

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**SPASTİSİTENİN ELEKTROFİZYOLOJİK VE
KİNEZYOLOJİK VERİLERLE TESPİTİ VE
DERECELENDİRİLMESİ**

DOKTORA TEZİ

Yalçın ALBAYRAK

Enstitü Anabilim Dalı : **ELEKTRİK- ELEKTRONİK
MÜHENDİSLİĞİ**
Tez Danışmanı : **Yrd. Doç.Dr. Gökçen ÇETİNEL**
Ortak Danışman : **Yrd. Doç.Dr. Süleyman BİLGİN**

Temmuz 2017

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

SPASTİSİTENİN ELEKTROFİZYOLOJİK VE
KİNEZYOLOJİK VERİLERLE TESPİTİ VE
DERECELENDİRİLMESİ


DOKTORA TEZİ

Yalçın ALBAYRAK

Enstitü Anabilim Dalı

ELEKTRİK-ELEKTRONİK
MÜHENDİSLİĞİ

Bu tez 13/07/2017 tarihinde aşağıdaki jüri tarafından oybirliği/oyçokluğu ile kabul edilmiştir.

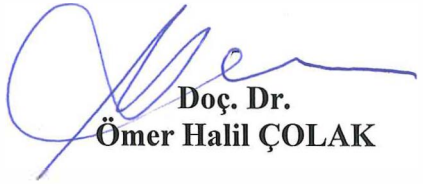

Yrd. Doç. Dr.
Gökçen ÇETİNEL

Jüri Başkanı


Yrd. Doç. Dr.
Sultan Aldırmaz ÇOLAK
Üye


Doç. Dr.
Cüneyt BAYILMIŞ

Üye


Doç. Dr.
Ömer Halil ÇOLAK

Üye


Yrd. Doç. Dr.
Özhan ÖZKAN
Üye

BEYAN

Tez içindeki tüm verilerin akademik kurallar çerçevesinde tarafımdan elde edildiğini, görsel ve yazılı tüm bilgi ve sonuçların akademik ve etik kurallara uygun şekilde sunulduğunu, kullanılan verilerde herhangi bir tahrifat yapılmadığını, başkalarının eserlerinden yararlanılması durumunda bilimsel normlara uygun olarak atıfta bulunulduğunu, tezde yer alan verilerin bu üniversite veya başka bir üniversitede herhangi bir tez çalışmasında kullanılmadığını beyan ederim.

Yalçın ALBAYRAK

13.07.2017

TEŞEKKÜR

Bu tez boyunca, çalışmalarım sırasında bilgilerinden faydalandığım, yanında çalışmaktan onur duyduğum, benden hiçbir karşılık beklemeden her zaman yanımda olan, kendisine ne zaman danışsam ilgisini ve önerilerini göstermekten çekinmeyen, ayrıca tecrübelerinden yararlanırken göstermiş olduğu hoşgörü ve sabırdan dolayı kıymetli ve değerli bilim insanı Prof. Dr. Hilmi UYSAL'a canı gönülden teşekkürlerimi sunarım.

Olgulardan veri alımında beraber çalıştığımız Dr. Mehmet GÜRBÜZ'e teşekkür ederim.

Sayın danışman hocam Yrd. Doç. Dr. Gökçen ÇETİNEL'e bana yol gösterdiği, kıymetli zamanını ayırıp beni sabırla dinlediği, faydalı olabilmek için elinden geleni yaptığı ve verdiği katkılardan dolayı çok teşekkür ederim.

Yrd. Doç. Dr. Süleyman BİLGİN'e de teşekkür ederim.

Bu günlere gelmemde büyük pay sahibi olan, süreç içerisinde benden desteklerini esirgemeyen, beni hiçbir zaman yalnız bırakmayan, bu hayattaki en büyük şansım olan canım aileme sonsuz teşekkür ederim.

İÇİNDEKİLER

TEŞEKKÜR	i
İÇİNDEKİLER	ii
SİMGELER VE KISALTMALAR LİSTESİ	iv
ŞEKİLLER LİSTESİ	v
TABLolar LİSTESİ	vii
ÖZET	viii
SUMMARY	ix
BÖLÜM 1.	
GİRİŞ	1
1.1. Tez Çalışmasının Katkıları	3
BÖLÜM 2.	
SPASTİSİTENİN TANIMI VE DEĞERLENDİRİLMESİ	5
2.1. Spastisitenin Tarihiçesi ve Tanımı	5
2.2. Spastisitenin Ölçülmesi ve Değerlendirilmesi	6
BÖLÜM 3.	
HAREKETİN NÖRAL MEKANİZMASI VE EMG	12
3.1. Hareketin Nöral Yapıları	13
3.2. Kas	15
3.3. EMG	18
3.3.1. EMG işaretin oluşumu	18
3.3.2. EMG işaretinin analizi	21

BÖLÜM 4.

SPASTİSİTENİN TESPİT EDİLMESİ VE DERECELENDİRİLMESİNDE

UYGULANAN ADIMLAR	23
4.1. Tendon Refleksi	24
4.1.1. Patella T-refleks	25
4.2. Olgular	27
4.2.1. Olguların hazırlanışı ve ölçüm düzeneği	28
4.3. Özniteliklerin Hesaplanması	31
4.3.1. Kinezyolojik özniteliklerin hesaplanması	31
4.3.2. Elektrofizyolojik özniteliklerin hesaplanması	36
4.4. Öznitelik Seçimi	38
4.4.1. Fisher Skoru ile öznitelik seçimi	38
4.5. Kullanılan Makine Öğrenme Algoritması	39
4.5.1. k-katlı çapraz doğrulama	41
4.5.2. Yapay sinir ağları	42
4.5.3. Destek vektör makineleri	44
4.5.4. k-en yakın komşuluk	46
4.6. Adaptif Artırma Algoritması (ADABOOST)	47
4.6.1. Adabost algoritması	48
4.6.2. Çok-sınıf AdaBoost algoritması	50
4.7. Makine Öğrenme Algoritması ile Spastisitenin Sınıflandırılması ...	52

BÖLÜM 5.

TARTIŞMA VE SONUÇLAR	58
----------------------------	----

KAYNAKLAR	63
-----------------	----

ÖZGEÇMİŞ	70
----------------	----

SİMGELER VE KISALTMALAR LİSTESİ

AS	: Ashworth Skalası
ADALINE	: Adaptive Lineer Neuron
BF	: Biceps Femoris
DVM	: Destek Vektör Makinesi
DTR	: Derin Tendon Refleks
EHA	: Eklem Hareket Açıklığı
EMG	: Elektromyogram
Hz	: Hertz
H-Refleks	: Hoffman Refleks
k-EYK	: k-En Yakın Komşuluk
kHz	: Kilo Hertz
MAS	: Modifiye Ashworth Skalası
MUAP	: Motor Ünit Aksiyon Potansiyeli
M-Yanıt	: Motor Yanıt
ms	: mili saniye
RF	: Rectus Femoris
YSA	: Yapay Sinir Ağları
ÜMN	: Üst Motor Nöron
SPASM	: Support Progame for Assembly of a Database for Spasticity
TS	: Tardieu Skalası

ŞEKİLLER LİSTESİ

Şekil 3.1. Hareketin temel birleşenleri	13
Şekil 3.2. Hareketin nöral yapıları	14
Şekil 3.3. Üst motor nöron ve alt motor nöron	15
Şekil 3.4. Kasın yapısı	16
Şekil 3.5. Kas içiği ve golgi tendon organı	17
Şekil 3.6. Motor kontrolün şematik gösterimi ve motor ünite	19
Şekil 3.7. Aksiyon potansiyelin oluşumu	20
Şekil 3.8. EMG işaretinin oluşumu	20
Şekil 4.1. Çalışmanın akış diyagramı	23
Şekil 4.2. Refleks çekici	26
Şekil 4.3. Patella Tendon Refleksinin oluşum safhası	26
Şekil 4.4. Ölçüm düzeneği	29
Şekil 4.5. Normal olguya ait Biometrics kayıt	30
Şekil 4.6. Normal olguya ait Matlab Analiz program görüntüsü	31
Şekil 4.7. Ashworth 2 olgusuna ait Pendulum Hareketi	32
Şekil 4.8. Kinezyolojik parametrelerin gösterimi	33
Şekil 4.9. a) Normal b) Ashworth 1 c) Ashworth 2 d) Ashworth 3 e) Ashworth 4 olgusuna ait Pendulum kayıtları	34
Şekil 4.10. Çentiklenme örneği	35
Şekil 4.11. Ashworth 2 olgusuna ait kayıt	36
Şekil 4.12. EMG kayıt örneği	37
Şekil 4.13. Çok katmanlı yapay sinir ağ yapısı	43
Şekil 4.14. YSA genel yapısı	43
Şekil 4.15. İki sınıf arasındaki hiper düzlem	45
Şekil 4.16. Lineer sınıflandırma için hiperdüzlem belirleme	45
Şekil 4.17. En yakın sınıf seçimi	47

Şekil 4.18. Normal ve spastisiteli olguları ayırt etmede üç eğitim seti için sınıflandırma performans eğrileri	56
Şekil 4.19. Normal ve spastisiteli olguları ayırt etmede üç eğitim seti için sınıflandırma performans eğrileri	57



TABLolar LİSTESİ

Tablo 2.1. Spastisitede ölçüm metotları	7
Tablo 2.2. Ashworth Skalası	8
Tablo 2.3. Modifiye Ashworth Skalası	9
Tablo 2.4. Modifiye Tardieu Skalası	9
Tablo 2.5. Spastisitenin değerlendirilmesi için nörolojik ölçüm metotları	11
Tablo 4.1. Olguların demografik yapısı	27
Tablo 4.2. Kinezyolojik parametreler	32
Tablo 4.3. Zaman - Frekans öznitelikleri	37
Tablo 4.4. Sınıflandırıcıların "normal" ve "spastisiteli" sınıfları için performansı (a) Öznitelik seçimi ile (b) Öznitelik seçimi olmadan	54
Tablo 4.5. Öznitelik seçimi ile "Ashworth 1" ve "Ashworth 2" sınıfları için sınıflandırıcıların performansı	54
Tablo 4.6. Sınıflandırıcıların üç sınıf için performansı (a) Öznitelik seçimi ile (b) Öznitelik seçimi olmadan	55

ÖZET

Anahtar kelimeler: Spastisite, Patella T-refleks, EMG, işaret işleme, makine öğrenmesi

Spastisite, üst motor yollarındaki lezyona bağlı hareket bozukluğu ile oluşan klinik bir durumdur. Spastisitesinin tanımlanmasında, ölçülmesinde ve değerlendirilmesinde genel kabul görmüş bir yöntem bulunmamaktadır. Bu tezde, sinyal işleme ve makine öğrenme tekniklerine dayalı olarak spastisite için güvenilir bir klinik değerlendirme yöntemi geliştirilmiştir. Bu amaçla, Patella T-refleksi tetiklendiğinde katılımcıların RF ve BF kaslarının EMG verilerini kaydeden bir ölçüm sistemi hazırlanmıştır. Sistem sayesinde kaydedilen veriler öncelikle bir ön işleme adımından geçirilmiştir. Bu adımı takip eden öznitelik çıkarma adımında, her iki kas grubundan ölçülen kısa süreli EMG sinyalinden zaman ve frekans uzaylarında beşer adet öznitelik belirlenmiştir. Bu özellikler, spastisiteyi karakterize eden öznitelik vektörünü oluşturmak için Patella T-refleksinin tetiklediği Pendulum hareketinin altı adet özneliği ile birleştirilmiştir. Sonuçta toplam 26 elemandan oluşan öznitelik vektörü elde edilmiştir.

Öznitelik çıkarma adımından sonra, öznitelik vektörünün ayırma kabiliyetini artırmak için gerçekleştirilen öznitelik seçimi sürecinde Fisher Skoru kullanılmıştır. Ön işleme, öznitelik çıkarma ve öznitelik seçme adımları tezin sinyal işleme kısmını oluşturmaktadır. Sistemin sınıflandırma evresinde ise, spastisite derecelendirmesinde kabul edilebilir ve güvenilir sonuçlar veren YSA, k-EYK ve DVM makine öğrenme algoritmaları uygulanmıştır. Ayrıca, sınıflandırıcıların performanslarını artırmak amacıyla tezde AdaBoost algoritmasından da faydalanılmıştır. Nörologların ifadelerine göre, klinik değerlendirmelerde % 80 ve üzeri doğruluk yüzdeleri kesinlikle kabul edilebilir ve uygulanabilir. Dolayısıyla, Fisher Skoru, üç katlı çapraz doğrulama ve DVM veya k-EYK teknikleri içeren önerilen yöntem spastisite değerlendirmeleri için etkin bir şekilde kullanılabilir. Normal, Ashworth 1 ve Ashworth 2 spastisite düzeylerini belirlemek amacıyla kullanılan bu kombinasyonların doğruluk değerleri sırasıyla % 86.66 ve % 80.33 olarak belirlenmiştir. Sunulan tez makine öğrenmesi ve sinyal işleme yöntemlerini kullanarak spastisite derecelendirilmesini otomatik olarak güvenilir bir şekilde gerçekleştiren, bu sayede nörologlara fayda sağlayan önemli bir çalışma özelliği taşımaktadır.

DIAGNOSIS AND GRADING OF SPASTICITY WITH ELECTROPHYSIOLOGICAL AND KINESIOLOGICAL DATA

SUMMARY

Keywords: Spasticity, signal processing, machine learning

Spasticity is a clinical condition caused by movement disorder induced by lesion in the upper motor pathways. There is no generally accepted method in diagnosis, measurement and evaluation of spasticity. In this thesis, a reliable clinical evaluation method is developed for spasticity based on signal processing and machine learning techniques. For this purpose, a measurement system that records the EMG data from RF and BF muscles when Patella T-reflex was triggered is designed. The data that is recorded by the system is passed through the preprocessing step. In the following feature extraction step, five features in time domain and frequency domain of the short time EMG signal that measured from each of two muscle groups are determined. These features are combined with six features of the Pendulum movement triggered by the Patella T-reflex to generate the feature vector that characterizes the spasticity. Feature vector that includes 26 elements is obtained eventually.

After feature extraction step, Fisher Score is used in the feature selection process that is developed to improve the separation ability of the feature vector. Preprocessing, feature extraction and feature selection steps constitute the signal processing part of the thesis. ANN, k-NN and SVM machine learning algorithms, which produce acceptable and reliable results in the grading of spasticity, were applied in the classification phase of the system. Furthermore, in this thesis AdaBoost algorithm is utilized to improve the performance of the classifiers. Neurologists reported that 80% and above accuracy scores in clinical trials are absolutely acceptable and feasible. Thus, the proposed method that includes Fisher Score, 3-fold cross validation and SVM or k-NN techniques can effectively be used for spasticity assessments. It was determined that the accuracy values of these combinations which are used to determine the normal, Ashworth 1 and Ashworth 2 spasticity levels were 86.66% and 80.33%, respectively. The proposed thesis performs the grading of spasticity in an automatic and reliable way by using signal processing and machine learning methods and thus it is an important study that provides valuable information to the neurologists.

BÖLÜM 1. GİRİŞ

Spastisite, bilinen motor bozukluklardan birisi olmasına rağmen gerek tanımlanmasında gerekse değerlendirilmesinde sorunlar yaşanmaktadır. Yapılan bir makale çalışmasında spastisitenin tanımı ve ölçümüne dair 250'ye (190 clinical trials, 46 literature reviews, 14 case reports) yakın çalışma incelenmiş, spastisitenin tanımı ve ölçümüne dair ortak bir tanımlama ve ölçüm metoduna ulaşılamamıştır [1]. Ancak incelenen çalışmaların yaklaşık % 78'inde Lance'nin tanımı kullanılmıştır. Lance, spastisiteyi “Üst motor nöron sendromunun bir komponenti olan germe reflekslerinin hipereksitabilitesi sonucu ortaya çıkan artmış tendon sıçramaları ile birlikte hıza bağımlı olarak tonik germe reflekslerindeki artış ile karakterize motor bozukluktur.” şeklinde tanımlamıştır [2]. Robert Young, bu tanımlamayı biraz daha genişletmiştir. Üst motor nöron sendromunun diğer karakteristiklerini ekleyerek, üst motor nöron sendromu hastalarda, spastisite ile ilişkili olarak hem anormal davranışlar hem de performans eksikliklerini tanımlamıştır [3]. SPASM (Support Programme for Assembly of a Database for Spasticity Measurement) adı verilen spastisite çalışma grubu; spastisiteyi üst motor nöron lezyonu sonucu kasların istemsiz aralıkla veya daimi aktivasyonu şeklinde gösteren sensori motor kontrol bozukluğu şeklinde tanımlamıştır [4].

Sonuç olarak spastisite kas tonusundaki istemsiz artışlardır. Bu durum istirahat halinde oluşmaz iken kas gerilimi süresince oluşur. İnci motor yolları etkileyen serebrum, beyin sapı ve omuriliğin lezyonlarında gelişir. Babinski yanıtı ve artmış tendon refleksleri spastisiteye genellikle eşlik eder.

Yapılan araştırmalara göre günümüzde spastisiteden etkilenen 12 milyondan fazla kişi olduğu düşünülmektedir [5,6]. Spastisitenin doğru olarak ölçülmesi ve objektif olarak değerlendirilmesi, altta yatan patolojik mekanizmanın daha iyi anlaşılmasını ve

dolayısıyla doğru bir tedaviye karar verilmesini de sağlar [7,8]. Günümüzde spastisitenin değerlendirmesinde basit anketler, gonyometrik değerlendirmeler, mekanik, elektromyografik ve biyomekanik ölçümler gibi çok sayıda ölçüm sistemleri geliştirilmeye çalışılmıştır [9,10,11]. Literatürde birçok çalışma olmasına rağmen, tüm bilim camiası tarafından ortak kabul görmüş tam etkin bir yöntem bulunmamaktadır.

Spastisitenin değerlendirmesinde 24 farklı skala mevcuttur. Bu skalalardan en çok kabul göreni 1964 yılında Ashworth'un geliştirdiği skaladır. Ashworth Skalası en yaygın kullanılan ve bilinen spastisite skalasıdır. 1987 yılında bu skala çok küçük değişikliklerle yeniden düzenlenmiş ve "Modifiye Ashworth Skalası (MAS)" olarak tanımlanmıştır [12].

Hastalığın tanımlanması ve kendi içerisinde sınıflandırılması karmaşık bir yapıya sahip olduğundan literatürde bir çok çalışmada rastlanmaktadır. Ama günümüzde genel kabul görmüş bir yöntem bulunmamaktadır.

Tez çalışmasının amacı, spastisitenin teşhisi ve derecelendirilmesi için uzmanlara destek sağlayıcı yüksek doğruluklu otomatik bir sistem geliştirmektir. Bu amaçla öncelikle kurulan sistem ile olguların Patella T-refleksleri tetiklenmiştir. Tetikleme sonucu ortaya çıkan Pendulum hareketinin kinezyolojik parametreleri hesaplanmıştır. Ayrıca tetikleme esnasında olguların Biceps Femoris (BF) ve Rectus Femoris (RF) kas gruplarının EMG kayıtları alınarak bu kayıtların elektrofizyolojik öznitelikleri de belirlenmiştir. Bu adım sonunda normal ve her dereceden spastik olgulara ait bir veri seti elde edilmiştir. Veri seti oluşturulurken spastisitesi olan olgularda Akdeniz Üniversitesi Tıp Fakültesi Nöroloji, Nöroşirurji, Fizik Tedavi ve Rehabilitasyon polikliniklerine başvuran ve Nöroloji kliniğine yatan gönüllü hastalara ait veriler kullanılmıştır. Tez çalışmasında hiçbir sentetik veri kullanılmamıştır.

Olgulardan kayıt alınırken Pendulum hareketi için Biometrics firmasına ait gonyometre, EMG kayıtları için ise aynı firmaya ait EMG cihazı kullanılmıştır. Ancak Biometrics yazılımı firmaya ait özel bir yazılım olduğundan ve tezin amacı için yetersiz kaldığından kinezyolojik ve elektro fizyolojik özelliklerin hesaplanması için

MATLAB programı üzerinden bir analiz programı yazılmıştır. Bu analiz programı ile toplamda 65 olgudan alınan 26 elemandan oluşan 90 adet veri vektörü elde edilmiştir.

Yukarıda açıklanan adımdan sonra, elde edilen özniteliklerden ayırt edicilik özelliği yüksek olanlar seçilmiştir. Bu işlem için Fisher Skorlama tekniği kullanılmıştır. Tez çalışmasında ayırt edilmesi amaçlanan üç sınıf mevcuttur. Bunlar Normal, Ashworth 1 ve Ashworth 2 sınıflarıdır. Ashworth 3 ve Ashworth 4 derecelerine sahip olgulardan da veri alınmasına rağmen, bu sınıflar herkes tarafından rahatça ayırt edilebildiğinden çalışmaya dâhil edilmemiştir.

Son aşamada ise literatürde hastalıkların derecelendirilmesi için yaygın olarak kullanılan ve kabul edilebilir sonuçlar veren YSA, DVM ve k-EYK tekniklerinden faydalanılmıştır [Sultan hocanın söylediği gibi bazı referanslar verilebilir]. Bu aşamanın uygulanması ile birlikte sistem bütün olarak çalışmakta ve olguları % 86.66 doğrulukla Normal, Ashworth 1 ve Ashworth 2 olarak sınıflandırabilmektedir.

1.1. Tez Çalışmasının Katkıları

Spastisitenin tanımı, ölçülmesi ve derecelendirilmesi için günümüzde ortak kabul görmüş bir yöntem bulunmamaktadır. Bu tezin amacı bahsedilen problemi çözmek amacıyla sinyal işleme ve makine öğrenme tekniklerinden faydalanarak, kurulan ölçüm düzeneği vasıtasıyla kaydedilen verileri işleyip değerlendiren nörologlara yardımcı olacak otomatik bir sistem sunmaktır. Yapılan tez çalışmasının bilime kazandırdığı yenilikler aşağıda özetlenmiştir.

- Ölçüm sistemi önceden Korkut Yaltkaya tarafından önerilmiş ve ölçüm alınmıştır. Bu sistemde 1967 yılının teknolojisini kullanmıştır. Tezde kullandığımız cihazlarla günümüz teknolojilerinden faydalanarak daha hassas ve detaylı ölçüm yapma imkânı sağlanmıştır.
- Bazı olguların Pendulum hareketinin ilk tepe noktasına ulaştığında bir çentiklenme olduğu gözlenmiştir. Bu çentiklenme bulgusu şimdiye kadar tanımlanmamış olup tez kapsamında yayınlanan bir makale ile bu bulgu literatüre kazandırılmıştır [13].

- MATLAB programı kullanılarak EMG ve kinezyolojik verileri analiz eden bir yazılım geliştirilmiştir.
- Kısa zamanlı EMG verisi ve kinezyolojik verilerin makine öğrenmesi algoritması ile % 86.66 sınıflandırma başarısına ulaşılmıştır. Bu yüzde sunulan sistemin doğruluk oranıdır. Yani spastisite % 86.66 doğrulukla derecelendirilmiştir.
- Tez, nörolojik bir probleme sinyal işleme ve makine öğrenmesi tekniklerini uygulayarak otomatik ve güvenilir bir çözüm sunmuştur.

Tez şu şekilde organize edilmiştir. Bölüm 2’de spastisitenin tarihçesi verilmiş ve spastisite için şimdiye kadar kullanılan tanımlamalardan bahsedilmiştir. Ayrıca, spastisitenin ölçülmesi ve derecelendirilmesi için kullanılan yöntemler ve skalalar açıklanmıştır. Bölüm 3’de spastisitenin nedeninin ve nasıl oluştuğunun daha iyi anlaşılabilmesi amacıyla hareketin nöral mekanizmasından ve EMG’den bahsedilmiştir. Bölüm 4’de ise spastisitenin tespiti ve derecelendirilmesi için tez çalışmasında kullanılan tüm yöntemler açıklanmıştır. Ölçüm sistemi ve alınan kayıtlar detayları ile bu bölümde incelenmiştir. Son olarak Bölüm 5’de tezden elde edilen sonuçlar ve tartışmalar verilmiştir.

BÖLÜM 2. SPASTİSİTENİN TANIMI VE DEĞERLENDİRİLMESİ

Bir hastalığın, etiyojisi (nedensellik) ile patofizyolojik mekanizmaların vücutta etkilediği bölgeler iyi bilinirse, hastalığın teşhisi, tanısı, sınıflandırması, tedavi yöntemleri daha net olabilmektedir. Spastisiteye sebep olan mekanizmaların net olarak çözülmemiş olması, bu hastalığın tanımlanmasında, ölçülmesinde, sınıflandırılmasında ve tedavisinde zorluklar oluşturmaktadır. Bu bölümde spastisitenin tarihsel gelişiminden, tanımından, ölçüm metotlarından ve değerlendirme skalalarından bahsedilmiştir.

2.1. Spastisitenin Tarihçesi ve Tanımı

Spastisite, Yunanca “Spasticos” kelimesinden türetilmiş olup, büzülüp kısalmak anlamına gelen “spastic” kelimesinden köken almıştır [14]. Bir tarafa doğru şiddetle çekme ve gerilme anlamına gelmektedir. Bu kelime literatürde ilk defa 1829’da Good tarafından kullanılmıştır [14]. Deneysel anlamda ise spastisite, ilk olarak bir İngiliz fizyolog olan Serrington’un deserebre hayvanlar üzerinde yaptığı çalışmalarda tanımlanmaya çalışılmıştır [15]. Daha sonra Babinski’nin gözlemleri üç tip spastisite klinik tanımı ortaya koymuştur. 1980 yılında Lance’nin yapmış olduğu tanıma göre spastisite “Üst motor nöron (ÜMN) sendromunun bir komponenti olan germe reflekslerinin hipereksitabilitesi sonucu ortaya çıkan artmış tendon sıçramaları ile birlikte, hıza bağlı tonik germe refleksindeki artış ile karakterize motor bozukluktur” [16]. Günümüzde en çok kabul gören tanım Lance’nin tanımıdır.

Spastisite, bilinen motor bozukluklardan birisi olmasına rağmen gerek tanımlanmasında, gerek ölçülmesinde, gerekse değerlendirilmesinde sorunlar yaşanmıştır. Yapılan bir literatür taraması çalışmasında spastisitenin tanımı ve ölçümüne dair 190’ı klinik, 46’sı literatür araştırması ve 14’ü durum raporu olmak

üzere yaklaşık 250 çalışma incelenmiş, spastisitenin tanımı ve ölçümünde ortak bir tanımlama ve ölçüm metodu olmadığı görülmüştür [1]. Bu çalışmaların % 78'inde yukarıda verilen Lance'nin tanımlaması kullanılmıştır. 1994 yılında Robert Young, Lance'nin tanımlamasını biraz daha genişletmiştir [2]. Young, üst motor nöron sendromunun diğer karakteristiklerini de ekleyerek üst motor nöron sendromunun hastalarda, spastisite ile ilişkili olarak hem anormal davranışlara hem de performans eksikliklerine neden olduğunu öne sürmüştür.

SPASM (Support Programme for Assembly of a Database for Spasticity Measurement) adı verilen spastisite çalışma grubu; 2005 yılında spastisiteyi üst motor nöron lezyonu sonucu kasların istemsiz intermittan veya daimi aktivasyonu şeklinde gösteren sensori motor kontrol bozukluğu şeklinde tanımlamıştır [17]. Spastisite genel anlamda kas tonusundaki istemsiz artışlardır. Bu durum istirahat halinde oluşmaz iken kas gerilimi süresince ortaya çıkar. İnici motor yolları etkileyen serebrum, beyin sapı ve omuriliğin lezyonlarında gelişir. Babinski yanıtı ve artmış tendon refleksi spastisiteye genellikle eşlik eder. Spastisite, ÜMN'nin herhangi bir nedenle tutulması sonrası, hareket yeteneğinin azalması ve ağrılı spazmlar ile ortaya çıkan nörolojik bir tablodur [15]. Spastisiteye neden olabilecek diğer durumlar ise, travmatik beyin hasarı, medulla spinalis yaralanmaları, hipoksik beyin hasarı ve inmedir [18]. Spastisite, hastaların kas-iskelet yapısını etkilemekte olup, postür bozuklukları, spazm ve uyku bozukluklarına neden olmakta ve hastaların günlük yaşam aktivitelerini (giyinme, hijyen vb.) yerine getirmelerini engellemektedir.

2.2. Spastisitenin Ölçülmesi ve Değerlendirilmesi

Spastisiteyi ölçmek, hastadaki kas tonusu değişiklikleri, hiperrefleksi, doku spazmları ve klonus varlığı hakkında bilgi edinmek, ayrıca merkezi sinir sistemi lezyonlarının teşhisi ve yapılan tedavinin etkinliğini değerlendirmek için önemlidir [15]. Spastisitenin ölçülmesi, hastalığın mevcut durumunun tespiti, hastalığın hangi evrede olduğu ve yapılan tedavilerin etkinliğini değerlendirmek açısından da önemlidir. Spastik hasta değerlendirilirken doktor dikkatli bir şekilde hastaya belirli sorular sorarak klinik öyküsünü almalıdır. Klinik öykü alındıktan sonra buna bağlı olarak tonus ve refleks muayenesi, pasif ve aktif hareket muayenesi, kas testi, fonksiyonel

değerlendirme yapılıır. Spastisitenin ölçümü doktordan doktora değişiklik gösterdiği gibi hastadaki spastisite değeri günden güne hatta aynı gün içerisinde bile farklılık gösterebilir. Bu nedenle, spastisitenin objektif ölçümü oldukça zor ve karmaşıktır. Spastisitenin objektif değerlendirilmesi ve buna bağlı olarak tedavinin planlanması için çeşitli ölçüm metotları olmakla birlikte tam ve etkin bir ölçüm metodu henüz kullanılmamaktadır. Tablo 2.1.'de ölçüm teknikleri özetlenmiştir [19].

Tablo 2.1. Spastisitede ölçüm metotları [19]

Spastisite Ölçüm Metotları	Yöntemler
Klinik Ölçümler / Skalalar	Eklem hareket açıklığı
	Tonus yoğunluğu ölçümü
	Spazm sıklığı
Mekanik Ölçümler	Pendulum Testi
	İzokinetik Dinamometreler
Elektrofizyolojik Ölçümler	H yanıtı
	H/M oranı
	F yanıtı
Fonksiyonel Ölçümler	Yürüme Analizi

Klinik ölçümler ve skalalar, hastaya bir cihaz bağlanmadan, değerlendiren doktorun gözlemine veya hastanın beyanına dayalı skalalardan oluşur. Doktor, kas tonusu ile spazm sıklığı ve şiddeti parametrelerini değerlendirir. Bu skalalar her ortamda kolayca uygulanabilir. Spastisitenin değerlendirilmesinde yaklaşık 24 farklı skala mevcuttur. Bunlardan en sık kullanılanları aşağıda verilmiştir:

- Ashworth Skalası
- Modifiye Ashworth Skalası
- Tardieu Skalası
- Penn Spazm Sıklık Skalası
- Spazm Sıklık Skalası
- Hijyen Skalası

- Derin Tendon Refleksleri Değerlendirme Skalası
- Klonus Skoru
- Plantar Stimülasyon Yanıt Skalası
- Fugyl Meyer Skalası
- Tonus Değerlendirme Skalası

Bu klinik ölçüm skalalarında en yaygın kullanılanı Ashworth Skalasıdır. Ashworth Skalası 1964 yılında geliştirilmiş olup, kasın pasif harekete verdiği direnci ve belli eklem hareket açıklığında hissedilen dirence göre sınıflandırmaya dayalı bir skaladır. Doktor, spastisitesi olan eklemi hızlı bir şekilde hareket ettirerek Tablo 2.2.'ye göre 0-4 arasında bir skor vererek spastisiteyi değerlendirmeye çalışır.

Tablo 2.2. Ashworth Skalası [15]

0	Kas tonusunda artış yok
1	Kas tonusunda hafif artış, eklem hareket açıklığı (EHA)'nın yarısından azında hissedilen direnç
2	Daha belirgin kas tonusu artışı, EHA'nın çoğunda hissedilen direnç, ama etkilenen ekstremitelerde kolaylıkla hareket ettirilir.
3	Kas tonusunda belirgin artış, pasif hareket zor
4	Ekstremitelerde fleksiyonda ve ekstansiyonda rijit

Hastaların, spastisitesi çoğunlukla orta derecelerde toplandığı için sınıflandırması oldukça zor ve karışık olmaktadır. Bu nedenle, Bohannon ve Smith klasik Ashworth Skalasına ilaveler yaparak Modifiye Ashworth Skalasını (MAS) oluşturmuşlardır [12]. Tablo 2.3.'de görüldüğü gibi MAS bir ara değerlendirme ekleyerek uygulayıcılar arası güvenilirliği artırmayı amaçlamıştır.

Tablo 2.3. Modifiye Ashworth Skalası [12]

0	Normal tonus. Kas tonusunda artış yok
1	Tonusta hafif artma. Etkilenen kısım fleksiyonda ve ekstansiyonda hareket ettirildiğinde, eklem hareket açıklığı (EHA) sonunda minimal direncin hissedilmesi veya yakalama-bırakma hissinin varlığı
1+	Kas tonusunda hafif artış. Hareket sırasında çekme hissi, EHA'nın yarısından azında hissedilen direnç
2	Tonusta daha belirgin artma. EHA'nın çoğunda hissedilir, ama etkilenen kısım kolaylıkla hareket ettirilir.
3	Tonusta belirgin artma, EHA boyunca pasif hareket zor.
4	Tonusta şiddetli artma. Etkilenen kısmın fleksiyon ve ekstansiyonda rijit-katı durumudur.

Bir diğer skala 1954 yılında geliştirilen Tardieu Skalasıdır. Bu skala, Ashtworth Skalasının Lance'nin tanımında tarif ettiği hıza bağımlılık durumunun ele alınmadığını dolayısıyla spastisiteyi doğru değerlendirmede iddia etmiştir [20]. Spastisitenin daha iyi değerlendirilmesi için üç durumun dikkate alınması gerektiğini öne sürmüştür. Bunlar, gerilme refleksinin gücü ve süresi, gerilme refleksinin etkinleştirdiği açı, gerilme refleksini tetiklemek için gerekli hızdır. Sonuç olarak, Held ve Pierrot-Deseiligny Tablo 2.4.'de verilen Modifiye Tardieu Skalasını yayınlamışlardır [21]. 1999 yılında Boyd ve Graham tarafından orjinal Tardieu Skalasına eklentiler yapılarak Tablo 2.4.'deki Modifiye Tardieu Skalası oluşturulmuştur [20].

Tablo 2.4. Modifiye Tardieu Skalası [20]

Hızlar:
V1: Olabildiğince yavaş, ekstremit segmentinin yerçekimi etkisi ile doğal düşüşünden daha yavaş hızda
V2: Ekstremit segmentinin, yerçekimi etkisi ile doğal düşüş hızda
V3: Olabildiğince hızlı, ekstremit segmentinin yerçekimi etkisiyle doğal düşüşünde daha hızlı
0-Pasif hareket süresince hiç hareket yok
1-Pasif hareket süresince minimal direnç, belli bir açıda hissi yok
2-Belli açıda yakalama hissi (pasif hareketi keser, sonrasında gevşeme olur)
3-Zayıflayan klonus (germe devam ettirildiğin de 10 saniyeden az süren belli açıda ortaya çıkan)
4-Kuvveli klonus (germe devam ettirildiğinde 10 saniyeden uzun süren ve belli açıda ortaya çıkan)
5-Eklem hareket ettirilmez

Ashworth, Modifiye Ashworth, Tardieu, Modifiye Tardieu Skalası dışında Penn Spazm Sıklığı Skalası backlofen tedavisinin etkinliğini değerlendirmek için saatte 0-10 arasında tekrar eden spazmlar ve düzenli/düzensiz oluşuma göre 0-4 arasında bir skorla değerlendirme yapmaktadır [19]. Spazm Şiddet Skalası ise, spazmın şiddetine göre “Hafif”, “Orta”, “Şiddetli” olmak üzere 1-3 arasında bir skora göre spastisiteyi değerlendirmektedir [22]. Klonus Skoru, klonusun varlığı/yokluğu ve sürekli/sürekli oluşuma göre 0-3 arasında bir skora göre spastisiteyi değerlendirmektedir [23]. Daha önce ifade edildiği gibi, 24’e yakın klinik skalanın ortak özelliği her yerde kolay uygulanabilir olması, olguya bir cihaz bağlamadan hızlı değerlendirme imkânı vermesidir. Bunun yanında en büyük problem ise, spastisitenin gün içinde seyir değiştirmesi, sıcaklık ve stres gibi faktörlerden etkilenmesidir. Bu klinik ölçüm skalalarına bakıldığında, hekimin tecrübesine bağlı ya da olgunun beyanına dayanan subjektif değerlendirmeler yapıldığı ortaya çıkmaktadır. Sonuç olarak oldukça fazla skala ortaya çıkmıştır ve spastisitenin değerlendirilmesinde herkes tarafınca kabul görmüş bir klinik ölçek yoktur. Literatüre bakıldığında ve derlemelerde yapılan çalışmalar incelendiğinde spastisiteyi değerlendirmek için Ashworth, Modifiye Ashworth, Tardieu, Modifiye Tardieu Skalalarının tercih edildiği anlaşılmaktadır [23, 24].

Spastisitenin değerlendirilmesinde kişiden bağımsız nicel verilere dayalı olarak değerlendirmeler yapmak, gerekirse biyomekanik ölçümlerle objektif sonuçlar elde etmek gerekir. Bu değerlendirme, hastalığın gelişimi ve spastisitenin altında yatan mekanizmayı anlamak için önemlidir. Biyomekanik ölçümler germe refleksindeki aktiviteyi ölçer. Bu ölçümler genellikle klinik skala ile birlikte değerlendirilir. Biyomekanik ölçümler için Pendulum Testi ve İzokinetik Dinamometre ölçümleri yapılmaktadır [15, 20]. Pendulum Testinde, yerçekimine karşı alt ekstremitenin direnci ölçülmeye çalışılır [25]. Bu ölçümde elektrogonyometre, video hareket analizi gibi yöntemler kullanılarak kinezyolojik değerler hesaplanır. İzokinetik ölçümde ise ekstremitenin pasif olarak açısal hızlarda hareket ettirilmesi ile tork ve güç ölçülerek spastisitenin değerlendirilmesinde objektif bir yaklaşım sağlanmaya çalışılır. Bu ölçüm araçlarında ekipman ihtiyaç olduğundan sadece araştırma için kullanılır. Genel kabul görmüş bir sistem de yoktur.

Biyomekanik ölçümler spastisitenin değerlendirilmesi için sayısal değerler vermesine rağmen, nörolojik değerlendirme ile birlikte uygulanmaktadır. Spastisite nörolojik bir nedenden dolayı tetiklendiği için, nörolojik değerlendirme yapılarak altta yatan mekanizmanın anlaşılmasına katkı sağlanır. Literatüre bakıldığında 9 farklı nörolojik metodun tanımlandığı görülmektedir [26]. Bu metotlar Tablo 2.5.'de verilmiştir.

Tablo 2.5. Spastisitenin değerlendirilmesi için nörolojik ölçüm metotları

Uyarı ile yapılan EMG ölçümleri	- H-refleks - F cevabı
Mekanik Tetikleme ile yapılan EMG ölçümleri	- Tendon refleksi - Polysynaptic refleksi
Pasif ve aktif hareket sırasındaki EMG ölçümleri	- Germe refleksi - Wartenberg Pendulum Testi
Aktif hareket esnasında EMG ölçümü	- Motor uyarılmış potansiyel - Duyusal uyarılmış potansiyel

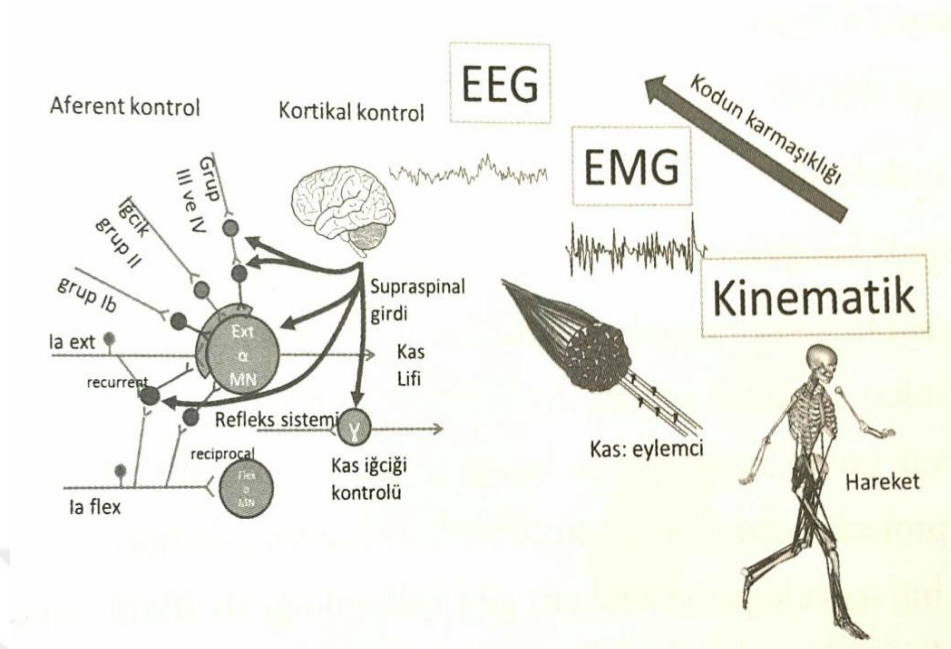
Hoffman refleksi (H-refleksi), çok çalışılan alfa motor nöron aktivitesindeki artışın değerlendirilmesine dayanan elektrofizyolojik bir yöntemdir [20]. H-refleksinde uyarı şiddeti yavaş yavaş artırıldığında 30 ms civarında ortaya çıkan geç yanıt görülür. Uyarının şiddeti artırıldığında bu yanıtın genliği artar, bu sırada daha erken latanslı motor yanıt (M yanıtı) görülmeye başlanır. İlk ortaya çıkan ve geç latanslı olan supramaksimal uyarılar ile kaybolan potansiyel, H-refleksidir [20]. Tendon refleksi ise, nörolojik muayenelerde kullanılan yöntemlerden bir diğeridir. Merkezi sinir sistemi hakkında bilgi verir. Tendon refleksi, bir kasın tendonuna refleks çekici yardımıyla vurulması sonucu oluşan, hem elektromekanik değişimleri ve kas içciklerinin işlevini hem de ön boynuzda bu içcikleri inerve eden gama motor nöronları uyarılabilme yeteneğini ölçmektedir [15].

BÖLÜM 3. HAREKETİN NÖRAL MEKANİZMASI VE EMG

Spastisite, üst motor lezyonuna bağlı hareket bozukluğu olarak tanımlanmıştır. Ayrıca, spastisitenin objektif değerlendirilmesinde Patella T-refleksi ile oluşan hareketin kinezyolojisi ve EMG kayıtları kullanılmıştır. Bundan dolayı bu bölümde, vücudumuzun istemli hareketi nasıl organize ettiği, hareketin oluşumundaki nöral mekanizmalar ve hareketin gerçekleşmesi için ilgili kas ya da kas gruplarının uyarılması ile sistemli hareketin gerçekleştirilme süreci açıklanmıştır.

İnsan vücudunun kusursuz hareketi sağlayabilmesi için, istemli ve istemsiz hareketleri organize edebilmesi gerekir. Bu da karmaşık ve kompleks yapıların bir arada koordineli çalışması ile gerçekleşir.

Şekil 3.1.'de yer alan hareketin temel birleşenlerine bakıldığında; hareket ilk önce merkezi sinir sisteminde planlandığı ve kontrol edildiği görülmektedir. Daha sonra periferel bilgilerle modüle edilip, karmaşık bir nöron ağı ile ilgili kas ya da kas grupları uyarılarak hareket düzenlenmeye çalışılır [27]. Hareketin oluşumunda ve düzenlenmesinde, serebellum ve sinir-kas sistemleri bir arada koordineli çalışmaktadır.

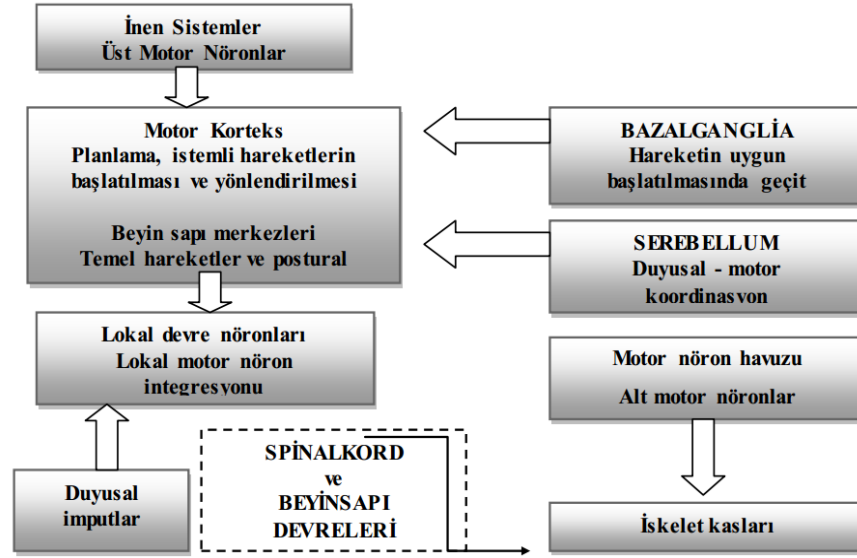


Şekil 3.1. Hareketin temel birleşenleri [27]

3.1. Hareketin Nöral Yapıları

İnsan, bedenini belli bir postürde tutabilmesi ya da birçok farklı hareketi ortaya çıkarabilmesi için adaptif bir kontrol sistemine sahiptir. Periferik organlardan gelen verilere göre pozitif ya da negatif besleme ile hareketi düzenlemeye çalışır. Bu yapı beyin ve spinal kordun birbirleriyle bağlantılı nöral merkezler, kaslar ve çok sayıda duyu reseptörü içeren kompleks bir yapıdan oluşmaktadır [28].

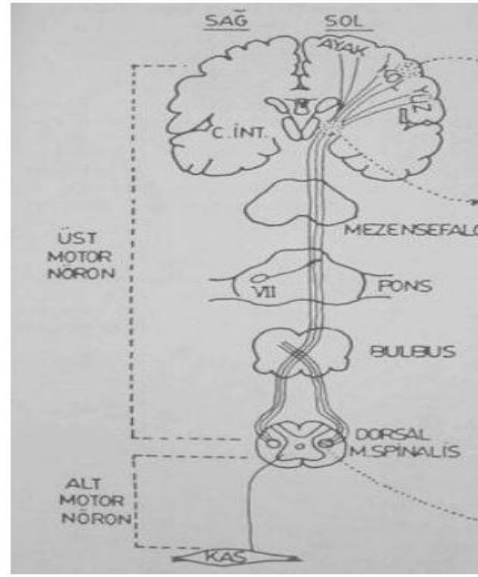
İstemli hareket öncesi beynimizde birçok kortikal bölge aktiftir. Bu bölgeler hareketin alan ve konum belirleme, hareket planı ve hareket gerçekleştirilmesi evrelerini organize eder. Beyin korteksinde yer alan primer korteks, premotor korteks, suplemer korteks motor alan ilgili süreçleri yönetmektedir.



Şekil 3.2. Hareketin nöral yapıları [28]

Şekil 3.2.'de görüldüğü üzere birbiriyle etkileşim içinde olan sistemlerin her biri hareketin düzgün ve pürüzsüz gerçekleşmesi için katkı sağlamaktadır. Hareketin kontrolünden sorumlu nöral devreler, birbirleri ile etkileşim içinde olan 4 farklı sisteme ayrılmaktadır. Bu sistemlerden ilki medulla spinalis ve beyin sapında yer alan nöronlar ile onlarla iletişim halinde olan alt motor nöronlardır. Bu alt motor nöronlar, tüm kasların gerek istemli gerekse refleksif hareketlerinin gerçekleşmesini sağlar.

İkinci alt sistem üst motor nöronlardan oluşmaktadır. Şekil 3.3.'de görüldüğü üzere üst motor nöronlar, serebral kortekste ve beyin sapında yerleşmiştir. Kortekste görülen üst motor nöronlar, beyin sapından geçerek çaprazdaki beyincik lobuna ulaşır. Oradan spinal kord üzerinden alt motor nöronlarla direk ya da indirek bağlantı kurarlar. Özellikle kas tonusunun düzenlenmesi, göz-baş uyumu ve postür kontrolünden üst motor nöronlar sorumludur [28].



Şekil 3.3. Üst motor nöron ve alt motor nöron [29]

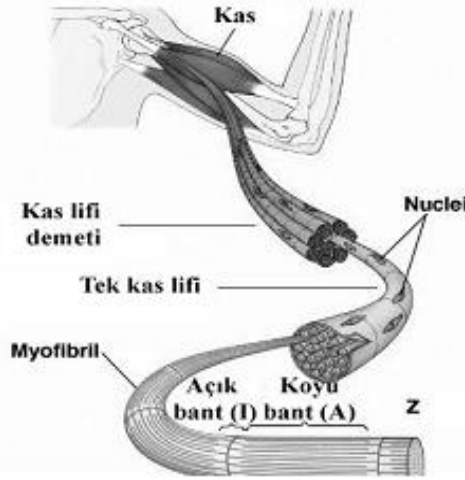
Üçüncü ve dördüncü alt sistem, Serebellum ve Bazalganglialardır. Bu sistemler üst motor nöronların aktivitelerini düzenleyerek hareketi kontrol ederler. Serebellum, üst motor yollara bilgi göndererek gerçekleştirilen ve gerçekleştirilmesi gereken hareket arasındaki farklılıkları ya da motor hataları bulur. Bu hareketlerin yumuşak, koordineli, istenilen şiddet ve sürede gerçekleşmesini sağlar. Bazalganglionlar da üst motor nöronlara bilgi göndererek hareketin planlanması ve başlatılmasında önemli bir rol üstlenir. Kasların kasılma gücü, süresi, şiddeti ile ilgili son bilgiyi götüren motor nöronlar “alt motor nöronlar” olarak adlandırılır. Şekil 3.3.’de görüldüğü üzere alt motor nöronlar medulla spinalisin ön boynuzda ve kranial sinir nükleuslarında yerleşmişlerdir. Alt motor nöronlar, gerek üst motor nöronlardan gelen emirlerle çalışmasını düzenler, gerekse kasın duyu reseptörlerinden 5-10 bin farklı bilgiyi üzerlerinde toplayarak kasa son kasılma emrini verir. Bu kasılma emri sinir sistemini kullanarak, ilgili kas ve kas gruplarını uyararak hareketi koordine eder.

3.2. Kas

İnsan vücudunda 600’den fazla kas vardır. Kaslar üç ana işlevi yerine getirirler. Isı üretim, dengeli bir vücut pozisyonunun korunması ve hareket işlevidir. Hareket, Serebrumda yer alan üst motor nöronlardan başlayan hareketin planlanma safhasını

gerçekleştirmesi ile uyarılan kasların tepkilerine göre iskelet sisteminin etkisini göstererek oluşur. Üç çeşit kas tipi vardır. Bunlar iskelet kasları, düz kaslar ve kalp kasıdır. İskelet kası, hareketi sağlayan iskelet etrafında bulunurlar ve istemli kas olarak da nitelendirirler. Düz kaslar, isteğimiz dışındaki otonom sinir sistemine bağlı kaslardır. Kalp kası, sadece kalp kasında bulunup kalbin sürekli çalışmasını sağlar. Tüm bu kas grupları bir arada karmaşık hareketler ortaya koyabilmektedir. Her kasın bireysel olarak iki hareketi vardır. Bunlar kasılma ve gevşemedir. Kasın kasılmasını anlamak için kasların özelleştirilmiş hücre yapısını anlamak gerekir.


Şekil 3.4.'de görüldüğü üzere bir kas, kas lifleri demetlerinden oluşmaktadır ve bu lifler de daha küçük birimler olan miyofibrillerden oluşmaktadır. Miyofibril bir dizi filamentlerin iç içe geçmiş halidir. Uyarıldıklarında, uzun filamentler kısalarak kendi içlerine doğru kayarlar.



Şekil 3.4. Kasın Yapısı

Binlerce lif eş zamanlı olarak kısaldığından kasta güçlü bir kasılma oluşur. Uyarı hali kaybolduğunda filamentler tekrar dışa doğru kayarak orjinal uzunluğuna döner ve kas gevşemiş olur. Kasılmayı sağlayacak uyarıcılar elektriksel formdadır. Bu uyarılar, motor nöron sinir hücreleri tarafından gönderilir. Bir motor nöron bütün kası uyarır, sadece o kas içindeki bir kaç lifi uyarır. Motor nöron ve onun uyardığı lifler motor ünitesi olarak adlandırılır. Motor ünite sayesinde inerve edilmiş kas, tendonla bağlı

olduğu kemiği hareket ettirir. Kaslarda, hareket esnasında geri bildirim yapan yapılar mevcuttur. Bunlar kas içcikleri ve golgi tendon organlarıdır. Kas içcikleri Şekil 3.5.'de görüldüğü üzere kasın orta kısmında yer alırlar ve intrafuzal liflerden oluşurlar. Kas içciğinin orta kısmında sadece gerilme duygusu yer aldığı için duyu alan, kutup bölgelerinde kasılma yeteneğine sahip motor alan olarak adlandırılır. Kasın boyundaki değişimi veya kasın boyundaki değişim hızıyla ilgili bilgi gönderirler. Kas içciklerin gerilme durumu ile bilgileri medulla spinalise taşıyan afferent sinir Grup Ia ve Grup II lifleridir. Medulla Spinalisin ön boynuzunda yer alan gama efferent nöronlarla kas içcikleri uyarılır. Üst merkezler kas tonusu üzerindeki etkisini gama motor nöronlar aracılığıyla gösterir [30].



Şekil 3.5. Kas içciği ve golgi tendon organı [31]

Bir diğer yapı ise golgi tendon organıdır. Tendon, kasın kemiğe bağlandığı yerdir. Tendondaki ani kasılma değişiklikleri Grup Ib afferent nöronlarla medulla spinalise iletilir. Ön boynuzda yer alan alfa motor nöronlar tarafından ektrafuzal kas liflerin kasılmasını sağlar. Böylelikle bir refleks içinde kas tonusunu ayarlamaya çalışırlar.


3.3. EMG

Vücudumuz birçok farklı biyoelektriksel sinyaller üretir. Bu sinyallerden biri de Electromiyogram'dır. EMG kelimesi, electro "elektriksel", myo "kas", gram "ölçme" ifadelerini içeren kısaltmadır. EMG işaretinin varlığı 1791 yılında Luigi Galvani tarafından kurbağa bacağı sinirinin, farklı metaller ile uyardığında bir reflekse cevap verdiğinin görülmesine dayanmaktadır [32]. H. Piper EMG sinyalleri üzerine çalışan ilk araştırmacı olarak kabul edilir [33]. 1912 yılında EMG sinyallerinin galvanometre çalışması ile kayıt altına alınması EMG işaretinin analizi ve nöromusküler hastalıkların tespiti için önemli bir adım olmuştur. Bu alanda yayınlanan ilk eser 1962 yılında J.V Basmajian tarafından yazılan "Muscle Alive" adlı kitaptır. De Luca tarafından da 1979 yılında EMG işaretinin fizyolojisini ve matematiksel metotlarını birleştiren bir makale yayınlanmıştır [34].

EMG işaretinin kayıt altına alınması iğne ve yüzey elektrotları ile yapılır. Bu kayıtların belli bir standarda göre yapılması için, bir grup araştırmacı tarafından SENIAM (Surface EMG for Noninvasive Assessment of Muscles) çalışma grubu kurulmuştur [35]. Günümüzde EMG çalışmaları sadece nöromusküler hastalıkların teşhisi için değil, birçok farklı alanda (biofeedback, protez kontrolü, ergonomi, spor, insan-makine etkileşimi, hareketin çözümlenmesi) araştırma konusu olmaktadır.

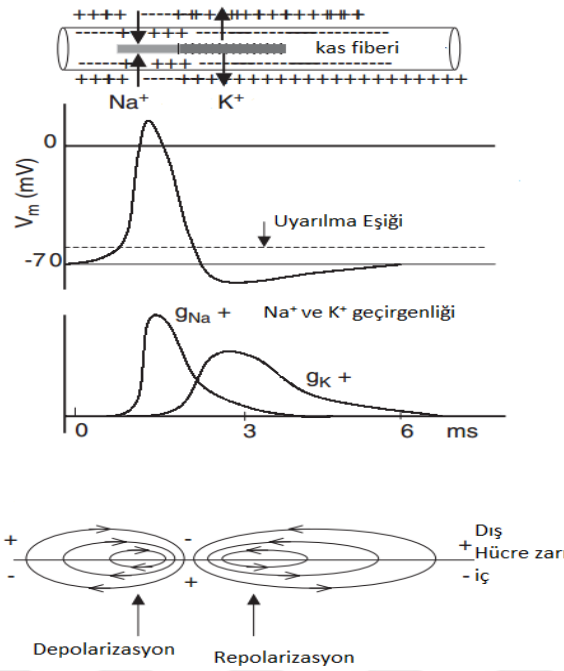
3.3.1. EMG işaretinin oluşumu

Kasların kasılması sonucu ortaya çıkan işaretin EMG olarak adlandırıldığı daha önce de belirtilmişti. Kas, kas lifi uyarıldığında kasılır. Bu kasılma ile beyin ve omurilik üzerinden ya da direk omurilikten (Şekil 3.6.) gelen uyarı, motor siniri ile iletilir. Motor sinirlerin kas uçlarına ulaştığı noktaya da motor uç plakaları adı verilir. Kasın kasılması bu uç plakalara bilgi geldiğinde gerçekleşir. Şekil 3.6.'da görüldüğü üzere bir motor ünitesi, merkezi sinir sisteminden gelip motor son plakalarına dağılan sinir hücresine sahiptir. Kasın en küçük işlevsel birimini de motor ünitesi oluşturur.



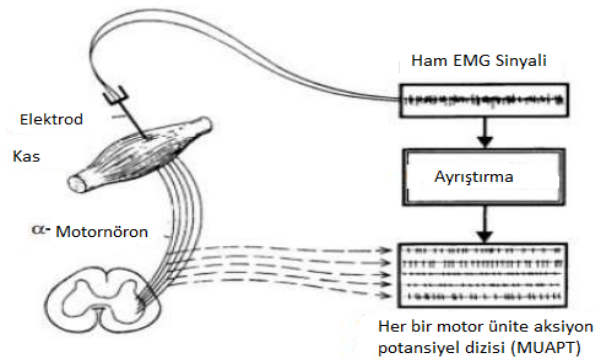
Şekil 3.6. Motor kontrolün şematik gösterimi ve motor ünite [35]

İstemli hareketin planlanması evresi üst motor nöronlardan başlar. Alt motor nöronlar vasıtasıyla da motor ünitelerin uyarılması devam eder. Nöromüsküler kavşakta Acetylcholine salgılanması ile kaslar uyarılmaya başlanır. Eşik değeri aşıldığında Voltaj kapılı iyon kanallarının Na^+ (Sodyum) geçirgenliği artar ve hücre içine geçiş başlar. Bu eylem de depolarize oluşuma sebep olur. Bu reaksiyon hızlı bir şekilde kas zarında yayılır [36]. Şekil 3.7.'de görüldüğü üzere hücre zarında oluşan zıt yükler, aksiyon potansiyeli oluşumuna sebep olur. K^+ (Potasyum) voltaj kapısı yavaş açıldığı gibi yavaş da kapanır. K^+ 'nın hücre dışına yavaş yavaş akması ile hücre içerisi polarize olur. Böylece hücre zarı normal geçirgenliğine geri dönmüş olur. Aksiyon potansiyeli, hücrenin dinlenme durumuna dönüşümü ile tamamen sıfır olmaz. Vücudu yer çekimine karşı ve belli postürde tutması için dinlenme potansiyeli vardır. Bu da kasları bir gerilimde tutmaya yarar ve kas tonusu olarak adlandırılır.



Şekil 3.7. Aksiyon potansiyelin oluşumu [35]

EMG sinyalinin ölçümünde yüzey elektrotlar, deri yüzeyinden o bölgedeki bütün kas liflerin ölçümü için tercih edilir. İğne elektrotlar ise bir ya da bir kaç kas lifini ölçmek için kullanılır. Deri üzerine elektrotların yerleştirilmesi durumunda, o bölgede faaliyette olan kas fiberlerinin oluşturduğu işaretler elektrotlar tarafından algılanacaktır. Şekil 3.8.'de görüldüğü üzere kasın kasılması sırasında n adet motor ünite devreye girer. Bu motor ünitenin uyardığı kas liflerinde oluşan aksiyon potansiyellerin toplamı EMG sinyalini oluşturur.



Şekil 3.8. EMG işaretinin oluşumu [35]

Bundan dolayı EMG sinyali stokastik bir yapı gösterir. EMG sinyalinin genliği 0 ile 10 mV arasında değişirken, sinyal enerjisi 50 ile 500 Hz frekansın aralığında olup baskın enerji 50 ile 150 Hz arasında değişir [37]. EMG sinyalini aşağıda verilen denklem ile modelleyebiliriz.

$$x(n) = \sum_{r=0}^{N-1} h(r)e(n-r) + w(n) \quad (3.1)$$

Burada $x(n)$ modellenmek istenen EMG sinyali, $h(r)$ MUAP (Motor Ünit Aksiyon Potansiyeli), $e(n-r)$ işlem gören nokta, $w(n)$ Gauss gürültüsü, N motor ünit sayısı olarak ifade edilebilir [38]. Ham EMG sinyalinden alınan verilerle çok fazla değerlendirme yapılamamaktadır. EMG sinyalinden ayırt edici ya da tespit edici veriler elde etmek için sinyalin zaman ve frekans uzayında ya da yeni metotlarla analizi yapılarak anlamlı öznitelik hesaplanmaya çalışılmaktadır.

3.3.2. EMG işaretinin analizi

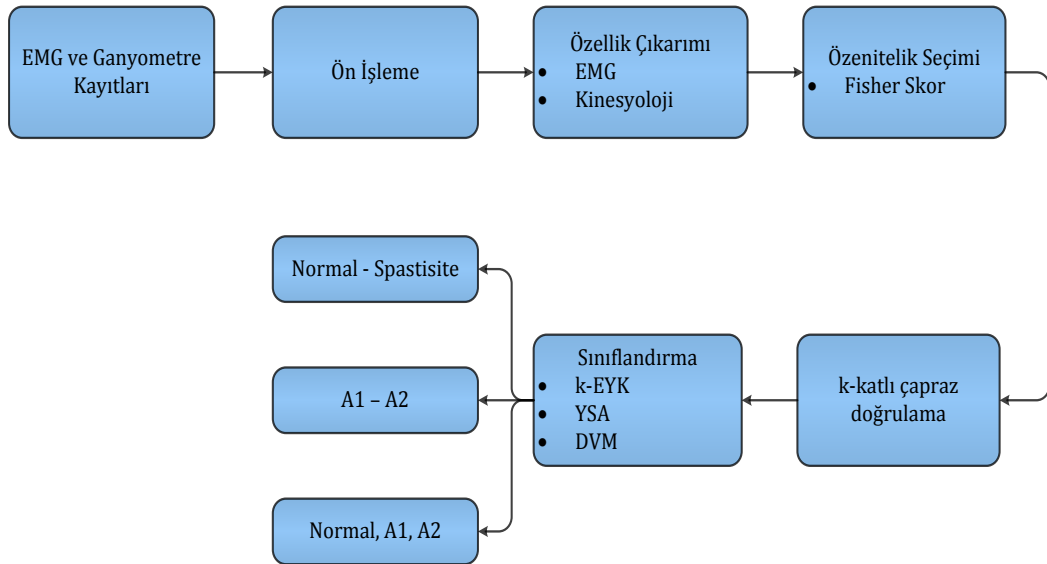
Günümüzde bilgisayar teknolojisinin gelişmesi ile biyolojik işaretlerin işlenmesine ve ve sınıflandırılmasına olanak sağlanmıştır. Bu alanda günümüzde bir çok çalışma yapılmıştır. EMG işareti frekans ve zaman uzayında incelenebilir. EMG işaretinin devamlılık süresi, genlik ve aşama parametreleri kas ve sinir hastalıklarının birbirinden ayrılmasında önemlidir. Bunlardan devamlılık süresinin ölçümü klinik çalışmalarda anahtar parametre olarak kullanılmaktadır [39]. Kas gücü arttıkça EMG işaretlerindeki yeni aktif olmuş MUAP'ların da sayısında artış gözlenmekte, bu da nörofizyolojistlerin her bir MUAP dalgacığını ayırt etmesini zorlaştırmaktadır. EMG işaretlerinin ayrıştırılması ve MUAP'lardan benzer şekilli olanlarının gruplandırılarak sınıflandırması nöromasküler patoloji değerlendirmesi açısından değerli bilgiler sunmaktadır [40].

Christodoulou ve Pattichis kendisini organize eden model (Self Organized Feature Maps) algoritmasını ve Learning Vector Quantization (LVQ, öğrenen vektör nicelendiricisi) ve Öklit (Euclidian) mesafesini temel alan istatistiksel örüntü tanıma

tekniklerinden faydalanarak denetimsiz öğrenme ile yapay sinir ağları tekniğini kullanmışlardır. Buna ek olarak, Schizas ve Pattichis EMG işaretlerindeki örüntü sınıflandırmaları için genetik tabanlı makine öğrenmesini kullanmışlardır. Çok katmanlı yapay sinir ağları ile genetik algoritmaları birleştirip EMG işaretinin sınıflandırılması yapılmıştır [41]. Bir başka çalışmada dört farklı hareket için Biceps ve Triceps kaslarından üretilen EMG işaretleri incelenmiştir. Bu amaçla çalışmada koldan alınan 4 farklı harekete ait EMG işareti k-ortalama, bulanık C-ortalama, DVM, Diskriminant Analizi, Olasılıksal Sinir Ağları ve İleri Beslemeli Yapay Sinir Ağları algoritmaları kullanılarak öbekleştirme ve sınıflandırma gerçekleştirilmiştir. Bu algoritmalar kullanılmadan önce işaretlerin bir ön işlemeden geçirilmesi gerekmektedir. Ön işlemede çok değişik uygulamalar mevcuttur. Bu amaçla işaretlerin Ortalama Mutlak Değer, Kayan Ortalama Alıcı Filtre, Eğri Uydurma ve Özbağlanım metotlarıyla öznitelik vektörleri elde edilmiştir [42].

BÖLÜM 4. SPASTİSİTENİN TESPİT EDİLMESİ VE DERECELENDİRİLMESİNDE UYGULANAN ADIMLAR

Spastisitenin ölçülmesi ve değerlendirilmesinde birçok yöntem olduğundan daha önceki bölümlerde bahsedilmiştir. Bu bölümde, spastisitenin objektif olarak ölçülmesi ve değerlendirilmesi için bir Tendon Refleksi olan Patella T-refleksin tetiklenmesi ile oluşan Pendulum hareketi incelenmiştir. Spastisiteyi tanımlayan parametrelerin belirlenme aşaması hareketin kinezyolojik parametrelerinin hesaplanmasından ve Patella T-refleksin tetiklenmesi esnasında oluşan, RF ve BF kas grubundan alınan kısa süreli EMG kayıtlarının elektrofizyolojik parametrelerin hesaplanmasından oluşmaktadır. Bu tezde, belirlenen amaçta ulaşmak için Şekil 4.1.'de belirtilen akış diyagramı kullanılmıştır.



Şekil 4.1. Çalışmanın akış diyagramı

Akış diyagramında görüldüğü gibi, öncelikle olguların bulunması ve spastisitelerinin nöroloji alanında uzman iki hekim tarafından değerlendirilmesi sağlanmıştır. Kinezyolojik ve elektrofizyolojik parametreler hesaplanmadan önce alınan ölçümlere ön işleme uygulanmıştır. Ön işlemlerden kasıt, Pendulum hareketinin başlangıç noktasının sıfır noktasına hizalanması, EMG verisinin gürültüden arındırılmasıdır. Bunların dışında özneliklerin hesaplanması için Matlab platformu kullanılarak analiz yazılımının geliştirilmesi de bu aşamada gerçekleştirilmiştir. Ön işleme adımından sonra, Pendulum hareketine ait altı adet kinezyolojik ve RF-BF kaslarından zaman ve frekans uzaylarında beşer öznelik ile toplamda 26 elemanlı bir öznelik vektörü elde edilmiştir. Elde edilen 26 öznelikten ayırt edici olanlar filtre tabanlı bir öznelik seçme metodu olan Fischer Skoruması ile belirlenmiştir. Öznelik çıkarma aşamasının sınıflandırma performansını doğrudan etkilediği bilindiğinden bu adım sınıflandırma performanslarının artırılmasında oldukça faydalı olmuştur. Spastisitenin tanılanmasında ve değerlendirilmesinde kullanılacak karakteristik parametreler belirlendikten sonra, spastisite derecesinin en doğru şekilde atanması için sınıflandırma yapmadan önce k-katlı çapraz doğrulama yapılmıştır. k-katlı çapraz doğrulamadaki amaç özellikle düşük boyutlu veri setlerinde öğrenme algoritmalarının daha iyi eğitilmesini sağlayarak sınıflandırıcı doğruluğunu yükseltmektir. Tezin son aşamasında makine öğrenme algoritmalarından en yaygın olanları YSA, k-EYK, DVM kullanılarak Normal ile Spastisite, Ashworth 1 ile Ashworth 2, Normal, Ashworth 1 ve Ashworth 2 olguların sınıflandırılması sağlanmıştır. Spastisitenin tespit edilmesi ve derecelendirilmesi için tezde uygulanan aşamalar kısaca özetlendikten sonra alt bölümlerde Tendon refleksi ve Patella T-refleksinden bahsedilmiştir.

4.1. Tendon Refleksi

Ölçüm metodumuz Patella T-refleks tetiklenmesine dayalı olduğundan bu kısımda refleksin ne olduğu anlatılmıştır. Sinir sisteminde çok sayıda refleks görülür. Refleks, vücudumuzun iç ve dış uyarana bilinç olmadan verdiği, motor yanıtlar olarak tanımlanabilir [43]. Refleksler, Nörologların klinik muayenede santral ve periferik sinir sistemi hakkında fikir edinmesine ve nöromusküler hastalıkların tanısına

yardımcı olmaktadır [44, 45]. Motor ve duyuşsal aktivitenin tamamlamasından oluşan temel yapı refleksi arkıdır [43]. Bir refleksi arkı beş parçadan oluşur [46]:

- Dıő veya iç ortamdaki fiziksel deęiőim alan duyuş organı,
- Uyarıyı refleksi merkezine taőıyan aferent nörön
- Santral integrasyonu saęlayan medula spinalis veya beyindeki merkez
- Refleksi cevabı çevreye taőıyan eferent nörön
- Cevabı saęlayan efektör organ

Aferent ve eferent nörönler arasında bir sinaps varsa, buna monosinaptik refleksi adı verilir. Birden fazla ara nörön varsa polisaptik refleksi olarak adlandırılır. Derin Tendon Refleksi (DTR) bir monosinaptik germe refleksidir. Tendon refleksi bir tendonun distaline refleksi çekici ya da el yordamı ile uyarılarak tetiklenir. Bireylerde tendon refleksini uyarmak için üst ve alt ekstremitede birçok tendon mevcuttur. Genelde tendon refleksi için diz (Patella T-refleksi) ve ayak bileęi (Aşil Refleksi) ekstremitesi uyarılır. Üst ekstremitedeki refleksi uyarmak genellikle daha zordur [47]. Tezde Patella T-refleksi kullanıldıęından Aşil Refleksi açıklanmamıőtır.

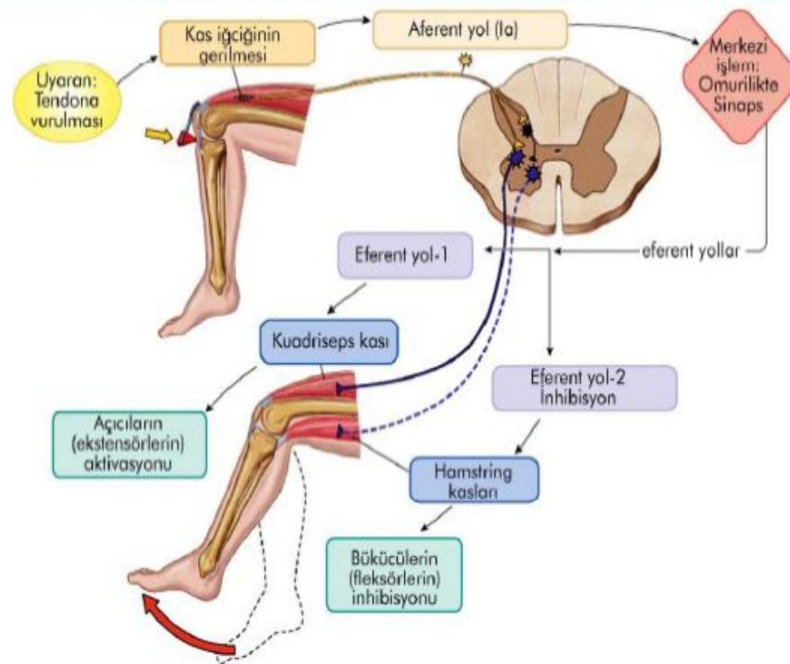
4.1.1. Patella T-refleksi

Patella (diz kapaęı), dizin önünde yukarıda kuadriseps tendon adı verilen, aőaęıdan patellar tendon adı verilen iki adet kiriőle bir kaldıraç görevi görür. Dizin eksitasyon mekanizması içinde yer alır [48]. Patella tendonu, bacaęı düzleőtirme görevini üstlenir. Patella Tendon Refleksi Őekil 4.2.'de görülen refleksi çekici (tendon çekici) kullanılarak Patella Tendonun tetiklenmesi ile oluşan monosinaptik bir refleksidir.



Şekil 4.2. Refleks çekici

Şekil 4.3.'de görüldüğü üzere Patella tendonu refleks çekici ile uyarıldığında kuadriseps kas iğciklerinin gerilmesi ile Grup Ia, afferent yolla kastaki değişimi ve hızı medial spinalisin ön boynuzundaki gama motor nöronlara iletilir. Eferent yollar ile hamstring kas grubu uyarılmış olur. Böylelikle alt ekstremitte fleksiyon ve eksitasyon hareketi yaparak pendulum ya da sarkaç hareketini oluşturur.



Şekil 4.3. Patella Tendon Refleksinin oluşum safhası [49]

Pendulum hareketi, hastalığın patolojik durumuna göre spastisitenin değerlendirilmesine yardımcı olmaktadır. Pendulum hareketini ilk kez 1951 yılında

Wartenburg tanımlamıştır [50]. Daha sonra 1964'te Schwab, üst motor nöron hastalıklarında tonus değişikliğini değerlendirmek için Pendulumu kullanmıştır [51]. Pendulum testinin en büyük avantajı testin uygulanmasının kolay ve objektif olmasıdır. Pendulum hareketi açıklandıktan sonra izleyen kısımda olgular tanıtılmıştır.

4.2. Olgular

Kayıt yapılan olgular, Nöromusküler bozukluk belirtisi olmayan yirmi beş gönüllü normal kişi ile Akdeniz Üniversitesi Tıp Fakültesi Nöroloji, Nöroşirürji ve Fizik Tedavi ve Rehabilitasyon polikliniklerine başvuran hastalar ve Nöroloji Kliniğine yatan hastalardan oluşmaktadır. Spastisitenin derecelendirilmesi, Ashworth Skalasına göre 4 gruba ayrılmıştır. Ashworth 1 grubunda 18, Ashworth 2 grubunda 23, Ashworth 3 grubunda 18, Ashworth 4 grubunda 6 kişi bulunmaktadır. Ölçüm aldığımız olgu sayısı 90 olup, Ashworth 3 ve Ashworth 4 olguların kinezyolojik ve EMG verilerin gözle görülür bir örüntüye sahip olduklarından makine öğrenme algoritması için değerlendirmeye alınmamıştır. Bundan dolayı değerlendirilen olgu sayısı 65'dir. Spastisite olguların muayene esnasındaki spastisite düzeylerine göre değerlendirilmesi, myorelaksan (kas gevşetici) alıp almadığına bakılmaksızın yapılmıştır.


Tablo 4.1. Olguların demografik yapısı

Olgu Sayısı	Normal: 25 Ashworth 1: 18 Ashworth 2: 23 Ashworth 3: 18 Ashworth 4: 6
Etkilendiği Taraf	24 olguda serebrovasküle bağlı inme 11 olguda spastik paraparezi 3 olguda spinal kord yaralanması 2 olguda kafa içi yaralanmaya bağlı aksoanal yaralanma 1 olguda serebral palsi skeli
Hastalığın süresi	1.5- 30 yıl
Cinsiyet	38 Erkek, 27 Kadın
Yaş	18 – 75 (ortalama 32)
Boy	155.5-176.8 cm

Olguların spastisite skoru Prof. Dr. Hilmi UYSAL ve Dr. Mehmet GÜRBÜZ tarafından Ashworth skalasına göre belirlenmiştir. İncelenen alt ekstremitedeki diz eklemine ait değer ise Bölüm 2’de belirtilen Tablo 2.2.’ye göre derecelendirilmiş olup, iki araştırmacı tarafından da ortak kabul görmüştür. Olguların demografik yapısı Tablo 4.1.’de verilmiştir.


4.2.1. Olguların hazırlanışı ve ölçüm düzeneği

Olgumuza, uygulanacak işlem ve bu işlem sırasında ağrı duymayacağı anlatılarak kendini serbest bırakması, meydana gelecek ekstremitte hareketini engellememesi veya harekete katkıda bulunmaması söylenmiştir. Olgular rahat olarak sırtını yaslayacak şekilde ayakların yerden yüksek olduğu bir konumda muayene masasına, arkası ve kollarının altına süngerden yapılmış desteklerle desteklenerek en rahat pozisyonda oturtulmuştur. İnceleme yapılacak olgunun cildi alkol ve cilt temizliğinde kullanılan bir solüsyonla iyice temizlendikten sonra elektrotlar yerleştirilmiş ve flaster ile sabitlenmiştir. Kinezyolojik özellikleri değerlendirmek için Biometrics Limited firmasının DATALOG Type No MWW8 Bluetooth portable EMG ve Goniometre cihazı kullanılmış olup, kayıtlar Şekil 4.4.’de gösterilen bağlantılar yapılarak alınmıştır. EMG elektrotları RF ve BF kaslarına konularak kas aktivitesi kaydedilmiştir. EMG kayıtları 1 kHz, Gonyometre kayıtları ise 500 Hz örnekleme frekansı ile alınmıştır. Darbe sensörleri, hep aynı noktaya vurulup vurulmadığını görmek için kullanılmıştır. Bu işlem 10 kere tekrarlanmıştır. Ayrıca Patella T-refleksinden oluşan sarkaç hareketin video kaydı da alınmıştır.




Şekil 4.4. Ölçüm düzeneği

Olgularda patella, elektronik tetikleme refleks çekici (084C001-Nicolet-Viasys Tendon Hammer) ile uyarılmıştır. Çalışma boyunca tüm tetikleme aynı araştırmacı tarafından yapılmış olup, patellar tendonuna dik ve 8 cm distalde en iyi refleks yanıtı alındığı belirlenmiş ve hep aynı noktaya vurulmaya çalışılmıştır. Burada aynı araştırmacı farklı kuvvetlerde patellayı tetiklediğinde Pendulum hareketi farklılık gösterir mi sorusuna dikkat çekilmiş ve tarafımızca yapılan bir çalışmada farklı kuvvetle patellayı tetiklemenin direk olarak Pendulum hareketi ile bir doğrusal ilişkisi olmadığı gösterilmiştir [52]. Her olguda 10 defa Patella T-refleksine bakılmıştır. Böylelikle oluşan Pendulum hareketi ve EMG kayıtları Şekil 4.5.'deki 10 ham veriden birbirine yakın işaretler (trace) seçilerek hesaplanmıştır. Hesaplamalar yapılırken hastanın istemsiz veya istemli olarak harekete katkıları ve tetikleme refleks çekicinin hep aynı noktaya aynı kuvvetle vurulması sorunu kısmi de olsa minimize edilmeye çalışılmıştır. Hesaplamalar için birbirine en yakın refleks yanıtının cevapları kullanılmıştır. Bu kayıtlama her olgu için yaklaşık 35 dakika sürmektedir. Tüm olgulardan ölçüm işleminin tamamlanması bir seneye yakın bir zaman almıştır. Böylelikle araştırmamız için gereken veri tabanı oluşturulmuştur.



Şekil 4.5. Normal olguya ait Biometrics kayıt

Olgulardan alınan kayıtlar için Biometrics firmasının yazılımı ve donanımı kullanılmıştır. Ancak mevcut yazılım, istediğimiz analizler için zaman-frekans uzayı ve kinezyolojik parametreleri hesaplama açısından yetersiz kalmıştır. Bu nedenle verilerimizle istenilen analizleri yapabilmek için Matlab programı üzerinden yeni bir analiz programı geliştirilmiştir. Matlab programı, mühendislik alanında kullanılan yaygın bir program olmasından ve hızlı çözüm üretmesinden dolayı tercih edilmiştir. Biometrics verileri Matlab veri formatına dönüştürülmüş ve tasarlanan program kullanılarak analizler yapılmıştır. Şekil 4.6.'da bir olguya ait Biometrics kaydının Matlab programındaki analiz görüntüsü verilmiştir. Analiz yapılmak istenen kayıt seçilip, o refleks cevabına ait Pendulum hareketi, RF ve BF kas grubuna ait EMG kayıtları da başka bir pencereye aktarılmıştır. Daha sonra elde edilen işaretler ön işlemden geçirilmiştir. Ön işlemede, Pendulum hareketinin başlangıç konumu sıfır olarak tanımlanmıştır. Olgularda, Patella T-refleks tetiklendikten sonra alt ekstremiteler her zaman tekrar sıfır konumuna getirilememektedir. EMG kayıtlarından özellikle BF kasına bağlı EMG elektrotunda hareketten kaynaklanan gürültü nedeni ile bir ön işlemeye ihtiyaç duyulmuştur. Pendulum hareketinin analizini yapan kişiden bağımsız olarak belli bir standartta hesaplaması mümkün hale gelmiştir.



Şekil 4.6. Normal olguya ait Matlab analiz program görüntüsü

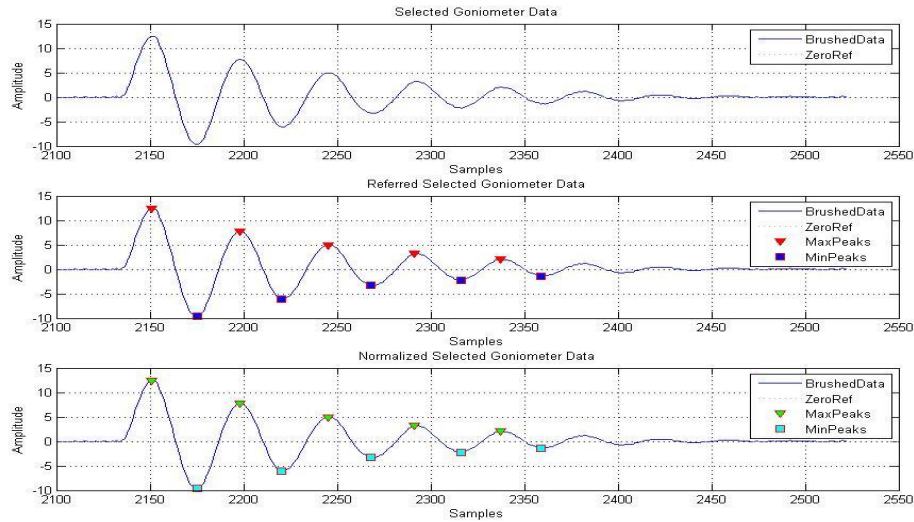
4.3. Özniteliklerin Hesaplanması

Bu aşamada, Tablo 2.2.'de verilen Ashworth Skalasına göre olguların spastisite seviyelerini değerlendirmek amacı ile hastalığın durumunu ayırt etmeyi sağlayan belirleyici temel öznitelikler elde edilmiştir. Ayırt edici öznitelik belirlenmesi adımının başarısı sınıflandırma performansını doğrudan etkilemektedir. Bundan dolayı EMG kayıtlarından elektrofizyolojik, Pendulum hareketinden kinezyolojik öznitelikler hesaplanmıştır. Aşağıda bu özelliklerin nasıl hesaplandığı detaylı bir şekilde açıklanmıştır.

4.3.1. Kinezyolojik özniteliklerin hesaplanması

Patella T-refleksi monosinaptik refleks olup, nörolojik muayenelerde kullanılan en temel unsurlardan biridir [52]. 1951 yılında Wartenburg Pendulum'u tanımlamıştır. İlk defa Bajd ve Volvonik tarafından spastisitesi olan hastalarda uygulanarak salınım hareketinin kinezyolojik öznitelikleri tanımlanmıştır [50]. Patella T-refleksi tetiklediğinde merkezi sinir sistemi uyarılmış olur ve gelen cevaba göre refleks yayı bir salınım hareketini tetikler. Bu da spastisitenin derecelendirilmesine ve objektif bir

şekilde değerlendirilmesinde yardımcı olur. Şekil 4.7.'de Ashworth 2 olgusuna ait Patella T-refleksinin oluşturduğu örnek bir Pendulum hareketi görülmektedir.




Şekil 4.7. Ashworth 2 olgusuna ait Pendulum hareketi

Şekil 4.7.'de en üst kısmında yer alan şekil kayıt esnasındaki pendulum hareketidir. Pendulum hareketinin başlangıç konumu sıfır noktasına çekilmiş ve her salınım hareketindeki maksimum ve minimum değerler yazılım tarafından otomatik olarak işaretlenmiştir. Böylelikle analiz yapan kişiye, Pendulum hareketinde kaç salınım olduğu yazılım sayesinde gösterilmiştir. Bu Pendulum hareketine ait BF ve RF kasların EMG verileri de arka planda tutulmaktadır. Kullanıcıdan onay alındıktan sonra, Pendulum hareketine ait Tablo 4.2.'de belirtilen kinezyolojik öznelikler hesaplanmaktadır.

Tablo 4.2. Kinezyolojik Parametreler


1-	Salınım Süresi
2-	Salınım Sayısı
3-	Genlik Oranı
4-	Relaksasyon (Gevşeme) indeksi
5-	Normalize Relaksasyon indeksi
6-	İlk Maksimundaki Açısal Hız

İlk ölçülen parametre, ilgili tetikleme için, birinci salınım ile son salınım arasında geçen zaman olarak ifade edilen salınım süresidir. Bir spastisite hastasının salınım süresi normal olgulardan daha kısadır ve Pendulum salınım örüntüsü dejenere olmuştur. Bu nedenle, salınım süresi özneliği spastisiteyi değerlendirmede etkili olabilir. İkinci öznelik salınım sayısıdır. Salınım sayısı, Pendulum hareketini oluşturan, sönümlenerek devam eden sinüzoidal dalga formunun kaç kez tekrarlandığını gösterir. Normal olgularda salınım sayısı 6-8 arasında iken, spastik olgularda bu sayının belirgin bir şekilde azaldığı gözlenmiştir. Şekil 4.9.'da görüldüğü üzere, Ashworth 3 olgularda salınım sayısı 1-3 arasında iken, Ashworth 4 olgularda hiç bir salınım yoktur. Üçüncü öznelik genlik oranıdır. Genlik oranı ise belden aşağı feçli hastaları kısıtlayan spastik davranış ile doğrudan ilişkilidir. Bu oran Şekil 4.8.'de R_1 olarak gösterilmiştir. Bu oranın spastik olgularda normal olgulara göre daha yüksek olduğu bilinmektedir. Dördüncü öznelik Relaksiyon indeksidir. Relaksiyon indeksi ya da Gevşeme indeksi R_2 , A_1 maksimum genliği ile A_0 büyüklüğü arasındaki oran olarak tanımlanmıştır. Yapılan çok sayıda denemelere göre R_2 'nin değeri 1.6 ve üzerindedir. Bu nedenle şekilde R_2 ile gösterilen normalleştirilmiş relaksiyon indeksi kullanılır. Eğer R_{2n} birden büyük ise bu spastik bir bacak olduğu anlamına gelir. Pendulum hareketinde ilk maksimumun açısal hızı doğrudan gerilme refleksine bağlıdır. Dolayısıyla ilk geri yönde osilasyonun maksimum hızı ve ilk ileri yönde osilasyonun maksimum hızı spastisite derecesini ölçümü için kullanılır. Böylelikle Pendulum hareketinin kinezyolojik parametrelerinden toplam 6 öznelik hesaplanmıştır.



Şekil 4.8. Kinezyolojik parametrelerin gösterimi

Spastisite var ise, Patella T-refleksinin tetiklenmesi sonucu oluşan Pendulum hareketindeki deformasyon belirgindir. Özellikle Ashworth 3 ve Ashworth 4 olgularında bu deformasyon çok net olarak gözlenmiştir. Şekil 4.9.'da Normal, Ashworth 1, Ashworth 2, Ashworth 3 ve Ashworth 4 olgularına ait Pendulum kayıtları görülmektedir.

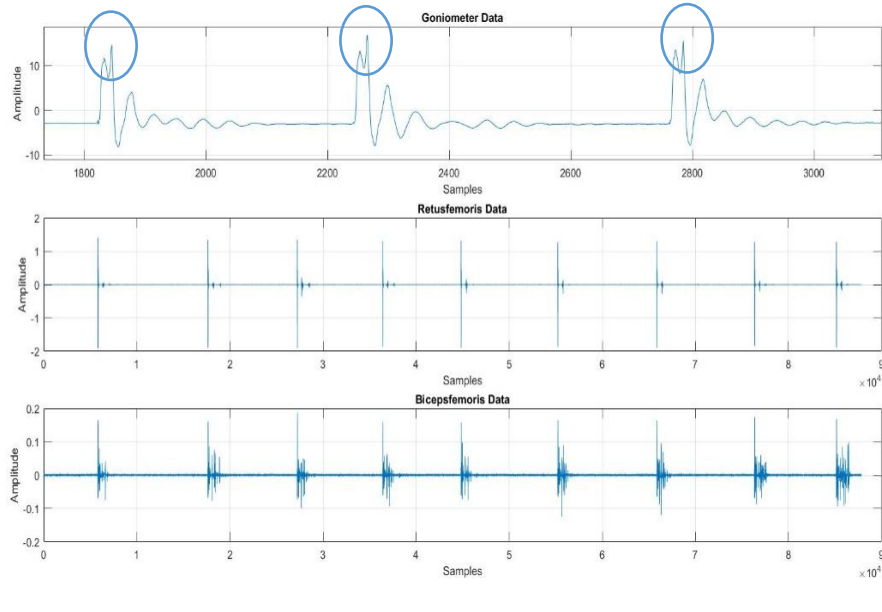


Şekil 4.9. a) Normal b) Ashworth 1 c) Ashworth 2 d) Ashworth 3 e) Ashworth 4 olgusuna ait Pendulum kayıtları

Şekilden de anlaşılacağı üzere Normal, Ashworth 1 ve Ashworth 2 olgularına ait Pendulum hareketlerinde çok belirgin bir deformasyon yoktur. Ashworth 3 olgusunda ise Pendulum deformasyonu net görülmekte olup, salınım sayısının iki ya da üçü geçmediği ve olguların Pendulum hareketi bittiğinde tekrar alt ekstremitelerini eski

konuma getiremedikleri görülmüştür. Yani orta şiddette klonus olduğu anlaşılmaktadır. Ashworth 3 ve Ashworth 4 olgularında Pendulumdaki yapısal bozukluk net olarak görülmektedir. Hatta ölçümler esnasında Ashworth 4 olguların reflekse cevap veremedikleri, çok şiddetli bir klonus hali olduğu görülmüştür. Zaten kayıt esnasında da koopere olamamışlardır. Bundan dolayı Normal, Ashworth 1 ve Ashworth 2 olgularının birbirinden ayırt edilmesi önem kazanmıştır.

Spastik olgularla normal olguların kayıtları karşılaştırıldığında, normal olgularda Patella T-refleksi ile tetiklenen Pendulumun tüm salınımları simetrik bir yapıya sahip iken, spastik olgularda dizin ilk ekstansiyonunda önemli bir yapısal değişiklik gözlenmiştir. Şekil 4.10.'da gösterilen çentiklenme (notching) değişimi oldukça dikkat çekicidir [13]. Bir olguda, Patella tetiklendiğinde çentiklenme ortaya çıkmışsa, bunun her 10 tetiklemede de ortaya çıktığı gözlenmiştir.




Şekil 4.10. Çentiklenme örneği

Spastiklerin % 15'inde ise Pendulumun ilk salınımlında belirginleşen, normallerde gözlemediğimiz deformasyon "plato" biçiminde mevcuttur. Ashworth 4 olguların tümünde pendullar deformasyon mevcut olduğundan çentiklenme gözlenmesi mümkün değildir. Çentiklenme ile ilgili olarak dikkat çeken bir özellik çentiklenmenin

BF kasında gözlenen geç yanıtlarla olan ilişkisidir. Biceps femoris kasında geç yanıt gözlenmediğinde deformasyon oluşmamaktadır. Bu deformasyonun nedeninin RF kasının antagonisti olan BF kasının gerilim refleksine bağlı olarak aktive oluşuyla bağlantılı olduğunu desteklemektedir.


4.3.2. Elektrofizyolojik özniteliklerin hesaplanması

Pendulum hareketinin kinezyolojik parametreleri hesaplandıktan sonra, Pendulum hareketine ait RF ve BF kas grubunun EMG verisinin öznitelikleri hesaplanmaktadır. Bu kas grubunun EMG özniteliklerini hesaplamada Şekil 4.11.'de görüldüğü üzere BF kasından alınan elektrotta harekete bağlı gürültü oluşmaktadır. Bundan dolayı öncelikle gürültünün giderilmesi için filtreleme işlemi uygulanmıştır. Gürültünün yoğun olduğu verilerde filtreleme işlemi verinin orjinal hali bozduğundan bu tür veriler çalışmaya dahil edilmemiştir.



Şekil 4.11. Ashworth 2 olgusuna ait kayıt

Analiz yapılacak Pendulum hareketi seçildiğinde ona bağlı olan RF ve BF EMG kayıtları Şekil 4.12.'de gösterilmiştir. Şekilden de anlaşıldığı gibi EMG kayıtları çok kısa bir aralıkta değişim gösterdiğinden EMG analizlerinde farklı dönüşüm yöntemleri kullanılamamıştır.



Şekil 4.12. EMG kayıt örneği

EMG sinyalleri için zaman, frekans ve zaman-frekans uzayında 37 farklı analiz yapmak mümkündür [53]. Ancak, EMG verilerimiz kısa süreli olduğundan dolayı tezde Tablo 4.3.'de verilen zaman ve frekans uzayı öznitelikleri hesaplanmıştır.

Tablo 4.3. Zaman - frekans öznitelikleri

Zaman Uzayı Analizleri			Frekans Uzayı Analizleri	
Tümleşik Değeri	EMG	$\sum_{i=1}^N x_i $	Ortalama Frekans	$\sum_{j=1}^M f_i P_i / \sum_{j=1}^M P_j$
Ortalama Değer	Mutlak	$\frac{1}{N} \sum_{i=1}^N x_i $	Ortanca Frekans	$\sum_{j=1}^{MDF} P_i = \sum_{j=MDF}^M P_j = \frac{1}{2} \sum_{j=1}^M P_j$
Karesel Toplam		$\sum_{i=1}^N x_i^2$	Tepe Frekans	$\max(P_j)$
Varyans		$\frac{1}{N-1} \sum_{i=1}^N x_i^2$	Ortalama Güç	$\sum_{j=1}^M P_j / M$
Ortalama Değeri	Karakök	$\sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2}$	Toplam Güç	$\sum_{j=1}^M P_j$

Tabloda x_i 'ler EMG örneklerinin genliklerini ve N , örneklenmiş EMG sinyalinin uzunluğunu göstermektedir. Tezde, EMG sinyalinin frekans uzayı özniteliklerinin hesaplanması için sinyale Ayrık Fourier Dönüşümü (DFT) uygulanmıştır. Tablo 4.3.'de verilen frekans uzayı formüllerinde f_i 'ler dönüştürülmüş sinyalin frekans değerlerini, P_j karşılık gelen değerlerin gücünü ve M DFT dizisinin uzunluğunu göstermektedir. Sonuç olarak, zaman uzayında 5 öznitelik ve frekans uzayında 5

öznitelik olmak üzere her iki kas grubu için toplamda 20 elektrofizyolojik öznitelik elde edilmiştir. Kinezyolojik özniteliklerle birlikte, öznitelik vektörünün eleman sayısı 26 olmuştur. Veri seti Normal, Ashworth 1, Ashworth 2 olgularından her birinden 30'ar veri seçilerek toplamda 26 öznitelik üzerinden 90x26 boyutlu bir matris formunda oluşturulmuştur.

4.4. Öznitelik Seçimi

Her bir işaretin öznitelikleri, o işareti karakterize eden, diğer işaretlerden ayırt edilmesini sağlayan parametrelerdir [54]. Doğru özniteliklerin belirlenmesi, sınıflandırma algoritmasının performansı açısından önemlidir. Öznitelik seçme algoritmaları literatüre bakıldığında sabit öznitelikler, kesintisiz öznitelikler ve yapısal öznitelikler için geliştirmek üzere üç grupta incelenmiştir [55]. Filtre modelleri sabit öznitelikler için geliştirilen öznitelik seçme yöntemleridir ve bu yöntemler özelliklerin birbirinden bağımsız olduğunu varsayar. Filtre modellerin en önemli özelliği, öznitelikleri herhangi bir sınıflandırma yöntemi olmaksızın değerlendirilmeleridir. Bu modeller, öznitelikleri özel bir kritere göre puan verir ve en düşük puanı alan öznitelikleri öznitelik vektöründen atarlar. Son yıllarda filtre modeline dayalı öznitelik seçme algoritmaları için çok sayıda kriter önerilmiştir. Tezde Fischer skoru öznitelik seçme işlemi için kullanılmıştır.

4.4.1. Fisher Skoru ile öznitelik seçimi

Fisher Skoru, en çok kullanılan öznitelik seçimi yöntemlerinden biridir [56]. Öznitelik seçim algoritmaları genellikle her bir özelliğe ikili ağırlık atanmasını amaçlar. Bu ağırlık bire eşitse, ilgili öznitelik seçilir. Aksi takdirde, bu öznitelik elimine edilir. Öznitelik seçme adımının, sınıflandırıcı performansını doğrudan etkilediği bilinmektedir. Dolayısıyla, ilgisiz öznitelik sayısını azaltmak, sınıflandırma verimliliğini artıran ve hesaplama süresini azaltan önemli bir unsur haline alır. İdeal olarak, öznitelik seçme yöntemleri, öznitelikleri alt kümelerine ayrıştırır ve aday alt kümeler arasından en iyisini bulmaya çalışır. Bu süreç özellikle yüksek hacimli öznitelik vektörleri için maliyetli ve pratik olarak imkansız bir hal alabilir. Bu nedenle,

performansı koruyarak hesaplama karmaşıklığını azaltmak için buluşsal ve rastgele arama yöntemleri önerilmektedir.

Fisher Skor kriteri, her bir örnek için belirleyici bir değer atamak amacıyla uygulanır. Bu değer, aynı sınıftaki örnekler için benzer, farklı sınıftaki örnekler için ayırt edici olmalıdır. Bu ifadeyi sağlayan Fisher Skoru denklemi aşağıda verilmiştir [57].

$$F(i) = \frac{(\bar{x}_i^{(+)} - \bar{x}_i)^2 + (\bar{x}_i^{(-)} - \bar{x}_i)^2}{\frac{1}{n_+ - 1} \sum_{k=1}^{n_+} (x_{k,i}^{(+)} - \bar{x}_i^{(+)})^2 + \frac{1}{n_- - 1} \sum_{k=1}^{n_-} (x_{k,i}^{(-)} - \bar{x}_i^{(-)})^2} \quad (4.1)$$

Denklem (4.1)'de, \bar{x}_i , $\bar{x}_i^{(+)}$, $\bar{x}_i^{(-)}$ sırasıyla tüm, pozitif ve negatif veri kümelerinin i 'inci özelliğinin ortalamasıdır. $x_{k,i}^{(+)}$, k 'inci pozitif örneğin i 'inci özelliğidir, n_+ ve n_- pozitif ve negatif sınıfların sayısıdır.

Yöntemimizin öznitelik seçimi aşamasında, katılımcılar normal ve spastisite olguları olmak üzere iki gruba ayrılmıştır. Daha sonra, Fisher Skoru uygulanarak normal olgular ile spastisite olgularını ayıran en etkin öznitelikler elde edilmiştir. Bu işlem öznitelik seçiminin ilk aşamasını oluşturmaktadır. İkinci aşamada, spastisite olguları Ashworth 1 ve Ashworth 2 düzeyleri olan olgular olmak üzere iki gruba ayrılmıştır. Bu grupları ayıran öznitelikleri belirlemek için Fisher Skoru tekrar kullanılmıştır. Son olarak, iki faz için hesaplanan sonuçlar değerlendirilerek öznitelik vektörü belirlenmiştir. Öznitelik seçimi sonunda 19 öznitelik elemeden geçmiş ve spastisite seviyesini belirleyen sınıflandırıcı algoritmasını uygulamak amacıyla kullanılmıştır. Sınıflandırıcılar bilindiği gibi birer makine öğrenme teknikleridir. Bu nedenle sonraki kısımda makine öğrenme algoritmalarından ve tezde kullanılacak sınıflandırıcıların genel çalışma prensiplerinden bahsedilmiştir.

4.5. Kullanılan Makine Öğrenme Algoritması

Bilgisayar teknolojisi geliştiğinden beri, çözümü zahmetli problemlerin yanı sıra günlük hayatımızdaki hesaplamalarımızı da bilgisayarlar yapmaktadır. Bu hesaplamalar için hazırlanan algoritmalar elde edildiğinde çok rahat bir şekilde çözüme ulaşmak mümkün hale gelir. Ancak günümüzde elektronik cihazların,

sensörlerin ya da sistemlerin hızlı gelişimi ve erişimlerinin kolay olması sebebi ile bir olay hakkında çok fazla örnek veri toplamak olanaklıdır. Bu tür verilerde en büyük sorun ise bir matematiksel formülün ya da algoritmanın olmamasından dolayı direk olarak programlayarak hesaplama imkanının olmasıdır. Bundan dolayı bilim insanları, var olan veri setinden bir problem için yeni bir veri seti geldiğinde önceki verilerden çıkarım yaparak öğrenme ile bir sonuca varabilirmiyiz sorusunu araştırmışlardır. Burada asıl yapılması hedeflenen şey insanın öğrenme sürecini modellemeye çalışmaktır. İnsan kendi öğrenme sürecinde örneklerle kendisini eğitir. Örnek olarak bir matematik konusu bir öğretmen tarafından anlatılır. Farklı sorular çözülerek o konu gelişir ve yeni sorular geldiğinde eski öğrenilenler ile ona çözüm aramaya çalışılır. Böylece her yeni problemde insan yeni bir şey öğrenmiş olur. İnsandaki bu kabiliyet aslında zeka olarak adlandırılır. Bu kavram bilgisayarda da oluşturabilir mi sorusu ile 1950'li yıllarda yapay zeka fikri ortaya atılmıştır [58]. Günümüze gelene kadar bir çok teori ortaya konulmuştur. Bunlar zeki sistemler, akıllı sistemler, uzman sistemler gibi farklı isimlerle adlandırılmıştır. 1990 yılından sonra bu teoriler ya da algoritmalar için makine öğrenmesi terimi kullanılmıştır. Simon bu alanda ilk tanımlamayı “zaman içinde yeni bilgilerin keşfedilmesi yoluyla davranışların iyileştirilmesi süreci” şeklinde yapmıştır [59,60]. Makine öğrenmesi sınıflandırma, kümeleme, regresyon, öznitelik seçimi ve ilişki belirleme alanlarında çözümler sunmaktadır [61]. Sınıflandırma, bir veri kümesindeki her bir veriyi etiketleyerek algoritmanın bu etiketlenmiş veri setinden bir ilişki ağını çıkarmasını sağlayan ve yeni gelen verinin hangi sınıfa dahil olduğunu bulmaya yarayan işlemdir. Kümeleme, veri setinde hiçbir etiketlenme yapılmadan, algoritmanın kaç kümeye ayrıştığını bulma işidir. Regresyon, geçmiş bilgilere karşılık gelen sınıflar yerine sürekli değerlerin yer aldığı problemdir [61]. Öznitelik seçimi, bir veri setine ait özniteliklerin sınıflandırması için en etkin olanların belirlenmesidir. İlişki belirleme, bulunan sınıf ya da küme arasındaki ilişkilerin çözümlenmesidir [62]. Görüldüğü üzere makine öğrenmesinde farklı problem alanlarına çözüm üretilmesi amaçlanmaktadır. Bunun için de matematik, olasılık ve istatistiksel yöntemlerin bir arada kullanıldığı çözüm yolları önerilmektedir. Bu çalışmadaki problem, bir sınıflandırma problemidir. Sınıflandırma metotlarında eğitim aşamasında girdilerimiz ile etiketlenmiş çıktılar arasında eşleme yapan modeli bulmak amaçlanmaktadır. Daha sonra bulunan bu modelin doğruluğu test verileri ile

ölçülür. Çoğunlukla istenen başarı oranı yakalanana kadar bir çok farklı sınıflandırma metotları denenerek en yüksek başarı oranı yakalanmaya çalışılır.

Tez çalışmamızda literatürde en çok kullanılan ve benzer problem için kabul edilebilir sonuçlar verdikleri bilinen YSA, k-EYK ve DVM yöntemleri tercih edilmiştir. Ayrıca 3 kat çarpaz doğrulama yaparak sınıflandırıcıların performansları yükseltilmiştir. İzleyen kısımlarda adı geçen yöntemler açıklanmıştır.

4.5.1. k-katlı çapraz doğrulama

Makine öğrenme algoritmalarında gözetimli öğrenme yapılıyorsa veri setinin bir kısmının eğitim ve diğer kısmının test verisi olarak ayrılması gerekir. Veri setinin eğitim ve test olarak ayrıştırılmasında kullanılan genel oran % 70 eğitim % 30 test şeklinde ifade edilmiştir. Ancak bu durumda veri setindeki verilerin çoğu eğitim için kullanılmamış olacaktır. Makine öğrenme algoritmasında aşırı öğrenme veya ezberleme gibi sorunlar ortaya çıkmaktadır. Bu sorunları aşmak için eğitim seti ve testin rastgele seçildiği Gross tarafından önerilen bir model mevcuttur [55, 58]. Bu modeled veri seti rastgele k gruba ayrılır. k değeri genelde 10, 5, 3 gibi değerler seçilmektedir. Veri setiniz büyük ise k'yı 10 olarak seçmek uygundur. Veri seti çok büyük değil ise daha küçük k değerleri seçilir. k-katlı çapraz doğrulama yöntemi olarak adlandırılan bu yöntemin küçük veri setleri için kullanışlı olduğu ve sınıflandırma performansını artırdığı bilinmektedir. k katlı çapraz doğrulama veri k adet eşit elemanlı kümeye bölünür. Bir küme doğrulama kümesi olarak kalan kümeler ise eğitim kümeleri olarak kullanılır. En iyi doğrulama istatistiğini sağlayan model final model olarak belirlenir. k değerine göre makine öğrenme algoritması k kadar işlem yapar ve Denklem (4.2)'ye göre makine öğrenme algoritmasının sınıflandırma başarı oranı hesaplanır.


$$SBO = \frac{\sum_{i=0}^k SF(t_i, VK - t_i)}{k} \quad (4.2)$$

Buradaki SF (test, eğitim) sınıflandırma fonksiyonu, VK veri kümesi, k kaç parça katlama kullanıldığı ve t_i ise veri kümesi üzerinden seçilen i.nci test kümesi olarak

verilmiştir. Yukarıda formülize edildiği üzere, sonuç bütün sınıflandırma fonksiyonlarının performanslarının toplamının, k sayısına bölünerek ortalamasının alınmasıdır. Çalışmada veri setimiz toplam 90 örnek içerdiğinden k değeri 3 olarak seçilmiştir.


4.5.2. Yapay sinir ağları

Yapay sinir ağları, insan beyninin yapısı ve fonksiyonlarının anlaşılması ile bu yapıyı taklit etmeye çalışan bir makine öğrenme algoritmasıdır. İnsan beyni, olaylar karşısında öğrenme, karar verme, tahmin etme gibi yeteneklere sahiptir. Bunu da nöron diye adlandırılan bir sinir hücresinin oluşturduğu karmaşık bir sinir ağı ile yönetilmektedir. Bilim insanları, bu yapıyı anlayarak makinelere var olan olguların ya da olayların veri setinden çıkarım yapan algoritmaları geliştirmeyi amaçlamışlardır. Yapay sinir ağları ilk olarak 1943 yılında yapay sinir hücrelerine dayalı hesaplama teorisinin ortaya atılması ile başlamıştır [58]. 1956 yıllarında ADALINE (Adaptive Linear Neuron) ve Widrow algoritmalarının geliştirilmesi sayesinde mühendislik alanında uygulanabilirliğin önü açılmıştır. Mühendislik alanındaki ilk sınıflandırma çalışması Standford Üniversitesinde 1960 yılında üç karakteri tanıma işlemi yapılarak gerçekleştirilmiştir [63]. 1970 yılında doğrusal olmayan bir probleme (XOR) çözüm geliştirmesi kırılma noktası olmuştur. Bu adımdan sonra çok katmanlı algılayıcılar gibi farklı çözüm önerileri sunulmuştur. Literatüre bakıldığında mühendisliğin dışında bir çok alanda da çalışmalara rastlanmaktadır. Google arama motorunun akademik yayınlar için geliştirdiği scholar arama motorunda yapay sinir ağları ingilizce anahtar kelimesi ile tarandığında yaklaşık 1.620.000 akademik içerik bulmaktadır [64]. Bu sayı günden güne artmaktadır. Sonuç bize yapay sinir ağlarının bir çok alandaki çözümler için araştırıldığını çok net olarak ortaya koymaktadır. Ayrıca yapay sinir ağları, sınıflandırma, örüntü tanıma, tahmin gibi popüler problemlerde eksik veya gürültülü veriler dahi olsa bir çıkarım yapabilmektedir. Şekil 4.13.'de görüldüğü üzere bir YSA'nın yapısında girdi katmanı, gizli katmanlar ve çıktı katmanı mevcuttur.



Şekil 4.13. Çok katmanlı yapay sinir ağ yapısı

Girdi katmanı, dış dünyadan bir probleme ait öznitelikleri alarak bir ağırlık katsayısını çarpıp gizli katmana iletir. Şekil 4.14.'de gösterilen ağırlık katsayıları ($w_1, w_2, w_3, \dots, w_n$), o özneliğin yapay sinir ağı modelindeki etkisini belirleyen katsayılardır.



Şekil 4.14. YSA genel yapısı


Gizli katman, girdi katmandan gelen veriyi işleyip bir toplama fonksiyonu ile o hücredeki net girdiyi çıktı katmanına iletir. Bir ağ yapısında birden fazla gizli katman da olabilir. YSA'nın genel yapısına ait matematiksel ifade Denklem (4.2)'de verilmiştir.

$$NET = \sum_{i=1}^n w_{ij}x_i + \theta_j \quad (4.2)$$

Çıktı katmanı ise, ara katmanlardan gelen veriyi bir aktivasyon fonksiyonundan geçirerek net çıktıyı üretirler. Burada aktivasyon fonksiyon kullanımı problem alanına göre değişmektedir. Belli başlı aktivasyon fonksiyonları Log-Sigmoid, Pureline, Sigmoid, Tan-Sigmoid, Radial Basis gibi sıralanabilir. YSA girdiler ile çıktılar arasındaki ilişkiyi en az hata oranı ile bulmaya çalışır. Bunun içinde sürekli geri beslemeli bir şekilde ağırlık katsayıları güncelleyerek en ideal YSA modelini oluşturmaya çalışır. Buradan da anlaşılacağı üzere YSA'daki veri setimizin etiketlenmesi gerekir. Bu veri setinin bir kısmı YSA ağının eğitilmesi için kullanılır. Kalan veri seti ise YSA modeli testi için kullanılır. Böylelikle hiç görülmeyen bir veri seti üzerindeki başarı oranı gözlemlenmiş olur.


4.5.3. Destek vektör makineleri

DVM , makine öğrenme algoritmaları içerisinde yüksek doğruluk vermesi, karmaşık problemleri çok kolay bir şekilde işleyebilmesinden dolayı yaygın olarak uygulanmaktadır [65]. DVM, sınıflandırma ve örüntü tanıma için danışmalı öğrenme metotudur. Bu metot 1995 yılında Vladimir Vapnik ve Corinna Cortes tarafından geliştirilmiştir [66]. Metot lineer ve lineer olmayan yaklaşımlar için çözüm önermektedir. Lineer sınıflandırma, iki sınıfa ait örneklerin birbirinden en geniş uzaklığa yerleşmesi sağlanır [67].



Şekil 4.15. İki sınıf arasındaki hiper düzlem [67]

Şekil 4.15.'de görüldüğü üzere iki sınıfı birbirinden ayıran bir çok farklı lineer sınırlar hesaplanabilir. Burada sınıflandırma hatasını en aza indirmek için iki sınıf arasındaki en geniş aralık bulunmaya çalışılır.



Şekil 4.16. Lineer sınıflandırma için hiperdüzlem belirleme [67]

DVM sınıflandırma veri seti $\{-1, +1\}$ olarak etiklendikten sonra, test verisi ile karar fonksiyonu bulunması için iki veri seti arasındaki iki sınır arası en uzak olacak şekilde destek vektörler hesaplanır. w hiper düzlemin normali, b eğilim değerini, x ise veri setine ait olan veri olarak gösterilmektedir.


$$wx_i + b \geq +1 \quad y = +1 \quad (4.3)$$

$$wx_i + b \leq -1 \quad y = -1 \quad (4.4)$$

Denklemler (4.3) ve (4.4) ile verilen DVM, eşitsizliğine göre en optimum uzaklığı verecek karar fonksiyonu hesaplanmalıdır. Bu bir optimizasyon problemi olarak düşünülebilir ve Lagrange denklemleri kullanılarak karar fonksiyonu oluşturulur. Bazı veri setlerinin doğrusal olarak ayrılması mümkün olmayabilir. Bu durumda ise karar sınırına yanlış düşen verilere bir ceza puanı uygulanır. Bu durumda iki veri seti arasında en geniş uzaklığa ve en az ceza puanına sahip bir sınır bulunur. Çekirdek fonksiyonu polinom, Radyal Tabanlı, Sigmoid olarak seçilebilir.

4.5.4. k-en yakın komşuluk

k-EYK, birçok sınıflandırma probleminde kabul edilir sonuçlar veren basit bir makine öğrenme algoritmasıdır. 1967 yılında T.M Cover ve P.E Hart tarafından önerilen, istatistikte kullanılan bir yöntemdir [68]. k-EYK algoritmasında eğitiminin olmaması, algoritmanın gerçekleştirilmesinin kolay olması ve gürültülü verilere karşı dirençli olması gibi avantajları vardır [69]. k-EYK algoritması bir öznitelik uzayında birbirine yakın noktaların benzer karakteristiklere sahip olacağı fikrine dayalı olarak çalışır. k-EYK'ya göre, sınıfı belirlenmek istenen yeni bir öznitelik k en yakın komşuları arasında en çok oyu alan sınıfa atanır. Burada k pozitif bir tamsayıdır. k değeri tek bir sayı seçilir ki, karar aşamasında bir üstünlüğe göre karar verilebilsin. k değeri çok büyük seçilirse farklı sınıflara ait örnekler aynı sınıfa dahil edilebilir, tersine k değeri küçük seçilirse aynı sınıfta olması gereken örnekler farklı sınıfa atanabilir. k-EYK algoritması beş adımdan oluşmaktadır. Öncelikle k değeri belirlenir. Şekil 4.16.'daki gibi sınıflar arasındaki uzaklık hesaplanır. Uzaklıklar sıralanır ve yakın komşular bulunur.



Şekil 4.17. En yakın sınıf seçimi

En yakın komşu kategoriler toplanarak en uygun sınıf seçimi gerçekleştirilir. Uzaklık ölçütlerinde ise Öklid, Manhattan, Minkowski, Chebyshev ve Dilca uzaklıkları kullanılabilir.

4.6. Adaptif Artırma Algoritması (ADABOOST)

Artırma (Boosting), iki-sınıf sınıflandırma problemlerini çözmek için kullanılan başarılı bir tekniktir. Bu teknik ilk olarak AdaBoost algoritması adı altında Freund ve Schapire tarafından tanıtılmıştır. İki-sınıftan çok-sınıf sınıflandırma problemine geçişte, verilen çalışmalarda yapıldığı gibi, yöntemlerin çoğu çok-sınıf sınıflandırma problemini iki-sınıf probleme indirgemek üzerine sınırlandırılmıştır [70-75].

Bu tezde, spastisitenin sınıflandırılmasında verilen sınıflandırıcı tekniklere ek olarak, Zhu ve arkadaşları tarafından önerilen AdaBoost algoritmasında yapıldığı, çoklu iki-sınıf probleme indirgmeden çok-sınıf probleme doğrudan uygulanan bir algoritma kullanılmıştır [76]. İki-sınıf durumdaki AdaBoost algoritmasına benzer olarak, bu yeni algoritma zayıf sınıflandırıcıları birleştirir ve sadece her bir zayıf sınıflandırıcının performansının rastgele tahminden daha iyi olmasını gerektirir ($1/2$ 'den oldukça az). Kullanılan algoritma kolay gerçekleştirilebilir. Tahmin hızının yüksek olması, düşük hafıza kullanması ve en yaygın olarak kullanılan mevcut çok-sınıf sınıflandırma yöntemleri ile oldukça uyumlu olması en önemli avantajlarıdır [72]. Bu bölümde öncelikle iki-sınıf AdaBoost yöntemi açıklanmıştır. Daha sonra, Ashworth 1, Ashworth 2 ve normal bireyleri ayırt etmek için uygulanacak çok-sınıf AdaBoost yöntemi tartışılmıştır.

4.6.1. AdaBoost Algoritması

Çok-sınıf artırma (Multi-class AdaBoost) algoritmasının detayına inmeden, çok-sınıf sınıflandırma problemi ve AdaBoost algoritması kısaca açıklanmıştır.

$(\mathbf{x}_1, c_1), \dots, (\mathbf{x}_n, c_n)$ şeklinde bir eğitim setimiz olsun. Burada $\mathbf{x}_i \in \mathbb{R}^p$ giriş (kestirici değişkeni) ve c_i çıkış (cevap değişkenleri) niteldir ve K sınıf sayısı olmak üzere değerlerini $\{1, 2, \dots, K\}$ şeklinde sonlu bir kümeden alır. Amaç, eğitim verisinden $C(\mathbf{x})$ şeklinde bir sınıflandırma kuralı elde etmektir. Öyle ki, yeni bir \mathbf{x} girişi verildiğinde bu girişe $\{1, 2, \dots, K\}$ kümesinden c adında bir etiket atanabilmelidir.

Şimdi soru, mümkün olan en iyi sınıflandırma kuralının ne olduğudur. Bu soruya cevap verebilmek için önce en iyi kavramının ne olduğu tanımlanmalıdır. En iyi için en yaygın tanım, en düşük yanlış sınıflandırma hata oranını sağlamak tanımıdır. Genellikle, eğitim verisinin $\Pr(X, C)$ ile gösterilen bilinmeyen bir olasılık dağılımından gelen bağımsız ve özdeş dağılımlı örnekler olduğu varsayılır. O halde, yanlış sınıflandırma hata oranı $C(\mathbf{x})$, şu şekilde hesaplanabilir:

$$\begin{aligned} E_{X,C} \Pi_{C(X) \neq C} &= E_X \Pr(C(X) \neq C \mid X) = 1 - E_X \Pr(C(X) = C \mid X) \\ &= 1 - \sum_{k=1}^K E_X [\Pi_{C(X)=k} \Pr(C = k \mid X)] \end{aligned} \quad (4.5)$$

$$C^*(\mathbf{x}) = \arg \max_k \Pr(C = k \mid X = \mathbf{x}) \quad (4.6)$$

Denklem (4.6)'nin bu niceliği $1 - E_X \max_k \Pr(C = k \mid X)$ 'e eşit yanlış sınıflandırma hata oranı ile minimum yapacağı açıkça görülmektedir. Bu sınıflandırıcı Bayes sınıflandırıcı olarak bilinir. Bayes sınıflandırıcının ulaşabildiği hata oranı ise Bayes hata oranıdır.

AdaBoost algoritması birçok zayıf sınıflandırıcıyı yaklaşık bir Bayes sınıflandırıcı $C^*(\mathbf{x})$ 'e kombine eden yinelemeli bir yöntemdir. AdaBoost yöntemi ağırlıklandırılmamış eğitim örneğinden başlayarak, sınıf etiketleri üreten bir sınıflandırıcı ağacı gibi sınıflandırıcı inşa eder. Eğer eğitim verisi yanlış

sınıflandırılmış ise, bu eğitim verisinin ağırlığı artırılır. Yeni ağırlıkları kullanan ikinci bir sınıflandırıcı inşa edilir. Tekrar, yanlış sınıflandırılmış eğitim verisi yeni ağırlıklarına artırılır ve prosedür devam ettirilir. Her bir sınıfa bir skor atanır ve final sınıflandırıcı her bir adımdan gelen sınıflandırıcıların doğrusal bir kombinasyonu olarak tanımlanır. Özel olarak, $T(\mathbf{x})$, \mathbf{x} 'e sınıf atayan çok-sınıf zayıf sınıflandırıcıyı gösterebilir. Bu durumda, AdaBoost algoritmasının adımları şu şekilde verilebilir:

a. Gözlem ağırlıkları ile başla.

$$w_i = \frac{1}{n}, i = 1, 2, \dots, n.$$

b. $m=1, \dots, M$ 'e kadar aşağıdaki adımları uygula.

- w_i ağırlıklarını kullanarak, eğitim verisine $T^{(m)}(\mathbf{x})$ şeklinde bir sınıflandırıcı uydur.

$$- \text{hata}^m = \sum_{i=1}^n w_i \Pi(c_i \neq T^{(m)}(\mathbf{x}_i)) / \sum_{i=1}^n w_i \quad (4.7)$$

şeklinde verilen hata değerini hesapla.

$$- \alpha^m = \log \frac{1 - \text{hata}^m}{\text{hata}^m} \quad (4.8)$$

değerlerini hesapla.

$$- w_i \leftarrow w_i \cdot \exp\left(\alpha^m \cdot \Pi\left(c_i \neq T^{(m)}(\mathbf{x}_i)\right)\right), i = 1, 2, \dots, n. \quad (4.9)$$

Denklem (4.9) ile verilen ağırlık güncelleme işlemini gerçekleştir.

- w_i ağırlıklarını normalize et.

c. Aşağıda verilen eşitliği kullanarak çıkışı hesapla.

$$C(\mathbf{x}) = \arg \max_k \sum_{m=1}^M \alpha^{(m)} \cdot \Pi(T^{(m)}(\mathbf{x}) = k) \quad (4.10)$$

İki-sınıf sınıflandırma problemlerine uygulandığında, AdaBoost'un doğru sınıflandırıcılar bulmada oldukça başarılı olduğu ispatlanmıştır. Ancak, çok-sınıf problemler için böyle değildir. Buna rağmen Freund ve Schapire tarafından AdaBoost'un çok-sınıf probleminde de uygulanması önerilmiştir. Şu hususa dikkat edilmelidir; yanlış sınıflandırılmış eğitim verisini artırmak için, her bir zayıf

sınıflandırıcının hata değerinin $\frac{1}{2}$ 'den küçük olması gerekmektedir. Aksi durumda, $\alpha^{(m)}$ negatif olur ve eğitim örneklerinin ağırlıkları yanlış doğrultuda güncellenir. İki-sınıf sınıflandırma problemleri için bu gereksinim rastgele tahmin gereksinimi ile aynıdır. Ancak, $K > 2$ olduğunda $\frac{1}{2}$ doğruluğa ulaşılması $1/K$ doğruluk oranı tahmininden daha zordur. Bu nedenle, eğer zayıf sınıflandırıcı $T(\mathbf{x})$ doğru seçilmezse AdaBoost yöntemi kötü sonuçlar verebilir.

4.6.2. Çok-sınıf AdaBoost algoritması

Teknik detaylara girmeden önce, önerilen çok-sınıf artırma algoritması AdaBoost ile karşılaştırmalı olarak açıklanmıştır. Burada çok-sınıf üstel kayıp fonksiyonu kullanılmaktadır. Algoritmanın adımları şu şekilde açıklanabilir:

a. Gözlem ağırlıkları ile başla.

$$w_i = \frac{1}{n}, i = 1, 2, \dots, n.$$

b. $m = 1, 2, \dots, M$ için:

- w_i ağırlıklarını kullanarak, eğitim verisine $T^{(m)}(\mathbf{x})$ şeklinde bir sınıflandırıcı uydur.

$$- \text{hata}^m = \sum_{i=1}^n w_i \Pi(c_i \neq T^{(m)}(\mathbf{x}_i)) / \sum_{i=1}^n w_i \quad (4.11)$$

şeklinde verilen hata değerini hesapla.

$$- \alpha^m = \log \frac{1 - \text{hata}^m}{\text{hata}^m} + \log(K - 1) \quad (4.12)$$

değerlerini hesapla.

$$- w_i \leftarrow w_i \cdot \exp\left(\alpha^m \cdot \Pi\left(c_i \neq T^{(m)}(\mathbf{x}_i)\right)\right), i = 1, 2, \dots, n. \quad (4.13)$$

Denklem (4.13) ile verilen ağırlık güncelleme işlemini gerçekleştir.

- w_i ağırlıklarını normalize et.

$$c. C(\mathbf{x}) = \arg \max_k \sum_{m=1}^M \alpha^{(m)} \cdot \Pi(T^{(m)}(\mathbf{x}) = k) \quad (4.14)$$

Denklem (4.14) ile çıkışı hesapla.

Yukarıda verilen çok-sınıf algoritmanın Denklem (4.12)'deki önemli farklılık dışında AdaBoost ile hemen hemen aynı olduğuna dikkat ediniz. Bu durumda α^m 'in pozitif olması için, tek ihtiyacımız olan şey $(1 - \text{hata}^m) > 1/K$ olması ya da her bir zayıf sınıflandırıcının doğruluğunun $1/2$ yerine rastgele tahmin değerinden daha iyi olmasıdır. Sonuç olarak, çok-sınıf algoritma yanlış sınıflandırılmış veri noktalarına AdaBoost'tan daha fazla ağırlık vermektedir ve bu algoritma zayıf sınıflandırıcıları AdaBoost'a göre biraz daha farklı bir şekilde birleştirmektedir ($\log(K-1) \sum_{m=1}^M \Pi(T^{(m)}(\mathbf{x}) = k)$). $K=2$ durumunda yukarıda verilen algoritma AdaBoost ile aynıdır. Fazladan eklenen $\log(K-1)$ terimi hatalı değildir aksine bu terim çok-sınıf için verilen algoritmayı çok-sınıf üstel kayıp fonksiyonu kullanan modele uyumlu hale getirmektedir [77].

Sunulan tezde, spastisitinin değerlendirilmesinde kullanılan sınıflandırıcıların performanslarını yükseltmek amacı ile AdaBoost tekniği de kullanılmıştır. AdaBoost, öğrenme algoritmalarının performansını yükseltmek için, seçilen algoritma ile birlikte kullanılır. Algoritma, öznitelik vektöründeki her bir öznitelik için zayıf bir sınıflandırıcı oluşturarak bu zayıf sınıflandırıcılardan oluşan yüksek performans sağlayan bir topluluk belirler. Bu topluluk güçlü sınıflandırıcı olarak adlandırılır. Güçlü sınıflandırıcıda yer alamayan zayıf sınıflandırıcıya karşılık gelen öznitelik atıldığından AdaBoost algoritması hem öznitelik seçme hem de sınıflandırma işlemini birlikte gerçekleştirmiş olur. AdaBoost tekniğinin k-EYK sınıflandırıcı performansını artırdığı gösterilmiştir [78]. Bu çalışmada, özellik seçme işlemi uygulanmadan iki sınıf (normal ve spastisiteli) ve üç sınıf (normal, Ashworth 1, Ashworth 2) için elde edilen sonuçlar yayınlanmıştır. Bu çalışmada görüldüğü gibi iki sınıf için k-EYK sınıflandırıcı ile elde edilen doğruluk oranı % 79.3, üç sınıf için elde edilen doğruluk oranı ise % 67.74 olarak elde edilmiştir. k-EYK ve AdaBoost teknikleri birlikte kullanıldığında elde edilen sonuçlar ise iki sınıf ve üç sınıf için sırasıyla % 89.6 ve % 87.09 olarak hesaplanmıştır. Sonuçlardan da görüldüğü gibi AdaBoost algoritması zayıf sınıflandırıcıları tespit edip sınıflandırıcılar arasından en doğru kombinasyonu belirleyerek performansı oldukça yükseltmektedir.

4.7. Makine Öğrenme Algoritmaları ile Spastisitenin Sınıflandırılması

Bu bölüm, akış şemasında belirtilen çalışmanın son aşamasıdır. Amacımız, olguların spastisite seviyesini minimum hata oranı ile belirleyen en iyi sınıflandırma sonuçlarına ulaşmaktır. Hata oranı doğruluğun tam tersi olarak ifade edilebilir. Doğruluk, sınıflandırıcının çıktısındaki gerçek kararların yüzdesidir. Sınıflandırıcının çıkışındaki kararın doğru olup olmadığı, nöroloji uzmanının kararına göre belirlenmiştir. Tezde, önceden belirtildiği üzere Ashworth 3 ve Ashworth 4 spastisitesi olan olgular dikkate alınmamıştır. Çünkü bu seviyeler herhangi bir nörolog tarafından çaba sarf edilmeksizin kolaylıkla ayırt edilebilmektedir. Öznitelik vektörü, hesaplanmış elektrofizyolojik ve kinezyolojik parametrelere dayanarak ve Fisher Skoru ile öznitelik seçme adımı uygulanarak oluşturulmuştur. Bu noktada spastisite seviyesini belirlemek için öznitelik vektörüne YSA, k-EYK ve DVM yöntemleri uygulanmıştır.

Sınıflandırma işlemini yerine getirmeden önce, sınıflandırma performansını yükseltmek amacı ile k-katlı çapraz doğrulama işlemi uygulanmıştır. k-katlı çapraz doğrulama yönteminin küçük veri setleri için kullanışlı olduğu ve sınıflandırıcının performansını arttırdığı bilinmektedir. k-katlı çapraz doğrulamada, veriler eşit elemandan oluşan k sayıda gruba bölünür. Geri kalan gruplar eğitim setleri olarak kullanılırken bir grup doğrulama kümesi olarak adlandırılır. k modelleri uygun olduğunda k doğrulama istatistikleri elde edilir. En iyi doğrulama istatistiğini sağlayan model nihai model olarak seçilmiştir. Çalışmamızda Normal, Ashworth 1 ve Ashworth 2 olguları için 90 adet örnek bulunmaktadır. Veri kümesi, eşit sayıda örnek içermektedir (yani 30 Normal, 30 Ashworth 1 ve 30 Ashworth 2 örnek). Her katmanda, 60 vaka arasında eşit olarak dağıtılmış bir doğrulama seti oluşturulur. Geriye kalan 30 vaka eğitim için kullanılır. Daha önce de belirtildiği gibi, sınıflandırma sonuçlarını geliştirmek için bu işlem üç kez tekrarlanır. Nihayetinde, olguların spastisite sınıflarını belirlemek için k-EYK, YSA ve DVM sınıflandırma teknikleri kullanılmaktadır.

k-EYK, verilerin dağılımı hakkında herhangi bir varsayım yapmayan, basit ve yaygın olarak kullanılan bir öğrenme algoritmasıdır. Bu teknik tüm eğitim verilerini tutar ve bunları test aşamasında kullanır. k-EYK sınıflandırma sürecinin iki aşaması vardır;

birinci aşama en yakın komşuları belirlemek ve ikincisi bu komşuları kullanarak bir sınıf atamak için uygulanır. Böylece, yeni bir veri noktası alındığında, yeni veri noktası ile diğer noktalar arasındaki mesafe hesaplanmış olur. Ardından uzaklık metriğine göre k komşuları seçilir. Son olarak, bu yeni veri noktasının sınıfı, en yakın k komşular arasındaki çoğunluk sınıfına göre atanır. Literatürde k -EYK, iyi sınıflandırma sonuçları veren yavaş bir öğrenme yaklaşımı olarak düşünülmektedir. Yapay sinir ağları da çok geniş bir şekilde kullanılmıştır ve bu yöntemle biyolojik bilgi işlemin matematiksel yorumları bulunmaya çalışılmaktadır. Sinir ağlarında doğrusal olmayan girdilerin kombinasyonları olan farklı doğrusal olmayan temel fonksiyonlar mevcuttur. Girdi değişkenlerinin kombinasyonundaki katsayılar adaptif olarak değişir. Girdi değişkenlerinin doğrusal kombinasyonlarını oluşturmak için aktivasyonlar olarak adlandırılan miktarlar tanımlanır. Daha sonra her aktivasyon, birkaç hesaplamadan sonra ağ çıktılarını elde etmek için doğrusal olmayan bir aktivasyon fonksiyonu uygulanarak dönüştürülür. Aktivasyon fonksiyonunun seçimi, veri setine göre belirlenir. Problemimizde, sigmoid aktivasyon fonksiyonlu ileri beslemeli sinir ağları kullanılmıştır. Ayrıca DVM, sınıflandırma, regresyon ve yenilik algılama problemlerini çözmek için popüler bir tekniktir. DVM, dışbükey bir optimizasyon problemine karşılık gelen model parametrelerini belirlemeye yarayan bir karar verme aracıdır. Böylece, DVM ile elde edilen herhangi bir çözüm, aynı zamanda sorunun global bir çözümüdür. DVM tekniğinin amacı, karar sınırı ile örneklerin herhangi biri arasındaki en küçük mesafeyi belirlemektir. DVM temelde iki-sınıf bir sınıflandırıcıdır, ancak çalışmamızda ikiden fazla sınıf bulunmaktadır. Bu nedenle, bu çalışmada sınıflandırma görevini gerçekleştirmek için çok sınıflı DVM'ye ihtiyaç duyulmuştur. Çok sınıflı DVM, diğerlerine karşı tek yaklaşım kullanarak çok sayıda iki-sınıflı DVM'ler birleştirilerek elde edilmiştir [79].

Gerçekleştirilen sınıflandırıcılar hakkında kısa bir bilgi aktardıktan sonra, artık performans sonuçlarını sunabiliriz. İlk deneyde, olgular "normal" ve "spastisite bulunan" olarak ayrılmıştır. Öznitelik çıkarım adımının çıktısında, öznitelik vektörünün boyutu 26 olarak belirlenmiştir. Normal ve spastisite sınıfları için öznitelik seçim adımında Fisher Skoru uygulandığında, öznitelik vektörünün boyutu 20'ye

düşmektedir. Tablo 4.4. (a) ve (b)'de, 3 kez doğrulama için sırasıyla öznitelik seçim adımı olan ve olmayan sınıflandırıcıların doğruluk değerleri gösterilmiştir.

Tablo 4.4 Sınıflandırıcıların "normal" ve "spastisiteli" sınıfları için performansı (a) Öznitelik seçimi ile (b) Öznitelik seçimi olmadan

(a)

Sınıflandırıcı	Doğruluk oranı (%)			
	Eğitim-1	Eğitim-2	Eğitim-3	Ortalama
k-EYK	75	82	97	84.66
YSA	64	82	79	75.33
DVM	82	85	100	89

(b)

Sınıflandırıcı	Doğruluk oranı (%)			
	Eğitim-1	Eğitim-2	Eğitim-3	Ortalama
k-EYK	70	72	93	78.33
YSA	61	72	79	70.66
DVM	70	82	87	79.66

Burada, veri kümesi ikinci deney için "Ashworth 1" ve "Ashworth 2" olarak iki gruba ayrılmıştır. Bu deneyde, normal olgular bir süre ihmal edilmiş. Fisher Skoru ile öznitelik seçiminin iki basamaklı olarak yapıldığını ve ikinci adımın "Ashworth 1" ve "Ashworth 2" sınıfları için uygulandığı belirtilmiştir. Bu nedenle, Tablo 4.5.'de sınıflandırıcının performans sonuçları bu iki sınıf için verilmiştir.

Tablo 4.5. Öznitelik seçimi ile "Ashworth 1" ve "Ashworth 2" sınıfları için sınıflandırıcıların performansı.

Sınıflandırıcı	Doğruluk oranı (%)			
	Eğitim-1	Eğitim-2	Eğitim-3	Ortalama
k-EYK	66	67	95	76
YSA	77	63	62	67.33
DVM	82	78	87	82.33

Son olarak da Normal, Ashworth 1 ve Ashworth 2 olgularının ayırt edilmesi için veriler 3 gruba ayrılmıştır. Sonuçların spastisitenin derecesini değerlendirmek için nörologlara destekleyici bir bilgi sağlaması beklenmektedir. Bu amaçla, yukarıda belirtilen üç sınıf için elde edilen simülasyon sonuçları Tablo 4.6.'da gösterilmektedir.

Tablo 4.6. Sınıflandırıcıların üç sınıf için performansı (a) Öznitelik seçimi ile (b) Öznitelik seçimi olmadan


(a)

Sınıflandırıcı	Doğruluk oranı (%)			
	Eğitim-1	Eğitim-2	Eğitim-3	Ortalama
k-EYK	69	83	89	80.33
YSA	64	63	92	72.33
DVM	75	87	98	86.66


(b)

Sınıflandırıcı	Doğruluk oranı (%)			
	Eğitim-1	Eğitim-2	Eğitim-3	Ortalama
k-EYK	75	67	75	72.33
YSA	60	58	85	67.66
DVM	71	74	93	79.33

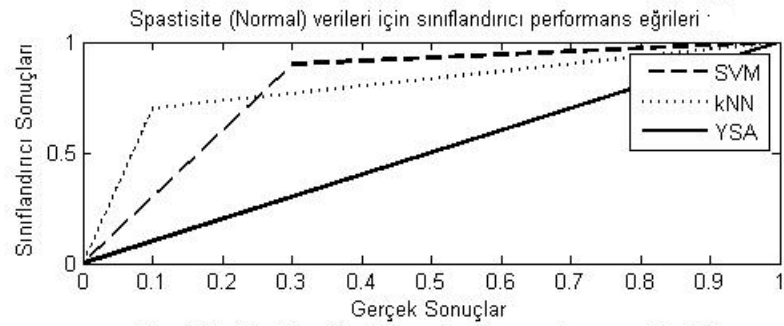
Sınıflandırıcıların üç farklı deneyde performansları doğruluk değerlerine göre verilmiştir. Bunun dışında sınıflandırıcıların başarımlarını incelemek amacıyla sınıflandırıcı performans eğrileri de tezde hazırlanmıştır. Her üç sınıflandırıcı için gerçek veri setinin etiketleri ile sınıflandırıcının verdiği sonuçlar kullanılarak performans değerlendirilmesi, Alıcı İşletim Karakteristik (Receiver Operator Characteristics, ROC) eğrileri oluşturularak incelenmiştir. Şekil 4.18. (a,b,c)'de normal ve spastisitelerin olguların sınıflandırma performans eğrileri üç eğitim kümesi için sırasıyla gösterilmiştir.



a




b




c

Şekil 4.18. Normal ve spastisiteli olguları ayırt etmede üç eğitim seti için sınıflandırma performans eğrileri


Benzer şekilde, Şekil 4.19. (a,b,c)'de Ashworth 1 ve Ashworth 2 sınıfları için her üç sınıflandırıcıya ait performans eğrileri verilmiştir. Eğrilerden görüldüğü gibi DVM en iyi performansı sağlayan sınıflandırıcı olmuştur.



a



b



c

Şekil 4.19. Normal ve spastisiteli olguları ayırt etmede üç eğitim seti için sınıflandırma performans eğrileri

BÖLÜM 5. TARTIŞMA VE SONUÇLAR

Bu çalışmada, sinyal işleme ve makine öğrenme tekniklerini birleştirerek etkili ve güvenilir bir spastisite klinik değerlendirme sistemi oluşturmak amaçlanmıştır. Bu amaçla, Patella T-refleksi tetiklendiğinde, 65 katılımcının RF ve BF kaslarından EMG sinyalleri elde etmek için bir ölçüm sistemi hazırlanmıştır. Bilindiği gibi, bu çalışmada kullanılan Pendulum testi, kontrollü vuruşlar sonucunda kasların ortak hareketine ait birçok parametrenin ölçülmesini mümkün kılmaktadır. Bununla birlikte, bu test kas aktivitesi hakkında yetersiz bilgi vermektedir. Bu dezavantajın üstesinden gelmek için, EMG sinyallerinin elektrofizyolojik özniteliklerini ve Pendulum hareketinin kinezyolojik özniteliklerini hesaba katan etkili bir öznitelik çıkarım adımı kullanılmıştır. Öznitelik çıkarımı yapıldıktan sonra, tüm sistemin performansını artırmak için öznitelik seçimi aşaması uygulanmıştır. Önceki bölümde verilen simülasyon sonuçları, öznitelik seçimi aşamasının olumlu etkisini doğrulamaktadır. Son olarak, bir olgunun spastisite düzeyinin belirlenmesi, veritabanına göre seçilen ve yaygın olarak kullanılan sınıflandırma teknikleri aracılığıyla yapılmıştır.

İlk deneyde hedefimiz, katılımcıları normal ve spastisitesi bulunanlar olarak ikiye ayırmaktır. Normal katılımcılar Tablo 2.1.'e göre "0" olarak etiketlenirken, spastisiteye sahip olguların spastisite düzeyini belirlemek için daha fazla değerlendirmeye tabi tutulmuştur. Sınıflandırıcı performans tabloları dört sütundan oluşmaktadır. İlk üç sütun, sonuçların sırasıyla 3 kez çapraz doğrulama sonuçlarını yani üç farklı eğitim ile elde edilen sonuçları yansıtmaktadır. Son sütun ise, ilgili sınıflandırıcının ortalama doğruluğunu göstermektedir. Tablo 4.4. (a) ve (b)'de görülebileceği gibi, öznitelik seçimi olan ve olmayan DVM tekniği en yüksek doğruluk değerini vermektedir. Ayrıca k-EYK ve YSA yöntemleri de kabul edilebilir sonuçlar vermiştir. Böylece, önerilen yöntem otomatik olarak katılımcıları normal veya spastisiteye sahip olarak ayırt etmek için kullanılabilir.

Bundan sonra, spastisiteli olguları Ashworth 1 ve Ashworth 2 olarak iki gruba ayırmaya çalışıyoruz. Tüm veri tabanında Ashworth 1 ve Ashworth 2 olguların Pendulum hareketi araştırıldığında, Ashworth 1 ve Ashworth 2'yi birbiriyle karıştırma ihtimalinin göreceli olarak yüksek olduğu söylenebilir. Dolayısıyla, bu deney için Tablo 4.5.'de gösterilen doğruluk yüzdeleri, Tablo 4.6. (a)'da verilen yüzdelerden daha düşük bulunmuştur. Yine, öznelik seçimli DVM yöntemi nörologlara iyi doğruluk değerleri ile destek olabilecek bilgiler sağlamaktadır denilebilir.

Son olarak, üçüncü deneyde Normal, Ashworth 1 ve Ashworth 2 olmak üzere üç sınıf mevcuttur. Ashworth 3 ve Ashworth 4 olgularının EMG kayıtları alınmasına rağmen, daha önce tartışılan nedenle bu olgular deneye dahil edilmemiştir. Bu deney, ilk iki deneyin sonuçlarını birleştirmek amacıyla yapılmıştır. Fisher Skoru olan ve olmayan üçüncü deneyin sonuçları sırasıyla Tablo 4.6. (a) ve (b) 'de verilmiştir. Tabloya göre, Şekil 4.1.'de özetlenen önerilen yöntemin spastisiteyi derecelendirmek için değerli bilgiler elde ettiği söylenebilir. Özellikle, Fisher Skoru, 3-katlı çapraz doğrulama ve DVM teknikleri birlikte uygulanarak spastisite derecelendirmesi için ortalama % 86.66 doğruluk oranı elde edilmiştir. Tabloya göre, k-EYK, YSA ve DVM sınıflandırıcıları için en iyi doğruluk değerleri sırasıyla % 89, % 92 ve % 98 olarak bulunmuştur. Bu sonuçlar, spastisiteyi belirleme ve nicelme çalışmaları için çok umut vericidir.

Bildiğimiz kadarıyla, spastisiteyi değerlendiren ve spastisitenin derecesini doğrudan belirleyen herhangi bir çalışma mevcut değildir. Ancak literatürde bulunan güncel ve en yakın çalışmalar ile bu çalışmaların sunulan tez çalışması ile yakınlığı şu şekilde özetlenebilir: Lueken ve arkadaşları tarafından 2015 yılında yapılan çalışmada spastisiteye bağlı EMG sinyallerinin sınıflandırılması amaçlanmış, hemiplejik hastanın EMG verileri, etkilenen kas aktivitesinin karakteristik özelliklerini türetmek ve bunları bir öznelik vektöründe birleştirmek için analiz edilmiştir [80]. Bu çalışmanın sınıflandırma evresinde DVM tekniği kullanılmıştır. DVM sonuçları yazarların önceki çalışmasında elde edilen sonuçlarla karşılaştırılmıştır [81]. DVM'nin tanı başarısı, spastisiteden etkilenen hastalar için robot destekli rehabilitasyon tedavisi için kullanılan Medit Aachen Vücut Sensör Ağı ile Entegre Duruş ve Aktivite Ağı

(Integrated Posture and Activity Network by MedIT Aachen, IPNEMA) için üretilen yeni bir EMG sensörü tarafından doğrulanmıştır. Bu makale hemipleji hastalarının kas aktiviteleri açısından aktif olmayan, sağlıklı aktiviteye sahip ve patolojik aktivite düzeyi olarak sınıflandırılmasını sağlamaktadır. Yazarların bildirdiğine göre, sunulan yaklaşım sadece elde edilen verilere ve örnek deneylerinden elde edilen verilere uygulanmıştır. Bu yüzden sonuçlar spastisitenin tüm bireysel hastalık modellerini temsil etmemektedir, yalnızca belirli bir vakada iyi sonuçlar vermiştir. Sonuç olarak [80, 81] ile elde edilen sonuçları doğrudan spastisite derecesini belirleyen tez çalışmamızın sonuçları ile karşılaştırmak uygun değildir. [82] ile verilen Yeh ve ekibinin 2016 yılında yaptığı bir başka çalışmada, spastik ve spastik olmayan ekstremiteyi faz genlik birleştirme (Phase Amplitude Coupling, PAC) analizine dayanan yeni bir indeksle ayırmayı hedeflemişlerdir. 22 hemiplejik inme hastada yöntemin ayırdedici performansını değerlendirmek için beş indeks kullanılmıştır. Çalışmanın sonuçlarına göre, kuadriseps ve hamstring kaslarının salınım açısı ve yüzey EMG (Surface Electromyography, SEMG) genliği arasındaki PAC endeksinin kullanılması, inme sonrası hastalarda spastik ve spastik olmayan ekstremiteyi ayırmak için mevcut goniometre parametrelerinden ve sadece SEMG'den daha yüksek performans sağlamaktadır. Katılımcılara bir spastisite düzeyi atamak bu çalışmanın kapsamı dışındadır. Dolayısıyla, tez çalışması ve bu çalışma arasında tablo veya ölçüler kullanarak bir performans karşılaştırması yapmak mümkün değildir. Bunlardan başka, tüm spazm vakalarının % 91.6 ± 1.9 'unu % 61.7 ± 16.2 'lik bir doğrulukla sınıflandıran bir otomatik algoritma 2015 yılında Winslow tarafından önerilmiştir [83]. Geliştirilen algoritmayı uygulamak için farklı omurgalarından yaralanmış yedi hastanın sekiz kasından 24 saatlik EMG kaydı alınmıştır. Bağımsız gürültü bileşeni ortadan kaldırıldığında yani gürültü temizleme işlemi uygulandığında doğruluk oranı % 85.5 ± 5.9 'a yükselmiştir. Çalışmanın amacı, spazmları tonik kas spazmı, birim spazm ve klonus spazmı olarak ayırmaktır. İlgili spazmların gerçek sınıflandırma yüzdeleri sırasıyla % 85 ± 9.4 , % 87.5 ± 6.2 ve % 67.9 ± 19.9 'dur. Sonuç olarak, bu çalışma da doğrudan hastaların spastisite düzeyini belirlememektedir. Ayrıca önerilen yöntemi uygulamak için uzun süreli EMG verisi gereklidir. Bu işlem oldukça fazla hesap yükü gerektirmekte ve zaman kaybına neden olmaktadır.

Tezde, sinyal işleme ve makine öğrenme teknikleri ile spastisite için güvenilir bir klinik değerlendirme yöntemi geliştirilmiştir. Bu amaçla, Patella T-refleksi tetiklendiğinde katılımcıların RF ve BF kaslarındaki EMG verilerini kaydeden bir ölçüm sistemi hazırlanmıştır. Çalışmanın sinyal işleme bölümünde, kısa süreli EMG sinyalinin 20 zaman ve frekans uzayı özellikleri belirlenmiş ve spastisiteyi karakterize eden öznitelik vektörünü oluşturmak için 6 Pendulum kinezyolojik parametresi ile birleştirilmiştir. Daha sonra, öznitelik vektörünün ayırt edici kabiliyetini artırmak amacı ile öznitelik seçimi işlemi için Fisher Skoru kullanılmıştır. Sistemin sınıflandırma evresinde, spastisite derecelendirmesi için kabul edilebilir ve güvenilir sonuçlar veren YSA, k-EYK ve DVM sınıflandırıcıları uygulanmıştır. Nörologların ifadelerine göre, klinik değerlendirmelerde % 80 ve üstü doğruluk yüzdeleri kesinlikle kabul edilebilir ve uygulanabilir. Dolayısıyla, Fisher Skoru, 3-katlı çapraz doğrulama ve DVM veya k-EYK teknikleri içeren önerilen yöntem, spastisite değerlendirmeleri için kolaylıkla kullanılabilir. Normal, Ashworth 1 ve Ashworth 2 spastisite düzeylerini belirlemek için bu kombinasyonların doğruluk değerleri sırasıyla % 86.66 ve % 80.33 olarak belirlenmiştir. Elde edilen sonuçlara göre önerilen bu sistemin spastisite bozukluğunun teşhisi ve derecelendirilmesi için umut verici olduğuna ve literatüre katkıda bulunacak bir klinik değerlendirme sistemi olacağı söylenebilir.

Tezde sunulan işlemlere ilave olarak gelecekte yapılması planlanan çalışmalar aşağıda sıralanmıştır:

- Tezde hesaplanan kinezyolojik parametrelere ek olarak sönümlenme oranı gibi yeni parametreler tespit edilebilir.
- Tezde elektrofizyolojik ve kinezyolojik özniteliklerin hesaplanması için Matlab programında yazılımı yapılmıştır. Bu analiz programına bir arayüz tasarımı yapılarak herkes tarafından kolayca kullanılabilir ve detaylı analiz yapabilme imkanı sağlanabilir.
- Ölçüm sistemi, analiz programı ve sınıflandırma bu tezde ayrı enstrümanlarla yapılmış ve birbirinden bağımsızdır. Bu üç sistem bir araya getirilerek tümleşik bir sistem oluşturulabilir. Diz eklemine basit üç adet led işaretçiler yerleştirilerek bir kamera yardımı ile Patella T-refleksinin tetiklediği Pendulum

hareketinin kinezyolojik verileri kayıt edilerek, doğruluđu için Biometric Ltd şirketine ait gonyometre kayıtları ile karşılaştırılabilir. Bu sistem EMG devresi ile birleştirildiğinde hem kinezyolojik hem de elektrofizyolojik parametreleri kaydedebilen bir sistem tasarlanabilir. DVM ile elde ettiğimiz sonuç ile entegre edildiğinde, kişilerden bağımsız nicel verilere dayalı olarak spastisitenin ölçülmesi ve değerlendirilmesine katkı sağlayan bir sistem geliştirilebilir.



KAYNAKLAR

- [1] Malhotra , S., Pandyan, A.D., Day, C., Jones, P.W., Hermens, H., Spasticity, an impairment that is poorly defined and poorly measured. *Clinical Rehabilitation*, 23(7), 651–658, 2009.
- [2] Lance, J.W., Feldman, R.G., Spasticity: disordered motor kontrol Symposium synopsis, 1980.
- [3] Young, R.R., Spasticity: a review. *Neurology*, 44(11), 12–20, 1994.
- [4] Burridge, J.H., Wood, De., Hermens, H.J., Voerman, G.E., Johnson, G.R., Wijck, F.V., Platz, T., Gregoric, M., Hitchcock, R., Pandyan, AD., Theoretical and methodological considerations in the measurement of spasticity. *Disability and Rehabilitation*, 27(1-2), 69–80, 2005.
- [5] Calota, A., Feldman, A.G., Levin, M.F., Spasticity measurement based on tonic stretch reflex threshold in stroke using portable device. *Clinical Neurophysiology*, 119(10), 2329–2237, 2008.
- [6] <http://www.aans.org/en/Patients/Neurosurgical-Conditions-and-Treatments/Spasticity.>, Eriřim Tarihi: 23.06.2017.
- [7] Gelber, D.A., Jeffery, D., *Clinical Evaluation and Management of Spasticity*, Humana Press, 1-385, 2002.
- [8] Skalsky, A., Spasticity: the need for objective assessment. *Development Medicine & Child Neurology*, 59(2),114, 2016.
- [9] Xin, Z., Adachi, N., Hase, K., A computed model for quantitative evaluation of spasticity in man. *Computational Engineering in Systems Applications*, Beijing, 1844–1847, 2006.
- [10] Ferreira, J., Moreira, V., Machado, J., Soares, F., A mechatronic device for spasticity quantification. *Industrial Informatics*, Portugal, 257–262, 2011.

- [11] Kim, C.S., Eom, G.M., Hase, K., Modeling and Identification of Mechanical and Reflex Properties related to Spasticity in Stroke Patients using Multiple Pendulum Tests. *Journal of Biomechanical Science and Engineering*, 6(3), 135–147, 2011.
- [12] Bohannon, R.W., Smith, M.B., Interrater reliability of a modified Ashworth scale of muscle spasticity. *Physical Therapy*, 67(2), 206–207, 1987.
- [13] Gürbüz, M., Bilgin, S., Albayrak, Y., Kızılay, F., Uysal, H., Biceps femoris late latency responses and the ‘notching sign’ in spasticity. *Journal of NeuroEngineering and Rehabilitation*, 12(1), 2015.
- [14] Ün, K., Spastik diplejik tip serebral paralizili hastaların hamstring spastisitesinin inhibisyonunda yüksek voltaj galvanik stimülasyonun etkinliğinin araştırılması. Yüzüncü Yıl Üniversitesi, Sağlık Bilimleri Enstitüsü, Yüksek Lisans Tezi, 2014.
- [15] Hancı, M., Erhan, B., Spastisite. Nobel Tıp Kitapevleri, 2011.
- [16] Lance, J.W., Spasticity: disordered motor control. *Clinical and Experimental Neurology*, 18, 27-35, 1981.
- [17] Burridge, J., Theoretical and methodological considerations in the measurement of spasticity. *Disabil. Rehabil.*, 27(1), 69–80, 2005.
- [18] Rekand, T., Clinical assessment and management of spasticity: a review. *Acta Neurol. Scand.*, 122(190), 62–66, 2010.
- [19] Başarır, M., Özek, M.M., Spastisite ve Tedavisi. *Türk Nöroşirüji Dergisi*, 23(2), 158–173, 2013.
- [20] Haugh, A.B., Pandyan, A.D., Johnson, G.R., A systematic review of the Tardieu Scale for the measurement of spasticity. *Disability and Rehabilitation*, 28(15), 899–907, 2006.
- [21] Abolhasani, H., Ansari, N.N., Naghdi, S., Mansouri, K., Ghotbi, N., Hasson, S., Comparing the validity of the Modified Ashworth Scale and the Modified Tardieu Scale (MTS) in the assessment of wrist flexor spasticity in patients with stroke: protocol for neuropsychological study. *BMJ Journal*, 2(6), 2012.
- [22] Sorensen, F.B., Nielsen, J.B., Klinge, K., Spasticity-assessment: a review. *Spinal Cord*, 44(12), 708–722, 2006.
- [23] Aybay, C., Spastisite-Yetişkin Hastaya Yaklaşım: Klinik, Elektrofizyolojik ve Biyomekanik Değerlendirme. *Türk Fiz Rehab Dergisi.*, 53(1), 45-52, 2007.

- [24] Pandyan, A.D., Johnson, G.R., Price, C.M., Curless, R.H., Barnes, M.P., Rodgers, H., A review of the properties and limitations of the Ashworth and modified Ashworth Scales as measures of spasticity. *Clinical Rehabilitation*, 13(5), 373–383, 1999.
- [25] Fowler, E.G., Nwigwe, A.I., Ho, T.W., Sensitivity of the pendulum test for assessing spasticity in persons with cerebral palsy. *Developmental. Medicine. & Child Neurology*, 42(3), 182–189, 2000.
- [26] Voerman, G.E., Gregorič, M., Hermens, H.J., Neurophysiological methods for the assessment of spasticity: The Hoffmann reflex, the tendon reflex, and the stretch reflex. *Disability and. Rehabilitation.*, 27(1–2), 33–68, 2005.
- [27] Yavuz, U.Ş., Hareketin Çözümlemesi: Metodoloji Tarihçesi. Hareketin Korkut Yaltkaya X. Klinik Nörofizyoloji Sempozyumu, Antalya, 2015.
- [28] Şimşek, D., Okçularda atış tekniğinin kinetik ve kinematik yöntemlerle incelenmesi. Anadolu Üniversitesi, Sağlık Bilimleri Enstitüsü, Beden Eğitimi ve Spor Anabilim Dalı, Doktora Tezi, 2013.
- [29] Gelener, P., Motor Nöron ve Kas Hastalıkları sunumu.
- [30] Numanoğlu, A., Spastik serebral palsili çocuklarda spastisiteyi değerlendirmede iki farklı klinik yöntemin gözlem içi güvenilirliğinin incelenmesi. Hacettepe Üniversitesi, Sağlık Bilimleri Enstitüsü, Fizik Tedavi ve Rehabilitasyon Programı, Yüksek Lisans Tezi, 2010.
- [31] Silbernagl, S., Lang, F., *Color Atlas of Pathophysiology*, 298.
- [32] Kipnis, N., Luigi Galvani and the debate on animal electricity. *Annals of Science*, 44(2), 107–142, 1987.
- [33] Piper, H., *Elektropysiologie Menschlicher Muskeln*. Springer Verlag, 1912.
- [34] De Luca, C.J., Physiology and mathematics of myoelectric signals. *IEEE Transactions on Biomedical. Engineering*, 26(6), 313–325, 1979.
- [35] Merletti, R., Parker, A.P., *Electromyography: Physiology, Engineering, and Non-Invasive Applications*. Wiley-IEEE Press, 2004.
- [36] <https://www.khanacademy.org/> Erişim Tarihi: 07.04.2017.

- [37] Akay, A., EMG sinyalleri kullanarak model bir araba kontrolü için parametre analizi. Karabük Üniversitesi, Fen Bilimleri Enstitüsü, Elektrik Elektronik Mühendisliği Anabilim Dalı, Yüksek Lisans Tezi, 2015.
- [38] Reaz, M.B.I., Hussain, M.S., Mohd-Yasin, F., Techniques of EMG signal analysis: detection, processing, classification and applications. Biol. Proced. Online, 8(1), 11–35, 2006.
- [39] Pattichis, C.S., Pattichis, M.S., Time-scale analysis of motor unit action potentials. IEEE Transaction.on Biomedical. Engineering, 46(11), 1320–1329, 1999.
- [40] Christodoulou, C.I., Pattichis, C.S., Unsupervised pattern recognition for the classification of EMG signals. EEE Transaction.on Biomedical. Engineering, 46(2), 169–178, 1999.
- [41] Yüksel, A., Korürek, M., EMG İşaretlerinin Genetik Algoritmalar ve Çok Katmanlı Yapay Sinir Ağı ile Sınıflandırılması. EMO dergisi.
- [42] Günay, M., Emg işaretlerinin sınıflandırılması ve öbekleştirilmesi. Kahramanmaraş Sütçü İmam Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 2011.
- [43] Milanlıoğlu, A., Refleksler. Ders notları.
- [44] Uslu, S., Nüzket, T., Albayrak, Y., Uysal, H., Detarmination of patellar T EMG response with the Deep Tendon Reflex grading and tapping force. Biomedical Engineering Meeting (BIYOMUT), İstanbul, 2015.
- [45] Yaltkaya, K., Normalde, Spastisitede, Rijitede Patella Reflekssin Elektrofizyolojik ve Mekanik Özellikleri Hakkında Çalışma. Ankara Üniversitesi, Tıp Fakültesi, Doçentlik Tezi, 1971.
- [46] Oymak, İ., Tek Taraflı ön Çapraz Bağ Yaralanması olan Hastaların Patellar Tendon Refleksi Sağlam Tarafla Kinezyolojik ve Elektromyografik Karşılaştırması. Akdeniz Üniversitesi, Fen Bilimleri Enstitüsü, Uzmanlık Tezi, 2012.
- [47] Canan, S., Refleksler ve Motor Hareketlerinin Kontrolü. Başkent Üniversitesi Tıp Fakültesi Fizyoloji Anabilim Dalı.
- [48] Karahasanoğlu, İ., Patellar Tendon Rüptürlerinin İnterferens Çivisi ile Tamilerinin Biyomekaniğinin Deneysel İncelenmesi. Karadeniz Teknik Üniversitesi, Tıp Fakültesi, Ortopedi ve Travmatoloji Anabilim Dalı, Uzmanlık Tezi, 2012.

- [49] Canan, S., Refleksler ve Motor Hareketlerinin Kontrolü. Başkent Üniversitesi Tıp Fakültesi Fizyoloji Anabilim Dalı.
- [50] Badj, T., Vodoniç, L., Pendulum Testing of spasticity. *Journal of Biomedical Engineering*, 6(1), 9–16, 1984.
- [51] Gürbüz, M., Normalde, Spastisitede ve Rijiditede Patella T-refleksi ve Pendulumunun Elektrofizyolojik ve Kineziyolojik Özellikleri. Akdeniz Üniversitesi, Tıp Fakültesi Nöroloji Anabilim Dalı, Uzmanlık Tezi, 2013.
- [52] Uslu, S., Nüzket, T., Albayrak, Y., Uysal, H., Patella T-refleksinin Vuruş Gücü Ölçebilen Refleks Çekici, Kas Vibrasyonu ve BKAP İle Değerlendirilmesi. *Journal of Neurological Sciences*, 33(2), 214–226, 2016.
- [53] Phinyomark, A., Phukpattaranont, P., Limsakul, C., Feature reduction and selection for EMG signal classification. *Expert System with Application*, 39(8), 7420–7431, 2012.
- [54] Tetik, Y.E., Bolat, B., Gürültülü ortamlarda konuşma tespiti için yeni bir öznelik çıkarım yöntemi. *Elektrik-Elektronik ve Bilgisayar Sempozyumu, Elazığ*, 2011.
- [55] Gümüşçü, A., Aydılek, İ.B., Taşaltın, R., 3 Farklı Filtre Modelli Öznelik Seçme Algoritmalarının Kombine Edilerek İyileştirilmesi. *Afyon Kocatepe Üniversitesi Fen ve Mühendislik Bilimleri Dergisi*, 31–35, 2016.
- [56] Gu, Q., Li, Z., Han, J., Generalized Fisher Score for Feature Selection. *Cornell University Library*, 2012.
- [57] Babur, S., Turhal, U., Akbaş, A., DVM Tabanlı Kalın Bağırsak Kanseri Tanısı için Performans Geliştirme. *Elektronik ve Bilgisayar Mühendisliği Sempozyumu (ELECO 2012)*, Bursa, 2012.
- [58] Öztemel, E., *Yapay Sinir Ağları*, Papatya Yayıncılık, 2016.
- [59] Simon, H., *Why Should Machines Learn?*, 1983.
- [60] Minsky, M., Papert, S., *Perceptons*, MIT Press, Cambridge, 1965.
- [61] Diri, B., *Makine Öğrenmesine Giriş*. Yıldız Teknik Üniversitesi Bilgisayar Mühendisliği Bölümü.
- [62] Uzun, E., *İnternet Tabanlı Bilgi Erişimi Destekli Bir otomatik Öğrenme Sistemi*. Trakya Üniversitesi, Fen Bilimler Enstitüsü, Bilgisayar Mühendisliği Anabilim Dalı, Doktora Tezi, 2007.

- [63] Widrow, B., Hoff, M.E., Adaptive switchig circuits. WEST-CON Conention Rec 96–104, 1960.
- [64] https://scholar.google.com.tr/scholar?hl=en&as_sdt=0,5&qsp=1&q=artificial+n Erişim Tarihi: 27.06.2017.
- [65] Ayhan, S., Erdoğan, Ş., Destek vektör makineleriyle sınıflandırma problemlerinin çözümü için çekirdek fonksiyonu seçimi. Eskişehir Osmangazi Üniversitesi İktisat ve İdari Bilimleri. Dergisi, 9(1), 2014.
- [66] Cortes, C., Vapnik, V., Support-vector networks. Machine Learning, 20(3), 273–297, 1995.
- [67] Duman, F., Destek vektör makineleri yardımıyla invaziv eeg verilerinden epileptik nöbet tahmini. Mustafa Kemal Üniversitesi, Fen Bilimleri Enstitüsü, Elektrik-Elektronik Mühendisliği Anabilim Dalı, Yüksek Lisans Tezi, 2013.
- [68] Cover, T.M., Hart, P.E., Nearest neighbor pattern classification. IEEE Transaction on Information. Theory, 13(1), 21–27, 1967.
- [69] Taşcı, E., Onan, E., K-En Yakın Komşu Algoritması Parametrelerinin Sınıflandırma Performansı Üzerine Etkisinin İncelenmesi. Akademik Bilişim Konferansı, Aydın, 2016.
- [70] Freund, Y., Schapire, R.E., A decision theoretic generalization of online learning and an application to boosting. Journal of Computer and System Sciences, 55, 119–139, 1997.
- [71] Schapire, R.E., Using output codes to boost multiclass learning problems. Machine Learning Proceeding of the Fourteenth International Conference, 97, 313–321, 1997.
- [72] Schapire, R.E., Singer, T., Improved Boosting Algorithms Using Confidence-rated Predictions. COLT' 98 Proceedings of the eleventh annual conference on Computational learning theory, Madison, USA, 1998.
- [73] Friedman, J., Hastie, T., Tibshirani, R., Additive logistic regression: a statistical view boosting, The Annals of Statistic, 28(2), 337–407, 2000.
- [74] Friedman, J.H., Greedy function approximation: a gradient boosting machine. The Annals of Statistics, 5(29), 2001.
- [75] Friedman, J., Another approach to polychotomous classification, 2004.

- [76] Zhu, J., Zou, H., Roset, S., Hastie, T., Multi-class adaboost. *Statistics and Its Interface Ann Arbor*, 2, 349-360, 2009.
- [77] Schapire, R.E., The boosting approach to machine learning: An overview. in *Nonlinear estimation and classification*, Springer, 149–171, 2003.
- [78] Albayrak, Y., Çetinel, G., Gül, S., AdaBoost ve k-NN Teknikleri Kullanılarak Spastisitenin Belirlenmesi ve Derecelendirilmesi. 25. Sinyal İşleme ve İletişim Uygulama Kurultayı, Antalya, 2017.
- [79] Bishop, C.M., *Pattern recognition and machine learning*. Corrected at 8. printing New York, NY: Springer, 2009.
- [80] Lueken, M.J., Misgeld, B.J.E., Leonhardt, S., *Classification of Spasticity Affected EMG Signals. Wearable and Implantable Body Sensor Networks (BSN)*, Cambridge, USA, 2016.
- [81] Misgeld, B.J.E., Lueken, M.K., Leonhardt, S., Body Sensor Network-based Spasticity Detection. *Journal of Biomedical and Health Informatics*, 20(3), 748-755, 2016.
- [82] Yeh, C.H., Young, H.W.V., Wang, C.H., Wang, Y.H., Lee, P.L., Quantifying Spasticity with Limited Swinging Cycles using Pendulum Test Based on Phase.
- [83] Winslow, J., Automatic Identification and Classification of Muscle Spasms in Long Term EMG Recordings. *IEEE Journal of Biomedical and Health Informatics*, 19(2), 2015.

ÖZGEÇMİŞ

Yalçın ALBAYRAK, 02.08.1976'da Berlin'de doğdu. İlk ve orta eğitimini Eskişehir'de tamamladı. 1994 yılında Özel Adana Fen Lisesinden mezun oldu. 1996 yılında başladığı Berlin Teknik Üniversitesi Bilişim Mühendisliği Bölümünden mezun oldu. AVITECH, SIEMENS gibi firmalarda bir süre yazılım geliştirme uzmanı olarak çalıştı. 2008 yılında Türkiye'ye dönüş yaptı. 2009 yılında Akdeniz Üniversitesi Teknik Bilimler Meslek Yüksek Okulunda öğretim görevlisi olarak çalışmaya başladı. 2009 yılında 13/b görevlendirme ile Akdeniz Üniversitesi Mühendislik Fakültesi Elektrik-Elektronik Mühendisliği Bölümüne geçti ve halen bu bölümde görev yapmaktadır.