabilir, bu sayede median palmar distal latanslar, referans değerlere göre veya aynı mesafe boyunca ulnar palmar distal latans ile karşılaştırıldığında göreceli uzama açısından incelenebilir. KTS tanısı açısından median palmar distal latans uzaması (60 yaş ve altı hastalar için $>2,3$ msn ve 60 yaş üstü hastalar için $>2,4$ msn) geleneksel ikinci parmaktan kayıt alınan antidromik duyuusal median sinir iletim çalışmalarına göre daha sensitif bulunmuştur. Median sinirin seyrinde avuç içinde dallara ayrılması antidromik çalışmaların sensitivitesini azaltır, ortodromik çalışmada bu segmentler inceleme dışına alındığı için ise bu sorun ortadan kalkmış olur. Yine burada da median palmar distal latans, ulnar palmar distal latans ile mukayese edilerek (palm-diff) ikisi arasındaki farka göre yorum yapılabilir. Bunun palmar distal latans uzaması ile kombine edilmesi, tetkikin sensitivitesini arttıracaktır.

Median-ulnar yüzük parmağı antidromik duyuusal latans farkı (ring-diff): Yüzük elektrotlar dördüncü parmağa yerleştirilir. Median ve ulnar sinirler, proksimal halka elektrodun (G1) 14 cm proksimalinde bilek üzerinden uyarılır. İki uyarımın mesafesi de aynı olmalıdır. İki ileti arasındaki distal latans farkı $>0,5$ ms olursa patolojik olarak kabul edilir ve bu durum 'ringdiff' olarak tesmiye edilir. Bu çalışmanın diğer sinir iletim çalışmalarına göre daha kolay uygulanabilir ve kriterlerinin daha iyi belirlenmiş olması, tekrarlanabilirlik açısından kolaylık sağlamakta ve testin daha yüksek sensitivite, spesifite değerlerine sahip olmasını sağlamaktadır. AANEM/AAN/AAPMR; avuç içi çalışmaları, median ve ulnar antidromik sinir iletim çalışmalarını KTS açısından 'yüksek sensitif ve eğer KTS açısından yüksek klinik şüphe varsa 'kullanılabilir' olarak tanımlar. Bu nedenle, tanı açısından şüpheli görülen KTS hastalarında tercih edilebilir.



Şekil 12- Median-Ulnar Yüzük Parmağı Antidromik Duyusal Latans Farkı Çekim Tekniği (45)

Median-radial başparmak antidromik duysal latans farkı(thumb-diff): Yüzük elektrotlar başparmağa yerleştirilir. Median ve radyal sinirler, ikisinin de mesafesi aynı olacak şekilde proksimal halka elektrodun (G1) 10 cm proksimalinde bilek üstünde uyarılır. Radyal sinir distal latansının median distal latanstan $>0,5$ ms uzaması KTS açısından anlamlı kabul edilir. Thumb-diff tekniği için duyarlılık %65, özgüllük ise %99'dur. Kliniği KTS'yi düşündüren ağırlıklı olarak başparmağı etkileyen ve diğer sinir iletim çalışmaları ile tanı konulamayan hastalarda kullanılır.



Şekil 13- Median-Radial Başparmak Antidromik Duyusal Latans Farkı Çekim Tekniği (45)

Kombine duyusal indeks (CSI): EMG parametreleri normal sınırlarda yer alan çok hafif kliniği olan vakalarda KTS tanısını doğrulamak için normalde fark edilmesi zor olan hafif farklılıkları büyütürken yalancı negatif ve yalancı pozitif sonuçları azaltmayı hedeflemektedir.

Hesaplanması Median-Ulnar palmar, median-ulnar dördüncü parmak ve median-radial başparmak çalışmaları (palmdiff + ringdiff + thumbdiff) arasındaki latans farklarının toplamıdır. Toplamı >1 ms ise patolojik olarak kabul edilir. Duyarlılığı %83 olarak belirtilmiştir.

Motor sinir iletim çalışmaları: G1 kayıt elektrodu, abduktör pollicis brevis (ABP) kaslarının orta noktasına yerleştirilir. G2, başparmağın lateral tarafındaki metakarpal-falangeal eklemin hemen distalinde yer alır, stimülatör katodu G1'in 7 cm proksimaline, fleksör karpi radialis ve palmaris longus tendonları arasındaki median sinir üzerine yerleştirilir, KTS tanısında rutin olarak bakılır (58)

Median-ulnar lumbrikal ve interosseöz çalışma: G1 kayıt elektrodu orta avuç içine, ikinci ve üçüncü metakarpaller arasındaki distal tenar kıvrımına yerleştirilir. G2 elektrodu, işaret parmağının proksimaline veya ikinci ve üçüncü parmaklar arasındaki boşluğa yerleştirilir. Bu pozisyonda, aktif kayıt elektrodu (G1) median innervasyonlu ikinci lumbrikalin hemen üzerindedir, derininde (yani dorsalinde) ulnar innervasyonlu ikinci palmar ve interosseöz kas bulunur. Median ve ulnar sinirlerin uyarılması G1'den 9 ila 10 cm mesafede bilek kıvrımının proksimalinde gerçekleştirilir. İkinci lumbrikale giden medial distal latansın, ikinci interosseöze giden ulnar latansla karşılaştırıldığında 0,5 ms veya daha fazla uzaması, KTS için anlamlı kabul edilir.

Hafif KTS vakalarında, median stimülasyon ile ikinci lumbrikal üzerindeki bileşik kas aksiyon potansiyelinden önce kaydedilebilen küçük bir duyuşal sinir aksiyon potansiyeli (DSAP) oluşur. Bu premotor yanıt, median dijital duyu liflerinin iletilmesi nedeni oluşur. Oluşan DSAP'ın distal latansının 2,7 ms'den fazla olması KTS açısından %77'lik bir duyarlılıkla anormal kabul edilir. Bu yöntem de rutin KTS tetkikleri arasında yer almaktadır ancak diğer duyuşal çalışmalarla karşılaştırıldığında ne kadar değer kattığı henüz belirsizdir. Daha çok sıklıkla çok ağır KTS vakalarında rutin sinir iletim çalışmaları iletileri alınamadığında kullanılan tetkikler arasında yer almaktadırlar.

Lumbrikal-interosseöz çalışmalar ise jeneralize periferik nöropati durumunda faydalıdır. Duyusal iletim çalışmaları KTS için daha hassas olmasına ve tek başına tanıyı doğrulamasına rağmen, KTS'nin elektrofizyolojik şiddetini tanımlamak ve tedavi yöntemini belirlemek için motor iletim çalışmalarının yapılması önemlidir. Median motor distal latansı (APB kayıtlı), ADM kayıtlı rutin ulnar motor iletim çalışması ile karşılaştırılabilir. Median motor distal latans karşı tarafla da karşılaştırılabilir ve >1,0 ms fark anlamlı kabul edilir, ama tabi ki KTS'nin genelde bilateral görülmesi bu yöntemi kullanımını kısıtlamaktadır.

Median motor distal latansının uzamasına ek olarak median sinirin karşı taraf median sinire göre veya aynı taraflı ulnar motor latansına göre kıyaslanması, duyarlılığı daha da artacaktır.

Diğer çalışmalarda da olduğu gibi izole amplitüd düşüklüğü bu teknikte de KTS harici patolojilere işaret etmektedir. KTS hastalarında iletim bloğu ile karşılaşılması normaldir, net lokasyon tayini için stimülatör bileğin üstünde her

seferinde 1'er cm'lik mesafelerle distale doğru ilerleyecek şekilde uyarı vererek değerlendirme yapılabilir ama distale ilerledikçe doğrudan kası uyarma riski ve motor dalın tenar eminense doğru seyretmesi nedeniyle bu tekniğin uygulanması zordur ve bundan dolayı rutin bir metot haline gelmemiştir. Bu arada, duyu distal latans uzaması olmadan motor distal latans uzaması da beklenen bir durum değildir, eğer saptanırsa alternatif motor sinir hastalıklarını dışlamak gerekir.

KTS'de proksimal iletim hızı azalması: KTS'li hastaların yaklaşık %10'unda, ön kolda median motor iletim hızında hafif yavaşlama vardır, bu durum retrograd dejenerasyon, aksonal atrofi veya karpal tüneldeki liflerinin iletim bloğu nedeni olmaktadır. Bu durumu iyi tanımak gereksiz bir şekilde proksimal median nöropati hastalıklarından (Struthers ligamantı sendromu, Pronator Sendrom) şüphelenilmesini engelleyecektir.

İğne EMG: İğne EMG tetkiki, özellikle de tenar kaslarda, genellikle elektrodiagnostik testlerin en rahatsız edici kısmı olarak kabul edilir. AAEM kılavuzları, eldeki parestezilerin nedeni olarak servikal radikülopati, brakiyal pleksopati veya proksimal median nöropatiyi ekarte etmek için C5-T1 kökleri tarafından innerve edilen kaslara iğne EMG'sinin yapılmasını önermektedir. Yine de iğne EMG, KTS tanısında “opsiyonel” kategoride yer almaktadır. Eğer elektrofizyolog, ayırıcı tanıları arasında olası servikal radikülopati, pleksopati veya diğer mononöropatileri düşünmüyor ve akson kaybı olasılığı tedavi yönetimi değiştirmeyecekse, o zaman iğne EMG gerekli değildir. El bileği boyunca median sinir iletimi normalse, APB'nin iğne EMG testinde anormal bir bulgu görülmesi çok zordur. İletim çalışmalarında bozukluk olması da iğne EMG tetkikinde bozukluk olacağının göstergesi değildir. İğne EMG, KTS'de akson kaybı, servikal radikülopati, proksimal median nöropati veya polinöropatiyi teşhis etmek için yardımcı olabilir ve genellikle gereklidir. Bu durumlar KTS ile veya izole olarak görülebilir. APB güçsüzlüğü, tenar eminens atrofi veya median birleşik kas aktivitesi amplitüdünde azalma durumları aksonal kayıp açısından şüphe uyandırır ve bu hastalarda iğne EMG yapmak gerekir (59).

2.2.5- KTS Sınıflama

Elektrodiagnostik çalışma bulguları KTS'nin şiddetini derecelendirmek için yaygın olarak kullanılmaktadır ancak bu durum bilimsel olarak ispatlanmamıştır. Sinir iletim

alışmalarının şiddeti ile semptomlar arasındaki korelasyon net olarak ortaya konulmamıştır. EMG sınıflandırma ölçeklerinin kullanımı, başta semptomlar ve diğer faktörler daha önemli olması gerekirken tedavinin sınıflamalara göre planlanabilme ihtimali nedeniyle önerilmemektedir (60-61). Bu durumlara rağmen, genellikle kullanılan KTS sınıflamalarında hafif-orta-ağır şeklinde 3 grup kullanılmış, bunun dışında Bland tarafından önerilen daha karmaşık altı seviyeli ölçek de kullanılmıştır.

Sınıflama;

Hafif KTS: Normal motor alışmalarla birlikte uzamış (göreceli veya mutlak) duyusal latanslar ve akson kaybı için bulgu olmaması

Orta KTS: Hafif KTS'deki gibi anormal median duyusal latanslar ve median motor distal latansında (göreceli veya mutlak) uzama ve akson kaybına dair kanıt olmaması

Ağır KTS:

- A. DSAP veya karma iletim aksiyon potansiyelinin olmaması veya düşük amplitüdü olması
- B. Tenar BKAP amplitüd düşüklüğü olması veya hiç alınamaması
- C. Akson kaybının kanıtı olan fibrilasyon potansiyelleri veya motor ünite potansiyel değışiklikleri (büyük amplitüdü, uzun süreli motor ünite potansiyelleri veya aşırı polifazik) olan iğne EMG bulguları ile yukarıda belirtilen sinir iletim alışması anormalliklerinden herhangi biri.

İletim alışmalarındaki amplitüd anormallikleri ağır iletim bloğuna bağlı olabilir bu nedenle amplitüd azalması, sinirde aksonotmezis olduğu anlamına gelmez. El bileğinden verilen uyarım ile SNAP alınamıyor veya çok düşük amplitüdü alınıbiliyor ama avuç içi uyarım ile amplitüd çok daha alınıbiliyor ise, bu durum akson kaybını değil iletim bloğunu düşündürür.

Avuç içi motor iletimine bakılırken dikkat edilmesi gereklidir, çünkü avuç içi motor stimölasyonu avuç içindeki median sinir yerine derin ulnar sinir liflerini veya Riche-Cannieu liflerini uyartabilir ve bu durumda median sinir normal olmasına rağmen motor nöropraksi varmış gibi görünebilir. Duyusal lifler avuç içi uyarımı için çok daha güvenilirdir.

Geçmişten günümüze kullanılan çeşitli KTS tanı ve şiddet sınıflama ölçekleri aşağıda dercedilmiştir;

KTS Şiddeti	Elektrodiagnostik bulgular	Müdahale
KTS yok	Yok	Semptomatik
Hafif KTS	Karşılaştırma çalışmalarda veya median duyusal sinirde anormallik mevcut.	Semptomatik
Orta KTS	Abductor pollicis brevis kasında normal amplitüd ile birlikte uzamış distal motor latans.	Enjeksiyon/cerrahi
Ağır KTS	Yukarıdakilere ek olarak median-APB CMAP amplitüdünün azalması ve/veya thenar kaslarında iğne EMG anormalliği	Kontrendikasyon yoksa cerrahi

Şekil 14- Örnek KTS Sınıflaması-1(62)

Çalışma Türü	Anormal Değerler	Duyarlılık (%)	Özgüllük (%)
Median antidromik 2. parmak	Latans >3.6 ms	65%	98%
Ortodromik palmar çalışma	Amplitüd < 15 µV	71%	97%
Median-ulnar(yüzük parmağı antidromik(ringdiff))	iletim hızı < 56 m/s	85%	97%
Median-radial (baş parmak) antidromik (Thumbdiff)	Latans farkı >0.4 ms	65%	
Kombine duusal indeks (CSI)	Latans farkı >0.5 ms	83%	
Median-ulnar lumbrikal vs interosseöz çalışma	Latans >4.5 ms	44%	

Şekil 15- Farklı İletim Çalışmaları Referans Değerleri (60)

KTS'nin ciddiyetini değerlendirmek için tek başına elektrodiagnostik kriterler veya klinik ve elektrodiagnostik kriterlerinin bir kombinasyonu kullanılarak birçok derecelendirme sistemi geliştirilmiştir. Elektrodiagnostik derecelendirme ölçeklerinin çoğu, iletim yavaşlaması veya amplitüd düşüklüğü varlığı dahil olmak üzere duyusal ve motor NCS anormalliklerine göre sınıflama yapar. Derecelendirme sistemleri, hastanın klinik ve elektrofizyolojik şiddeti arasındaki korelasyon eksikliği nedeniyle hiçbir zaman kesin kriterler olarak ele alınamamıştır bu nedenle KTS'de tedavi

kararları, subjektif uygulamalar yerine klinik kanıya ve seçilen bir sınıflama sisteminin etkili bir şekilde kullanımına dayanmalıdır. Elektrodiagnostik KTS şiddeti ile cerrahi cevap arasında da bir korelasyon gösterilmiştir.

Sınıflandırma	Elektrodiagnostik Bulgular
Çok ağır KTS (EXT)	Tenar motor (ve duyuşal) yanıt yokluğu
Ağır KTS (SEV)	Median SNAP'lerin (parmak-bilek segmenti) yokluğu ve anormal distal motor latans
Orta KTS (MOD)	Median parmak-bilek segmentinde yavaşlama ve anormal DML (Distal motor latans).
Hafif KTS (MILD)	Median parmak-bilek segmentinde yavaşlama ve normal DML.
Çok hafif KTS (MIN)	Standart testlerin normal olduğu ellerde anormal karşılaştırmalı veya segmental testler.
Normal (NEG)	Tüm testlerde (karşılaştırmalı veya segmental dahil) normal bulgular

Şekil 16- Örnek KTS Sınıflaması-2 (63)

Sınıflandırma	Semptom Süresi	Güçsüzlük/Atrofi	Elektrodiagnostik Bulgular
Hafif (Mild)	1 yıldan kısa	Yok	Anormal duyuşal sinir ileti hızı; normal distal motor latans
Orta (Moderate)	1 yıldan uzun	Minimal	Anormal duyuşal sinir ileti hızı; anormal distal motor latans
Ağır (Severe)	1 yıldan uzun	Belirgin güçsüzlük ve/veya atrofi	Anormal (veya yok) duyuşal sinir ileti hızı; anormal (veya yok) distal motor latans

Şekil 17- Örnek KTS Sınıflaması-3 (64)

Derece	Tanım
Normal (Grade 0)	SCV > 50 m/s ve amplitüd $\geq 5 \mu V$, DML ≤ 4.2 ms, amplitüd ≥ 5 mV ve MCV ≥ 50 m/s.
Erken (Grade 1)	SCV 45-50 m/s (III. parmak), IV. parmakta çift tepe latansı >0.5 ms, DML ≤ 4.2 ms, duysal ve motor amplitüd >5 (duysal μV , motor mV).
Hafif Duyusal (Grade 2)	SCV 40-44.9 m/s (III. parmak), duysal amplitüd normal, motor değerler (Grade 0'daki gibi).
Hafif Duyusal-Motor (Grade 3)	SCV 40-44.9 m/s (III. parmak), duysal amplitüd normal, DML ≥ 4.2 ms, motor amplitüd ve iletim hızı normal.
Orta Duyusal (Grade 4)	SCV <40 m/s (III. parmak), duysal amplitüd normal, motor değerler (Grade 0'daki gibi).
Orta Duyusal-Motor (Grade 5)	SCV <40 m/s (III. parmak), duysal amplitüd normal, DML ≥ 4.2 ms, motor amplitüd ve iletim hızı normal.
Ağır Duyusal-Motor (Grade 6)	III. ve II. parmaklardan duysal potansiyel yok veya her iki parmakta <3 μV , SCV <30 m/s, DML ≥ 4.2 ms, MCV yavaş veya normal.
Çok Ağır Duyusal-Motor (Grade 7)	Duyusal ve motor potansiyeller yok, yalnızca 2. lumbrikallerden yanıt alınabiliyor; median lumbrikaller, ulnar lumbrikallere göre uzamış ve düşük amplitüd gösteriyor.
Tam (Grade 8)	Duyusal ve motor potansiyeller yok, median 2. lumbrikallerden yanıt alınamazken ulnar 2. lumbrikallerden yanıt alınabiliyor.

Şekil 18- Örnek KTS Sınıflaması-4 (65)

(SCV: Duyusal iletim hızı, MCV: Motor iletim hızı)

Görüldüğü üzere KTS şiddeti sınıflaması tedavi planında çok önemli bir rol üstlenmekte beraber sınıflama için geçmişten günümüze kadar birçok farklı kriterler kullanılmıştır. Bu durum herkes tarafından kabul gören tek bir referans sistemin kullanılmasını gerektirmektedir.

2.2.6- KTS için EMG sonuçlarının yorumlanması

Klinisyenler arasında normal, anormal veya sınırda sonuçların sınıflaması ve eğer anormalse bunun derecesinin nasıl yorumlanacağı ve ayırt edileceği konusunda farklı fikirler vardır. Yaş, ekstremitte sıcaklığı, cilt kalınlığı, eşlik eden tıbbi durumlar ve diğer birçok konu bu kararların verilmesini zorlaştırır ve KTS tanısının eşlik edebilecek olası diğer nöropatilerden ayrılması da önemli bir konudur.

KTS ile median mononöropati ayrımı da önemlidir. KTS tanısı sadece EMG testi ile konulabilen bir tanı değildir ek olarak karpal tüneldeki median sinir

disfonksiyonu ile ilişkili semptomların varlığı gereklidir. Bu nedenle, KTS semptomları ve destekleyici EMG testi olan hastalar doğrulanmış KTS olarak tanımlanır. Anormal NCS'leri olan ancak semptomları olmayan hastalar KTS olarak değil, MMW (Bilek seviyesinde median nöropati) vakaları olarak tanımlanmaktadır. Bu durum özellikle yüksek BMI'ye (Vücut kitle indeksi) sahip olan hastalarda önemlidir çünkü obezite ile MMW arasında yüksek korelasyon vardır fakat KTS ile obezite arasında aynı ilişki gösterilememiştir. Bu ilişkinin nedeni tam olarak anlaşılamamış ancak varlığı çeşitli çalışmalarda doğrulanmıştır. Bu durum KTS tanısında karışıklığa yol açabilir. Hastalarda el bileğindeki KTS ile ilişkili görünmeyen belirsiz semptomlar varsa, hekimler MMW mevcut olsa bile bu hastalara KTS tanısı koyma hatasına düşebilmektedir. Bu durum gereksiz ve etkisiz tedavilere yol açabilir. Bazen de klasik KTS semptomları olan hastalarda elektrodiagnostik testler normaldir. Bu durumlarda, test yalancı negatif olarak değerlendirilebilir ve hastada EMG testi ile doğrulanamamış KTS vardır. Bu durum raporda belirtilebilir.

Bazı elektronörofizyologlar EMG akabinde tedavi düzenlemesi de yaparken, bazıları bunu yapmaz. Hastanın şikayetlerinin KTS dışında olası başka bir patolojiye bağlı olup olmadığını (tendinit, artrit vs.) poliklinik hekimi belirtmelidir. Raporun vurgusu da istem yapan hekimin isteklerine bağlı olarak farklılık gösterebilir (66).

2.2.6- KTS Tedavisi

Konservatif ve cerrahi olarak iki farklı tedavi seçeneği vardır. Cerrahi müdahaleden önce genellikle ameliyatsız tedavi stratejileri uygulanırken hem birinci basamak hekimlerinin hem de tedavi eden el cerrahlarının ne zaman cerrahi tedavinin endike olduğunu anlamaları önemlidir. Orta ve ağır KTS elektrodiagnostik bulgularına sahip birçok hastanın ideal tedavisi erken cerrahi müdahaledir, aslında ameliyattan sonra iyileşme, hafif ile orta derece hastalığı olanlarda, ağır hastalığı olanlara göre genellikle daha iyidir. Ameliyatsız tedavinin süresi de cerrahın deneyimine veya hastanın tercihinine bağlı olarak değişebilir; ameliyatsız tedavileri süresi konusunda da literatürde farklı görüşler bildirilmiştir.

Tedavi yöntemi ne olursa olsun, hastaya optimal bakım sağlanması için KTS açısından mevcut tanı ve çoklu tedavi seçeneklerinin değerlendirilmesinde ortak bir karar verme modelinin kullanılması önemlidir (67).

2.2.6.1- Konservatif tedavi

Genellikle hafif veya orta derecede semptomları olan KTS hastalarında kullanılır, el ateli, lazer tedavisi, farmakoterapi (örn. lokal kortikosteroid enjeksiyonları veya oral ilaçlar), fizik tedavi, terapötik ultrason ve kas-iskelet egzersizleri bu grup tedaviler arasında yer almaktadır ama konservatif tedaviler kısa vadede hastalar için yüz güldürücü sonuçlar ortaya çıkarmakta iken; bu tedavilerin uzun vadedeki faydaları tartışmaya açıktır (68).

Bekle ve gör tedavisi: KTS'nin semptomları dalgalanma gösterir. İnsanlar genellikle semptomların en kötü olduğu zamanlarda rahatlatıcı tedavi arama eğilimindedir, şikayetlerde zamanla azalma görülebilmektedir. Ayrıca fleksör retinakulumdaki enflamatuvar değişiklikler zamanla azalırsa da semptomlar iyileşebilir. Gözlemsel çalışmalardan elde edilen kanıtlar, bekle ve gör stratejisinin hafif ve stabil KTS semptomları olan kişilerde kullanılabileceğini göstermektedir. Klinik semptom ve fonksiyonel sonuçlar için spontan iyileşme oranı %23-40 arasında değişmektedir ve bu oranlar, çalışmalar arasında hastalığın ciddiyetine bakılmaksızın oldukça benzer seviyededir (69).

Atel, ortez: Çalışmalar, bilek ateli takmanın dinlenme sırasında KTS semptomlarını iyileştirebildiğini, ancak aktivite ile kötüleştirdiğini göstermiştir, bununla birlikte, altı hafta boyunca genellikle geceleri atel takılmasının, hafif veya orta şiddette semptomları KTS hastalarında klinik iyileşmeler sağlayabildiği gösterilmiş ama atelleme altı haftadan daha fazla uzatılmasının herhangi bir yararı gözlenmemiştir. Atelleme, hastalığın başlangıcından sonraki üç ay içinde uygulandığında uygun bir tedavi seçeneğidir. Atel, düzenli olarak her gece kullanıldığında uzun süreli takiplerde duysal ve motor sinir iletim hızlarında iyileşmeler gözlenmiştir (70).

Steroid enjeksiyonu: Etki mekanizması kesin olarak bilinmemekle birlikte anti- enflamatuvar etkiye bağlı olduğu düşünülmektedir, bir başka olası mekanizma da kortikosteroidlerin karpal tüneldeki ödemi azaltarak tünel içindeki basıncı doğrudan düşürmesidir. Hafif ve orta şiddette semptomları olan KTS hastaları, el bileğindeki karpal tünele yapılan lokal kortikosteroid enjeksiyonlarından fayda görürler. Bu enjeksiyonlar, inflamasyonu ve tenosinovyumdaki ödemi azaltarak tünel içindeki basıncı hafifletir. Ağır KTS'si olan hastalarda lokal kortikosteroid enjeksiyonları ile

bir ayda klinik semptomlarda iyileşmeler gözlenirken, hafif-orta şiddette KTS'si olan hastalarda bu tür iyileşmeler net bir şekilde görülememiştir. Tek bir enjeksiyona kıyasla iki veya daha fazla lokal enjeksiyondan sonra da anlamlı ek bir rahatlama gözlenmemiştir. Bütün bunlarla birlikte KTS'de steroid enjeksiyonunun faydasının görülmediğine dair çalışmalar da mevcuttur. Ultrason yardımı ile uygulanan enjeksiyon ile cihaz kullanmadan yapılan enjeksiyon arasındaki fark klinik olarak önemsiz bulunmuştur, ancak USG kılavuzluğunda enjeksiyon yüksek maliyet oluşturmuyor ise tercih edilebilir (71).

Trombositten zengin plazma (PRP) enjeksiyonu: Trombositler, yaralı dokunun iyileşmesini desteklemek için yaralanma bölgesinde çeşitli büyüme faktörleri ve diğer aktif proteinleri salgılar. PRP, plazma ve trombositlerin bir konsantresidir. Birçok kas-iskelet sistemi hastalıklarında yaygın olarak kullanılmaktadır ancak semptomları etkili bir şekilde iyileştirme yeteneğini destekleyen sınırlı kanıt vardır. Büyüme faktörleri veya PRP sinir onarım bölgesine enjekte edildiğinde, aksonal rejenerasyonu teşvik ettiği, anjiyogenezi uyardığı ve ayrıca fibrozisi azaltabileceği düşünülmektedir (72, 73).

Oral Tedaviler: Prednizolon gibi oral steroidlerin uygulanması sadece kısa vadede semptomlarda bazı klinik iyileşmelere neden olur. Eskiden kullanılan non-steroid anti-inflamatuar ilaçlar, piridoksin ve diüretikler KTS tedavisinde artık etkili kabul edilmemektedir. Gabapentin de KTS hastalarında nöropatik ağrı tedavisinde kullanılan anti-konvülzan bir ilaçtır. Orta derecede kanıtlar, diyabetik nöropati ve post-herpetik nevraljide nöropatik ağrıyı iyileştirdiğini göstermektedir (74).

El fizyoterapisi: El terapisi, sinir ve tendon hareketlerini en üst düzeye çıkarmayı ve sinir iletimini iyileştirmek için karpal tünel içinde tendonların ve sinirlerin kaymasını kolaylaştırmayı amaçlar. Kayma egzersizlerinin yanı sıra yeni araştırmalar, el bileğinin volar yüzeyine uygulanan bir yama yoluyla iyonize ilacın transdermal olarak uygulanması şeklinde yapılan iyontoforez kullanılarak tendon ve sinir hareketliliğini geliştirmeye odaklanmıştır. Şimdiye kadar elde edilen veriler sınırlı olup, yapılan bir çalışmada deksametazon sodyum fosfat iyontoforezini takiben, 2 ve 8 haftalık takiplerde semptomatik iyileşme görülmüştür (75).

Kinezyo bant (KT): 1970'lerde Dr. Kenzo Kase, eklem hareket açıklığını engellemeden kaslarda stabilite ve desteği artırmak için kinezyo bantlama (KT)

yöntemini geliřtirdi. Kinezyo bant, deriye uygulanan ve alttaki eklemlerin hareket etmesini saęlayan elastik bir banttır. Genellikle çeřitli kas-iskelet sistemi semptomlarını tedavi etmek için kullanılır, merkezi ve periferik sinir sistemi patolojilerinde terapötik potansiyeli olduęu bildirilmiřtir. Kinezyo bantlama tekniklerinin rahatsızlık hissini azalttıęı, hareket aralıęını artırdıęı ve fonksiyonel işlevi iyileřtirdięi bildirilmiřtir. Ek olarak KT, kan ve lenf dolařımını artırır, bu sayede iltihabı azaltır ve iyileřme ortamının oluřmasını destekler. KTS'de KT'nin etkinlięi konusunda giderek artan bir literatür çalışması olmasına raęmen, en uygun KT teknięi konusunda bir anlařmaya varılamamıřtır. 2024 yılında yapılan bir çalışma KTS'li hastalarda egzersiz tedavisine eklenen KT'de hem “dügme delięi” hem de “I bandı” yöntemlerinin işlevsellik, semptom řiddeti, kavrama gücü ve elektrofizyolojik açıdan etkili olduęunu ortaya koymuřtur (76).

Ultrasonografi: Geleneksel olarak tanı amaçlı ve hedefe yönelik enjeksiyonlara yardımcı olarak kullanılsa da USG hafif ve orta dereceli KTS için tek başına bir tedavi yöntemi olarak da kullanılmaktadır. USG, hem termal hem de termal olmayan etkilere sahip yüksek frekanslı dalgalar yayarak iltihaplanmayı azaltır ve geliřmiř kan akıřı ve membran geçirgenlięi yoluyla sinir rejenerasyonunu uyarır, derin dokulara enerji vererek dokunun sıcaklıęını artırır, bu da sinirin rejenerasyonunu ve iletim hızını artmasını saęlayabilir, ancak kesin fizyolojik etki mekanizmaları belirsizdir. řu ana kadar yapılan randomize çalışmalar KTS'de USG tedavisinin klinik faydasına iliřkin karıřık sonuçlar göstermiřtir (77).

Ekstrakorporeal řok dalgası tedavisi (ESWT): Son zamanlarda ESWT, yeni ve noninvaziv bir yöntem olarak KTS tedavisinde kullanılmaktadır, birkaç randomize kontrollü çalışma da ESWT'nin fonksiyonel sonuçları ve elektrofizyolojik parametreleri iyileřtirebileceęini bildirmiřtir. Bununla birlikte, ESWT'nin KTS için etkinlięine iliřkin hala net kanıtlar bulunmamaktadır (78).

Düşük seviyeli lazer tedavisi (LLLT): LLLT, genellikle 600 ila 1000 nm arasındaki dalga boylarına sahip kırmızı ve kızılötesi ışın, terapötik etkiler üretmek için biyolojik dokulara kullanılmasıdır, mitokondride hücresel oksijen tüketimini ve ATP üretimini artırarak KTS semptomlarını etkili bir řekilde hafifletebilir, ayrıca cilt kan akıřını iyileřtirir, prostaglandin sentezini inhibe ederek iltihabı azaltır ve sinir hücresi membranlarının sodyum ve potasyum iyonlarına karřı geçirgenlięini azaltır.

Bu da nöronların hiperpolarizasyonunu sağlar, lenfatik drenajı artırır ve ödemi azaltır buna ek olarak, nöron rejenerasyonunu destekleyen miyelin kılıfın sentezinde artış da sağlanabilir (79).

Akupunktur: Kökeni doğu tıbbına dayanan akupunktur tedavisi, hafif ve orta dereceli KTS'nin tedavisinde dünya çapında kullanılmaktadır. Akupunktur kan dolaşımını, metabolizmayı artırabilir ve nöronal dokunun onarımını hızlandırabilir. Modern tıbbi araştırmalar akupunktur tedavisinin sinir fonksiyonunun iyileşmesini güçlendirebileceğini, enflamatuvar faktörlerin ekspresyon seviyesini azaltabileceğini, kas gerginliğini dengeleyebileceğini ve kas spazmını hafifletebileceğini göstermektedir (80).

2.2.6.2- Cerrahi Tedavi

Karpal tünelin cerrahi olarak gevşetilmesi, şiddetli KTS'si olan hastalarda cerrahi dekompresyon tedavisi olarak uygulanmaktadır fakat konservatif tedavilerden sonra cerrahi tedavi uygulanmasının iyileşmeye olumlu etkisi olduğuna dair kanıt bulunmamaktadır. Konservatif tedavi ile semptomlar %80 azalsa da bu tedavilere olumsuz yanıt veren bazı vakalarda ameliyat gerekmektedir. Bazı çalışmalarda KTS hastalarının %70-90'ında karpal tünel operasyonu, uzun vadeli kabul edilebilir klinik sonuçlarla ilişkilendirilmiştir. Karpal tünelin gevşetilmesi, geleneksel açık veya yarı açık gevşetme olarak tanımlanan yaklaşımlarla veya tek kanallı bir ameliyat olarak yapılabilen endoskopik yaklaşımla gerçekleştirilebilir. Uzun dönem sonuçlarda açık veya endoskopik operasyonlar arasında fonksiyonel iyileşme açısından anlamlı fark bulunamamıştır (81).

2.3 Yapay Zeka (Artificial Intelligence, YZ, AI)

2.3.1- Tanım

Yapay zeka (YZ), makinelerin genellikle insanlar için ayrılmış görevleri yerine getirmesini sağlamayı amaçlayan bir dizi hesaplama tekniğidir. On yıllar boyunca çoğunlukla teorik bir yapı olarak ele alınmış olsa da son 15 yılda YZ, biyomedikal araştırmalar da dahil olmak üzere çok çeşitli alanlarda insan düzeyinde performansa ulaşmıştır.

Teknik olarak, yapay zekanın günümüzdeki uygulamalarının çoğu, beyindeki biyolojik sinir ağlarından esinlenen hesaplama modelleri olan yapay sinir ağlarına (Artificial Neural Network, YSA, ANN) dayanmaktadır. Bir ANN, katmanlar halinde organize edilmiş 'nöron' adı verilen bağlantılı birimlerden oluşur. ANN'ler tipik olarak her biri çok sayıda nöron içeren birden fazla katmana sahiptir, bunlar;

1. Girdi verilerini alan bir girdi katmanı
2. Nihai çıktıyı üreten bir çıktı katmanı
3. Hesaplamaların çoğunu gerçekleştiren gizli katmanlardır.

Bir YSA bu gizli katmanlardan yüksek miktarlarda içerdiğinde, artık derin YSA (deep neural network) olarak adlandırılır. Bu bağlamda 'derin' terimi, katman sayısının bir ölçüsü olan ağın derinliği ile ilgilidir. Derin sinir ağları, verilerin daha fazla soyutlama ve temsil düzeyine izin veren genişletilmiş mimarileri nedeniyle karmaşık kalıpları öğrenebilir, büyük veri kümeleri kullanılarak ve ağın parametreleri (nöronlar arasındaki bağlantıların etki katsayıları gibi), alınan sonuçların hata miktarına göre ayarlanarak eğitilir. Bu süreç derin öğrenme (deep learning) olarak bilinir. Derin öğrenme sırasında ağ, verilen parametreler ve sonuçlar arasındaki korelasyonları tespit ederek sonrasında sonuçları bilinmeyen parametreler hakkında öngörü yapabilmeyi öğrenir. Günümüzde yapay zeka kavramı derin öğrenme ile büyük ölçüde örtüşmektedir, öyle ki bu terimler sıklıkla birbirlerinin yerine kullanılmaktadır (82).

2.3.2- Makine Öğrenmesi (Machine Learning, ML)

Makine öğrenmesi, çeşitli görevlerde performansı artırmak için veriler arasındaki korelasyonları bulmayı amaçlayan bir bilgisayar bilimi dalıdır. Makine öğrenimi, bilgisayarın "öğrenme"sini (learn) sağlayan algoritmalar oluşturmakla ilgilidir. "Öğrenme" dediğimiz kavram ise ML için, istatistiksel düzenlilikleri veya diğer veri kalıplarını bulma süreci anlamına gelmektedir. Uygulamalı sağlık hizmetleri araştırmalarında, ML tipik olarak karmaşık veri yapılarındaki (örneğin, doğrusal olmayan ilişkiler, alt-korelasyonlar veya alt gruplar) kalıpları tanımlamak için otomatikleştirilmiş, oldukça esnek ve hesaplama açısından yoğun iş yükü gerektiren verileri tanımlamak için kullanılır. Yani bu tanım geleneksel tıp literatüründe araştırma yapmak için öncelikle hangi veriler arasında bir korelasyon bulunduğunu geçmiş tecrübelerle dayanarak tahmin edip sonrasında bu korelasyonun varlığını ispatlamak

için kontrollü deney ve gözlemler yapma zorunluluğunu bir kenara bırakarak, mevcut olan tüm verileri tek seferde değerlendirip varsa tüm veriler arasındaki herhangi bir korelasyon varlığını tespit etmenin önünü açmıştır.

ML yöntemlerinin kullanılıp kullanılmayacağını ve hangisinin kullanılacağını belirlemenin ilk adımı, araştırma sorusunu belirlemektir. Görüldüğü gibi ML algoritmaları geleneksel istatistiksel metotlara göre çok büyük üstünlük göstermiş olsa bile yine de çok spesifik araştırmalarda halen geleneksel istatistiksel yöntemler önemini korumaktadır. Makine öğreniminin, sEMG sinyallerinin yorumlanması, sınıflandırılması ve tespit edilmesinde etkili olduğunu gösterilmiştir.

Makine öğrenimi tabanlı modelleme hastalık sınıflandırması, karar verme ve yeni terapötik müdahalelerin geliştirilmesinde uygulanabilir. Çeşitli çalışmalar, nöromusküler bozuklukları sınıflandırmak için hareket sınıflandırması, kas yorgunluğu tespiti ve denetimsiz (unsupervised) öğrenme üzerine odaklanmıştır. Destek vektör makineleri (support vector machine, SVM) ve Evrimsel sinir ağları (convolutional neural networks, CNN) en yaygın kullanılan modeller arasındadır.

EMG sinyalleri çokça çalışmada ele alınmasına rağmen elektromiyografi sinyallerinin uygun şekilde işlenmesi, sinyal özelliklerinin belirlenmesi ve farklı kas gruplarının pasif ve aktif durumlarını sınıflandırmak için en iyi modelin belirlenmesi için gerekli olan kas aktivasyonu çalışmaları EMG sinyallerine göre daha az çalışmanın konusu olmuştur (83-85).

Örneğin Di Nardo, sEMG sinyallerinin dalgacık spektrogramını bir yapay sinir ağına girdi olarak kullanan yüksek verimli bir yaklaşım (DEMANN) geliştirmiştir. Bu yöntem, yüksek sinyal değişkenliğinde bile kas aktivasyonu için %90 üzerinde pozitif değerlere ulaşmayı başarmıştır. Benzer şekilde Ghislieri, orta ve düşük artefakt oranlarında yarı otomatik yöntemlerden daha iyi performans gösteren bir “uzun kısa süreli bellek” (LSTM) sinir ağı eğitmiştir.

Makine öğrenimi tabanlı tıbbi araştırmalardaki artışa rağmen, KTS üzerine yapılan araştırmalar nispeten seyrek. Bazı çalışmalar KTS tanısı için tahmin modellerini araştırmış olsa da kapsamlı klinik verilere dayalı olarak KTS şiddetini sınıflandırmaya yönelik makine öğrenimi tabanlı bir model henüz sunulmamıştır.

Makine öğrenimi hattı dört aşamadan oluşmaktadır:

- (1) Özellik çıkarma (feature-extraction),
- (2) Özellik seçimi (feature selection),
- (3) Sınıflandırıcının eğitimi (training of a classifier)
- (4) Hiperparametre optimizasyonu (hyperparameter optimization) (86-87).

2.3.2.1- Denetimli Öğrenme (Supervised Learning)

Denetimli öğrenme, tahmin görevlerini tanımlamak için kullanılır çünkü burada amaç daha önceden belirlenmiş bir sonucu tahmin etmektir. Denetimli öğrenme, örnek girdi-çıkı çiftlerine dayalı olarak bir girdiyi bir çıktıya eşleyen bir işlevi öğrenmeye yönelik makine öğrenmesi algoritma grubudur. Grupları bilinen (labelled) bir dizi eğitim verilerini değerlendirerek ortaya bir fonksiyon çıkarır.

Denetimli makine öğrenimi algoritmaları, harici yardıma ihtiyaç duyan algoritmalar. Giriş veri kümesi eğitim ve test veri kümelerine ayrılır. Eğitim veri kümesi, tahmin edilmesi gereken sonuç değişkenine sahiptir (88).

2.3.2.2- Denetimsiz Öğrenme (Unsupervised Learning)

Denetimsiz makine öğrenimi yöntemleri, daha öncesinde belirlenmiş bir sonuca(label) sahip olmadan bir veri yapısındaki ilişkileri bulmayı amaçladıkları için tanımlama görevlerinde özellikle yararlıdır. Bu makine öğrenimi kategorisi, analizin doğruluğunu denetleyebilecek bir sonuç değişkenine sahip olmadığı için denetimsiz olarak adlandırılır. Denetimsiz öğrenmenin amacı, bir veri yapısı içinde altta yatan boyutları, bileşenleri, kümeleri belirlemektir (89).

Veri araştırma biliminin temelde 3 ana görevi bulunmaktadır;

- 1-) Tanımlama(description)
- 2-) Tahmin(prediction)
- 3-Nedensellik (causal inference) (korelasyon tespiti)¹

¹ Yazar notu: Geçmişten gelen ve günümüzde devam etmekte olan varlığa dair ontolojik ve bilginin kaynağına dair epistemolojik tartışmalar, halen objektif ve genel geçer bir zemine oturmamış ve çözüm olarak bireysel bazda gerek pragmatik gerekse ampirik vs. gibi düşünsel sistemler ile aşılmaya çalışılan bu durum aynı şekilde bu ilgili çalışmada da nedensellik(causality) ile aşılmaya çalışılmıştır. Tüm bu düşünce sistemlerinin bahsettiğimiz gibi objektif ve genel geçer bir zemine oturmamış

Tanımlama (Description): Tanımlama, belirli değişkenlerin nicel bir özetini sağlamak için verilerin kullanılmasını içerir. Tanımlayıcı bir soruya örnek olarak şu verilebilir; bir sağlık hizmeti veritabanında travma sonrası stres bozukluğu (TSSB) olan bireylerin oranı nedir? Bu sorunun cevabı temel istatistiksel yöntemler (örneğin, tanı kodunun sıklığı) kullanılarak doğrudan elde edilebilir ve bu durumu belirlemek için makine öğrenimi gerekli olmayabilir. Bununla birlikte, sağlık hizmeti veri tabanında TSSB için fazla yanlış tanı girilmiş ise makine öğrenimi, diğer tanı kodları (örn. depresyon, yaygın anksiyete bozukluğu), ilaçlar (örn. prazosin) ve klinisyen notlarından elde edilen serbest metin verileri (örn. kaçınma davranışlarının ve kabusların açıklaması) gibi çoklu veri kaynaklarını birleştiren bir TSSB profili oluşturmaya çalışmak için kullanılabilir. Denetimsiz makine öğrenimi (unsupervised learning) yöntemleri, daha öncesinde belirlenmiş bir sonuca sahip olmadan bir veri yapısındaki ilişkileri bulmayı amaçladıkları için tanımlama görevlerinde özellikle yararlıdır.

Tahmin (prediction): İkinci büyük veri bilimi görevi tahmindir. Örneğin, “kişilik özellikleri”nin ve “travmaya maruz kalma”nın daha sonra majör depresif bozukluk gelişimi için riski artırdığı hipotezini test etmek yani, kırılganlığın ve stresin psikolojiyi ne ölçüde öngördüğünü test etmek için kullanılabilir. "Logistik regresyon" gibi geleneksel ML algoritmaları veriler ve sonuç arasındaki ilişkilerin istatistiksel önemi hakkında yorumlanabilir tahminler elde ederek bu hipotezi test etmek için kullanılabilir.

olmasının yanı sıra nedensellik(causality) de kendi içerisinde naturalizm ve ara nedencilik(occasionalizm) gibi sistemler üzerinden açıklanmakta olup, bu çalışmada ve genellikle çoğu bilimsel çalışmada nedensellik), naturalist anlamda ele alınmaktadır.

Bilimsel toplumda, “aksi görülmeyecek şekilde süreklilik arz eden korelasyonlar” kavramı için “nedensellik(causation)” açıklaması yapılması lehine bir eğilim söz konusu iken bu durumun halen hem felsefi ve hem de özellikle nedensel anlamda mutlak bir genelgeçer bir açıklamasının olmaması nedeniyle bizim çalışmamızda “süreklilik arz eden korelasyon” dediğimiz kavram da yine korelasyon adı altında ele alınarak epistemolojik ve ontolojik açıdan olmasa bile nedensellik açısından objektiflik sağlanmaya çalışılmıştır. Ana konumuzun bu felsefi yaklaşım olmaması nedeniyle bu durumun ayrıntısı ilgili yayınlara bırakılmış ve okuyucuyu yanıltmamak için bu kısa bilgi yazısının eklenmesi uygun görülmüştür.

Başka bir örnek olarak da travmaya maruz kaldıktan sonraki üç ay içinde majör depresif bozukluk yaşama olasılığı en yüksek olan kişileri doğru bir şekilde belirlemek için yüzlerce değişkeni uygun katsayılarıyla birlikte içeren bir algoritma geliştirmek için kullanılabilir. Amaç büyük veya karmaşık veri yapılarında tahmin yapmak ise makine öğrenimi geleneksel istatistiksel yöntemlere tercih edilebilir çünkü bu tür yöntemler geleneksel parametrik yöntemlere kıyasla daha az sayıda istatistiksel varsayımlara sahiptir.

Tahmin işleminin amacı, sonucun doğruluğuna en güçlü şekilde katkıda bulunan değişkenleri belirlemektir. Denetimli öğrenme, tahmin görevlerini tanımlamak için kullanılır çünkü burada amaç, daha önceden belirlenmiş bir sonucu tahmin etmektir.

Korelasyon tespiti (causal inference): Korelasyon tespiti, sonucu etkilediği düşünülen bir verinin dahil edildiği sonuçları, bu veri dahil edilmemiş olsaydı karşılaşılabileceğimiz olgusal sonuçlarla karşılaştırarak bu korelasyonların tahmin edilmesini ifade eder. Bunun bir örneği, bir çalışma popülasyonundaki tüm bireylerin psikososyal bir intihar önleme müdahalesi almış olması durumunda gözlemlenecek intihar oranının, müdahale almamış olmaları durumunda gözlemlenecek intihar oranı ile karşılaştırılmasıdır. Genelde bu tür korelasyonları tespit etmek için klinisyenler randomize kontrollü çalışma ve geleneksel istatistiksel yöntemler kullanırlar. Nedensel çıkarım yöntemleri onlarca yıldır mevcut olmasına rağmen denetimli öğrenme yöntemlerinin bu işleme entegrasyonu daha yenidir.

Özetle; makine öğrenmesi algoritmaları, çalışmanın amacına bağlı olarak gerekli olabilir veya olmayabilir, burada dikkate alınması gereken ilk şey araştırma sorusunun niteliği, bunu takip eden soru ise bu soruyu cevaplamak için en uygun istatistiksel aracın hangisi olduğudur.

2.3.3-Makine Öğrenimi (Machine Learning, ML) Algoritmaları

Makine öğrenimi (ML), bilgisayar sistemlerinin belirli bir şekilde programlanmadan belirli bir görevi yerine getirmek için kullandıkları algoritmaların ve istatistiksel modellerin bilimsel çalışmasıdır. Öğrenme algoritmaları günlük olarak kullandığımız birçok uygulamada yer almaktadır. Google gibi bir web arama motoru internette arama yapmak için her kullanıldığında, bu kadar iyi çalışmasının

nedenlerinden biri, web sayfalarını nasıl sıralayacağını öğrenen bir öğrenme algoritması kullanmasıdır

Makine öğrenimi (ML), makinelere verileri daha verimli bir şekilde nasıl kullanacaklarını öğretmek için kullanılır. Bazen verileri görüntüledikten sonra, verilerden çıkarılan bilgileri yorumlayamayız. Bu durumda, makine öğrenimini uygularız (90).

2.3.3.1- Supervised Learning Algoritmaları

Regresyon modelleri: Lineer regresyon en basit ve en yaygın makine öğrenimi algoritmalarından biridir. Tahmine dayalı analiz yapmak için kullanılan matematiksel bir yaklaşımdır. Bağımlı ve bağımsız değişkenler arasında doğrusal ilişkiler kuran bir veri değerlendirme ve modelleme yöntemidir. İlk kez Sir Francis Galton tarafından 1894 yılında ortaya atılmıştır. Hyun-il Lim yazılım talimatlarına dayalı kod vektörlerini kullanarak yazılım özellikleri tanımlı uygulamaların değerlendirilmesinde doğrusal regresyon kullanımı için bir çerçeve geliştirilmiştir. Bu yöntemi test etmek için deneyler yapılmıştır ve deneysel bulgular doğrusal regresyonun yazılım analizinde ilgili yazılımları sınıflandırmak için etkili bir yol olabileceğini ve sonuç olarak, iyi tasarlanmış bir makine öğrenimi modeli yazılım analizinde kolaylıkla kullanılabilir olduğu gösterilmiştir.

Tek değişkenli regresyon analizleri [Ki-kare, Fisher ile exact test ve student T testi ve varyans analizi (ANOVA)], analizdeki diğer ortak değişkenlerin sonuçlarını dikkate almak için kullanılamaz. Bu nedenle, kısmi korelasyon ve regresyon, bilim insanlarının iki değişken arasındaki ilişkiyi değerlendiren testlerdir. Linear regression değişkenlerin etkilerinin ölçülmesinde ve çoklu girdi değişkenlerine karşı modelleme yapmanın mümkün olduğu matematiksel araştırma yöntemlerinde yaygın olarak kullanılmaktadır (91-93).

Regresyon iki teori için kullanılan bir tekniktir; İlk olarak, regresyon analizleri genellikle tahmin ve öngörü için kullanılır ve bu uygulamalar makine öğrenimi alanıyla büyük ortanda ilgilidir. İkinci olarak ise, regresyon analizi bazı durumlarda bağımsız ve bağımlı değişkenler arasındaki güçlü korelasyonları belirlemek için kullanılabilir. Regresyon modellerine göre bağımsız değişkenler, bağımlı değişkenleri öngörmektedir.

Regresyon analizi, 'x' bağımsız değişken değerlerine bağlı olarak bağımlı 'y' değişken değerini tahmin eder. Regresyon linear (basit, doğrusal) regresyon veya multipl(çoklu) regresyon olabilir (93).

Basit (simple) doğrusal (linear) regresyon: Basit doğrusal regression tek bağımsız değişkenli bir durum modelidir. Basit doğrusal regresyon değişkenin bağımlılığını tanımlayarak bağımsız değişkenlerin etkisini bağımlı değişkenlerin etkileşiminden ayırır. “ $y = \beta_0 + \beta_1 x + \epsilon$ ” formülünü kullanır (94).

Multipl (Multivariate, çoklu) linear regresyon (MLR): MLR, birden fazla bağımsız değişken kullanarak bir bağımlı değişkeninin sonucunu tahmin etmek için kullanılan istatistiksel bir tekniktir (95).

Polinom regresyonu (polynomial regression): Polinom regresyonu, bağımsız ve bağımlı değişkenler arasındaki ilişkinin n. derece polinom modellemesinde analiz edilen bir regresyon türüdür. Verilerin polinom denkleminin bağımlı ve bağımsız değişkenlerin eğrisel etkileşimiyle harmanlandığı özel bir MLR durumudur (96)

Karar ağacı (Decision tree, DT) regression: Decision tree algoritması, bir nesnenin(object), öznitelik(attribute) vektörüne göre (öznitelik1, öznitelik2 , . . . öznitelikN, karar sınıfı) şeklinde temsil edildiği, nesnelerin karar sınıflarına ayrıştırılması için kullanılan bir makine öğrenimi yöntemidir. Öznitelik değerleri bir nesnenin özelliklerini tanımlar. Öznitelikler genellikle veri setini oluşturan kişiler tarafından tanımlanır ve seçilir. Karar sınıfı (decision class), öğrenme setindeki nesneler için değeri bilinen ve diğer tüm özniteligi bilinmeyen nesneler için öğrenilmiş decision tree algoritmasına göre tahmin edilecek olan niteliklerdir. Karar sınıfı normal şartlar altında elimizdeki verilerle ölçemediğimiz bir özelliktir (örneğin, geleceğe yönelik bazı tahminler yapılması) veya ölçümü kabul edilemeyecek kadar pahalı, karmaşık veya hiç bilinmeyen bir özelliktir.

Decision tree iki tür problem için kullanılabilir;

1. Sınıflandırma (karar sınıfı sabit(kalitatif) bir değişkendir.)
2. Regresyon (karar sınıfı sürekli (kantitatif) bir değişkendir.)

Öznitelik-karar sınıfı nesnelere örnek olarak hastanın muayene sonuçları ve bu sonuçlara göre konulan hastalık teşhisi veya geçmişteki hava koşulları ve bunlara göre öngörü yapılmış hava tahmini verilebilir. Tümevarımsal çıkarım, karar sınıfları

bilinen bir dizi örneği analiz ederek nesnelerin nasıl sınıflandırılacağını öğrenmeyi amaçlayan, somut örneklerden genel modellere geçme sürecidir.

Öğrenme verisi, her biri bilinen bir karar sınıfına ait olan bir tür veri grubundan oluşur ve çıktı ise karar sınıfı bilinmeyen verilerin öznitelik değerlerine göre eşlendiği karar sınıflarından oluşur. Bu eşleme hem öğrenme verilerini hem de öngörülen verileri doğru bir şekilde sınıflandırmalıdır. Decision tree, bu tür eşlemeleri ifade etmek için kullanılan bir algoritmadır ve iki veya daha fazla alt-ağaca (sub-tree) bağlı dallardan (node) ve bir karar sınıfı ile isimlendirilmiş yapraklardan (leaf) oluşur.

Her bir dal, her bir olası sonucun alt ağaçlardan herhangi biriyle ilişkilendirildiği verinin öznitelik değerlerine dayalı olarak bazı işlemler yapar. Bir veri, ağacın birinci dalından başlanarak sınıflandırılır. İlk dal için bir sonuç belirlenir ve süreç uygun alt-ağaç kullanılarak devam eder. Bu şekilde en sonunda yaprağa ulaşıldığında sonuç belirlenmiş olur.

Dallandırma (bölümleme, split node) oluşturma'nın iki temel türü vardır;

1. Değişken değerli bir grup: her değer için yeni bir dal üretir her dal üretiminde farklı sayıda dal oluşur
2. Sabit değerli bir grup: sürekli iki dala ayrılarak yaprağa kadar ilerler.

1960'larda Hunt ve arkadaşları, karar ağaçları oluşturmak için sezgisel bir yöntem kullanan CLS'yi (concept learning system) tanıttı (98). CLS, kavramları öğrenen ve bunları yeni vakaları sınıflandırmak için kullanan bir öğrenme algoritmasıydı ve DT'lerin öncüsüydü ve Quinlan'ın ID3 sistemine öncülük etti. ID3 ise sınıflandırma yapılacak özneliği belirlemek için bilgi içeriğini kullanma fikrini ortaya atmıştır.

Quinlan daha sonra ID3'ü, geleneksel istatistiksel yaklaşıma dayalı bir karar ağacı oluşturmak için hâlâ referans model olarak kabul edilen geliştirilmiş C4.5 modeline yükseltmiştir. Bununla birlikte, DT sınıflamaları için, çeşitli bölme kriterleri ve budama metodolojileri de vardır (97)

Rastgele orman (Random Forest, RF): RF, sınıflandırma ve regresyon ağacı (Classification and regression trees, CART) modellerinin bir ileri aşamasıdır. CART modelleri basittir, parametrik değildir ve hem sınıflandırmada veya regresyon çalışmaları için kullanılabilir. Bir CART modelinin çıktısı genellikle bir karar ağacı (decision tree)'dir. Yani aslında RF modeli birçok decision tree sonuçlarını bir arada

değerlendirilerek ortaya çıkan en doğru sonucu veren bir algoritmadır, yani ağaç (tree) miktarı arttıkça forest (orman) daha çok genişler ve daha doğru sonuçları ortaya koyar.

Tek ağaca sahip CART modelleri genellikle çok sayıda etkileşimli veriye sahip karmaşık verileri analiz etme görevine uygun değildir, bu nedenle karışık verilerde ağaç sayısı mümkün olduğunca fazla tutulmalıdır (98).


Klasifikasyon (Clustering) modelleri:

Lojistik regresyon (Logistic regression): Lojistik regresyon, bir sınıflandırma modeli olan doğrusal regresyonun bir varyasyonudur. Amaç, tüm verileri net bir şekilde ayırabilen ve sınıflandırabilen düz bir çizgi belirlemektir (99).

K- En yakın komşu (K-nearest neighbour, KNN): KNN bir denetimli öğrenme yöntemidir ve kullanışlı bir sınıflandırma algoritmasına sahiptir. Bu yöntemde veriler matematiksel bir uzayda noktalar olarak temsil edilir. Noktalar arasındaki mesafeyi ölçmek için ise öklid metodu kullanılır. Bu metotiki veri noktasının koordinatları arasındaki farkların karelerinin toplamının karekökünü alır. KNN algoritmasında, bu mesafeler kullanılarak veri noktalarının sınıflandırılması yapılır (100-101).

Destek vektör makine (Support vector machine, SVM): Tipik olarak SVM'ler, sınıflandırma ve regresyon analizi ile ilgili veri sorunlarını çözen denetimli makine öğrenimi metodu olarak kabul edilir. Çalışma prensibinde hiperdüzlem oluşturma mantığı yatar, hiperdüzlem ise veri kümeleri arasını ayıran sınırdır (Eğer veriler iki özellik içeriyor ise bu sınır çizgi olur, üç adet özellik içeriyor ise düzlem olarak adlandırılır, daha fazla özellik içeriyor ise görselleştirmek mümkün olmasa da mantığı aynıdır). SVM ayırıcı bir sınıflandırıcıdır ve format olarak optimal bir hiperdüzlem ile tanımlanmaktadır. Yeni örnekleri sınıflandıran optimum bir hiperdüzlem üretir, hiperdüzlemi destekleyen veri kümelerine ise destek vektörleri denir. Bununla birlikte, optimum hiper düzlemin seçimi kolay bir iş değildir, çünkü optimum düzlem, gürültüye (yanlış ve anlamsız veri) duyarlı olmamalı ve veri setlerinin genelleştirilmesini doğru bir şekilde yapabilmelidir.

Özetle, SVM, eğitilmiş veri setine minimum mesafe veren optimize edilmiş hiper düzlemi bulmaya çalışır (102).



Şekil 19- SVM Algoritması Hiper Düzlem Oluşturma Yöntemi (103)

Naive bayes: Yapılan çalışmalar Naive bayes'in birçok yaklaşım arasında en yüksek doğruluğa sahip olduğunu göstermiştir. Bayes teoremine dayanan Naive bayes sınıflandırıcı, olasılıksal bir istatistiksel sınıflandırıcıdır; “naive” terimi, özellikler veya nitelikler arasında koşullu bağımsızlığa işaret eder. Yani, algoritma her bir özelliğin diğerlerinden bağımsız olduğunu düşünerek çalışır. Naive bayes modeli, çok büyük veri kümeleri oluşturmak ve daha fazla analiz yapmak için uyumludur. Naive bayes modeli çok basit ve karmaşık bir sınıflandırma yöntemidir ve karmaşık senaryolarda bile iyi performans göstermiştir (104).

Decision tree ve random forest klasifikasyon: Bu iki metot hem regresyon hem de klasifikasyon metotları içinde yer aldığı ve daha önceki bölümde regresyon başlığı altında incelendiği için tekrar değinilmemiştir.

2.3.3.2- Unsupervised Learning Algoritmaları

Kümeleme algoritmaları:

K- ortalamalar kümeleme (K-Means clustering): Bir sınıflama algoritması olan K-Means, Steinhaus da dahil olmak üzere farklı araştırmacılar tarafından bağımsız

olarak önerilmiştir. K-means kümeleme algoritması, kümenin nesne ortalama değerini kullanarak kümeler oluşturur. K-means algoritması, başlangıçta merkez noktalarını (kümelerin merkezlerini) rastgele seçer ve daha sonra verileri bu merkezlere atar. Bu süreçte, algoritma her bir merkezin konumunu iteratif olarak günceller. Ancak bu güncellemeler sırasında, algoritma bazen verileri global minimuma değil, sadece yerel minimuma ulaştırır, bu durum K-means algoritmasının olası handikapları arasındadır, bu nedenle, optimum sınıflama sonucunu elde etmek için farklı başlangıç küme merkezi seçimleriyle belirli bir “K” değeri için birkaç çalıştırma gerekir. Buna ek olarak, standart algoritma, uzaklık ölçüsü olarak öklid metriğinin kullanılması nedeniyle yalnızca küresel kümeleri tespit eder. Bu sınırlamalara rağmen, K-means kümeleme algoritması esneklik, verimlilik ve uygulama kolaylığı ile tanındığından dolayı veri madenciliğinde kullanılan kümeleme algoritmaları arasında yer almaktadır. Basitliği ve düşük hesaplama karmaşıklığı, K-means algoritmasına kümeleme problemlerini çözmek için birçok alanda geniş bir kabul sağlamıştır. Performansını artırmak için çeşitli K-means kümeleme algoritması varyantları geliştirilmiştir.

Hiyerarşik kümeleme (Hierarchical clustering): Hiyerarşik kümeleme teknikleri iç içe geçmiş kümeleri yinelemeli olarak ya yığılmalı ya da bölünmeli bir şekilde bulur. Hiyerarşik kümeleme grubunun bir alt kümesi olan yığılmalı kümeleme, her bir veri noktasının kendi kümesinde başladığı ve daha sonra benzer küme çiftlerini art arda birleştirerek bir hiyerarşi oluşturduğu kümelemedir. Başka bir alt grup olan bölücü kümeleme tek bir kümedeki tüm veri noktalarıyla başlar ve her kümeyi tekrar tekrar daha küçük kümelere böler. Bölünmeler veya birleşmeler bir kez yapıldıktan sonra geri döndürülemezler ve bu nedenle hiyerarşik kümeleme ile yeniden ayarlama mümkün değildir.

Yığılmalı hiyerarşik kümeleme algoritması genellikle aşağıdaki gibi uygulanır;

Adım 1: Her gözlem başlangıç kümeleri olarak kabul edilir.

Adım 2: Kümeler arasındaki uzaklıklar hesaplanır.

Adım 3: Minimum mesafeye sahip iki küme birleştirilir ve bunlardan tek bir küme oluşturulur. Daha sonra bu birleştirme işlemi göstermek için mesafe matrisi yeniden hesaplanır.

Adım 4: Tüm gözlemleri içeren tek bir küme kalana kadar Adım 2 ve 3 tekrarlanır.

Nesneler arasındaki benzerliği ölçmek için mesafe veya yakınlık ölçüsü gereklidir. En yaygın olarak kullanılanı mesafe ölçüm tekniği öklid uzaklığıdır. Diğer uzaklık hesaplama metotları; Manhattan, Minkowski ve Hamming yöntemleridir. Hiyerarşik kümeleme algoritmasının çıktısı, iç içe geçmiş kümelerin sırasını gösteren iki boyutlu ağaç benzeri bir yapı olan bir dendrogramdır (105).

DBSCAN (Density-based spatial clustering of applications with noise): DBSCAN, bir kümeleme algoritmasıdır ve verileri yoğunluk temelli bir şekilde gruplara ayırır. Bu algoritma, özellikle yoğunluk açısından farklılaşan kümeleri belirlemek ve gürültülü verileri ayıklamak için kullanılır (106).

SVM Kümeleme: Destek vektör makine klasifikasyon yöntemi ile benzer mantığı olan denetimsiz bir yöntemdir (107).

Boyut indirgeme (dimensionality reduction) algoritmaları: Boyut indirgeme verilerdeki önemli bilgileri kaybetmeden, verilerin boyutunu (örneğin, özellik sayısını) azaltmayı hedefler. Bu, büyük ve karmaşık veri setlerini daha kolay işleyebilmek için yapılır. Bir veri kümesine uygulanan boyut azaltma tekniklerinin avantajları şöyledir;

1. Boyut sayısını ve veri depolama alanını azaltır.
2. Hesaplama için daha az zaman gerektirir.
3. Alakasız, istatistiği bozan ve gereksiz veriler silinebilir.
4. Veri kalitesi optimize edilebilir.
5. Bir algoritmanın verimli çalışmasına yardımcı olur ve doğruluğu artırır.
6. Verilerin görselleştirilmesine izin verir.
7. Sınıflandırmayı basitleştirir ve performansı da artırır (108).

2.3.3.3- Pekiştirmeli Öğrenme (Reinforcement Learning, LR)

Algoritmaları

Pekiştirmeli öğrenme, makine öğrenimi alanının bir alt kümesidir ve beklenen ödülü maksimize eden bir eylem dizisinin öğrenilmesi konseptine dayanır. Büyük miktarda eğitim verileri olsun veya olmasın kullanılabilmesi nedeniyle, diğer ML tekniklerinin büyük miktarda eğitim verisi gerektirdiğinin aksine az miktarda eğitim verisi ile de çalışabilmesi nedeniyle son zamanlarda birçok alanda uygulanmaktadır.

RL, özellikle tedavi rejimleri, tıbbi tanı ve tıbbi görüntüleme gibi sağlık uzmanlarının karşılaştığı gerçek dünya karar verme problemlerini çözme gücüyle sağlık alanında dikkat çekici bir başarıya ulaşmıştır. Birçok ilgili bilimsel araştırma makalesi ve uygulama, RL'nin tıbbi verilerin özelliklerine özellikle uygun olduğunu önermektedir (109).

2.3.3.4- Ensemble Learning (Topluluk Öğrenimi) Algoritmaları

Ensemble learning, birçok modelden gelen tahminleri karıştırarak tahmin performansını artırmaya çalışan bir makine öğrenmesi yaklaşımıdır. Topluluk modellerinin kullanılması, tahmin genelleme hatasını azaltmayı amaçlar. Bu teknikte kullanılan modeller çeşitli ve birbirlerinden bağımsız olduğunda, modellerin tahmin hatasını azaltmış olur. Bu teknik, bir tahmin geliştirmek için her bir modelin kolektif sonuçlarına göre karar verir. Çok sayıda temel model içermesine rağmen, topluluk modeli tek bir model gibi çalışır yani her bir modelin ayrı ayrı yaptıkları hataları azaltmak ve modelin genellemesini korumak için birden fazla modeli birleştirir. Bu modellerden bagging, boosting, stacking ve voting, topluluk öğrenme algoritmalarının dört ana sınıfıdır ve her birini anlamak ve her tahmine dayalı modelleme çabasına dahil etmek kritik öneme sahiptir (110).

Torbalama (bagging): Bagging, aynı veri kümesinin farklı örneklerine uygun hale getirilmiş birçok karar ağacının tahminlerinin bir araya getirilmesidir. Ensemble bagging, eğitim veri setinin farklı versiyonları üzerinde belirli bir algoritmayı tekrar tekrar çalıştıran bir dizi sınıflandırıcının bir araya getirilmesiyle oluşturulur. Aynı kardinaliteye (veri kümesindeki öge sayısı) sahip olacak şekilde eğitim veri kümesinden tekrar tekrar örnekleme (resampling) yapma sürecidir. Bu yöntem, sınıflandırıcının çeşitliliğini ve aşırı uyum (overfitting) riskini azaltmayı hedefler. Tek bir modele kıyasla, nihai modelin overfitting yapma olasılığı daha düşük olmalıdır.

Bagging tekniklerinden birisi olan bootstrapping, bir veri kümesinin sapmasını (bias) ve değişkenliğini daha iyi anlamak için kullanılan, rastgele tekrar örnekleme gibi bir yöntemdir. Birden fazla karar ağacı, her bir eğitim alt kümesine uyacak şekilde oluşturulur. Veri kümesindeki özniteliklerin ve örneklerin dağılımı genellikle rastgele yapılır.

Başka bir bagging tekniği ise "extra trees" yöntemidir, bu teknik random forest gibi çok sayıda karar ağacını bir araya getirir. Ancak, diğer ağaçlardan farklı olarak,

bu yöntemde ağaçlar, tüm örnekleri kullanırken bölünmeleri (splits) rastgele seçer. Model birleştirme işlemi hesaplama karmaşıklığını artırabilse de bagging eş zamanlı olarak çalıştırılabilir. Bu da uygun donanım mevcut olduğu sürece modelin eğitim süresini önemli ölçüde azaltabilir. Derin öğrenme modellerinin eğitimi uzun sürdüğü için, birden fazla derin öğrenme modelini optimize etmek mantıklı değildir, çünkü derin öğrenme modelleri uzun süre eğitim gerektirir ve bu modellerin eğitimi sırasında eş zamanlı işlem yapma şansı çok da mümkün değildir (111).

Boosting: Boosting algoritmaları, zayıf öğrenicileri (poor learners) güçlü öğrenicilere dönüştürmek için “ağırlıklı ortalamalar” kullanır. Boosting sırasında, orijinal veri kümesi birkaç alt gruba ayrılır. Bu alt kümeler, modeli eğitmek için kullanılır ve bu süreç sonunda yeterli performansa sahip birden fazla model elde edilir. Bir önceki model tarafından yanlış kategorize edilen veriler, ağırlıkları artırılarak yeni alt kümeler oluşturmak için kullanılır. Yani topluluk yöntemi, zayıf modelleri maliyet fonksiyonuna göre birleştirip performansını iyileştirir. Görüldüğü üzere, bagging’den farklı olarak, her model girdileri birleştirmeden önce bağımsız olarak çalışır ve süreç sonunda bir model seçimi yapılmaz. Yeni model, önceki modellerin en az başarılı olduğu kısımlara odaklanır, bu da sürecin sonunda biası daha az olan güçlü bir modelin oluşmasını sağlar.

Boosting, tıpkı bagging gibi, regresyon ve sınıflandırma problemlerini çözmek için kullanılabilir. Tek bir zayıf model ile karşılaştırıldığında, bu tarz topluluk yöntemleri daha üstün tahmin sonuçları vermektedir (112).

Stacking: Stacking, bir veya daha fazla temel seviye sınıflandırıcının bir meta-learner sınıflandırıcı ile birleştirildiği topluluk yöntemidir. Orijinal veri, stacking yönteminde birçok farklı modele giriş olarak kullanılır. Meta-learner daha sonra her modelin girdi ve çıktısını, ayrıca ağırlıklarını tahmin etmek için kullanılır. En iyi performans gösteren modeller seçilirken, geri kalanlar elenir. Her bir ardışık katmandan gelen model tahminleri, bir sonraki katman için girdilerle karıştırılır ve yeni bir tahmin seti üretilir. Topluluk stacking yöntemi, bazen "mixing" (karıştırma) olarak da adlandırılır çünkü tüm veriler bir tahmin veya sınıflandırma oluşturmak için birleştirilir.

Multilinear response (MLR) ve Probability distribution (PD) stacking, en gelişmiş teknikler arasında yer alır. Bu prosedürde, veri kümesi rastgele olarak $\square$ eşit

bölüme ayrılır. Bu bölümlerden biri test için kullanılırken, geri kalanlar eğitim için kullanılır; bu süreç, $\square$ -fold cross-validation olarak adlandırılır. Bu eğitim ve test çiftlerini kullanarak çeşitli öğrenme modellerinin tahminleri elde edilir ve bu tahminler, metamodel oluşturmak için veri olarak kullanılır. Metalog, nihai tahmini üretir ve bu yöntem genellikle “winner-takes-all” tekniği olarak bilinir (113).

Voting: Voting classifier topluluk yöntemi, birçok bağımsız temel tahmin edici modelin tahminlerini birleştirerek nihai tahmin yapma metodudur. Bu yöntem, tek bir modele bağımlı kalmak yerine, birden fazla modelin ortak sonucunu dikkate alarak daha doğru tahminler yapmayı hedefler. Voting classifier'da üç tür oylama bulunur:

1. Hard voting: Her model bir tahmin yapar ve sınıflandırma, en fazla oyu alan model üzerinden yapılır.
2. Soft voting: Her model, sınıflar için olasılık veya güven puanları oluşturur. Nihai tahmin, tüm modellerdeki beklenen olasılıkların toplanması ve en yüksek ortalama olasılığa sahip modelin seçilmesi ile yapılır.
3. Weighted voting: Farklı modellerin nihai tahmin üzerindeki etkisinin farklı olmasına olanak tanır. Bu ağırlıklar manuel olarak belirlenebilir ya da bireysel modellerin performansına dayalı olarak otomatik olarak öğrenilebilir. Bu çeşitlilik sayesinde, her modelin performansına göre nihai tahmin üzerindeki etkisi farklı olabilir. Böylece daha başarılı modellerin tahmine daha fazla katkıda bulunması sağlanır (114).

Çalışmamızda boosting metotları kullanıldığı için bir sonraki bölümde boosting algoritmaları ayrıntılı olarak incelenecektir.

2.3.3.5- Boosting Metotları (Gradient Boosting Machines, GBM)

CatBoost: CatBoost, denetimli makine öğrenmesi için kullanılan açık kaynaklı bir gradyan arttırmalı karar ağacı (GBDT) uygulamasıdır ve iki farklı özelliği vardır:

Ordered target statistics (Sıralı hedef istatistikleri):

Bu özellik, özellikle kategorik verilerle çalışırken kullanılır. Hedef değişkenin istatistiksel özelliklerini kullanarak kategorik değişkenleri dönüştürmeyi sağlar, ancak overfitting'i önlemek için bu işlem belirli bir sıralama ile yapılır.

Ordered (sıralı) Boosting:

Normalde boosting algoritmaları, tüm veriyi bir seferde işler. Ancak bu durumda, model bazen gelecek verilerden bilgi öğrenebilir ve bu da modelin aşırı uyum yapmasına neden olabilir. Ordered boosting ise, modeli sırayla ve kademeli olarak eğitir. Yani, her aşamada veri setini küçük bölümlere ayırır ve sadece önceki kısımdan öğrenilen bilgileri kullanır. Bu sayede modelin, ileride göreceği verilere dair bilgi edinmesi engellenir ve model daha sağlam ve genel hale gelir.

Özetle, bu iki yenilik, modelin yanlış bilgilere dayanarak aşırı uyum yapmasını engeller ve özellikle kategorik verilerle çalışırken daha doğru sonuçlar elde etmeye yardımcı olur (115).

XGBoost (Extreme Gradient Boosting): XGBoost, GBDT'ye dayanan optimize bir topluluk algoritmasıdır. Boosting algoritmasının temel düşüncesi, birçok karar ağacının bir arada kullanıldığında tek bir ağaçtan daha iyi performans göstermesidir. Her bir karar ağacı tek başına kötü sonuçlar verebilir. Ancak, birçok ağaç birleştirildiğinde performans önemli ölçüde iyileşir.

XGBoost çalışma prensibi şu şekilde özetlenebilir;

- 1- Korelasyonları güçlü bir şekilde bulabilen bir kural seti oluşturulur ve eğitim setindeki özellik vektörleri sürekli ise bunlar ayrık hale getirilir (discretizasyon) yani süreklilik arz eden verileri belirli kümeler altında sınıflanır.
- 2- Doğru grupları tahmin edebilen kurallar seçilir, ardından yeni bir kural seti oluşturulur. Her kuralın kazanç değeri hesaplanır ve kazanç oranı(win-rate) 1.0'dan düşük olan kurallar çıkarılır. Bu şekilde, etkili kural seti elde edilmiş olur.
- 3- Etkili kural setindeki kurallar, en kısa uzunluk, en yüksek kazanç ve en yüksek destek değerine göre sıralanır.
- 4- Eğer döngü sayısı belirtilen sınırdan büyükse, özellik listesindeki öge yazdırılır ve işlem sonlandırılır. Değilse etkili kural setindeki ilk kural alınarak sonucu, özellik listesine eklenir ve bu kural tekrardan bulunmaya çalışılmaması için etkili kural setinden çıkarılır. Bu şekilde listede zaten daha önceden bulunan özelliklerin tekrar bulunması engellenir.
- 5- Kurala uyan örnekler çıkarılarak kaydedilir, kalan eğitim setindeki kazanç ve destek değerleri yeniden hesaplanır.

- 6- Etkili kural setindeki kurallar en yüksek kazanç ve en yüksek destek değerine göre sıralanır, ardından 4. adıma geri dönülür. Bu işlem kullanıcı tarafından belirtilen miktar sayısına devam eder (116).

AdaBoost (Adaptive Boosting): Yoav Freund ve Robert Schapire tarafından 1995 yılında tanıtılan AdaBoost (Adaptive Boosting) algoritması hem sınıflandırma hem de regresyon görevleri için önde gelen ve yaygın olarak kullanılan bir makine öğrenimi tekniği haline gelmiştir. Algoritmanın ana gücü, tek bir güçlü sınıflandırıcı oluşturmak için birden fazla zayıf öğreniciyi birleştirme ve böylece genel sınıflandırma doğruluğunu önemli ölçüde artırma yeteneğinde yatmaktadır.

AdaBoost algoritması şu şekilde çalışır; başlangıçta, her eğitim verisi örneğine eşit bir ağırlık verilir. İlk model eğitilir ve doğal olarak bazı örnekler yanlış sınıflandırılır. Algoritma, bu yanlış sınıflandırılan örnekler daha fazla önem vererek sonraki model bu hataları düzeltmeye çalışır. Yani, yanlış sınıflandırılan verilerin ağırlıkları artırılır, böylece sonraki model bu hatalar üzerinde daha fazla durur. Bu süreç, adım adım devam eder ve her yeni model, önceki modellerin hatalarını düzeltmeye odaklanır. Sonuç olarak, zayıf modeller birleşerek daha güçlü bir tahmin modeli oluşturur (117).

LightGBM: LightGBM, Microsoft tarafından geliştirilen bir topluluk algoritmasıdır. LightGBM'in temel avantajı, eğitim algoritmasının büyük ölçüde hızlandırılmasıdır. LightGBM, karar ağacı algoritmalarının üzerine inşa edilmiştir ve n-estimators sayısında güçlendirilmiş ağaçlar kullanır. Ağaç güçlendirme (tree boosting) algoritmaları, tahmin problemleri için diğer algoritmalarından daha üstün performans gösterir.

LightGBM'in diğer algoritmalarından farkı, ağacın yapısını nasıl genişlettiğiyle ilgilidir. Normalde, çoğu ağaç tabanlı algoritma, ağacı katman katman veya derinlik bazlı genişletir. Yani, ağacın her katmanındaki tüm dalları aynı anda oluşturur bu yöntem "derinlik bazlı" (depthwise) olarak adlandırılır. LightGBM ise farklı bir yaklaşım kullanır, ağacı "yaprak bazlı" genişletir. Bu şu anlama gelir; tüm dalları aynı anda büyütme yerine, sadece o an üzerinde çalışılan yaprağı genişletir. Diğer algoritmalar bir katmanı tamamlarken, LightGBM sadece cost fonksiyonun en fazla olduğu yaprağı genişletir. Böylece hatayı daha hızlı bir şekilde azaltır ve modelin doğruluğu artar. Bu yüzden, LightGBM'in bu yaprak bazlı yaklaşımı, aynı veri

üzerinde çalışırken daha fazla hatayı ortadan kaldırarak, seviye bazlı algoritmalara göre daha yüksek doğruluk sağlar. Diğer algoritmalar tüm katmanları aynı anda genişlettiği zaman, hatanın en büyük olduğu noktaya odaklanamaz ve bu düzeyde bir doğruluğa ulaşamaz (118).

2.3.2- Derin öğrenme (deep learning, DL)

Derin öğrenme algoritmaları denetimli, denetimsiz ve pekiştirmeli öğrenme olarak ayrılabilir. DL, ML'nin bir alt dalıdır ve yapay sinir ağları (artificial neural networks, ANN, YSA) kullanarak yani çok sayıda gizli katman içererek çok büyük miktarlardaki veriden özellik öğrenilmesinde kullanılır.

Son yıllarda, yapay sinir ağı araçları EMG sınıflandırması alanında birçok araştırmacının ilgisini çekmiştir. YSA'ların örneklerden öğrenme yetenekleri EMG çalışmalarındaki belirsizlik durumunu tolere etmelerini sağlamaktadır. YSA'lar ayrıca yüksek boyutlu girdilerle çalışırken genelleme yapabilme yetenekleriyle de tanınmaktadır. Bir YSA'nın öğrenme kabiliyeti onun gücüdür, ancak bu durum halen YSA'ların elde ettiği sonuçların nedenlerini açıklayamadığı gerçeğini değiştirmemektedir. Bu sorun bir yana, yüksek özellik değişkenliğine sahip büyük veri setlerinden doğrudan öğrenme yetenekleri EMG sınıflandırması için güçlü bir avantajdır.

Pattichis ve arkadaşları nöromüsküler bozuklukların teşhisi için EMG sinyallerini sınıflandırmak amacıyla parametrik patern tanıma algoritması (PPR) ve YSA modelinden oluşan entegre bir sistem kullanmışlardır. Bu sistem YSA'ları hem denetimli hem de denetimsiz eğitim paradigmaları altında kullanmıştır. Pattichis'in çalışmasında denetimli öğrenme için geri yayılım (Backward Propagation, BP) ve denetimsiz öğrenme için Kohonen kendi kendini organize eden özellik haritaları (SOFM) algoritması kullanılmıştır. Bu sayede, yapay zeka aracılığı ile miyopatik kasların sıklıkla kısa süreli, düşük genlikli ve azalmış faza sahip MUP'lara sahip olduğu, nöropatik hastaların ise uzun süreli, yüksek genlikli ve çok sayıda faza sahip MUP'lara sahip olduğu modeli keşfedilmiştir. Ayrıca bu çalışma her bir grup için net sınırlar önerilemeyeceğini de göstermiştir. Başka bir çalışmada Abel ve arkadaşları nöromüsküler bozuklukların EMG ile tanısında teşhisinde farklı yapay zeka öğrenme algoritmalarının kullanımını incelemişlerdir ve bu çalışmada dönüş analizi (turn analysis), küçük segmentler (small segments) ve sıklık analizi (frequency analysis) gibi

parametrelerin kombinasyonlarını kullanarak üç denetimli ve bir denetimsiz sinir ağının performansını araştırmışlardır. Çalışmada kullanılan denetimli algoritmalar Levenberg-Marquardt optimize edilmiş geri yayılım ağı (LBPN), radyal tabanlı ağ (RBN), öğrenen vektör niceleme ağı (LVQ) ve denetimsiz algoritmalar ise Kohonen SOFM karşılaştırılmıştır.

Çalışmanın ayrıntıları ve kullanılan algoritmalar, bizim çalışmamız ile çok ilgili olmadığı için ayrıntılı ele alınmamış olup çalışmanın sonucunda sinir ağlarından herhangi birinin doğruluk açısından diğerlerinden üstün olduğunu gösterilmemiştir. Ancak, LBPN ve RBN ağlarının benzerlerine göre daha hızlı eğitildiği kaydedilmiştir ve kayda değer diğer bir durum ise birçok parametre ile kombine edilmiş bazı algoritmaların tek bir parametre kullanılanlara göre daha düşük skorlar üretmiş olduğudur.

Bu çalışmadan iki yıl sonra Christodoulou ve Pattichis aynı problem için modüler bir YSA önermiştir. Bu sistem, uzman bir nörofizyoloğun MUP özelliklerini analiz ederken başvuracağı karar verme sürecini taklit etmek üzere tasarlanmıştır. Zaman alanı parametreleri (time domain parameters), frekans alanı parametreleri (frequency domain parameters), cepstral katsayılar (cepstral coefficients) ve üç farklı dalgacık katsayısı (three different wavelet coefficients) dahil olmak üzere altı farklı özellik seti hesaplanmış ve çoklu SOFM sınıflandırıcılarına girdi olarak kullanılmıştır. Tüm bireysel sınıflandırıcılardan elde edilen sonuçlar daha sonra çoğunluk oylaması esas alınarak birleştirilmiştir. Her bir özellik setinin ve sınıflandırıcının nihai teşhise katkısı, güven ölçüsüne göre ağırlıklandırılmıştır (119-120).

3. GEREÇ VE YÖNTEM

3.1- Çalışma grubu

Tezimizde klinik olarak KTS düşünülmüş ve test için EMG laboratuvarına yönlendirilen hastalar seçilmiştir. Araştırmaya toplamda 1.649 hastaya ait her el için birer tane olmak üzere toplamda 3298 EMG verisi dahil edilmiştir.

Dahil edilme kriterleri;

1. 18 yaşından büyük olması
2. Karpal tünel sendromu ön tanısı almış olması
3. EMG iletim verilerinin ve sonuçlarının değerlendirilebilir olması (veri kaybının tolere edilemeyecek ölçüde yüksek olmaması).

Dışlama kriterleri olarak ise hastaların polinöropati, mononöropati multipleks, radikülopati, sinir kesisi gibi standardizasyonu önemli miktarda bozabilecek özellikler taşıyan hastalar çalışma dışı bırakılmıştır.

3.2- Veri Toplama

Çalışmada kullanılan veriler, 01.10.2011-30.06.2023 tarihleri arasında hastanemizdeki Dahili Tıp bilimleri Nöroloji Anabilim dalı Elektronörofizyoloji Laboratuvarı'ndan toplanmıştır. EMG testleri, Natus Dantec Keypoint Focus (Natus, USA) cihazları kullanılarak gerçekleştirilmiştir. EMG testi sırasında AANEM tarafından belirlenen global olarak kabul görmüş EMG çekim teknikleri uygulanmıştır. Toplanan veriler, EMG cihazında dijital yöntemlerle kaydedilmiştir. EMG sonuçları çekim esnasında değerlendirilirken AANEM tarafından belirlenen karpal tünel sendromu tanısı için EMG testinde kullanılan değerler referans alınmış ve sınıflamada literatürde pek çok çalışmada kabul görmüş karpal tünel sendromu sınıflaması kullanılmıştır.

EMG'de elde edilen veriler

1. Median sinir motor yanıtı (bkap)
2. Bilek(wrist)- abdükör pollicis breves (w-apb) latans(lat), amplitüd(amp)
3. Dirsek (elbow)- abdükör pollicis breves (e-apb) latans(lat), amplitüd(amp), iletim hızı(cv)

4. Median sinir duyusal yanıtı (dsap) latansı(lat), amplitüdü(amp), iletim hızı(cv)
5. Ulnar sinir motor yanıtı (bkap)
6. Bilek(wrist)- abductor digiti minimi (adm) latans ve amplitüdü
7. Dirsek (elbow) -adm latans, amplitüd, iletim hızı
8. Ulnar sinir duyusal yanıtı (dsap) latans, amplitüd, iletim hızı olmuştur.

Hastalar KTS açısından dört gruba ayrılmıştır. Gruplar oluştururken objektif referans değerlerle birlikte, daha subjektif olan hastaların klinik ve muayene bulguları da göz önüne alınarak hastalar ilgili gruplara yerleştirilmiştir.

3.3-Veri ön işleme

Veriler EMG cihazının kendi yazılımı üzerinden “.xpx” ve “.oxpx” formatlarında elde edilmiş ve harici ortama aktararak python - pymupdf kütüphanesi destekli özel bir kod hazırlanarak görüntülenmiş ve ilgili veriler tablolaştırılmıştır. Bu aşamada sayısal olmayan veriler sayısal değere çevrilmiştir. KTS sınıflandırılmasında EMG verileri ile birlikte EMG raporunun sonucu manuel olarak iki farklı araştırmacı (F.Y. ve A.G.) tarafından değerlendirilerek karpal tünel sendromu açısından “0: Normal”, “1: Hafif KTS”, “2: Orta KTS”, “3: Ağır KTS” olarak sınıflandırılmıştır. Veri ön işleme aşamasına ilişkin yazılım kodlarına <https://github.com/ITimeLoggeRI> adresinden ulaşılabilir.

3.4- Eksik verilerin yönetimi

Toplanan EMG verileri, analiz öncesinde aykırı verileri temizleme ve eksik verileri doldurma işlemlerine tabi tutulmuştur. Verilerdeki eksik veya hatalı kayıtlar “Hot deck imputation” yöntemi ile düzeltilmiş ve doldurulmuştur.

3.5- Veri Analizi

Toplanan ve ön işleme tabi tutulan EMG verileri, makine öğrenimi algoritmaları ile analiz edilmiştir. Bu çalışmada kullanılan makine öğrenimi algoritmaları arasında; “Decision Tree”, “K-Nearest Neighbour”, “Suport Vector Machine”, “Random Forest”, “Naive Bayes”, “CatBoost”, “Xgboost”, “Light GBM” yer almaktadır. Bu algoritmaların seçilme nedeni, seçilen algoritmaların sadece

regresyon değil sınıflama da yapabilmesi ve sonuç sınıflarında ikiden fazla grup için kullanılabilir olması idi.

Veri seti, %80 eğitim, %20 test oranında eğitim ve test setlerine bölünmüştür. Ayrıca elde edilen sonuçların daha doğru olması için “Çapraz doğrulama doğruluk puanları” (K-Fold Cross-Validation) doğrulama yöntemi kullanılmıştır.

Ayrıca veriler ML algoritmaları ile değerlendirilirken veri işlemenin otomatikleşmesi ve standardizasyon sağlanması için hiperparametre optimizasyonu gerektiren algoritmaların hiperparametreleri “optuna” kütüphanesi kullanılarak elde edilen en iyi doğruluk skoru veren hiperparametreler seçilerek yapılmıştır.

Makine öğrenimi modellerinin performansı; karışıklık matrisi (confusion matrix), sınıflandırma raporu (classification report), kullanılarak değerlendirilmiştir.

Çapraz doğrulama doğruluk puanları, modeli yalnızca tek bir eğitim ve test bölmesi üzerinde değerlendirmeye kıyasla, modelin genelleme yeteneği hakkında daha kapsamlı bilgi sağlar. Çapraz doğrulama, veri setini farklı bölümlere ayırarak modelin her bir bölümdeki performansını değerlendirir. Bu yöntem, modelin belirli bir veri setine aşırı uyum sağlamasını önlemeye yardımcı olur ve genel performansını daha doğru bir şekilde ölçer.

Karışıklık matrisi, detaylı performans analizi yaparak modelin hangi sınıflarda daha başarılı çalıştığını göstermeye yardımcı olur.

Sınıflandırma Raporu ise kesinlik (precision), duyarlılık (recall, sensitivite), F1-skoru ve support değerleri ile dengesiz veri setlerini değerlendirmeye yardımcı olur.

Çalışmada uygulanan makine öğrenmesi yazılım kodlarına yazılım kodlarına <https://github.com/ITimeLoggeRI> adresinden ulaşılabilir.

3.6- Performans ölçütleri:

1. **Duyarlılık (Sensitivity):** Modelin bir sınıftaki gerçek pozitifleri ne kadar doğru şekilde yakalayabildiğini gösterir.
2. **Kesinlik (Precision):** Modelin pozitif olarak tahmin ettiği örneklerin ne kadarının gerçekten pozitif olduğunu belirtir.

3. **F1 Skoru:** Kesinlik ve duyarlılığın harmonik ortalamasıdır. Özellikle dengesiz veri setlerinde kullanılır.
4. **Doğruluk (Accuracy):** Tüm sınıflandırmaların ne kadarının doğru olduğunu gösterir. Modelin genel başarısını ortaya koyar.
5. **Karmaşıklık Matrisi (Confusion Matrix):** Her bir sınıfın doğru ve yanlış sınıflandırma sayısını gösteren tablodur.

3.7- Kullanılan Yazılımlar ve Araçlar

Verilerin elde edilmesinde ve analizinde yapay zeka ve makine öğrenimi konusunda en fazla tercih edilen yazılım dili olan Python (v3.12.7) kullanılmıştır. Analiz sürecinde python diline ait açık kaynak kodlu; Pandas (v2.2.3), Numpy (v2.2.0), Scikit-learn (v1.6.0), Optuna (v 4.1.0), joblib (v1.4.2), json, google.colab (v1.0.0), io, TensorFlow (v2.18.0), Keras (v3.7.0), pymupdf (v1.25.1) ve matplotlib (v3.10.0) kütüphaneleri kullanılmıştır. Donanım olarak Google Colab üzerinden 40 gb ram desteğine sahip Nvidia 100 ekran kartı, 2 adet vCPU çekirdeğine sahip Intel Xeon işlemci ve 52 GB bellek kullanılmıştır.

3.8- Güçlükler ve Sınırlamalar

Bu çalışmada karşılaşılan zorluklar arasında veri eksikliği ve yanlış girilmiş veriler mevcut idi. Bu sorunların üstesinden gelmek için manuel olarak aykırı verileri temizleme, eksik verileri ise “hot deck imputation” metodu ile tamamlama yöntemleri uygulanmıştır. Veri imputation aşamasında “hot deck” metodunun tercih edilirken veri sınıflarının gruplar şeklinde olması ve veri dağılımının birbirleri ile olan ilişkileri göz önüne alınmıştır. Çalışmanın diğer sınırlamaları arasında tüm hastaların tek bir hastaneden olması, EMG tetkikinde referans alınan sonuç değerlerinin aynı merkezdeki tek bir ekolü uygulayan hekimler tarafından yorumlanmış olması ve hastaların klinik bilgilerinin elimizde olmaması sayılabilir.

3.9- Etik ve Yasal Uygulamalar

Bu çalışma için “Afyonkarahisar Sağlık Bilimleri Üniversitesi Müdahale Olmayan Bilimsel Araştırmalar Etik Kurulu” tarafından 07/06/2024 tarihinde etik kurul onayı alınmıştır (Toplantı no: 2024/04, Karar no: 158).

Veri toplama ve analiz aşamasında hastaların kimlik bilgilerinin gizliliği ve verilerin anonimliği uygun yöntemlerle sağlanmıştır.

4. BULGULAR

Afyonkarahisar Sağlık Bilimleri Üniversitesi Araştırma ve Uygulama Hastanesi’nde 01.10.2011-30.06.2023 tarihleri arasında poliklinik muayenesi sonrası karpal tünel sendromu ön tanısı ile EMG çekimi için yönlendirilen 1649 hastaya ait her iki kol için birer adet olmak üzere toplam 3298 EMG verisi çalışmaya alınmıştır. Hastaların ortalama yaşı $46,88 \pm 40$ ’tır. EMG verilerinin 2647’si kadın (%80), 650’si erkek (%20) hastaya aittir. Verilerin 141’i ağır (%4), 692’si orta (%21), 375’i hafif (%11) KTS sınıfındaydı. 2089 (%63) veride ise KTS saptanmadı (normal).

EMG verileri üzerinde “Decision Tree”, “K-Nearest Neighbour”, “Suport Vector Machine”, “Random Forest”, “Naive Bayes”, “CatBoost”, “Xgboost”, ve “Light GBM” makine öğrenimi algoritmaları uygulanmış ve sonuçlar Tablo 1, 2, 3 ve 4’te verilmiştir.

ALGORİTMA	DOĞRULUK (ACCURACY)	DUYARLILIK (RECALL)	F1 SKOR	ÖZGÜLLÜK (SPECIFICITY)
DECISION TREE	0.76	0.57	0.65	0.95
CATBOOST	0.74	0.54	0.62	0.94
XGBOOST	0.74	0.57	0.64	0.95
NAIVE BAYES	0.32	0.65	0.43	0.95
SVM	0.70	0.45	0.55	0.93
KNN	0.67	0.38	0.48	0.93
LIGHTGBM	0.70	0.64	0.67	0.95

Tablo 1- Hafif Derece KTS Grubu ML Algoritmaları Başarı Durumları

ALGORİTMA	DOĞRULUK (ACCURACY)	DUYARLILIK (RECALL)	F1 SKOR	ÖZGÜLLÜK (SPECIFICITY)
DECISION TREE	0.87	0.92	0.90	0.98
CATBOOST	0.86	0.91	0.89	0.97
XGBOOST	0.87	0.91	0.89	0.97
NAIVE BAYES	0.86	0.73	0.79	0.92
SVM	0.81	0.90	0.85	0.98
KNN	0.78	0.87	0.82	0.98
LIGHTGBM	0.89	0.91	0.90	0.98


Tablo 2- Orta Derece KTS Grubu ML Algoritmaları Başarı Durumları

ALGORİTMA	DOĞRULUK (ACCURACY)	DUYARLILIK (RECALL)	F1 SKOR	ÖZGÜLLÜK (SPECIFICITY)
DECISION TREE	0.86	0.68	0.76	0.99
CATBOOST	0.85	0.61	0.71	0.99
XGBOOST	0.86	0.64	0.73	0.99
NAIVE BAYES	0.67	0.71	0.69	0.98
SVM	0.78	0.50	0.61	0.97
KNN	0.92	0.39	0.55	0.97
LIGHTGBM	0.92	0.82	0.87	0.98

Tablo 3- Ağır Derece KTS Grubu ML Algoritmaları Başarı Durumları

ALGORİTMA	DOĞRULUK (ACCURACY)	DUYARLILIK (RECALL)	F1 SKOR	ÖZGÜLLÜK (SPECIFICITY)
DECISION TREE	0.94	0.98	0.96	0.96
CATBOOST	0.94	0.98	0.96	0.96
XGBOOST	0.94	0.98	0.96	0.96
NAİVE BAYES	0.95	0.84	0.89	0.76
SVM	0.93	0.97	0.95	0.95
KNN	0.92	0.98	0.95	0.96
LIGHTGBM	0.95	0.97	0.95	0.94

Tablo 4- Normal Grup ML Algoritmaları Başarı Durumları



Tablo 5- ML Algoritmaları Accuracy ve Cost Function Karşılaştırması

Kullanılan makine öğrenimi algoritmaları değerlendirildiğinde;

4.1- XgBoost:

XGBoost algoritmasında genel doğruluk oranı %91 olarak bulunmuştur. KTS olmayan hastalardaki başarı oranı (doğruluk: 0.94, duyarlılık: 0.98, F1-skor: 0.96) oldukça yüksek olarak bulunmuş, hafif derecede KTS için doğruluk %74, duyarlılık %57 ve F1-skor %64 olarak ölçülmüştür. Bu değerler, hafif KTS sınıflandırmasında orta düzey bir performansa işaret etmektedir.

Orta derece KTS için %89 F1-skor, ağır derece KTS için %73 F1-skor elde edilmiştir. Bu sonuçlar, orta ve ağır KTS sınıflarında daha düşük bir performansı göstermektedir.

4.2- SVM:

SVM algoritmasının genel doğruluk oranı %88 olarak bulunmuştur. KTS olmayan grup için doğruluk %93, duyarlılık %97 ve F1-score %95 gibi yüksek başarı oranları elde edilmiş, hafif derecede KTS (Sınıf 1) için doğruluk %70, duyarlılık %45 ve F1-score %55 olarak hesaplanmıştır. Bu sonuçlar, hafif derece KTS sınıflandırmasında kısmen daha düşük bir performansı göstermektedir.

Orta derece KTS sınıflandırmasında %85 F1-score, ağır derece KTS sınıflandırmasında %61 F1-skor elde edilmiştir. Görüldüğü üzere ağır KTS sınıflandırmasında sınırlı başarı sağlanabilmiştir.

4.3- Random Forest:

Random Forest algoritması %90 genel doğruluk oranı ile en iyi performans sergileyen modellerden biri olmuştur. KTS olmayan sınıf ve orta derece KTS sınıfının tespitinde yüksek başarı (F1-skor: %96 ve %88) elde edilmiştir.

Ancak F1-skor değeri hafif derece KTS sınıfı için %64 ve ağır derece KTS sınıfı için %68 olarak bulunmuştur, bu da bu sınıfların tespitinde sınırlı bir performansa işaret etmektedir.

4.4- Naive Bayes:

Naive Bayes algoritması, %79 doğruluk oranı ile diğer algoritmalara göre daha düşük bir performans sergilemiştir. KTS olmayan sınıf için %95 doğruluk ve %84 duyarlılık ile iyi bir başarı elde edilmişken hafif derecede KTS sınıfı için doğruluk %32, duyarlılık %65 ve F1-skor %43 gibi daha düşük değerler görülmüştür.

Orta derece KTS sınıfı için F1-score %79, ağır derece KTS sınıfı için %69 F1-score elde edilmiştir. Bu sonuçlar, Naive Bayes'in hafif KTS tespitinde sınırlı başarı gösterdiğine işaret etmektedir.

.

4.5- LightGBM:

LightGBM algoritması %92 doğruluk oranına sahiptir. KTS olmayan grup için F1-skor %96, orta derece KTS için %90, ağır derece KTS için %87 F1-skor ile iyi bir performans göstermiştir.

Hafif derecede KTS sınıfında ise F1-score %67 olarak hesaplanmış, bu da bu sınıfta diğer sınıflara kıyasla nispeten daha düşük bir başarıya işaret etmektedir.

4.6- K-Nearest Neighbors (KNN):

KNN algoritması %87 doğruluk oranı ile diğer algoritmalar arasında orta seviyede bir performans sergilemiştir. KTS olmayan grup için F1-skor %95; Orta derece KTS (Sınıf 2) için %82; ağır derece KTS için %55 F1-skor elde edilmiştir.

Hafif derecede KTS sınıfı için doğruluk %67, duyarlılık %38 ve F1-skor %48 olarak ölçülmüştür.

.

4.7- Decision Tree:

Decision Tree algoritması %91 genel doğruluk oranına sahiptir. KTS olmayan ve orta derece KTS sınıflarındaki başarısı oldukça yüksektir (sırasıyla %96, %90).

Hafif derece KTS sınıfı için %65 F1-skor, ağır derecede KTS için %76 F1-skor elde edilmiştir. Bu değerler diğer sınıflara kıyasla hafif KTS sınıflandırmasında kısmen daha düşük bir performansı göstermektedir.

4.8- CatBoost:

CatBoost algoritması, %90 doğruluk oranı ile dikkat çekmiştir. KTS olmayan grup için F1-skor %96, orta derece KTS için %89 F1-skor, ağır derece KTS için %71 F1-skor elde edilmiştir.

Hafif derecede KTS (Sınıf 1) için doğruluk %74, duyarlılık %54 ve F1-score %62 olarak hesaplanmıştır. Bu sınıfta diğer sınıflara kıyasla daha düşük performans gözlenmiştir.

4.9- Confusion Matrix (Karmaşıklık Matrisi) değerlendirmesi:

Genel değerlendirme olarak, kullanılan algoritmalar KTS olmayan bireyler ve orta derece KTS'ye sahip olan bireyler üzerinde yüksek başarı göstermiştir ancak sınıf 1 (hafif KTS) ve sınıf 3 (ağır KTS) gruplarında sınırlı performans mevcuttur.

Hafif KTS vakalarındaki düşük performans, hafif KTS grubunun EMG özelliklerinin silik olması ile, ağır KTS grubunun düşük performansı ise sınıf dengesizliği ve yetersiz veriyle ilişkili olabilir. Bu nedenle, sınıf dengesizliklerini azaltmak, veri setini genişletmek ve daha gelişmiş ön işleme yöntemleri kullanmak, genel model performansını artırabilir.

4.10- Genel Doğruluk (Accuracy) Değerlendirmesi:

Tüm algoritmalar genel doğruluk (accuracy) açısından makul bir performans sergilemiştir. CatBoost, Decision Tree, LightGBM ve Random Forest modelleri, doğruluk oranlarıyla diğer yöntemlerin önünde yer alırken (%90-%92 arası), XGBoost %91 ile bu güçlü modelleri yakından takip etmiştir.

Naive Bayes ve KNN ise %77 ve %79 ile daha düşük doğruluk oranları göstermiştir.

5. TARTIŞMA

Pubmed veri arşivinde EMG ile yapay zekanın kullanımı alanındaki çalışmalara bakıldığında bazı çalışmalar EMG sayısal verileri kullanılarak derin öğrenme alanında yapılırken bazı çalışmalar ise ham elektriksel sinyal verileri kullanmışlardır, yine de yapay zeka konularının güncel olması nedeniyle yapılan çalışma sayısı henüz yeterli sayılara ulaşamamıştır.

Sakarya Üniversitesi Tıp Fakültesi'nde yürütülmüş ve 2 Mart 2022'de onay alan “Application of Machine Learning Algorithms for Carpal Tunnel Syndrome” isimli, “Journal of the Anatomical Society of India” dergisinde yayınlanan bir makalede karpal tünel sendromu tanısı olan ve kadın erkek dağılımı eşit olan 315 hastanın dahil edildiği bir çalışmada hastalar yaş, cinsiyet, boy, kilo, vücut kitle indeksi (BMI), dominant el (sağ veya sol), elektrofizyolojik veriler (Median sinir motor distal latansı, median sinir duyuşal sinir aksiyon potansiyeli amplitüdü, median sinir motor iletim hızı (>49 m/s), median sinir duyuşal iletim hızı, ulnar sinir motor distal latansı, ulnar sinir iletim hızı (bilek-dirsek arası), ulnar sinir duyuşal aksiyon potansiyeli amplitüdü, ulnar sinir duyuşal iletim hızı verileri kullanılarak machine learning algoritmaları ile değerlendirilmiş ve bu makalede kullanılan makine öğrenmesi algoritmalarının performansı şu şekilde bulunmuştur:

SVM (Support Vector Machines) en yüksek başarı oranına sahip algoritma olup, %96 başarı oranı elde edilmiştir. Lojistik Regresyon (LR) %93 başarı oranı ile ikinci sırada yer almıştır. Naive Bayes (NB) %92 başarı oranı sağlamıştır KNN algoritması da %92 başarı oranı elde etmiştir.

İncelenen algoritmalar arasında en yüksek doğruluk oranı SVM algoritmasında elde edilmiştir (121).

2021 yılında Yunanistan'ın Ioannina Üniversitesi'nde yapılan “Automatic Electrodiagnosis of Carpal Tunnel Syndrome Using Machine Learning” isimli prospektif bir çalışma “Bioengineering” isimli bir dergide 2021 yılında yayınlanmış çalışmaya toplamda 38 gönüllü dahil edilmiştir; bunların 28'i KTS belirtileri ve semptomları gösteren hastalar, 10'u ise yaşları uygun olarak eşleştirilen sağlıklı kontrol grubu olarak seçilmiş hastalardan oluşmaktadır. Çalışmaya hasta dahil edilme kriterleri; KTS belirtileri ve semptomları olan hastalar (örn. median sinir dağılımında hissizlik veya parestezi, gece parestezisi, el bileği ve avuç içi ağrısı, tenar kas atrofisi

veya zayıflığı), hastaların merkezi sinir sistemi lezyonları veya diğer nörolojik bozukluklarının bulunmaması, önceden KTS cerrahi müdahalesi geçirmemiş olma olarak kabul edilmiş ve veriler DT, SVM, KNN, Naive Bayes, Lojistik Regresyon algoritmaları ile değerlendirilmiş, veriler arasına hastaların klinik verileri dahil edilmemiş. EMG verilerinde ise; median sinir duyu amplitüdü, median sinir duyu maksimum amplitüdü, median sinir maksimum ve minimum amplitüd farkı, median sinir duyu başlangıç latansı, median sinir duyu tepe latansı, median sinir iletim başlangıçtan tepe amplitude kadar olan latans süresi, median sinir duyu iletim hızı, median sinir duyu alanı, median sinir motor distal amplitüdü, median sinir motor proksimal amplitüdü, median sinir motor distal başlangıç latansı, median sinir motor proksimal başlangıç latansı, median sinir motor iletim hızı verileri yapay zeka algoritmalarına sunulmuştur. Yayındaki en iyi sonuçlar SVM ve Decision Tree algoritmaları ile elde edilmiş, bu algoritmalarla %91-95 doğruluk seviyelerine ulaşılmış (122).

2024 yılında Türkiye'deki Kırşehir Ahi Evran Üniversitesi'nde yapılan “Carpal tunnel syndrome prediction with machine learning algorithms using anthropometric and strength-based measurement” isimli çalışmada karpal tünel sendromunu (KTS) öngörmek için makine öğrenimi algoritmaları kullanılarak elin antropometrik ve kuvvet temelli ölçümleri incelenmiştir (123).

Kanada'da 2014 yılında “Computers in Biology and Medicine” isimli dergide yayımlanan “Characterizing EMG data using machine-learning tools” isimli bir makalede EMG sinyal özellikleri veri olarak alınmış, toplam 433 kişiye ait 1015 EMG sinyali toplanmış ANN ve ML algoritmalar ile değerlendirilmiş ve en yüksek başarı oranı SVM(%99.4) ile elde edilmiştir.(124)

Özbekistan'da 2021 yılında Tashkent University of Information Technologies tarafından yürütülen "Comparative Analysis of the Results of EMG Signal Classification Based on Machine Learning Algorithms" başlıklı çalışma EMG sinyalleri kullanılarak el hareketlerinin sınıflandırılmasını amaçlamış ve bu sinyallerin analizi için RF, K-NN ve SVM gibi makine öğrenimi algoritmaları kullanılmıştır. Çalışma, BITalino cihazı kullanılarak toplanan düşük frekanslı EMG sinyalleri üzerine odaklanmıştır. 20-500 Hz frekans aralığında elde edilen bu sinyaller, Butterworth filtresi kullanılarak filtrelenmiş ve sinyalin sadece aktif bölümleri işlenmiştir. Makale

sonuçları incelendiğinde SVM, Çalışmada %95 doğruluk oranıyla en yüksek başarıyı sağlarken Random Forest; %93 doğruluk oranına ulaşmıştır KNN algoritması ise; çalışmada %90 doğruluk seviyesine ulaşmıştır.(125)

2019-2020 yılları arasında Kafrelsheikh Üniversitesi'nde gerçekleştirilen “Deep Learning-Based Approaches for Enhanced Diagnosis and Comprehensive Understanding of Carpal Tunnel Syndrome” isimli 2023 yılında “Diagnostics” isimli dergide yayınlanan bir çalışmada, 20-60 yaş arası KTS semptomları olan ve median sinir iletiminde latans uzaması tespit edilen ve semptom başlangıcından sonra en az 3 ay süreyle tıbbi tedaviye yanıt vermeyen hastaların dahil edildiği 160 adet hasta değerlendirilmiş ve hastaların EMG sinyalleri DL algoritmaları ile değerlendirilerek KTS açısından tanı koyma başarısı ölçülmüş ve DL algoritmaları %96.9 doğruluk oranına ulaşılmıştır. Ayrıca hastaların median sinir USG ölçümleri ile elde edilen CSA’ya ait metrik veriler RF ile değerlendirilmiş ve CSA ölçümlerinin zaman içindeki değişimlerini tahmin etme başarısı ölçülmüştür. RF burda bir ay sonrası için %88.41 doğruluk oranı, üç ay sonrası için ise %86.40 doğruluk oranı ve altı ay sonrası için de %91.40 doğruluk oranı elde edebilmiştir (126).

2010-2019 yılları arasında İskoçya'da bir el merkezinde yapılan 1916 hastanın verilerini analiz edildiği “Developing Machine Learning Algorithms to Support Patient-centered, Value-based Carpal Tunnel Decompression Surgery” isimli bir çalışmada karpal tünel dekompresyon cerrahisinden sonra işlevsel ve semptomatik iyileşmeyi öngörmek için makine öğrenimi algoritmaları kullanılmıştır. Bu çalışmada, işlevsel ve semptomatik iyileşme tahminleri için kullanılan veriler; hasta tarafından bildirilen sonuç ölçütleri (PROMs), objektif kriterler olarak da işlevsel iyileşme tahmini için, QuickDASH’ın 1–6. maddeleri, semptomatik iyileşme için, QuickDASH’ın 9–11. maddeleriyle el bileğinde his kaybı, ağrı gibi semptomlar analiz edilmiştir. Semptomatik iyileşme tahmininde, hastaların genel mobilite durumunu değerlendiren EQ-5D skorları ek veri olarak alınmıştır. Yaş, cinsiyet, baskın el gibi demografik faktörler ve sigara içme, diyabet gibi komorbiditeler de tahmin modellerine dahil edilmiştir. Hasta verileri, demografik, klinik özellikler ve hasta bildirimli sonuç ölçütleri (PROMs) dahil olmak üzere 61 değişkenle analiz edilmiş ve veriler eğitim (%75) ve test (%25) seti olarak ayrılarak sonrasında LR K-NN, SVM, XGBoost (RF kullanarak), ANN gibi çeşitli algoritmalar kullanılmıştır. Fonksiyonel

iyileşme için en iyi doğruluk oranı XGBoost ile %71,8; semptomatik iyileşme için en iyi doğruluk oranı XGBoost ile %75,9 olmuştur (127).

” Machine learning-based approach for disease severity classification of carpal tunnel syndrome” isimli Güney Kore, Pohang'da bulunan Pohang Stroke and Spine Hospital'da yapılan bir çalışmada 2015 ile 2021 yılları arasında KTS tanısı almış 1037 el değerlendirilmiştir. Çalışma 2021 yılında “Scientific Reports” isimli dergide yayınlanmıştır. Veri seti olarak kişisel veriler (yaş, cinsiyet, vücut kitle indeksi, diyabet varlığı), klinik semptomlar (semptom süresi, ağrı derecesi, gece ağrısı, tenar kas zayıflığı/atrofisi) ve USG bulguları [CSA ve fleksör retinakulumun palmar eğimi (PB)], kullanılmış. Yüzeyel EMG sinir iletim sonuçlarının sayısal özellikleri ve iğne EMG denervasyon bulguları verileri ise karpal tünel derecesinin referans sınıflamasını belirlemek için kullanılmış. Hastalara ait klinik veriler klasik istatistiksel yöntemler ile KTS derecelerine göre değerlendirilmiş ve KTS şiddetini belirlemede anlamlı bulunan değişkenler veri olarak ele alınmıştır.

Diyabet: İkili bir değişken olarak 0 ve 1 ile kodlanmış. "0" diyabet yok, "1" diyabet var şeklinde.

Gece ağrısı: Bu da bir ikili değişken olarak temsil edilmiş. Gece ağrısı olanlar "1", olmayanlar ise "0" olarak kodlanmış.

Nümerik ağrı skalası (NRS): Hastanın ağrı derecesini yansıtan sürekli bir değişken olarak 1 ile 10 arasında puanlanmış.

Tenar zayıflık/atrofi varlığı da 0 ve 1 olarak ikili değişken şeklinde kodlanmış; "1" varsa, "0" yoksa şeklinde temsil edilmiştir.

Vücut Kitle İndeksi (BMI), yaş, semptom süresi (ay), CSA ve palmar eğim gibi sürekli değişkenler ise doğrudan sayı olarak temsil edilmiş ve normalize edilerek algoritmaya dahil edilmiş. Hastalara ait klinik veriler machine learning algoritmalarına “var” veya “yok” şeklinde; ağrı gibi skala ölçekleri ile bulunan değerler ise puan sonuçlarına göre girilmiş.

Bu yayında kullanılan farklı makine öğrenmesi algoritmalarının doğruluk oranları aşağıdaki gibidir:

ANN: %73,7 doğruluk oranı; SVM: %74,5 doğruluk oranı; K-NN: %75,6 doğruluk oranı sağlanmıştır. CART algoritması ise %70,8 doğruluk oranı elde etmiştir. RF %75,6; stochastic gradient boosting %73,4 doğruluk oranına sahiptir.

XGBoost ise %76,6 doğruluk oranı ile en yüksek performansı göstermiştir (128).

2023 yılında Mısır'da Kaferelşikh Üniversitesi Hastanesi'nin Nöroloji Bölümü'nde gerçekleştirilen “Predicting CTS Diagnosis and Prognosis Based on Machine Learning Techniques” isimli bir çalışmada toplamda 160 hasta incelenmiştir. Bu hastaların 80'i KTS tanısı almışken, diğer 80 hasta KTS ile benzer semptomlara sahip (örneğin, servikal radikülopati de Quervain tendiniti) hastalıklara sahiptir. KTS tanılı hastalar arasında, 40 sol el ve 40 sağ el olmak üzere toplam 80 el incelenmiştir.

Çalışma teşhis ve tedavi olarak iki bölümden oluşturulmuştur;

Teşhis Modeli: KTS ve benzer semptomları olan diğer hastalıkları ayırt etmek amacıyla ML modelleri kullanılmış. Özellikle Boston Karpal Tünel Sendromu Anketi (BCTQ) ve sinir iletim çalışmaları gibi klinik verilerden faydalanılarak teşhis modeli geliştirilmiştir. Çeşitli ML algoritmaları ile karşılaştırıldığında, önerilen model %95,5 doğruluk sağlamıştır.

Tedavi Sonrası İyileşme Tahmini: USG rehberliğinde yapılan median sinir hidrodiseksiyonu sonrası, hastaların bir, üç ve altı aylık dönemlerde iyileşme durumları tahmin edilmiştir. Bu model, tedavi sürecinde hastaların sağlık durumlarını izlemeyi ve tedaviye yanıtlarını değerlendirmeyi amaçlamaktadır. Önerilen model, altı aylık iyileşme için %91,2 doğruluğa ulaşmıştır.

Yayının iyileşme tahmini bölümünde ise USG rehberliğinde median sinir hidrodiseksiyonu sonrası bir, üç ve altı aylık iyileşme dönemlerini tahmin etmek amacıyla bir model geliştirilmiştir. Tedavi sonrası iyileşme tahmininde kullanılan veri seti aşağıdaki bilgileri içermektedir:

BCTQ Anketi: Bu anket, hastaların ağrı, parestezi, uyuşukluk, güçsüzlük gibi semptomlarını ve işlevsel durumlarını (örneğin yazma, düğme ilikleme gibi günlük aktivitelerdeki zorluklar) değerlendirmektedir.

Sinir İletim Çalışmaları: Median sinir iletimi ölçümleri KTS'nin şiddetini değerlendirmek için kullanılmaktadır.

CSA: USG ile ölçülmektedir ve KTS'nin şiddeti hakkında bilgi vermektedir. Çalışmada, 9 mm² üzerindeki değerler KTS tanısı için belirleyici kabul edilmiş ve şiddet sınıflandırması yapılırken farklı alan aralıkları kullanılmıştır (örneğin, 13 mm²'ye kadar hafif, 13-15 mm² arası orta, 15 mm² üzerinde ise ağır olarak sınıflandırılmıştır.)

Demografik ve Kişisel Bilgiler: Hastaların yaşı, cinsiyeti, BMI (Vücut Kitle İndeksi) gibi kişisel veriler.

Çalışmada elde edilen doğruluk oranlarına göre 1 ay sonrası doğruluk oranlarında Bagging Random Forest en yüksek doğruluk oranına (%87,7) sahipken, Logistic Regression (%81,7) en düşük doğruluğa sahiptir; 3 ay sonrası doğruluk oranlarında Bagging Random Forest (%90,1) yine en yüksek doğruluğu gösterirken, Logistic Regression (%82,5) yine en düşük doğruluğu elde etmiştir; 6 ay sonrası doğruluk oranlarında Bagging Random Forest en yüksek doğruluk oranını (%91,2) alırken, Logistic Regression yine en düşük doğruluk oranını (%82,1) ulaşabilmiştir (129).

Çin'deki Sichuan Geleneksel Çin Tıbbı Hastanesi'nden elde edilen 2352 EMG raporunu kapsayan "The Application of the Machine Learning Method in Electromyographic Data" isimli bir çalışmada veriler temizlenerek iki ana veri seti oluşturulmuştur:

1. Fasiyal Motor Sinir İletim Çalışması (F-MNCS): 575 veri
2. İşitsel Beyin Sapı Yanıtı (ABR): 233 veri

Çalışma "IEEE Access" isimli bir dergide yayınlanmıştır. EMG raporlarının sonuçları normal ve anormal olarak sınıflandırılmış ve EMG raporlarına ait sayısal veriler machine learning algoritmaları ile değerlendirilmiştir. F-MNCS değerlendirmesi için doğruluk oranları daha yüksek seviyelerde iken, ABR değerlendirmesi için doğruluklar daha düşüktür. Standartizasyon her iki değerlendirme türü için de doğruluk oranlarını artırmıştır (130).

"Use of machine learning methods in diagnosis of carpal tunnel syndrome" isimli çalışma Türkiye'de Amasya Üniversitesi Tıp Fakültesi'nde gerçekleştirilmiş ve KTS tanısında makine öğrenimi yöntemlerinin uygulanmasını incelemiştir. Araştırmada 154 hastaya ait 195 EMG verisi kullanılmıştır. Çalışma "Computer Methods in Biomechanics and Biomedical Engineering" isimli dergide 2024 yılında

yayınlanmıştır. Bu çalışmada, karpal tünel sendromunun (KTS) teşhisi ve hastalık şiddetinin sınıflandırılması amacıyla makine öğrenimi (ML) algoritmaları kullanılmıştır. Çalışma, KTS teşhisi ve sınıflandırmasını desteklemek için EMG verilerinden elde edilen altı özellik (median motor distal latans, motor hız, motor amplitüd, median duyuşal distal latans, duyuşal hız ve duyuşal amplitüd) kullanılarak gerçekleştirilmiştir. Çalışma grubuna normal, hafif, orta ve ağır KTS seviyelerinde bireyler dahil edilmiştir. Çalışmada, sınıflandırma başarısını artırmak ve modelin daha genel geçer hale gelmesini sağlamak için boyut azaltma yöntemleri kullanılmıştır. Algoritma olarak DT, lineer ayırma analizi (LDA), Naive Bayes, SVM, K-NN ve ANN gibi farklı sınıflandırma algoritmaları kullanılarak sonuçlar dört sınıfa (normal, hafif, orta, ağır KTS) ayrılmıştır. Çalışmada DT, %96,99 doğruluk oranı ile en iyi performansı göstermiştir. SVM, %96,98 doğruluk oranıyla DT'ye çok yakın bir performans sergilemiştir. Naive Bayes, %96,95 doğruluk oranıyla, diğer algoritmalarından biraz daha düşük bir performansa sahiptir. K-NN, %96,98 doğruluk oranıyla SVM ile eşit bir performans göstermiştir. ANN, %96,99 doğruluk oranıyla DT ile aynı seviyede, makalede en iyi performans gösteren algoritmalarından biridir. RF, %96,91 doğruluk oranıyla listede yer alan diğer algoritmalarından biraz daha düşük bir doğruluk sergilemiştir, ancak hâlâ oldukça yüksek bir performans göstermektedir (131).

6. SONUÇLAR

Bu çalışmada, karpal tünel sendromunun (KTS) farklı derecelerini EMG verilerine dayalı olarak sınıflandırmak amacıyla çeşitli makine öğrenimi algoritmaları kullanılmıştır. KTS'nin farklı şiddet derecelerini ayırt edebilmek için sınıflandırma doğruluğu yüksek modellerin geliştirilmesi hedeflenmiştir. Özellikle CatBoost, Decision Tree ve LightGBM modelleri en yüksek genel doğruluk oranlarını göstermiştir. Bu modeller, özellikle KTS olmayan (sınıf 0) bireyler ile orta derece KTS (sınıf 2) hastalarını doğru bir şekilde sınıflandırma konusunda üstün performans göstermiştir. Bu durum, KTS'nin bu gruplarda daha belirgin özellikler göstermesi ve EMG verilerinin bu ayrımları daha kolay yansıtması ile açıklanabilir ancak, hafif derece KTS ve ağır derece KTS hastalarının sınıflandırılmasında tüm modellerde sınırlı başarı elde edilmiştir. Hafif derece KTS hastalarında sınıflandırma zorlukları, bu grubun klinik ve EMG özelliklerinin daha az belirgin olması ve normal bireylerle örtüşen özellikler göstermesi nedeniyle ortaya çıkmış olabilir. Ağır derece KTS hastalarında ise sınırlı sayıda veri bulunması ve bu grubun genellikle küçük bir örnekleme ile temsil edilmesi, sınıflandırma doğruluğunu olumsuz etkilemiştir.

Çalışmada kullanılan veri setinin sınırlılıkları göz önünde bulundurulduğunda, daha geniş çaplı ve farklı merkezlerden sağlanmış verilerin, algoritmaların performansını artırma potansiyeli taşıdığı düşünülmektedir. Özellikle, hasta sayısının artırılması ve veri çeşitliliğinin sağlanması, makine öğrenimi modellerinin hem genel doğruluğunu hem de hafif ve ağır derece KTS hastalarını sınıflandırma yeteneğini iyileştirebilir. Farklı merkezlerden temin edilen veri setlerinin kullanılması, modellerin genelleştirilebilirliğini arttıracak ve klinik uygulamalarda daha güvenilir sonuçlar elde edilmesine olanak tanıyacaktır.

Ayrıca, bu çalışmada kullanılan algoritmaların performansını artırmak için daha gelişmiş ön işleme yöntemleri ve özellik seçimi tekniklerinin uygulanması da gelecekteki çalışmalar için önerilmektedir. Örneğin; yaş, cinsiyet ve meslek gibi demografik verilerin yanı sıra diğer biyolojik sinyallerin de (örneğin, sinir ileti hızı veya kas fonksiyonlarına yönelik ölçümler) modellerde kullanılması, KTS'nin daha doğru sınıflandırılmasını sağlayabilir. Buna ek olarak, zamanla değişen verilerin analizi için zaman serisi tabanlı modellerin ve derin öğrenme yöntemlerinin uygulanması, mevcut yöntemlere kıyasla daha yüksek doğruluk sağlayabilir.

Sonuç olarak, bu çalışmada kullanılan CatBoost, Random Forest ve XGBoost algoritmaları, KTS'nin belirli şiddet seviyelerini ayırt etmede başarılı olmuş, ancak sınıf dengesizlikleri ve sınırlı veri miktarı nedeniyle tüm gruplar için ideal sonuçlara ulaşamamıştır. Bu doğrultuda daha geniş kapsamlı, farklı merkezlerin katkı sağladığı veri setleri ile yapılacak çalışmaların, KTS sınıflandırmasında makine öğrenimi algoritmalarının etkinliğini artıracağını düşünmekteyiz. Bu tür çalışmalar hem tanı süreçlerini iyileştirecek hem de hastalara uygulanan tedavi yaklaşımlarının daha iyi bireyselleştirilmesine olanak sağlayacaktır.



7. KAYNAKÇA

1. Kang J, Cho Y, Kim S, Lee J, Lee J, Lee J, et al. Development and validation of a deep learning model for real-time automated detection of sleep apnea in adults using electrocardiogram signals. *Sleep Med.* 2022;91:68-73.
2. Kukker A, Sharma R, Malik H. Forearm movements classification of EMG signals using Hilbert Huang transform and artificial neural networks. 2016 IEEE 7th Power India International Conference (PIICON). 2016;1-6.
3. Khezri M, Jahed M. Real-time intelligent pattern recognition algorithm for surface EMG signals. *Procedia Comput Sci.* 2017;120:259-66.
4. Pecolt S, Błażejowski A, Królikowski T, Młyński B. Conversion of bioelectric sEMG signals into analog form for the BLDC motors control. *Procedia Comput Sci.* 2022;207:3846-56.
5. Lulic-Kuryllo T, Negro F, Jiang N, Dickerson CR. Standard bipolar surface EMG estimations mischaracterize pectoralis major activity in commonly performed tasks. *J Electromyogr Kinesiol.* 2021;56:102509.
6. Ashwal S, ed. The Early 20th Century 1900–1940. In: *Child Neurology* (Second Edition). 2nd ed. Academic Press; 2021:177-183.
7. Hodges PW, Tucker K. Pain and motor control: From the laboratory to rehabilitation. *Appl Physiol Nutr Metab.* 2011;36(6): .
8. Gechev A, Kane NM, Koltzenburg M, Rao DG, van der Star R. Potential risks of iatrogenic complications of nerve conduction studies (NCS) and electromyography (EMG). *Clin Neurophysiol Pract.* 2016;1:62-66.
9. Cushman DM, Strenn Q, Elmer A, Yang AJ, Onofrei L. Complications associated with electromyography: a systematic review. *Am J Phys Med Rehabil.* 2020;99(2):149-155.
10. Biswas S, Shapiro CA, Kranz WL, Mader TL, Shelton DP, Snow DD, et al. Current knowledge on the environmental fate, potential impact, and management of growth-promoting steroids used in the US beef cattle industry. *J Soil Water Conserv.* 2013;68(4):325-336. doi:10.2489/jswc.68.4.325.
11. Sanders DB, Arimura K, Cui L, Ertas M, Farrugia ME, Gilchrist J, et al. Guidelines for single fiber EMG. *Muscle Nerve.* 2019;60(3):S113-S121.

12. Lu YA, Pei YC, Wong AMK, Chiang HC, Fang TJ. Hemodynamic stability during laryngeal electromyography procedures. *Acta Otolaryngol.* 2017;137(10):1110-1114.
13. Dundas N, Patton CM, Parker RH, Smithwick RW, Washington JA, Hollis DG, et al. An outbreak of infections due to *Mycobacterium fortuitum* associated with electromyography. *J Infect Dis.* 1991;163(5):1150-1153.
14. Walpin LA, Reiss F. Urticaria changing to vitiligo provoked by electromyographic examination. *Arch Dermatol.* 1967;95(6):640-641.
15. Kang J, Cho Y, Kim S, Lee J, Lee J, Lee J, et al. Development and validation of a deep learning model for real-time automated detection of sleep apnea in adults using electrocardiogram signals. *Sleep Med.* 2022;91:68-73.
16. Kassardjian CD, O'Gorman CM, Sorenson EJ. The risk of iatrogenic pneumothorax after electromyography. *Muscle Nerve.* 2016;53(4):518-521.
17. Zhan C, Miller MR. Excess length of stay, charges, and mortality attributable to medical injuries during hospitalization. *JAMA.* 2003;290(14):1868-1874.
18. Athar P, Jilani A, Nguyen TT. Comparison of ring versus disposable disk electrodes in recording antidromic sensory median nerve conduction study for diagnosis of carpal tunnel syndrome. *J Clin Neurophysiol.* 2013 Aug;30(4):428-30.
19. Geddes LA, Baker LE. The specific resistance of biological material—A compendium of data for the biomedical engineer and physiologist. *Med Biol Eng.* 1967;5:271–293.
20. Almeida HF, Buckingham TA. Inappropriate implantable cardioverter defibrillator shocks secondary to sensing lead failure: utility of stored electrograms. *Pacing Clin Electrophysiol.* 1993;16(3):407-411.
21. Bardy GH, Ivey TD, Allen MD, Johnson G, Mehra R, Greene HL. A prospective randomized evaluation of biphasic versus monophasic waveform pulses on defibrillation efficacy in humans. *J Am Coll Cardiol.* 1989;14(3):728-733.
22. Grimm RA, Stewart WJ, Arheart K, Thomas JD, Klein AL. Impact of electrical cardioversion for atrial fibrillation on left atrial appendage function and spontaneous echo contrast: characterization by simultaneous transesophageal echocardiography. *J Am Coll Cardiol.* 1993;22(5):1359-1366

- 23- Mellion ML, Buxton AE, Iyer V, Almahameed S, Lorvidhaya P, Gilchrist JM. Safety of nerve conduction studies in patients with peripheral intravenous lines. *Muscle Nerve*. 2010 Aug;42(2):189-91. doi: 10.1002/mus.21714.
24. Rishal I, Fainzilber M. Axon–soma communication in neuronal injury. *Nat Rev Neurosci*. 2014;15(1):32-42. doi:10.1038/nrn3609.
25. Harrington AW, Ginty DD. Long-distance retrograde neurotrophic factor signalling in neurons. *Nat Rev Neurosci*. 2013 Mar;14(3):177-87.
26. Nix WA, Hopf HC. Electrical stimulation of regenerating nerve and its effect on motor recovery. *Brain Res*. 1983;272:21e25.
27. Hoffman H. Acceleration and retardation of the process of axon-sprouting in partially denervated muscles. *Aust J Exp Biol Med Sci*. 1952;30:541-566.
28. Tankisi H, Burke D, Cui L, de Carvalho M, Kuwabara S, Nandedkar SD, Rutkove S, Stålberg E, van Putten MJAM, Fuglsang-Frederiksen A. Standards of instrumentation of EMG. *Clin Neurophysiol*. 2020 Jan;131(1):243-258.
29. Fuglsang-Frederiksen, Anders, and Kirsten Pugdahl. “Current status on electrodiagnostic standards and guidelines in neuromuscular disorders.” *Clinical neurophysiology : official journal of the International Federation of Clinical Neurophysiology* vol. 122,3 (2011): 440-455.
30. Tankisi H, Burke D, Cui L, de Carvalho M, Kuwabara S, Nandedkar SD, et al. Standards of instrumentation of EMG. *Clin Neurophysiol*. 2020;131(1):243-258.
32. Al-Ayyad M, Owida HA, De Fazio R, Al-Naami B, Visconti P. Electromyography Monitoring Systems in Rehabilitation: A Review of Clinical Applications, Wearable Devices and Signal Acquisition Methodologies. *Electronics*. 2023;12(7):1520.
33. Li C, Li G, Jiang G, Chen D, Liu H. Surface EMG data aggregation processing for intelligent prosthetic action recognition. *Neural Computing and Applications*. 2018 Nov 24. Epub 2018 Nov 24.
34. <http://www.seniam.org> Erişim tarihi: 20.10.2024
35. Huenaerts C, Dewit T, Soentjens D, Monari D, Van Campenhout A, Desloovere K. Differences in surface electrode placement and its effect on duration of EMG activity. *Gait Posture*. 2022;97:S7-S8.

36. Valli G, Ritsche P, Casolo A, Negro F, De Vito G. Tutorial: Analysis of central and peripheral motor unit properties from decomposed High-Density surface EMG signals with openhdemg. *J Electromyogr Kinesiol.* 2024;74:102850.
37. Boyer M, Bouyer L, Roy J-S, Campeau-Lecours A. Reducing noise, artifacts and interference in single-channel EMG signals: A review. *Sensors (Basel).* 2023;23(6):2927.
38. De Luca, Carlo J et al. "Filtering the surface EMG signal: Movement artifact and baseline noise contamination." *Journal of biomechanics* vol. 43,8 (2010): 1573-9.
39. Ibrahim I, Khan WS, Goddard N, Smitham P. Carpal tunnel syndrome: a review of the recent literature. *Open Orthop J.* 2012;6:69-76.
40. Yoshii, Yuichi et al. "Recent Advances in Ultrasound Diagnosis of Carpal Tunnel Syndrome." *Diagnostics (Basel, Switzerland)* vol. 10,8 596. 15 Aug. 2020,
41. Encyclopedia Britannica. Encyclopedia Britannica. 15th ed. Chicago: Encyclopedia Britannica, Inc.; 2007.
42. Malakootian M, Soveizi M, Gholipour A, et al. Pathophysiology, diagnosis, treatment, and genetics of carpal tunnel syndrome: A review. *Cell Mol Neurobiol.* 2023;43:1817-1831.
43. Chammas M, Boretto J, Burmann LM, Ramos RM, dos Santos Neto FC, Braga Silva J. Carpal tunnel syndrome – Part I (anatomy, physiology, etiology and diagnosis). *Rev Bras Ortop (Engl Ed).* 2014;49(5):429-436.
44. El Miedany YM, Aty SA, Ashour S. Ultrasonography versus nerve conduction study in patients with carpal tunnel syndrome: substantive or complementary tests? *Rheumatology (Oxford).* 2004;43(7):887-895.
45. Watson, James C. "The electrodiagnostic approach to carpal tunnel syndrome." *Neurologic clinics* vol. 30,2 (2012): 457-78.
46. Balcerzak, A. A., Ruzik, K., Tubbs, R. S., Konschake, M., Podgórski, M., Borowski, A., Drobniewski, M., & Olewnik, Ł. (2022). How to Differentiate Pronator Syndrome from Carpal Tunnel Syndrome: A Comprehensive Clinical Comparison. *Diagnostics*, 12(10), 2433.
47. Wipperman J, Goerl K. Carpal tunnel syndrome: diagnosis and management. *Am Fam Physician.* 2016;94(12):993-999.

48. Zanette G, Marani S, Tamburin S. Proximal pain in patients with carpal tunnel syndrome: a clinical-neurophysiological study. *J Peripher Nerv Syst.* 2007;12(2):91-97.
49. Jablecki CK, Andary MT, Floeter MK, et al. Second AAEM literature review of the usefulness of nerve conduction studies and needle electromyography for the evaluation of patients with carpal tunnel syndrome. *Muscle Nerve.* 2002;(Suppl X):S1-S53.
50. Lifchez, Scott D et al. "Intra- and inter-examiner variability in performing Tinel's test." *The Journal of hand surgery* vol. 35,2 (2010): 212-6.
51. <https://drmartinschmaltz.com> Erişim tarihi: 11.11.2024
52. Eppenberger, Patrick et al. "Magnetic resonance neurography: diffusion tensor imaging and future directions." *Neuroimaging clinics of North America* vol. 24,1 (2014): 245-56.
53. Yoshii, Yuichi et al. "Recent Advances in Ultrasound Diagnosis of Carpal Tunnel Syndrome." *Diagnostics (Basel, Switzerland)* vol. 10,8 596. 15 Aug. 2020,
54. Yeh CL, Wu CH, Hsiao MY, Kuo PL. Real-time automated segmentation of median nerve in dynamic ultrasonography using deep learning. *Ultrasound Med Biol.* 2023;49(5):1129-1136.
55. American Association of Electrodiagnostic Medicine, American Academy of Neurology, and American Academy of Physical Medicine and Rehabilitation. "Practice parameter for electrodiagnostic studies in carpal tunnel syndrome: summary statement." *Muscle & nerve* vol. 25,6 (2002): 918-22.
56. Malladi, Niriksha et al. "Correlation between the combined sensory index and clinical outcome after carpal tunnel decompression: a retrospective review." *Muscle & nerve* vol. 41,4 (2010): 453-7.
57. Jablecki, Charles K et al. "WITHDRAWN: Second AAEM literature review of the usefulness of nerve conduction studies and needle electromyography for the evaluation of patients with carpal tunnel syndrome." *Muscle & nerve*, 11 Jun. 2002,
58. Robinson, L R et al. "Optimizing the number of tests for carpal tunnel syndrome." *Muscle & nerve* vol. 23,12 (2000): 1880-2.
59. Werner, Robert A, and Michael Andary. "Electrodiagnostic evaluation of carpal tunnel syndrome." *Muscle & nerve* vol. 44,4 (2011): 597-607.

60. Heagerty PJ, et al. The relationship between electrodiagnostic findings and patient symptoms and function in carpal tunnel syndrome. *Arch Phys Med Rehabil.* 2007;88:19-24.
61. Sucher, Benjamin M. "Stop using arbitrary grading schemes in carpal tunnel syndrome." *Muscle & nerve* vol. 38,5 (2008): 1526.
62. Hidayati H, Subadi I, Baswedan F, Puspamanian V. Current diagnosis and management of carpal tunnel syndrome: A review. *Anaesth Pain Intensive Care.* 2022;26(3):394-404.
63. Padua, L et al. "Neurophysiological classification and sensitivity in 500 carpal tunnel syndrome hands." *Acta neurologica Scandinavica* vol. 96,4 (1997): 211-7.
64. Ostergaard PJ, Meyer MA, Earp BE. Non-operative treatment of carpal tunnel syndrome. *Curr Rev Musculoskelet Med.* 2020;13:141-147.
65. Hirani S. A study to further develop and refine carpal tunnel syndrome (CTS) nerve conduction grading tool. *BMC Musculoskelet Disord.* 2019;20:581.
66. Werner RA, Andary M. Electrodiagnostic evaluation of carpal tunnel syndrome. *Muscle Nerve.* 2011;44(4):597-607.
67. Kronlage, Steven C, and Mariano E Menendez. "The benefit of carpal tunnel release in patients with electrophysiologically moderate and severe disease." *The Journal of hand surgery* vol. 40,3 (2015): 438-44.e1.
68. Padua, Luca et al. "Carpal tunnel syndrome: clinical features, diagnosis, and management." *The Lancet. Neurology* vol. 15,12 (2016): 1273-1284.
69. Resende, L A et al. "The natural history of carpal tunnel syndrome. A study of 20 hands evaluated 4 to 9 years after initial diagnosis." *Electromyography and clinical neurophysiology* vol. 43,5 (2003): 301-4.
70. Atroshi, Isam et al. "Treatment of carpal tunnel syndrome with wrist splinting: study protocol for a randomized placebo-controlled trial." *Trials* vol. 20,1 531. 27 Aug. 2019
71. Yang, Fu-An et al. "Ultrasound-guided corticosteroid injection for patients with carpal tunnel syndrome: a systematic review and meta-analysis of randomized controlled trials." *Scientific reports* vol. 11,1 10417. 17 May. 2021,

72. Karjalainen TV, Silagy M, O'Bryan E, Johnston RV, Cyril S, Buchbinder R. Autologous blood and platelet-rich plasma injection therapy for lateral elbow pain. *Cochrane Database Syst Rev*. 2021;9(9):CD010951.
73. Bennell, Kim L et al. "Effect of Intra-articular Platelet-Rich Plasma vs Placebo Injection on Pain and Medial Tibial Cartilage Volume in Patients With Knee Osteoarthritis: The RESTORE Randomized Clinical Trial." *JAMA* vol. 326,20 (2021): 2021-2030.
74. Derry, Sheena et al. "Pregabalin for neuropathic pain in adults." *The Cochrane database of systematic reviews* vol. 1,1 CD007076. 23 Jan. 2019,
75. Gökoğlu, Figen et al. "Evaluation of iontophoresis and local corticosteroid injection in the treatment of carpal tunnel syndrome." *American journal of physical medicine & rehabilitation* vol. 84,2 (2005): 92-6.
76. Ickert, Edmund C et al. "Effects of kinesiotaping during early post-operative rehabilitation in individuals who underwent a total knee arthroplasty: A systematic review and meta-analysis of randomized control trials." *Clinical rehabilitation* vol. 38,6 (2024): 732-748.
77. Armagan, Onur et al. "Effects of placebo-controlled continuous and pulsed ultrasound treatments on carpal tunnel syndrome: a randomized trial." *Clinics (Sao Paulo, Brazil)* vol. 69,8 (2014): 524-8.
78. Kim, Ju Chan et al. "Effect of extracorporeal shockwave therapy on carpal tunnel syndrome: A systematic review and meta-analysis of randomized controlled trials." *Medicine* vol. 98,33 (2019): e16870.
79. Shooshtari, S M J et al. "The effects of low level laser in clinical outcome and neurophysiological results of carpal tunnel syndrome." *Electromyography and clinical neurophysiology* vol. 48,5 (2008): 229-31.
80. Zhu, Tao et al. "Efficacy of acupuncture and rehabilitation therapy on brain function activation area and neurological function in ischemic stroke: A systematic review and meta-analysis." *PloS one* vol. 19,2 e0298547. 23 Feb. 2024,
81. Chen, Long et al. "Effectiveness and safety of endoscopic versus open carpal tunnel decompression." *Archives of orthopaedic and trauma surgery* vol. 134,4 (2014): 585-93.

82. Perez-Lopez R, Ghaffari Laleh N, Mahmood F, et al. A guide to artificial intelligence for cancer researchers. *Nat Rev Cancer*. 2024;24:427-441.
83. Jiang, Tammy et al. "Supervised Machine Learning: A Brief Primer." *Behavior therapy* vol. 51,5 (2020): 675-687.
84. Mitchell TM. Does Machine Learning Really Work?. *AIMag* [Internet]. 1997Sep.15 [cited 2024Dec.26];18(3):11.Availablefrom: <https://ojs.aaai.org/aimagazine/index.php/aimagazine/article/view/1303>
85. Nasteski V. An overview of the supervised machine learning methods. *Horiz B*. 2017 Dec 15;4:51-62.
86. Di Nardo, Francesco et al. "Machine Learning for Detection of Muscular Activity from Surface EMG Signals." *Sensors (Basel, Switzerland)* vol. 22,9 3393. 28 Apr. 2022,
87. Ghislieri, Marco et al. "Long short-term memory (LSTM) recurrent neural network for muscle activity detection." *Journal of neuroengineering and rehabilitation* vol. 18,1 153. 21 Oct. 2021
88. Batta M. Machine Learning Algorithms - A Review. *Int J Sci Res*. 2019;9.
89. James J, Sandhya L, Thomas C. Detection of phishing URLs using machine learning techniques. In: *Proceedings of the 2013 International Conference on Control Communication and Computing (ICCC)*; 2013; 304-309.
90. Alba, Ana Carolina et al. "Discrimination and Calibration of Clinical Prediction Models: Users' Guides to the Medical Literature." *JAMA* vol. 318,14 (2017): 1377-1384.
91. A Review on Linear Regression Comprehensive in Machine Learning. *JASTT* [Internet]. 2020 Dec. 31 [cited 2024 Dec. 26];1(2):140-7.
92. Lim H. A linear regression approach to modeling software characteristics for classifying similar software. In: *2019 IEEE 43rd Annual Computer Software and Applications Conference (COMPSAC)*; 2019; 1:942-943.
93. Zeebaree D, Abdulazeez A. Evaluating data mining classification methods performance in Internet of Things applications. *J Soft Comput Data Mining*. 2020;1.
94. Abdulazeez AM, Salim BW, Zeebaree DQ, Doghramachi D. Comparison of VPN Protocols at Network Layer Focusing on Wire Guard Protocol. *Int. J. Interact*.

- Mob. Technol. [Internet]. 2020 Nov. 10 [cited 2024 Dec. 26];14(18):pp. 157-177. Available from: <https://online-journals.org/index.php/i-jim/article/view/16507>
95. Zhang Z, Li Y, Li L, Li Z, Liu S. Multiple linear regression for high efficiency video intra coding. In: Proceedings of the 2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP); 2019; 1832-1836.
 96. Chen Y, He P, Chen W, Zhao F. A polynomial regression method based on Trans-dimensional Markov Chain Monte Carlo. In: Proceedings of the 2018 IEEE International Conference on Industrial Electronics and Applications (IAEAC); 2018; 1781-1786.
 97. Kokol P, Pohorec S, Štiglic G, Podgorelec V. Evolutionary design of decision trees for medical application. WIREs Data Min Knowl Discov. 2012;2(3):275-285.
 98. Rigatti SJ. Random Forest. J Insur Med. 2017;47(1):31-39. doi:10.17849/in-sm-47-01-31-39.1.
 99. Po-Jung Pan, Chia-Hsuan Lee, Nai-Wei Hsu, Tien-Lung Sun. Combining principal component analysis and logistic regression for multifactorial fall risk prediction among community-dwelling older adults. Geriatr Nurs. 2024;57:208-216.
 100. Chen LF, Li M, Su W, Wu M, Hirota K, Pedrycz W. Adaptive feature selection-based AdaBoost-KNN with direct optimization for dynamic emotion recognition in human–robot interaction. IEEE Trans Emerg Top Comput Intell. 2019;PP:1-9.
 101. Manca, Andrea et al. “A Survey on the Use and Barriers of Surface Electromyography in Neurorehabilitation.” Frontiers in neurology vol. 11 573616. 2 Oct. 2020
 102. Battineni G, Chintalapudi N, Amenta F. Machine learning in medicine: Performance calculation of dementia prediction by support vector machines (SVM). Informatics Med Unlocked. 2019;16:100200.
 103. Battineni G, Chintalapudi N, Amenta F. Machine learning in medicine: Performance calculation of dementia prediction by support vector machines (SVM). Informatics Med Unlocked. 2019;16:100200.
 104. Ismail M, Hassan N, Bafjaish S. Comparative analysis of Naive Bayesian techniques in health-related classification tasks. J Soft Comput Data Mining. 2020;1.

- 105- Govender P, Sivakumar V. Application of k-means and hierarchical clustering techniques for analysis of air pollution: A review (1980–2019). *Atmos Pollut Res.* 2020;11(1):40-56.
106. Fahim A. Adaptive Density-Based Spatial Clustering of Applications with Noise (ADBSCAN) for clusters of different densities. *Comput Mater Contin.* 2023;75(2):3695-3712.
107. Chowdhary CL, Mittal MP, Pattanaik PA, Marszalek Z. An efficient segmentation and classification system in medical images using intuitionist possibilistic fuzzy C-mean clustering and fuzzy SVM algorithm. *Sensors.* 2020;20(14):3903.
108. Hasan B, Abdulazeez A. A review of principal component analysis algorithm for dimensionality reduction. *Appl Soft Comput.* 2021;2:20-30.
109. Saadi H, Abdulshahed AM. Reinforcement learning applications in medical imaging. In: *Proceedings of the 2024 8th International Conference on Image and Signal Processing and their Applications (ISPA); 2024; Biskra, Algeria.* p. 1-6.
110. Mahajan P, Uddin S, Hajati F, Moni MA. Ensemble learning for disease prediction: A review. *Healthcare.* 2023;11(12):1808.
111. Shorewala V. Early detection of coronary heart disease using ensemble techniques. *Informatics Med Unlocked.* 2021;26:100655.
112. Dharavath R, Katheria Y. Ensemble method based predictive model for analyzing disease datasets: a predictive analysis approach. *Health Technol.* 2019;9:1-13.
113. Singh N, Singh P. A stacked generalization approach for diagnosis and prediction of type 2 diabetes mellitus. In: *Proceedings of the 2020 Conference; 2020.* p. 559-570.
114. Ashri SEA, El-Gayar MM, El-Daydamony EM. HDPF: Heart disease prediction framework based on hybrid classifiers and genetic algorithm. *IEEE Access.* 2021;9:146797-146809.
115. Hancock JT, Khoshgoftaar TM. CatBoost for big data: an interdisciplinary review. *J Big Data.* 2020;7:94.
116. Azmi SS, Baliga S. An overview of boosting decision tree algorithms utilizing AdaBoost and XGBoost boosting strategies. In: *Proceedings of the 2020 Conference; 2020*

118. Rufo DD, Debelee TG, Ibenthal A, Negera WG. Diagnosis of diabetes mellitus using gradient boosting machine (LightGBM). *Diagnostics*. 2021;11(9):1714.
119. Basha SM, Rajput DS, Vandhan V. Impact of gradient ascent and boosting algorithm in classification. *Int J Intell Eng Syst*. 2018;11:41-49.
120. Yousefi J, Hamilton-Wright A. Characterizing EMG data using machine-learning tools. *Comput Biol Med*. 2014;51:1-13.
121. Yener, Yıldız^{1,2}; Darol, Elif Sarıca³; Uzun, Süleyman⁴; Alemdar, Murat⁵; Çolak, Tuncay¹. Application of Machine Learning Algorithms for Carpal Tunnel Syndrome. *Journal of the Anatomical Society of India* 73(2):p 178-183, Apr–Jun 2024
122. Tsamis, Konstantinos I et al. “Automatic Electrodiagnosis of Carpal Tunnel Syndrome Using Machine Learning.” *Bioengineering (Basel, Switzerland)* vol. 8,11 181. 10 Nov. 2021,
123. Yetiş, Mehmet et al. “Carpal tunnel syndrome prediction with machine learning algorithms using anthropometric and strength-based measurement.” *PloS one* vol. 19,4 e0300044. 17 Apr. 2024,
124. Yousefi, Jamileh, and Andrew Hamilton-Wright. “Characterizing EMG data using machine-learning tools.” *Computers in biology and medicine* vol. 51 (2014): 1-13.
125. Turgunov A, Zohirov K, Nasimov R, Mirzahalilov S. Comparative analysis of the results of EMG signal classification based on machine learning algorithms. In: *Proceedings of the 2021 International Conference on Information Science and Communication Technology (ICISCT)*; 2021. p. 1-4.
126. Elseddik, Marwa et al. “Deep Learning-Based Approaches for Enhanced Diagnosis and Comprehensive Understanding of Carpal Tunnel Syndrome.” *Diagnostics (Basel, Switzerland)* vol. 13,20 3211. 14 Oct. 2023
127. Harrison, Conrad J et al. “Developing Machine Learning Algorithms to Support Patient-centered, Value-based Carpal Tunnel Decompression Surgery.” *Plastic and reconstructive surgery*. *Global open* vol. 10,4 e4279. 18 Apr. 2022
128. Park, Dougho et al. “Machine learning-based approach for disease severity classification of carpal tunnel syndrome.” *Scientific reports* vol. 11,1 17464. 31 Aug. 2021

129. Elseddik M, Mostafa RR, Elashry A, El-Rashidy N, El-Sappagh S, Elgamal S, Aboelfetouh A, El-Bakry H. Predicting CTS diagnosis and prognosis based on machine learning techniques. *Diagnostics*. 2023;13(3):492.
130. Liu T, Li Z, Tang Y, Yang D, Jin S, Guan J. The application of the machine learning method in electromyographic data. *IEEE Access*. 2020;8:9196-9208.
131. Öten, Erol et al. "Use of machine learning methods in diagnosis of carpal tunnel syndrome." *Computer methods in biomechanics and biomedical engineering*, 1-11. 28 Oct. 2024,

