

**ÇUKUROVA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

YÜKSEK LİSANS TEZİ

Aybike PİROL

**DERİN ÖĞRENME YÖNTEMİ İLE YÜZEYEL EMG
İŞARETLERİNİ KULLANARAK DİRSEK EKLEMİ İÇİN
POZİSYON KESTİRİMİ**

BIYOMEDİKAL MÜHENDİSLİĞİ ANABİLİM DALI

ADANA-2021

ÖZ

YÜKSEK LİSANS TEZİ

DERİN ÖĞRENME YÖNTEMİ İLE YÜZEYEL EMG İŞARETLERİNİ KULLANARAK DİRSEK EKLEMİ İÇİN POZİSYON KESTİRİMİ

Aybike PİROL

ÇUKUROVA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
BİYOMEDİKAL MÜHENDİSLİĞİ ANABİLİM DALI

Danışman : Dr. Öğr. Üyesi Cabbar Veysel BAYSAL
Yıl: 2021, Sayfa: 97
Jüri : Dr. Öğr. Üyesi Cabbar Veysel BAYSAL
: Prof. Dr. Mutlu AVCI
: Dr. Öğr. Üyesi Necdet Sinan ÖZBEK

Kasların hareket bilgisini barındıran yüzeyel elektromiyografi (sEMG) işaretlerinin sınıflandırılması, rehabilitasyon amaçlı sistemlerde doğala yakın bir çalışma düzeni elde etmede kullanılmaktadır. Bu tez çalışmasında, üst ekstremité biceps ve triceps kaslarının sEMG sinyalleri, bir Derin Öğrenme yöntemi olan Uzun Kısa Vadeli Bellek (LSTM) yapay sinir ağı ile sınıflandırılarak dirsek eklem açısı tahmini yapılmıştır. LSTM modeli sEMG işaretinin değişken ortalama değerini ve tepe kılıf değerini kullanarak iyi bir doğruluk elde etmiş, başarılı ve etkin bir şekilde dirsek eklemi açısı tahmini yapmıştır. Sonuçlar, işaretin özneteliklerini kullanan Çok Katmanlı Algılayıcı'nın (MLP) dirsek eklem açısı tahmini ile kıyaslanmıştır. Tasarlanan LSTM modeli, hesaplama açısından daha etkin bir şekilde, MLP kadar yüksek doğruluk elde ederek dirsek eklemi açısı tahmini yapabileceğini göstermiştir.

Anahtar Kelimeler: Yüzeyel Elektromiyografik İşaretler, Yapay Sinir Ağları, Öznetelik Çıkarma, Derin Öğrenme, Uzun Kısa Vadeli Bellek

ABSTRACT

MSc THESIS

POSITION ESTIMATION FOR ELBOW JOINT USING SURFACE EMG SIGNALS WITH DEEP LEARNING METHODS

Aybike PİROL

**ÇUKUROVA UNIVERSITY
INSTITUTE OF NATURAL AND APPLIED SCIENCES
DEPARTMENT OF BIOMEDICAL ENGINEERING**

Supervisor : Asst. Prof. Dr. Cabbar Veysel BAYSAL
Year: 2021, Pages: 97
Jury : Asst. Prof. Dr. Cabbar Veysel BAYSAL
: Prof. Dr. Mutlu AVCI
: Asst. Prof. Dr. Necdet Sinan ÖZBEK

Classification of surface electromyography (sEMG) signals, which contain movement information of muscles, are used to achieve a natural working order in systems for rehabilitation. In this thesis, sEMG signals of upper extremity biceps and triceps muscles were classified with Long Short Term Memory (LSTM) artificial neural network which is a Deep Learning method, in order to estimate elbow joint angle. LSTM model successfully and effectively made elbow joint angle estimation by obtaining high accuracy using varying average and peak envelope value of sEMG. The results are compared with the elbow joint angle estimation of the Multi-Layer Sensor (MLP) which uses the attributes of the sEMG signals. The designed LSTM model has shown that it can estimate elbow joint angle more effectively in terms of calculation, by obtaining accuracy as high as MLP.

Key Words: Surface Electromyographic Signals, Artificial Neural Networks, Feature Extraction, Deep Learning, Long-Short Term Memory

GENİŞLETİLMİŞ ÖZET

Elektromiyografi kasta oluşan fizyolojik süreçlere erişip yorumlayabilmeyi sağlayan, günümüzde de hastalıkların tanı ve tedavisinde sıklıkla kullanılan bir yöntemdir. Yüzey elektromiyografisinin, (sEMG) noninvaziv olması, buna bağlı olarak insan güvenliğini kolay sağlayabilmekte ve rehabilitasyona ihtiyaç duyan kişilerin tedavisinde iyi sonuçlar verebilmesinden dolayı rehabilitasyon amaçlı sistemler için (protez ve ortez kontrolünde) insan-makine iş birliğini sağlamada kullanıma elverişli olduğu görülmüştür.

Biyolojik sinir sistemini ve insan beyninin bilgi işlemlerini taklit eden yapay sinir ağlarının sEMG'ye dayalı kontrollerde kullanılması uygundur. Yapay sinir ağlarının veriler arasında başarılı ilişkiler kurabilmesi, doğrudan ve kullanışlı bir çözüm sağlayabilmesi avantajlarıdır. Ancak her sistem için her yapay sinir ağı bir çözüm değildir. Sistemdeki verilerin yapısı, problemin türü hangi ağ mimarisinin tercih edilmesi gerektiği hakkında çözüm sunmaktadır.

Önceki çalışmalar incelendiğinde yapay sinir ağlarının kullanılmasının yanında sEMG tabanlı bir sınıflandırma ya da tahminde başarı sağlanması için işaretin özniteliklerinin kullanımı da önemli bir yer tutmaktadır. Bu teknikte işaretin kendi ham hali direkt verilmez. Kas işaretinin, yapay sinir ağına verilmeden önce zaman veya frekans düzleminde öznitelik çıkarımı yapılmaktadır. Öğrenme sürecini kolaylaştıran bu yöntemde, işaretin yapısına ve problemin türüne göre hangi özniteliklerin olacağı ve kaç özniteliğin modele verileceği belirlenerek giriş boyutu azaltılmış veri kümesi sunulur. Sistemin performansının başarısı bu özniteliklerin seçimi, hangi özniteliklerin kullanılacağına belirlenmesi ve seçilen özniteliklerin hazırlanması gibi işlemlere bağlıdır. Zaman düzleminde sıklıkla kullanılan özniteliklerin dışında (RMS, WL, VAR vs.) sEMG işaretinin zaman düzleminde yalnızca değişken ortalama değerleri ve tepe kılıf değerlerinin dirsek ekleme açısını tahmin etmede kullanılması ile ilgili yeterli inceleme bulunmadığı görülmüştür.

Bu tezde yukarıda bahsedilen konuya bir iyileştirme getirilmesi amaçlanmıştır. Biceps, triceps kas işaretlerinin değişken ortalama değerleri ve tepe kılıf değerleri ile başarılı bir dirsek eklem açısı tahmini yapılmış ve zaman düzleminde 3 özniteliği kullanan Çok Katmanlı Algılayıcı (MLP) ile kıyaslanması sunulmuştur. Tahmin için bir Derin Öğrenme yöntemi kullanılmıştır. Doğal sinyalleri içeren bir diziden başka bir diziye tahmin uygulamalarında, biyolojik işaretleri işlemede bu yöntemin kullanıldığı görülmüştür. Buna göre verilerin özelliklerini öğrenebilen, hiyerarşik katman yapısı ile verileri değerlendiren ve direkt tahmin yapmada başarılı olan Derin Öğrenme yönteminin LSTM ağı tercih edilmiştir. Tasarlanan LSTM ağ modelinin doğruluğu BiLSTM modeli ile kıyaslanmış ve kas işareti ile açı bilgisini ilişkilendirmede BiLSTM modelinin daha başarılı olduğu değerlendirilmiştir. İşaretin değişken ortalama değerini ve tepe kılıf değerini kullanan BiLSTM sinir ağının açı tahmininin, etkin değer (karekök ortalama-RMS), dalga formu uzunluğu (WL), ortalama mutlak değer (MAV) şeklinde 3 özniteliği girdi olarak alan MLP modeli kadar başarıya ulaştığı görülmüştür.

TEŞEKKÜR

Tez çalışmam süresi boyunca paylaştığı bilgiler, fikirleri, sağladığı çalışma ortamı ile zamanını ayırarak önümde ışık olan saygıdeğer danışman hocam; Dr. Öğr. Üyesi Cabbar Veysel BAYSAL’a teşekkür ederim.

Tez çalışmamın sunumunda yer alan ve katkılarını esirgemeyen jüri üyeleri Sayın Prof. Dr. Mutlu AVCI’ya ve Sayın Dr. Öğr. Üyesi Necdet Sinan ÖZBEK’e de teşekkür ederim. Ayrıca bu çalışmamın gerçekleşmesinde manevi desteğini hissettiğim Biyomedikal Mühendisliği’ndeki tüm hocalarıma teşekkür eder ve saygılarımı sunarım.

Son olarak hayatımın her aşamasında bana destek olmuş ve olmaya da devam eden canım aileme ve sevgili Behset Elmas’a sonsuz teşekkür ederim.

İÇİNDEKİLER

SAYFA

ÖZ	I
ABSTRACT.....	II
GENİŞLETİLMİŞ ÖZET	III
TEŞEKKÜR.....	V
İÇİNDEKİLER	VI
ÇİZELGELER DİZİNİ	VIII
ŞEKİLLER DİZİNİ	X
SİMGELER VE KISALTMALAR.....	XIV
1. GİRİŞ	1
2. ÖNCEKİ ÇALIŞMALAR	3
3. MATERYAL VE METOD	9
3.1. Giriş	9
3.2. EMG İşaretinin Fizyolojisi	10
3.3. Kas Kasılma Çeşitleri	14
3.4. EMG İşaretinin Özellikleri	15
3.5. sEMG İşaretlerinin Ölçülmesi	17
3.6. sEMG İşaretinin Kaydedilmesi	21
3.7. BIOPAC MP36 Veri Toplama Sistemi	22
3.8. Açık Ölçüm Düzenekleri	24
3.9. Veri Toplama ve Ölçümler	30
3.10. Veri Seti Hazırlanması	34
3.11. Zaman Düzlemi Öznitelik Çıkarımı	35
3.12. Sınıflandırma için Yaygın Kullanılan Sinir Ağları	37
3.12.1. Çok Katmanlı Algılayıcı Sinir Ağı	37
3.12.2. Derin Öğrenme Yöntemi	41
3.12.3. Tekrarlayan Sinir Ağları	42
3.12.4. LSTM Ağ Yapısı	45

3.12.5. BiLSTM Ağ Yapısı.....	49
3.13. Tasarlanan MLP Modeli	51
3.14. Tasarlanan Derin Öğrenme BiLSTM Modeli	59
3.15. Derin Ağ Modeli Optimizasyonu ve Hiperparametreler.....	68
4. BULGULAR VE TARTIŞMA	69
4.1. Çok Katmanlı Algılayıcı Modeli Dirsek Eklem Açısı Tahmini Deneysel Sonuçları.....	69
4.2. Derin Öğrenme Modeli ile Dirsek Eklem Açısı Tahmini Deneysel Sonuçları.....	76
5. SONUÇLAR VE ÖNERİLER	91
KAYNAKLAR	93
ÖZGEÇMİŞ	97

ÇİZELGELER DİZİNİ

SAYFA

Çizelge 3.1.	Açı Bilgisinin Derece Olarak Elde Edilmesi İçin Yapılan Ayar	30
Çizelge 3.2.	Veri Setlerinin Oluşturulması	34
Çizelge 3.3.	Eğitim ve Test Verisi İçin Ölçümlerin Sıralaması	35
Çizelge 4.1.	MLP Ağ Sonuçları	76
Çizelge 4.2.	LSTM ve BiLSTM Ağ Performansı	85
Çizelge 4.3.	Katman Sayısına Göre BiLSTM Ağının Sonuçları.....	85
Çizelge 4.4.	Üç Katmanlı BiLSTM Ağında Farklı Bölünme Oranına Göre Sonuçlar	85
Çizelge 4.5.	Üç Katmanlı BiLSTM Ağında Farklı Dropout Sonuçları.....	86



ŞEKİLLER DİZİNİ

SAYFA

Şekil 2.1.	EMG ile Kontrol ve Sınıflandırma Sistemlerine Genel Bir Bakış	3
Şekil 3.1.	Dirsek Eklem Açısı Tahmini Blok Diyagramı	9
Şekil 3.2.	İnsanda Kas Sistemi ve CNS Arasındaki İletişimin Genel Şeması	10
Şekil 3.3.	Motor Birimi ve Kas Lifleri ile Bağlantısı	11
Şekil 3.4.	Motor Ünitesi Kontrolü ve EMG Sinyali	12
Şekil 3.5.	Bir Sarkomerin Yapısı	13
Şekil 3.6.	EMG Sinyalinin Zaman ve Frekans Düzlemi Gösterimi.....	16
Şekil 3.7.	Orta ve Ortalama Frekans Spektrumu	16
Şekil 3.8.	EMG İşaretinin a) Yüzeyden elde edilmesi için kablo ve tek kullanımlık elektrot b) Kas içi alınmasında kullanılan tel elektrot	17
Şekil 3.9.	Kas Ölçümü İçin Referans Alınan Noktalar.....	19
Şekil 3.10.	Özel EMG Elektrotlarının Seçimi (1,2 NORAXON INC. USA).....	20
Şekil 3.11.	MP36 Ön Panel	23
Şekil 3.12.	MP 36 Veri Toplama Seti ve Açısı Ölçüm Düzenekçi	24
Şekil 3.13.	Solidworsk Ortamında Açısı Ölçüm Düzenekçinin Çizimi	25
Şekil 3.15.	AMS22b Pozisyon Sensörü	26
Şekil 3.16.	Sensörün Mekanik Açısı Değişimine Göre Sergilediği Vout Çıkışı.....	27
Şekil 3.17.	Kestamit Levhalar	27
Şekil 3.18.	Açısı Ölçüm Düzenekçi MP36 İçin Derece Ayarlaması	28
Şekil 3.19.	Açısı ve Voltaj Arasındaki İlişki.....	29
Şekil 3.20.	Deneğin Ölçüme Hazır Durumu.....	31
Şekil 3.21.	EMG İşareti ve Dirsek Eklem Açısı (izotonik_yük1_veri1)	32
Şekil 3.22.	EMG İşareti ve Dirsek Eklem Açısı (izokinetik_yük1_veri3).....	33
Şekil 3.23.	Yapay Nöron Modeli Girdi, Ağırlık ve Çıktı Gösterimi	38
Şekil 3.24.	Gizli Katmana Sahip İleri Beslemeli Bir Ağ	40
Şekil 3.25.	Hata Sinyallerinin Geri Yayılmasıyla Sinyal Akış Grafiği	41

Şekil 3.26.	RNN Ağ Yapısı	43
Şekil 3.27.	RNN için Katlanmamış Bir Hesaplama Grafiği	44
Şekil 3.28.	RNN Zincir Yapısı	46
Şekil 3.29.	Bir LSTM Biriminin Kapıları.....	47
Şekil 3.30.	Çift Yönlü LSTM Mimarisinin 3 Ardışık Adımı	51
Şekil 3.31.	Dirsek Eklem Açısı Tahmini İçin Oluşturulan MLP Ağı.....	52
Şekil 3.32.	MLP Eğitim Verisinin 3 Öznitelik Grafiği.....	53
Şekil 3.33.	MLP Eğitim Verisinin Biceps İşareti ve 4 Farklı Özniteliğinin Grafiği	54
Şekil 3.34.	MLP Eğitim Verisinin Triceps İşareti ve 4 Farklı Özniteliğinin Grafiği	55
Şekil 3.35.	MLP Hedef Eklem Açısı İşareti	56
Şekil 3.36.	MLP Regresyon Grafiği	57
Şekil 3.37.	MLP Eğitimin Performans Grafiği	58
Şekil 3.38.	LSTM Ağ Modeli İçin Eğitim Verisi	60
Şekil 3.39.	LSTM Ağ Modeli İçin Doğrulama Verisi	61
Şekil 3.40.	Normalize Edilmiş Hedef Eklem Açısı	62
Şekil 3.41.	LSTM Eğitim Verisinin Giriş Sinyalleri Ortalamasının Tepe Kılıf Değerleri	64
Şekil 3.42.	Dirsek Eklem Açısı Tahmini İçin Oluşturulan LSTM Ağ Konfigürasyonu	65
Şekil 3.43.	Derin Öğrenme BiLSTM Ağ Mimarisi Katmanları(MATLAB).....	67
Şekil 4.1.	MLP Test Verisinin Biceps İşareti ve Öznitelik Grafiği	70
Şekil 4.2.	MLP Test Verisinin Triceps İşareti ve Öznitelik Grafiği	71
Şekil 4.3.	Dirsek Eklem Test Açısı Verisi ve MLP Ağına Tahmin Grafiği -1	72
Şekil 4.4.	Dirsek Eklem Test Açısı Verisi ve MLP Ağına Tahmin Grafiği -2	73
Şekil 4.5.	Dirsek Eklem Test Açısı Verisi ve MLP Ağına Tahmin Grafiği -3	74
Şekil 4.6.	Dirsek Eklem Test Açısı Verisi ve MLP Ağına Tahmin Grafiği -4	75
Şekil 4.7.	LSTM İçin Test Verisi İşaretleri	78

Şekil 4.8. Test Verisi Giriş Sinyalleri Ortalaması ve Normalize Hedef Açısı	79
Şekil 4.9. LSTM Test Verisi İçin Değişken Ortalamanın Tepe Kılıf Değerleri- Giriş Sinyalleri	80
Şekil 4.10. Normalize Test Verisi ve Derin Öğrenme Modelinin (LSTM) Tahmin Grafiği	81
Şekil 4.11. Test Açısı ve Derin Öğrenme Modelinin Tahmini -1.....	82
Şekil 4.12. Test Açısı ve Derin Öğrenme Modelinin Tahmini -2.....	83
Şekil 4.13. Test Açısı ve Derin Öğrenme Modelinin Tahmini -3.....	84
Şekil 4.14. Test Verisi ve Farklı Sinir Ağlarının Tahmin Kıyaslama Grafiği - 1.....	87
Şekil 4.15. Test Verisi ve Farklı Sinir Ağlarının Tahmin Kıyaslama Grafiği - 2.....	88
Şekil 4.16. Test Verisi ve Farklı Sinir Ağlarının Tahmin Kıyaslama Grafiği - 3.....	89
Şekil 4.17. Test Verisi ve Farklı Sinir Ağlarının Tahmin Kıyaslama Grafiği - 4.....	90



SİMGELER VE KISALTMALAR

h_{t-1}	: Önceki Hücreden Gelen Bilgi
EMG	: Elektromiyografi
sEMG	: Yüzey elektromiyografi
CMRR	: Ortak Mod Bastırma Oranı
EKG	:Elektrokardiogram
EEG	:Elektroensefalogram
CNS	: Merkezi Sinir Sistemi
MUAP	: Motor Birim Aksiyon Potansiyeli
MAV	: Ortalama Mutlak Değer
WL	: Dalga Boyu
RMS	: Karekök Ortalama
VAR	: Varyans
YSA	:Yapay Sinir Ağı
GBYSA:	: Geri Beslemeli Yapay Sinir Ağı
MLP	: Çok Katmanlı Algılayıcılar
RNN	: Tekrarlayan Sinir Ağı
NLP	: Doğal Dil İşleme
LSTM	: Uzun-Kısa Vadeli Bellek
BiLSTM	: Çift Yönlü Uzun Kısa Vadeli Bellek
FCL	:Tamamen Bağlı Katman
Hz	: Hertz
MSE	: Ortalama Kare Hata
MAE	: Ortalama Mutlak Hata
RMSE	: Kök Ortalama Kare Hat



1. GİRİŞ

İnsan vücudunda çeşitli elektrofizyolojik işaretler vardır. Bu işaretlerden Elektromiyogram, bir kas dokusu kasıldığı sırada oluşan elektriksel aktiviteyi ifade eder. (Konrad, 2006) Elektromiyografi, kasın neler yapabildiğini sergileyebilmeyi, kuvvet ile hareket üretmesini inceleyebilmeyi, çevredeki dünyayla etkileşime girmesini sağlayan ve sayısız işlevi yerine getiren fizyolojik süreçlere erişebilmeyi kolaylaştırmaktadır. Fiziksel rehabilitasyonda, (fizik tedavi / fizyoterapi, kinesiterapi, kayropratik ve ortopedi) ürolojide, (inkontinans tedavisi) biyomekanikte (spor eğitimi, hareket analizi, araştırma) ergonomide, (işyerinde çalışmalar, iş riski analizi, ürün tasarımı) klinikte biyo geri bildirimde, kasların eğitilmesi gibi birçok uygulamada yaygın olarak kullanılmaktadır. (De Luca, 2006) (Alyea, 2010)

Yüzeyel EMG (sEMG) işaretleri cilt üzerinden elektrotlar ile alınıp elektronik cihazlarla ölçülmekte ve analiz edilmektedir. Kas kasılma ve gevşeme döngüsünün invaziv olmadan cilt yüzeyinden sEMG ile ölçülmesi tekniği, rehabilitasyon amaçlı sistemlerde yaygın olarak kullanılmaktadır.

sEMG'ye dayalı tahmin veya sınıflandırma çalışmalarının birçoğunda tasarlanan sinir ağına işaretler doğrudan verilmemektedir. Sinyalin boyutunu azaltıp eğitimi kolaylaştırmak ve öğrenme başarısını arttırmak adına hemen hemen tamamında öznitelik çıkarımı yapılmaktadır. Elde edilen özellik sinyalleri ile yapay sinir ağı modelleri bir tahmin sunmaktadır. Eğitimi kolaylaştırıp performansını arttıran veri boyutu azaltma işlemi için sEMG işaretinin değişken ortalama değerleri ve tepe kılıf değerlerinin kullanılması rehabilitasyon amaçlı cihazlarda aç, kuvvet veya tork tahminleri için seçimi iyi yapılmış bir yapay sinir ağı ile etkin bir rol oynamayı mümkün kılar.

Literatürde üst ekstremité sEMG işaretinin değişken ortalama ve tepe kılıf değerlerinin sinir ağına kullanılıp bir aç tahmini yapabilmesi ile ilgili yeterli çalışma bulunmadığı gözlemlenmiş ve bu eksikçe yönelik bir çalışma hedeflenmiştir.

Geleneksel sinir ağları yerine son yıllarda sEMG sinyalleri üzerinde iyi bir performans gösteren (Geng et al., 2018) (Chen et al., 2019) Derin Öğrenme yöntemleri bu alanda umut vadeditici gözüktüğünden biceps ve triceps kaslarından alınan sEMG işaretlerinin değişken ortalama değerleri ve tepe kılıf değerlerini kullanan derin öğrenmeli yapay sinir ağı ile dirsek eklemine aç kestirimini yapılması amaçlanmıştır. sEMG işareti ile derin öğrenme modelinden elde edilen sonuçların başarısını değerlendirmek için işaretin özniteliklerini kullanan farklı bir tahmin ağı MLP ile karşılaştırılması hedeflenmiştir.

Çalışma için yapılan açi düzeneği tasarımı ile omuz ve bilek eklemine hareketler sırasında sabit olduđu, modele dahil edilmediđi, izotonik ve izokinetik hareketlerden yalnızca biceps ve triceps kaslarının fleksiyon/ekstansiyon yapması ile sorumlu olduđu varsayılmıştır. Ayrıca kasta meydana gelebilecek yorulmalar ve deri direncindeki farklılıkları göz önüne alarak tez çalışması için elde edilen işaretler özellikle farklı günlerde kaydedilmiştir.

Yapılan tez çalışması aşağıdaki bölümleri takip etmektedir:

2.Bölüm’de literatürdeki sEMG işaretinin işlenmesi ve rehabilitasyon sistemleri ortez, protez cihazlarındaki kontrol kullanımı ve sınıflandırma ile ilgili çalışmalara değinilmiştir. Hangi yöntemlerin kullanıldığı, işlemin nasıl sağlandığı ve sonuçları incelenmiştir.


3.Bölüm’de sEMG işaretinden, bu tez çalışması için işaretin nasıl elde edildiđi ve analizinin nasıl yapıldığından bahsedilmiştir. Ardından kayıtlı bu işaretler ile açi tahmini için kullanılan Derin Öğrenme yöntemi ile Çok Katmanlı Algılayıcı (MLP) mimarisi sunulmuştur. sEMG işaretinin açi tahmini yaptığı 2 ayrı model detaylı bir şekilde gösterilmektedir.

4. Bölüm’de ise üst ekstremitte kaslarından alınan sEMG işareti ile açi tahmini için tasarlanan iki ayrı ağı modelinin sonuçları ve birbiri ile kıyaslaması yer almaktadır.

5. Bölüm bu tez çalışmasının bütün bir özetini ve çalışmanın daha fazla nasıl geliştirilip iyileştirilebileceğini ifade etmektedir.

2. ÖNCEKİ ÇALIŞMALAR

Rehabilitasyon sistemlerinin tasarımı için elektromiyogram işaretlerin incelenmesi günümüze kadar etkili sonuçlar vermiş ve bu sebeple oldukça önemli hale gelmiştir. Protez ve ortezler için pozisyon ve kuvvet kestirimi önemli bir çalışma alanı olduğundan bu örüntü tabanlı analizlerde Şekil 2.1’deki gibi bir süreç takip edilmektedir. Ham sEMG sinyalinden gürültü uzaklaştırılır özellik çıkarımı yapılır. Ardından sinir ağları ile sınıflandırma, tahmin veya kontrol gerçekleştirilir. (Chowdhury ve ark., 2013)



Şekil 2.1. EMG ile Kontrol ve Sınıflandırma Sistemlerine Genel Bir Bakış (Nazmi ve ark., 2016)

sEMG sinyallerini doğrudan sinirsel bir sınıflandırıcıya sunmanın, sinyallerin boyutları ve rastgele özellikleri nedeniyle pratik olmadığı ifade edilmiştir. Sinyalin, sinyal bilgisini daha kompakt bir şekilde gösterme yeteneğine sahip, azaltılmış bir boyut vektörü ile temsil edilmesi gerekir. Böyle bir vektöre özellik vektörü denir. Özellik çıkarma, bir özellik vektörü oluşturmak için ham sEMG girdi boyutunun azaltılmasıdır. Sınıflandırma sürecini basitleştirmek ve fazla sayıda veriyi azaltmak için uygulanır. Doğru özelliklerin seçilmesi önemlidir çünkü model sınıflandırma sisteminin doğruluğu büyük ölçüde bu özelliklerin seçimine bağlıdır. (Eroğlu & Baysal, 2018) (Nazmi ve ark., 2016) Literatürdeki

çalışmalarda 3 tür analiz yapılmaktadır. Zaman düzleminde, frekans düzleminde ve zaman-frekans düzleminde. Yapılan literatür araştırmasında, bu özelliklerden nelerin tercih edildiği ve hangi algoritmalar kullanılarak tahmin ya da sınıflandırma yapıldığı ayrıntılı şekilde incelenmiştir.

Derin katmanlı ağ yapılarının günümüz şartlarında rahat bir şekilde eğitilebilmesi, iyi performans sergileyebilmesi son yıllardaki sEMG'ye dayalı Derin Öğrenme yöntemleri ile yapılan çalışmaları artırmıştır. Bu gelişme de göz önüne alındığında özellikle Derin Öğrenme ile ilgili son çalışmalar ayrıntılı incelenmiştir. Bunlardan bazıları aşağıda açıklanmıştır:

Kwon ve arkadaşı, insan makine işbirliği için yaptıkları çalışmada yüzey elektromiyografisi ile üst ekstremiteler hareket tahmini yapmışlardır. Yapay sinir ağı kullanarak, sEMG ve eklem açısal hızlarından fleksiyon ve ekstensiyon hareketini belirlemek için gerçek zamanlı bir tahmin gerçekleştirmişlerdir. sEMG analizi için uygun olan 5 kastan alınan bilgi ön işlemden geçirilerek sinyalin ortalama mutlak değer (MAV) özelliğini kullanmışlardır. MAV'ın pencere uzunluğunu 200 olarak ayarlamışlardır. Dirsek ve omuz eklem açılarını gonyometre ile ölçmüşler ve açısal hızları elde etmek için açıların zamana göre türevini almışlardır. İleri beslemeli YSA modeline girdi olarak sEMG'nin MAV'ı ve açısal hızlar, çıktı olarak eklem açıları verilmiş ve modelin performansını normalize edilmiş ortalama karekök hata (NRMSE) ve tahmin-ölçülen değer arasındaki korelasyon katsayısı (CC) ile değerlendirmişlerdir. NRMSE 0,15'ten küçük, CC 0,9'dan büyük olarak hesaplanmış ve temassız koşullar altında önerilen bu yöntemin kabul edilebilir bir performansı olduğu sonucuna varmışlardır. Fiziksel temastan sonra geri bildirimin modelin performansı için gerekli olan bir unsur olduğunu ifade etmişlerdir. (Kwon & Kim, 2011)

Koldan alınan EMG sinyalinin örüntü tabanlı analizinin yapıldığı farklı bir çalışmada sınıflandırma performansı yüksek ve yaygın kullanıldığı ifade edilen ortalama mutlak değer, ortalama mutlak değer eğimi, sıfır geçiş tespiti sayısı, dalga boyu ve eğim gösterge değişikliği zaman düzlemi öznelikleri ve Özbağlanım

Katsayıları (AR) kullanılmıştır. 8 denekten 7 farklı el hareketinin EMG işaretleri ileri beslemeli geri yayımlı sinir ağına bahsedilen özneteliklerin farklı sayılarda giriş olarak verilmesi ile eğitimi sağlamışlardır. 3 katmandan oluşturulan sinir ağının ikinci katı gizli katmandır ve 40 sinir hücresi, çıkış katmanında ise 3 sinir hücresi bulunduğu belirtilmiştir. Girişi $[-1,1]$ aralığında normalleştirmişlerdir. Çalışmada, AR katsayılarının zaman düzlemi öznetelikleri ile kullanılması, bütün durumlarda sınıflandırma başarısını artırdığı ifade edilmiştir. Zaman düzlemi ve zaman frekans düzleminden 7 hareketin sınıflandırma başarılarında en iyi sonucu veren öznetelik grupları birleştirilip oluşan yeni öznetelik uzayından sınıflandırma yapıldığında 7 hareket problemi için başarının yaklaşık %83 olduğu görülmektedir.(Guvenc ve ark., 2014)

Mamikoğlu ve arkadaşları integrali alınmış bir EMG sinyali kullanarak ARIMAX modeli ile fleksiyon ekstansiyon hareketi için eklem açılarını tahmin etmişlerdir. Üst kol ve bilek ekleminin sabit olduğunu varsayarak 4 denekten biceps kas sinyali alınmış, ardından ön işlem sonrası mutlak değerinin integrali ARIMAX modeline verilmiştir. Çalışmanın yaygın EMG işleme tekniklerinden ortalama %21,85'lik bir artışla daha iyi performans sergilediğini ifade etmişlerdir. (Mamikoglu ve ark., 2016)

CNN ile RNN mimarisinin kombinasyonu ile üst ekstremitte hareket tahmini yapan bir model, Xia ve arkadaşları (2017) tarafından önerilmiştir. CNN mimari yapısının, değişken, düşük genlikli ve rastgele olan sEMG gibi sinyalleri modellemede sergilediği olumlu yaklaşımından ve RNN mimarisinin sıralı verileri işlemedeki avantajından yararlanılmıştır. Dirsek ve omuz eklem hareketini ihmal eden bilek hareketi ile 3 boyutlu el pozisyonuna odaklanan çalışma için 8 kişinin 5 kasından sinyal bilgisi alınmıştır. Kayıtlı veri 50ms'lik pencerelere ayrılarak açıcı kaydı ile senkronize edilmiş ardından zaman frekans düzlemine aktararak frekans alanında, ham sinyallerin, her analiz penceresinde Fourier dönüşümüne dayalı olarak doğrusal spektral katsayıları oluşturulmuştur. RCNN modelinde eğitim girişi için 5 kası temsil eden bu zaman frekans spektrum

değerleri kullanılmıştır. 3 tane 1D CNN katmanı ve 2 LSTM katmanından oluşan modelde 8 denek için ortalama değer es0as alınmış ve üç eksen boyunca tahmini hareket için R^2 değeri %91,7 olarak ifade edilmiştir. RCNN modeli yalnızca CNN modeli ile kıyaslanmıştır. RCNN'ler için ortalama R^2 değeri 90,3 bulunmuş ve CNN'den (%77,6) önemli ölçüde daha yüksek olduğu ifade edilmiştir. (Xia ve ark., 2017)

Geng, Hu ve arkadaşları (2018) derin öğrenme yöntemlerinin performansından esinlenerek sEMG sinyalleri ile hareket tanımlamak için hibrit bir yaklaşım ile CNN-RNN mimarisini önermişlerdir. Önerilen modelin hem mekânsal hem de zamansal bilgiyi yakalamayı hedeflediğini belirtmişlerdir. Modele verilmek üzere 5 kanaldan sinyal alınmış ve bunları RGB görüntüsü ile aynı boyutlara sahip (renk kanalı, genişlik ve yükseklik) bir sEMG görüntüsüne dönüştürmüşlerdir. Her elektrottaki sEMG bilgisi, sEMG görüntülerinin pikseli olarak kabul edilmiştir. 2 evrişim katmanı, 3 tamamen bağlı (FC) katman ardından 1 LSTM katmanı ile FC'ye bağlanmış ve softmax ile sınıflandırma modeli oluşturularak hareket tanımayı sağlamışlardır. Sinyalin şerit halinde ($1 \times 1 \times sEMG_{feature}$) verildiği sınıflandırmanın, yaptıkları diğer görüntü temsil yöntemlerine göre %86,3 doğrulukla daha iyi performans sergilediği sonucuna ulaşmışlardır. Sadece CNN tabanlı modeller ile karşılaştırmış hibrit yaklaşımın daha iyi performans sergilediğini ifade etmişlerdir. (Geng ve ark., 2018)

sEMG işaretlerini kullanarak gerçek zamanlı dirsek eklem açısı tahmini yapan Eroğlu ve Baysal, hesaplamalı sadeliği nedeniyle zaman alanı özellik çıkarımını seçerek MLP ve Genel Regresyon sinir ağı (GRNN) modelinde uygulamışlardır. Farklı ağırlık ve hızlarda 2 kastan alınan sinyal bilgisi ön işlemden geçirilerek; sinyalin zaman düzlemi özelliklerini temsil eden ortalama mutlak değer, dalga biçim uzunluğu, ortalama karekök öznelilikleri 250 'lik örneklere bölerek sinir ağına açısı tahmini için vermişlerdir. Sagital düzlemde açısal yer değiştirmeyi elektrogoniometre ile almışlardır. Dirsek kolu ekleminin gerçek zamanlı tahmini için fazla bir gecikme söz konusu olmadığı ifade etmişlerdir. Çıkış katmanı dahil 3

gizli katmanı bulunan MLP ağındaki tahmin için 130 derecelik açı aralığında ortalama mutlak hata (MAE) %10, GRNN ağı tahmini 135 derecelik açı aralığında %11 MAE hesaplamışlardır. MLP ve GRNN için doğruluğun sırasıyla 89.63% ve 88,35% olduğunu belirtmişlerdir. (Eroğlu & Baysal, 2018)

Chen ve arkadaşları (2019) sEMG işaretlerini ve derin öğrenme yöntemini kullanarak üst ekstremitte eklem açılarının sürekli tahmini için bir model önermişlerdir. Dokunma ve birleşik görev hareketi inceleyen çalışmada, 7 denekten 7 kasın sinyal bilgisini almışlardır. Açısız hareketi kameralı bir sistem ile elde etmişlerdir. sEMG sinyalinin veri ön işleme ardından tepe kılıf değeri (envelope) alınmıştır. Hareket verisi ile birlikte anlamlandırabilmek için 10ms'lik pencerelere bölmüşlerdir. Zaman alanındaki analizin sınıflandırmadaki başarısına değinerek 4 zaman özelliğini, kök ortalama kare (RMS), varyans (VAR), ortalama mutlak değer (MAV) ve dalga formu uzunluğu (WL) seçmişlerdir. Her katmanında 20 nöron bulunan 3 gizli katmana sahip LSTM ağı ve 4 gizli katmana sahip MLP ağındaki sonuçları kıyaslamışlardır. Her iki ağı tahmin sonuçlarında RMSE ve R^2 7 deneğin ortalaması şeklinde verilmiş ve sonuçta MLP modelinde 120 sn'lik kayıt için R^2 0,8651 iken, LSTM modeli ile R^2 0,9449 olarak hesaplamışlardır. (Chen ve ark., 2019)

GA Elman sinir ağını kullanan Wang ve arkadaşları üst ekstremitede sürekli eklem açı tahmini yapmışlardır. Omuz ve dirsek açısını inceledikleri bu çalışmada sEMG sinyalinin özel dalgacık paket enerji entropisini (WPEE) kullanmışlardır. 6 sağlıklı denekten alınan 8 kanallı sEMG sinyaline 6 katmanlı dalgacık dönüşümü uygulamışlardır. Bitişik olmayan alt uzayının entropi özelliklerini modele vermeyi tercih etmişlerdir. Bu özellik, bir veri kümesinin düzensizliğinin ölçüsü olarak ifade edilebilen bilgi veya Shannon entropisi olarak bilinmektedir. Genetik algoritma ile optimize ettikleri, 4 katmanlı, her katmanında 20 düğüm bulunan Elman sinir ağı modelinde gizli katmanın çıkışı bir sonraki girişe ekleyen bellek moduna sahip yapısıyla dinamik bilgileri işleme yeteneğinin güçlendiğini ifade etmişlerdir. Sadece omuz hareketinde RMSE 3,4717 ve R^2


82,83, omuz ve dirseğin sürekli senkron olduğu harekette RMSE 4,1582 ve R2 81,14 sonuçlarına ulaşmışlardır. (Wang ve ark.,2020)

RNN'nin türü olan LSTM'yi kullanarak sEMG sinyallerine dayalı diz eklemi için sürekli tahmin yapan Ma ve arkadaşları (2020) RMS ve RMSTAF 'ı kullanan LSTM ağı ile geri yayılım sinir ağını (BPNN) kıyaslamışlardır. Bu çalışma için 5 denneğin 8 kasından alınan sinyal bilgisi işlendikten sonra pencere genişliği 20 olacak şekilde zaman düzleminde RMS öznitelikli çıkarmışlardır. Kaydedilen açı sinyalinin örnekleme frekansının sEMG öznitelik sinyalinin örnekleme frekansına uyması için alt örnekleme yapmışlardır. Modelde başarı elde etmek adına açı değerlerini normalize etmişlerdir. RMS özellik dizisini giriş olarak alan 16 girişe sahip 100 katmanlı ve her katmanında 200 düğüm bulunan LSTM modeli ile tansig ve purelin taransfer fonksiyonu kullanan 3 katmanlı bir BP modeli oluşturmuşlardır. RMSTAF kullanan LSTM ağının RMSE sonuçlarının, RMS kullanan LSTM ve RMS ile RMSTAF kullanan BPNN ağına göre sırasıyla %8,57 %46,62, %68,69 oranında azaldığını belirtmişlerdir. RMSTAF kullanan LSTM modelinin diz eklemine hareketini tahmin etmede diğerlerinde daha iyi performans sergilediği sonucunu elde etmişlerdir. (Ma ve ark., 2020)

3. MATERYAL VE METOD

3.1. Giriş

Dirsek eklem açısı tahmini için bu tez çalışmasında geliştirilen sisteme genel bir bakış şekil 3.1’de verilmiştir. Buna göre sEMG işaretinin ölçülmesi, açısı bilgisinin elde edilmesi ve verilerin toplanması işlemleri sıralanmaktadır. Burada biceps ve triceps kaslarından EMG sinyalleri yüzey elektrotları ile elde edilmesi sağlanır. Eşzamanlı olarak açı ölçüm düzeneği ile açı bilgisinin kaydedilmesi gerçekleştirilir. Ardından veri setleri oluşturularak sinir ağına verilmek üzere hazır hale gelir. Son bileşen ise bu verilerden tahmin sağlayacak sinir ağı modülüdür. Bu modülün yeterince sağlam ve doğru tahmin sağlayabilmesi tasarımın esas hedeflerindendir. Tasarlanan derin öğrenme sinir ağının ayrıntılı yapısı ve kıyaslandığı MLP sinir ağı mimarisi sonraki bölümlerde detaylı bir şekilde anlatılmıştır.




Şekil 3.1. Dirsek Eklem Açısı Tahmini Blok Diyagramı

Çalışma için yazılım bir MATLAB paketinde uygulanmıştır. Kullanılan paket ve veri işleme yazılımı MATLAB R2019a, Intel Core i5 CPU 2.6 GHz'dir.

3.2. EMG İşaretinin Fizyolojisi

Canlı organizmalardan kaynaklanan her türlü işaret, biyolojik işaret olarak kabul edilmekte ve bu işaretler hücrelerdeki elektriksel aktivite sonucu oluşmaktadır. Bu aktivite hücrelerdeki elektrokimyasal olaylardır. Elektriksel aktivite ve elektrokimyasal olayları, kas iskelet sistemi merkezi sinir sistemi (CNS) ile sürekli haberleşerek sağlamaktadır.




Şekil 3.2. İnsanda Kas Sistemi ve CNS Arasındaki İletişimin Genel Şeması


Genel olarak ışık ya da ses gibi harici bir fiziksel sinyal, duyu sistemlerinden biri tarafından algılanır ve vücuttaki sensörler fiziksel sinyali Merkezi Sinir Sistemine (CNS) iletilen sinir darbelerine dönüştürür. Ardından önceki alınan, depolanan bilgileri karşılaştırarak güncel bilgi oluşturulur. Kaslardaki kontrolün bu genel şeması Şekil 3.2'de gösterilmiştir. Kaslar bu işleyişi CNS'nin sinir hücreleri olan motor nöron birimi ile sağlamaktadır. (Kooij ve ark., 2008)

Motor birim, kas kasılma sürecinin sinirsel kontrolünü tanımlayan en küçük işlevsel birimdir. Bir motor ünitesi motor nöronun hücre gövdesi, dendritleri, aksonunun çoklu dalları ve kas liflerinden oluşmaktadır. (Şekil 3.3)

Motor nöronu kas lifinin kasılmasını sağlayacak uyarıyı alır ve yapısındaki motor uç plakların her biri bir kas lifine bağlanarak aktarım sağlanır. (Konrad, 2006) Motor sinir hücresi iki şekilde yani polarize ve depolarize olarak kas lifine uyarı gönderir ve kastaki bu uyarı elektrotlar tarafından kaydedilir. Bu kayıt bir motor birim aksiyon potansiyeli (MUAP) olarak görüntülenir.




Şekil 3.3. Motor Birimi ve Kas Lifleri ile Bağlantısı (Konrad, 2006)



Şekil 3.4. Motor Ünitesi Kontrolü ve EMG Sinyali (De Luca, 2006)

Gözlemlenen sinyalin büyüklüğünü ve yoğunluğunu etkileyen en önemli iki mekanizma, MUAP'lerin katılımı ve ateşleme hızlarıdır. İnsan deri katmanları filtre etkisine sahip olduğundan MUAP ateşleme ve genlik özellikleri tespit edilemez ve kas içinden bunlar incelenir. Üst üste binen MUAP'ların algılanmasıyla ham EMG sinyali oluşur. (Şekil 3.4) (Konrad, 2006)

MUAP kaslardaki liflerde birtakım etkiler oluşturarak hareket ve kuvvet üretilir. Kas liflerinde bulunan miyofibriller sarkomer bölümlerinden oluşmaktadır. Sarkomerde kasılma ve gevşeme durumunda birbirine geçen filamanlar bulunmaktadır. (Şekil 3.5) Burada kalın flamenti miyosin inceyi aktin proteini oluşturur. Sarkomerin kuvvet üretmesi Ca^{2+} yoğunluğuna göre düzenlenmektedir. Ca^{2+} etkisi altında, miyozinin başları çapraz köprüler oluşturmak için aktin molekülünün troponin bölgelerine bağlanır. Miyozin kafası daha sonra yaklaşık 45° döner: Kuvvet üretilir veya harici bir kuvvetin yokluğunda aktin filamentleri miyosin üzerinde birbirleri boyunca kayar ve kasılma gerçekleşir. (Kooij ve ark., 2008)



Şekil 3.5. Bir Sarkomerin Yapısı

CNS ile kaslara bir girdi üretilerek kas kuvveti oluşumu sağlandığında, bu kuvvet ile bulunan bölgedeki eklemden bir moment ve tork oluşarak iskelet sistemi

üzerinden hareket gerçekleşir. Kas iskelet sisteminin konumu ile ilgili bilgiler duyu reseptörleri ile aktararak CNS’de belirlenen konumla karşılaştırılır ve gerekirse kasa tekrar telafi amaçlı sinyal gönderilir. Kasın hareketinin hassasiyeti kas tarafından CNS’ne gönderilen geri bildirim ile sağlanmaktadır. Bu geri bildirimi spindle, golgi tendon organı gibi kasların duyu reseptörleri ile sağlanmaktadır. Kasın uzamasını algılayan, aktif veya pasif şekilde kasta oluşan gerilim değişimini CNS’ye ileten spindle, kas içiği olarak da bilinmektedir. Golgi tendon kas lifleri ve tendonlar arasında bağ dokuda yer alan, bir load cell gibi kasa uygulanan kuvveti algılayan duyu reseptörüdür. (Kooij et al., 2008)

3.3. Kas Kasılma Çeşitleri

Merkezi sinir sisteminin, insan hareketinde önemli bir yeri olan kaslarda oluşturduğu küçük iyonik potansiyel ve akımlar, kas kasılması meydana getirmektedir. Kas kasılması ile ilgili farklı sınıflandırmalar mevcut olmasına karşın temelde 3 tip kas kasılması vardır. Bunlar konsantrik, eksantrik ve izometrik kasılma şeklindedir. (Alyea, 2010) Bu kas kasılmaları dışında izotonik ve izokinetik kasılmalar da literatürde bulunmaktadır.(Serbest & Eldoğan, 2014)

Konsantrik kasılmada kaslarda oluşan gerilim, yükten büyük olduğunda kaslar kısalmakta ve eklem hareketi sağlanmaktadır. Net moment ile eklem açısının değişimi aynı yöndedir. Bu kasılma türünde kas boyu değiştiğinden izotonik kasılma da bu sınıflandırmada yer almaktadır. İzometrik kasılma ise kasın boyunda bir kısalma oluşturmeyen kasılma türüdür. Kas kısalmaya çalışsa dahi gerginliği yükten büyük olmayıp yüke eşit olduğundan dolayı hareket sağlayamaz ve statik kasılma olarak da bilinmektedir. Yer çekimine karşı ayakta dik durabilme en temel örneklerinden biridir. Eksantrik kasılma türünde kas gerilimi yükten daha az olur ve kasın boyunda uzama meydana gelir. Net moment eklem açısının tersi yönündedir. Bu kasılmanın amacı eklem hareketini yavaşlatmaktır.(Serbest & Eldoğan, 2014)(Alyea, 2010) Eklem hareket açıklığı boyunca kasta maksimum direnç ile kasılma sağlayan kasılma türü izokinetik kasılma türüdür. İzokinetik kasılma,

hareket hızı sabit olacak şekilde kas kuvvetini artırır. Bu kasılma türü bir cihaz eşliğinde yapılmaktadır. (izokinetik dinamometre gibi.)(Şahin, 2010)


Harekete katkısına göre literatür kasları 3 gruba ayırmaktadır. Agonist kaslar hareketin oluşmasını sağlarken antagonist kaslar agonist kaslara karşı bir eklem torku üreterek stabilize edici bir kuvvet sağlamaktadır. Sinerjist kaslar agonist kaslara destek olarak görev almakta ve hareketin kontrolüne katkı sağlamaktadır. Biceps ve triceps kaslarının fleksiyon ve ekstansiyon hareketleri agonist ve antagonist harekete verilen örneklerden biridir. (Alyea, 2010)

3.4. EMG İşaretinin Özellikleri


Elektromiyogram (EMG) kas liflerinde oluşan akımın veya elektriksel potansiyelin ölçülmesi ve grafiksel olarak kaydedilmesi yöntemidir.(Alyea, 2010)

EMG işaretinin özelliklerini bilmek işaretin analiz edilebilmesini sağlamada önemlidir. Merkezi sinir sisteminin dokularda oluşturduğu tepkiler küçük iyonik potansiyel ve akımlar kimyasal uyarılara, dokunun işlevine ve durumuna göre farklı genlik ve frekanslara sahiptir. Genel olarak sEMG frekanslarının 20-500 Hz arasında olduğu yaygın olarak kabul edilmektedir. Yavaş kasılan liflerin 20-90Hz arasında hızlı kasılan liflerin 90-500Hz arasında frekansa sahip olduğu belirtilmiştir. (Şekil 3.6)

Frekans spektrumunda sinyale ait farklı bilgiler elde edilmektedir. Şöyle ki kas yorgunluğu arttığı zaman ateşleme sıklığı azalır ancak zaman bölgesinde toplam genlik sabit kalabilir ve bu sebeple kas yorgunluğu zaman bölgesinde tespit edilmeyebilir. Bu durumda kas yorgunluğu için şekil 3.7’de gösterildiği gibi ortanca frekans (yeşil çubuk) ve ortalama frekans (kırmızı çubuk) önemlidir. Frekans spektrumundaki tüm değerler sıralandığında bunları eşit 2 ayrı bölüme ayıran Ortanca frekanstır. Ortalama frekans tüm frekans değerlerin aritmetik ortalamasıdır.(Alyea, 2010)



Şekil 3.6. EMG Sinyalinin Zaman ve Frekans Düzlemi Gösterimi (Alyea, 2010)




Şekil 3.7. Orta ve Ortalama Frekans Spektrumu (Alyea, 2010)

EMG sinyalinin stokastik bir yapı gösterdiği ve Gaussian dağılım fonksiyonu ile tanımlandığı belirtilmiştir. EMG sinyalinin genliği 0-10 mV arasında değiştiği bilinmektedir. (Şenli,2007;Taşar 2016'dan)

3.5. sEMG İşaretlerinin Ölçülmesi

EMG işareti iki temel şekilde elde edilmektedir. Deri yüzeyine iletken elemanlarla noninvaziv olarak yerleştirilmesi mümkün elektrotlar ile veya kas içine invaziv olarak iğne-tel elektrotlarının yerleştirilmesi şeklindedir. (Şekil 3.8)(Konrad, 2006)(Alyea, 2010)EMG işaretinin yüzeysel olarak elde edilmesinde noninvaziv olması, çalışma ve araştırmalarda insan güvenliğini kolay sağlayabilmesi ve yapılan literatür çalışmasında görüldüğü üzere iyi bir kontrol performansı sergileyebilmesi iğne elektrotları yerine bu yöntemin tercih edilmesini mümkün kılar.




Şekil 3.8. EMG İşaretinin a) Yüzeysel elde edilmesi için kablo ve tek kullanımlık elektrot b) Kas içi alınmasında kullanılan tel elektrot (Konrad, 2006)

Konrad (2006), bahsettiği üzere, insan vücudu iyi bir iletkenidir ancak elektriksel iletkenlik doku tipine, kalınlığına, sıcaklığa, kişiden kişiye değişen insan fizyolojisine göre değişmektedir. Bu sebeple EMG sinyali yüzeysel elektrotları ile elde edildiğinde bazı faktörlerden etkilenmektedir. Elektrot seçimi, dokunun

karakteristiği, doku ile elektrot arasındaki iletkenlik, kas lifi ve elektrot arasındaki uzaklık, kasta meydana gelen elektriksel potansiyelin büyüklüğü ve crosstalk bu faktörlerdendir.(Soderberg & Cook, 1984)

Deri altındaki subkutan yağ tabakasının kalınlığı sinyalin zayıflayarak yani küçük genlikler ile elde edilmesine neden olmaktadır. Dinamik hareket çalışmalarında ise sinyal kaynağı kas ile tespit bölgesi olarak nitelendirilebilen elektrotlar arasındaki değişiklikler meydana gelebilmektedir. Ortamdaki harici cihazlardan kaynaklanan dış gürültü faktörü EMG sinyal elde edimini etkilemektedir.(Konrad, 2006) Crosstalk, yüzeysel elektromiyografide ölçülen kasın işareti ile çevresindeki kas işaretlerin üst üste binmesini ifade eden istenmeyen durumdur. Özellikle küçük kasların elektrotları, hemen altındaki kası değil komşu kasların elektriksel aktivitesini de algıladığından elektrotların yerleştirilme konumu yüzeysel elektromiyografi ölçümlerinde oldukça önemli bir yer tutmaktadır. Bunun için bazı standartlar oluşturulmuştur. SENIAM (kasların non-invaziv değerlendirilmesi için yüzey elektromyografi) yüzey EMG için elektrotların kas liflerine paralel ve elektrotlar arasındaki mesafenin 20 mm olmasının ideal ölçüm olduğunu belirtmiştir. Buna göre bipolar elektrotlar küçük kaslara uygulandığı takdirde elektrotlar arasındaki mesafenin kas lifinin 1/4'ünü geçmemesi gerekmektedir.

Biceps kası için medial akromiyon ile fossa kübiti arasını 3 eşit parçaya bölerek 2/3'ü yukarıda kalacak şekilde elektrot yerleşimi yapılmalıdır. Referans veya toprak olarak bilinen elektrot bileğin çevresine yerleştirilmelidir. Triceps kası için ölçüm, akromionun arka kristası ile olekranon arasındaki noktaya eşit mesafede yerleştirilmelidir. Bu konumlar dikkate alınarak tendon ve motor uç plakası etkilerinde oluşacak dengesiz ölçümler en aza indirilmektedir. (Stegeman & Hermens, 2007) Şekil 3.9 'da biceps ve triceps kas ölçümü için referans alınan noktaların gösterimi mevcuttur.




Şekil 3.9.Kas Ölçümü İçin Referans Alınan Noktalar(Stegeman & Hermens, 2007)

Yüzeyel ölçülen EMG işaretinin elde edilmesinde elektrot seçimi yani elektrotların yapısı, boyutu önem arz etmektedir. Elektrotların temel işlevi dokudaki potansiyeli en iyi şekilde aktarabilmektir. İyi iletkenliği dışında toksit olmaması ve bozulmaması da istenen özelliklerdendir.

İki tip yüzey elektrotu yaygın olarak kullanılmaktadır. Biri ciltle doğrudan temasta olan kuru elektrotlardır. Statik elektrot olarak da bilinmektedir. Diğeri ise cilt ve elektrotun metalik kısmı arasında kimyasal bir arayüz olarak elektrolitik bir jel kullanan jelleşmiş elektrotlardır. Tek kullanımlık şekilde karşımıza çıkmaktadır. (Şekil 3.10) EMG kaydı sırasında, elektrot ile doku ya da deri arasında bir polarizasyon oluşması veya kapasitif etkilerin oluşup işaretin sağlıklı aktarılmasında problemlere sebep olmaması için genellikle bu tip Ag/AgCl kaplı metaller kullanılmaktadır. (Güven, 2012) Ayrıca Ag, Au, AgCl gibi farklı metal ve bileşikler kullanılabilmektedir. Ag/AgCl elektrotlar kolay temin edilebilirliği düşük gürültü ile stabil bir geçiş sağlayabilmelerinden dolayı sıklıkla tercih edilmektedir.

Bu elektrot türü için iletken alan olan elektrotun çapı 1 cm veya daha küçük olmalıdır. Islak jel elektrot veya yapışkan jel elektrot olarak bulunmaktadır. Elektrot cilt empedansını düşürmek için ayrıca elektrot jeli kullanılabilir. Elektrotlara bağlı kabloların hareketi sonucu oluşabilecek dengesiz ölçümleri önlemek adına sabitleme bantları kullanılmalıdır. (Stegeman & Hermens, 2007)(Day, 2002)(Konrad, 2006)



Şekil 3.10. Özel EMG Elektrotlarının Seçimi (1,2 NORAXON INC.USA) (Konrad, 2006)

Cilt yüzeyini ölçüme uygun hale getirmek EMG elde edinimini etkileyen önemli faktörlerden biridir. Amaç, cilt yüzeyinde düşük bir güç empedansı oluşturmak ve direkt olarak elektrot teması sağlayabilmektir. Hareket artefaktları oluşturabilecek şekilde dinamik bir çalışma ile yüzey EMG elde edinimi durumunda, oluşabilecek nemli koşullardan ya da terlemeden dolayı yüzeydeki kıl, tüy ve kirden arındırılması gerekmektedir. Bu sayede elektrotların deri yüzeyine daha iyi ve sıkı yapışması mümkün hale gelmektedir. Cilt yüzeyini temizlemede Konrad 3 farklı yöntem belirtmiştir. Aşındırıcı ve iletken olan yüzeydeki ölü deriyi

ve kiri elimine eden temizleme macunları kullanmak yöntemlerden biridir. Sürtünmeden dolayı zarar gelmeyecek şekilde dikkatli bir basınç uygulayarak yüzeyde zımpara kağıdı ile birlikte alkol ile temizlemek de bu yöntemler arasındadır. Son olarak yumuşak ancak sürtünmeye izin veren bir havluyla alkollü temizleme işlemi de yeterli bir alternatiftir. Yöntem seçimine ve seçilen elektrot türüne bakılmaksızın açık kırmızı renge sahip cilt tipi iyi bir empedans hali sergilemektedir. (Konrad, 2006)

3.6. sEMG İşaretinin Kaydedilmesi

Kas bilgisi küçük genlikli ve düşük frekanslı bir yapıya sahip olduğundan EMG yoluyla doğru olarak ölçülebilmesi için elektrotlar, amplifikatörler, sinyal görüntüleme araçları kullanılmaktadır. EMG amplifikatörleri yüksek giriş empedansına ve diferansiyel girişe sahiptir. Elektrotlar arasındaki potansiyel farkları tespit etmektedir. Amaç, 1) sinyal kaynağı ile kayıt cihazı arasında izolasyonu sağlamak, 2) akım voltaj dönüşümü, 3) voltaj kazancı sağlamak, 4) harici parazitleri ve artefaktları engellemektir. Şöyle ki harici gürültüler faz kayması olmadan iki elektroda ulaşır ve bu sinyaller ortak mod olarak bilinen aynı genlik ve frekansa sahiptir. Bu yüzden amplifikatörlerin ortak modu engellemek adına ortak mod bastırma oranlarının (CMRR) yüksek olup harici gürültüyü bastırması, elde edilen EMG işaretinin kalitesini önemli ölçüde etkilemektedir. SENIAM, CMRR değerinin 95 dB ‘den büyük olmasının kaliteli ve güvenilir EMG elde ediniminde kabul edilebilir değer olduğunu belirtmiştir. İdeal olarak bir EMG amplifikatörünün giriş empedansı, elektrot-cilt empedansının en az 10 katı olmalıdır. Yüzey elektrotlar için empedansın genellikle 1 M Ω olmasının yeterli olduğu ifade edilmiştir. Ölçüm sırasında elektrot empedansının ilk başta yüksek olabileceği ve daha sonra cilt – elektrot – elektrolit arasında bir denge kurulmasının ardından değişebileceğinin bilinmesi önemlidir. Genellikle elektrotlardan amplifikatöre bağlantı hattında kapasitif etkileri ortadan kaldırmak için ön amplifikatör kullanılmaktadır. Ön amplifikatör kabloların içine veya elektrotların

(aktif elektrotlar için) üzerine yerleştirilmektedir.(Konrad, 2006)(Soderberg & Cook, 1984)

EMG amplifikatörünün voltaj kazancı, çıkış sinyalinin giriş sinyaline oranı olarak tanımlanmaktadır. Amplifikatörün kazanç aralığı genellikle 100 ile 10000 arasında olmaktadır. Bunlar dışında amplifikatörün frekans cevabı ve bant genişliği de EMG ölçümünde önemlidir. Bant genişliği yüzey EMG'si için 10-1000 Hz'dir. (Soderberg & Cook, 1984)

sEMG sinyali elde edilirken istenmeyen bilgiler olan artefaktlar daha sonra uygulanan filtreleme işlemi ile elimine edilebilmektedir. 10-20 Hz arası yüksek geçiren bir filtre ile 500-1000 Hz arası alçak geçiren filtre uygulanmasının sEMG'deki önemli frekansları koruyacağı belirtilmiştir. (Stegeman & Hermens, 2007)

3.7.BIOPAC MP36 Veri Toplama Sistemi

Elektrik sinyallerini kaydetmek ve koşullandırmak için izole edilmiş güvenli yerleşik evrensel amplifikatörlere sahip MP36 deney seti AcqKnowledge BSLv4.1 yazılımıyla birlikte çalışan bir veri toplama ünitesidir. Transducer, sensör, prob ve elektrotlar bağlanarak hem insanlar hem de hayvanlar üzerinde birçok farklı ölçüm yapabilmekte ve elektriksel sinyaller (EMG, EKG, EEG gibi.) dışında görsel, işitsel uyarılar verebilmektedir. Sinyalleri elektrotlardan ve dönüştürücülerden alıp yazılımı sayesinde bilgisayar ortamında bu sinyalleri dalga formu şeklinde görüntülemektedir. Bu işlemleri yapabilmesini sağlayan dahili bir mikroişlemciye sahiptir. BIOPAC Sistem'in desteklediği, MP veri toplama birimlerinin özelliklerini barındırdığı platform ve teknik bilgi sayfalarından alınan bilgiler ışığında MP36 biriminin özellikleri aşağıda sıralanmıştır.

- Analog çıkışı ve 4 kanallı analog girişi bulunmaktadır. Şekil 3.11'de analog girişlerin bulunduğu ön panel gösterilmektedir.
- Kanalları aynı anda örneklenebilmektedir.

- 24 bit A/D örnekleme çözünürlüğü mevcuttur.
- $200\mu\text{V}$ ile 2 V arasında giriş (input) gerilim aralığına sahiptir.
- Sinyal gürültü oranı 89 dB min ‘den büyük ve CMRR minimum 85 dB’dir.
- IIR, otomatik ya da kişinin ayarlayabileceği yazılımsal filtreleme ve 20 kHz alçak geçiren, 5 - 0.5 - 0.05 Hz yüksek geçiren donanımsal filtrelemeye sahiptir.



Şekil 3.11. MP36 Ön Panel

Elektrotlar, dönüştürücüler MP36 birimine bağlanmalı, MP36 birimi ise bilgisayara bağlanmalıdır. Bu tez çalışmasında, MP36 biriminde EMG sinyalinin kaydı için bağlantı BSL-SS2LB seri port kablo ile sağlanırken, açılı ölçüm düzeneğinin bağlantısı 9 pinli D-sub konnektör ile yapılmıştır. MP36 biriminin bilgisayara bağlantısı USB kablo ile sağlanmıştır. Şekil 3.12’de MP36 birimi, seri port kablolar ve bu tez çalışması için yapılan açılı ölçüm düzeneğinin bağlantısı gösterilmektedir.




Şekil 3.12. MP 36 Veri Toplama Seti ve Açı Ölçüm Düzenegi


3.8. Açı Ölçüm Düzenegi

Bu tezde biceps ve triceps kasılma bilgisi ile eş zamanlı olarak açı işaretinin elde edilmesi adına, açı ölçüm düzeneğinin ilk olarak SOLIDWORKS ortamında tasarım çizimi yapılmıştır. (Şekil 3.13) Burada kullanılan Jane 3D insan modeli ücretsiz bulut tabanlı GrabCAD ortamından alınarak, bu model üzerinde açı ölçüm düzeneği tasarımı yapılmıştır. Daha sonra çizilen yapıya uygun olarak tasarımı Şekil 3.14'te gösterildiği gibi gerçekleştirilmiştir.

Açı ölçüm düzeneği sağ kol için tasarlanmıştır. Doğru ve tutarlı ölçümler alabilmek adına kestamit malzemenin kullanıldığı üst kolda bulunan parça, bir destek ile omuza sabitlenmiştir. Aynı sabitleme bilek kısmına doğru olan levhaya da yapılmıştır. (Şekil 3.14)



Şekil 3.13.Solidworsk Ortamında Açı Ölçüm Düzeneginin Çizimi




Şekil 3.14. Açı Ölçüm Düzenegİ

Kullanılan yerdeki veriyi elektriksel işarete dönüştüren yapılar sensör olarak adlandırılmaktadır. Bir referans noktasına göre pozisyonu belirlemek için pozisyon sensörleri kullanılmakta ve bu sensörler yapılarına göre temaslı ve temassız olarak ayrılmaktadır. Temaslı pozisyon sensörleri ölçüm için fiziksel bir temas kontağı kullanmaktadır. Temassız yapıda ise manyetik, elektromanyetik veya elektrik alan aracılığıyla ölçüm yapılmaktadır. Temel mantığı, endüktif yapıda olan bir bobinin sürekli olarak değişen manyetik alan içinde bulunduğu sırada uçlarda sürekli bir gerilim oluşturmastır.

Yapılan bu tez çalışmasında açılı ölçümü için Bourns firmasına ait AMS22B pozisyon sensörü kullanılmıştır. (Bourns,2015) Pnömatik kontrol valfi konumu geri bildirimi, uzaktan iletişim anteni konumlandırma, aktüatör motor konumu geri bildirimi ve ayak pedalı, direksiyon, kaldır, götür ve süspansiyon sistemleri gibi birçok uygulamada kullanılabilir. AMS22B temassız manyetik ölçüm yapan bir analog döner konum sensörüdür. VDD besleme gerilimi 5V ($\pm\%10$), tek analog çıkış 12 bit çözünürlük, maksimum 500 RPM özelliklerine sahiptir. Şekil 3.15'te AMS22B pozisyon sensörü gösterilmiştir. Şekil 3.16'da mil dönme açısı derecesine göre değişen analog voltaj çıkış grafiği görülmektedir. Çalışmada A tipi kullanıldığından kalibrasyon işleminde bu eğri baz alınmıştır.




Şekil 3.15. AMS22b Pozisyon Sensörü (Bourns, 2015)



Şekil 3.16. Sensörün Mekanik Açı Değişimine Göre Voltaj (Vout) Çıkışı (Bourns, 2015)

Üst ve alt kol sabitlemesi ile sensörün bağlantısı için kullanılan parçalar kestamit levha olarak seçilmiştir. Poliamid grubundan döküm yolu üretilen bir plastik çeşididir. Aşınma dayanımı yüksek, iyi yapışma özelliği, kolay işlenilebilirliğinin yanı sıra mekanik mukavemetinin yüksek olması açı ölçüm düzeneği için tercih edilmesinde önemli kriterlerdir. Şekil 3.23'te açı ölçüm düzeneği için kullanılan 10 mm kalınlığında 50 x 170 mm ve 50 x 190 mm boyutlarında kestamit levhalar gösterilmektedir.



Şekil 3.17. Kestamit Levhalar

sEMG sinyal kaydı ile eş zamanlı açı bilgisinin elde edilmesi için açı düzeneğindeki enkoder,D-sub konnektör ve bir gerilim bölücü ile MP36 ünitesine bağlanmıştır. Şekil 3.18'deki 0-180° aralığa sahip açı çizelgesi referans alınarak (180°'den 10 ar 10 ar azalarak) açı voltaj arasındaki ölçekleme kontrol edilmiştir. Enkoderin 3,5 V-1,5 V aralığına göre, MP36 ünitesinin CH3 kanalı ayarlanmıştır.



Şekil 3.18. Açı Ölçüm Düzeneği MP36 İçin Derece Ayarlaması

Birbiri ile ilişkili değişkenleri ilintilendirmek, temelde bir hata teriminin minimize edilmesi ile gerçekleştirilmektedir. Bunun için sık kullanılan regresyondaki en küçük kareler yöntemi ile kanal ayarında voltaj ve açı değeri arasındaki ilişki incelenmiştir. Lineer bir ilişki oluşturacak olan $y=ax+b$ denklemi ile yaklaşım yapılmıştır. Buna göre n tane veri için toplam hata:

$$E^2 = \sum_{i=1}^n (y_i - ax_i - b)^2 \quad (3.1)$$

Denklem 3.1'den yola çıkarak a ve b bilinmeyenleri için 2 denklem elde edilir.


$$\sum_{i=1}^n (y_i - ax_i - b) x_i = 0 \quad (3.2)$$

$$\sum_{i=1}^n (y_i - ax_i - b) = 0 \quad (3.3)$$

Denklem 3.2 ve 3.3 ile bağımsız açı değişkenleri (x) ile bağımlı voltaj değişkenleri (y) arasındaki ilişki denklem 3.4 ile ifade edilir.

$$y = -0,0146x + 4,4399 \quad (3.4)$$

Bu denklemin doğrusu hatayı minimize ettiğinden bir eğri uydurmak istenirse eğrinin doğruluk ölçütü için R^2 kullanılmaktadır. Buna göre $R^2=0,997$ 'dir. Yaklaşım yapılan denklemin grafiği Şekil 3.19'da gösterilmektedir.



Şekil 3.19. Açı ve Voltaj Arasındaki İlişki

Bu hesaplardan yola çıkarak CH3 kanalı için yapılan ölçekleme değerleri çizelge 3.1’de gösterilmektedir.CH3 kanalına 90° ve 180° için karşılık gelen voltaj değerleri girilmiş ve BIOPAC’te voltaj bilgisinin açı bilgisi olarak elde edilmesi sağlanmıştır.

Çizelge 3.1. Açı Bilgisinin Derece Olarak Elde Edilmesi İçin Yapılan Ayar

CH3 Kanalı	Input Milivolts	Map Value (degree)
1	907,33 mV	180 °
2	1607,99 mV	90 °

3.9. Veri Toplama ve Ölçümler

Herhangi bir kas problemi olmayan bir denekten sEMG ölçümü biceps ve triceps kasından iki çift bipolar yüzey elektrotları yerleştirilerek alınmıştır. (yaşı 25, ağırlığı 50kg olan bayan) Denekten veriler elde edilirken paraziti engellemek adına laboratuvar ortamındaki diğer cihazların kapatılmasına dikkat edilmiştir. Sensörler ve sensör yerleşimi hakkında çalışmalar yapan, sEMG için sinyal işleme yöntemleri içeren, eğitim test için bir takım model barındıran, SENIAM (kasların non-invaziv değerlendirilmesi için yüzey elektromyografi) ölçüm sistemi dikkate alınarak ölçümler yapılmıştır. (Stegeman & Hermens, 2007) Buna göre ilk olarak cilt yüzeyi alkollü bir pamuk ile silinmiş ardından jel sürülmüş tek kullanımlık elektrotlar, SENIAM tarafından önerilen referans noktalara göre yerleştirilmiştir. Kasta meydana gelebilecek yorulmalar ve deri direncindeki farklılıkları da göz önüne almak adına ölçümler özellikle farklı günlerde yapılmıştır. Deneğin, çalışmadaki izotonik ve izokinetik 2 kasılma türünü, 24 saatlik aralıklarla flexion ve extension hareketini sağlayarak gerçekleştirmesi istenmiştir. Denek, istenen bu hareketleri hiç ağırlık olmadan (serbest el), 0,5 kg ağırlık ve 1 kg ağırlıklar ile tekrarlamıştır.


Şekil 3.20’de görülen, sağ kol için tasarlanan EMG ölçüm düzeneğindeki sensörün düzenekteki bağlantılar ile deneğin tam dirseğine göre konumlandırılması

sağlanmıştır. Ardından dik oturması; izokinetik kasılda flexion ve extension hareketini sürekli olarak tekrarlaması; izotonik kasılma da ise flexion ve extension hareketlerini bekleme yaparak, kesikli adım adım tekrarlaması istenmiştir.




Şekil 3.20. Deneğin Ölçüme Hazır Durumu

Ölçümlerin her biri için yaklaşık 350 sn'lik kayıt alınmıştır. Ölçümlerde sEMG sinyallerinin alındığı 2 kanal için örnekleme hızı 500Hz, açı bilgisinin alındığı diğer kanal için örnekleme hızı 250Hz seçilmiştir. Şekil 3.21 ve 3.22 Biopac ortamında izotonik ve izokinetik kasılma türü için birer tane ölçüm örneği dirsek eklem açısı bilgisi ile beraber gösterilmiştir. Yukarıdan aşağıya biceps, triceps kasılması ve bu sırada eş zamanlı alınan açı bilgisi sıralanmaktadır. Alınan sinyallere Biopac ortamında 20-250Hz ile sınırlayan bant geçiren filtreleme uygulanmıştır. MATLAB ortamına aktarılırken kayıtlı veride; zaman (dk cinsiden)-biceps ile triceps kasılması ve açı bilgisi bulunmaktadır.



Şekil 3.21. EMG İşareti ve Dirsek Eklem Açısı (izotonik_yük1_veri1)



Şekil 3.22. EMG İşareti ve Dirsek Eklem Açısı (izokinetik_yük1_veri3)

3.10. Veri Seti Hazırlanması

MATLAB ortamına aktarılan ölçümler ile sinir ağına verilmek üzere uygun veri setleri oluşturulmuştur. Eğitim ve test için hazırlanan bu veri setleri; 3 izotonik, 3 izokinetik hareket olan toplam 6 farklı ölçümden farklı aralıklarda örnekler alınarak, farklı ağırlık ve kasılma türüne göre rastgele birleştirilmiştir.

Çizelge3.2’de gösterildiği üzere eğitim ve test için kullanılacak verilerin hepsi kasılma türü ve ağırlığa göre isimlendirilmiştir. Boyutu küçültmek adına 350 saniyelik her ölçümün tüm değerleri alınmamıştır. Kasılmaların net bir şekilde belirgin analiz edilebilir olduğu örnek aralıkları seçilmiştir. (Çizelge 3.2) Oluşturulan eğitim ve test verisinin sıralaması ise Çizelge3.3 gösterilmektedir.

Çizelge 3.2. Veri Setlerinin Oluşturulması

Ölçümler	Ağırlık (kg)	Alınan Örnek Aralığı	Matris Boyutu
Eğitim İçin Seçilen			310794x4
izotonik_serbest_el_veri4	0	(110000:161798)	(51799x4)
izotonik_yük0.5_veri1	0,5	(66000:117798)	(51799x4)
izotonik_yük1_veri1	1	(66000:117798)	(51799x4)
izokinetik_serbest_el_veri4	0	(66000:117798)	(51799x4)
izokinetik_yük0.5_veri3	0,5	(66000:117798)	(51799x4)
izokinetik_yük1_veri4	1	(66000:117798)	(51799x4)
Test için Seçilen			222356x4
izotonik_serbest_el_veri1	0	(7187:138100)	(67791x4)
izotonik_yük0.5_veri1	0,5	(72390:138100)	(65711x4)
izotonik_yük1_veri1	1	(81370:149100)	(48924x4)
izokinetik_serbest_el_veri3	0	(83020:96349)	(13330x4)
izokinetik_yük0.5_veri2	0,5	(83020:96349)	(13330x4)
izokinetik_yük1_veri3	1	(83020:96349)	(13330x4)

Çizelge 3.3. Eğitim ve Test Verisi İçin Ölçümlerin Sıralaması

Verilerin Sıralanması	
Eğitim Verisi	izotonik_serbest_el_veri4 izokinetik_yük1_veri4 izokinetik_serbest_el_veri4 izotonik_yük0.5_veri1 izotonik_yük1_veri1 izokinetik_yük0.5_veri3
Test Verisi	izokinetik_serbest_el_veri3 izotonik_yük1_veri1 izotonik_serbest_el_veri1 izokinetik_yük0.5_veri2 izotonik_yük0.5_veri1 izokinetik_yük1_veri3

3.11. Zaman Düzlemi Öznitelik Çıkarımı

Zaman düzlemi öznitelikleri için herhangi bir dönüşüm işlemi yapılmadan basit ve hızlı hesaplanabilir. (Pinyomark, 2013; Guvenc et al., 2014 ‘ten) (Guvenc et al., 2014) Bu nedenle çalışma kapsamında literatürde yaygın olarak kullanılan yöntemler incelenmiş ve ortalama mutlak değer, dalga formu uzunluğu, etkin değer olan ortalama karekök, ve varyans tercih edilmiştir.

1) Ortalama Mutlak Değer (MAV-OMD): Her bir pencerenin mutlak değerlerinin ortalamasını alınır. Diğer özniteliklerle birlikte kullanıldığında güçlü bir ayırıştırıcıdır. Denklem 3.5’de MAV_k bir k segmentindeki tüm x_n değerlerini ekler ve N değerine bölüp hesaplamaktadır. Burada n penceredeki her bir veriyi, N

pencere boyunu ve x_n ise hesaplanan OMD değerini ifade eder. Kas kontrolü için kullanılan yaygın bir özelliktir. (Scott 1967:Guvenc ve ark., 2014'ten)

$$MAV_k = \frac{1}{N} \sum_{n=1}^N |x_n| \quad (3.5)$$

2) Dalga Formu Uzunluğu: Dalga biçiminin zaman segmenti üzerindeki kümülatif uzunluğudur. Dalga formunun genliği, sıklığı ve zamanı ile ilişkilidir.(Phinyomark et al., 2016) Pencere boyunca örnekten örneğe genliklerdeki artan değişimleri ölçer.

$$WL = \sum_{n=1}^{N-1} |x_{n+1} - x_n| \quad (3.6)$$

3) Etkin Değer (RMS): Kök ortalama kare değeri, her bir veri noktasının karesi alınarak, kareler toplanarak, ardından toplamı gözlem sayısına bölerek ve son olarak karekök alınarak hesaplanır. (Hudgins ve ark., 1993:Eroğlu & Baysal, 2018'den)EMG sinyallerinin işlenmesinde sık kullanılan bir değerdir. Sabit kuvvet ve yorulmayan kasılma ile ilgilidir. (Phinyomark et al., 2009).

$$RMS = \sqrt{\frac{1}{N} \sum_{n=1}^N x_n^2} \quad (3.7)$$

4) Sıfır Geçiş Tespiti Sayısı (SGTS): Her bir pencere içerisinde sinyalin pozitif bir değerden sıfır değerine ya da negatif bir değerden sıfır değerine ulaştığı yerlerin tespit edilerek sayılmasıdır. Bu öznelik ile belirli bir eşik seviyesi üzerindeki sinyallere ait önemli değişiklikler sıklığı bilgisi çıkartılır.(Guvenc et al., 2014)

$$SGTS = \sum_{n=1}^N [sgn(-x_i \times x_{n+1}) \cap |x_n - x_{n+1}| \geq thr] \quad (3.8)$$

5) Varyans (Var): Sinyalin varyansı, kendisi ile olan ilişkisidir. Bu değer, her bir sinyal bilgisinin birbirinden ne kadar farklı olduğunun bir ölçüsünü verir. EMG'nin varyansı (VAR), sEMG sinyalinin gücünü bir özellik olarak kullanır. Genel olarak varyans, o değişkenin sapmasının karesinin ortalama değeridir. Bununla birlikte, EMG sinyalinin ortalaması sıfıra yakındır. Sonuç olarak, EMG'nin farklılığı denklem 3.9'teki gibi hesaplanabilir.(Phinyomark et al., 2016)

$$VAR = \frac{1}{N-1} \sum_{n=1}^N x_n^2 \quad (3.9)$$

6) Özbağlanım Katsayıları (AR): Çoğu sistem geçmişteki çıkışlarının, o andaki ve geçmişteki girişlerinin doğrusal kombinasyonları ile modellenir. Burada en çok kullanılan model AR modelidir.


$$X_k = \sum_{i=1}^p a_i x_{k-i} + e_k \quad (3.10)$$

Denklem 3.10'da X_k , sistemin k. ayrık zamandaki kaydedilen işaretini, a_i AR model parametrelerini, p AR modelinin derecesini, e_k ise beyaz gürültüyü ifade etmektedir.(Karlık et al., 2005)

3.12.Sınıflandırma için Yaygın Kullanılan Sinir Ağları

3.12.1.Çok Katmanlı Algılayıcı Sinir Ağı

Biyolojik sinir hücrelerine benzer yapay bir sinir ağında bilgi işleme birimi olan ve yapay sinir ağlarının temelini oluşturan nöron modeli Şekil 3.23'te verildiği gibidir.



Şekil 3.23.Yapay Nöron Modeli Girdi, Ağırlık ve Çıktı Gösterimi(Haykin, 2017)

Şekil 3.10’da yer alan k. nörona ait modelde sinaptik girişteki x_j , sinaptik ağırlık w_{kj} ile çarpılır ve toplanarak genliğini sınırlamak adına aktivasyon fonksiyonundan geçirilir. Sonuçta y_k çıktısı elde edilir. Bu tıpkı bir biyolojik nöron gibi farklı ağırlıklara (dendrit) sahip bir dizi girdinin (sinaps) bir araya toplanması (hücre gövdesi) şeklindedir. (Haykin, 2017)(Laezza, 2018) Denklem 3.11 ve 3.12 şeklindeki yapının matematiksel olarak tanımlanmasını göstermektedir. Denklem 3.11’de ağırlık ve girdini çarpımının aritmetik toplamı ile u_k çıktısı elde edilir.

$$u_k = \sum_{j=1}^m w_{kj} x_j \quad (3.11)$$

$$Output(y_k) = \phi(u_k + b_k) \quad (3.12)$$


Net girdi olarak ifade edilen u_k bias değeri ile bir aktivasyon fonksiyonundan geçerek denklem 3.12 gibi bir çıktı oluşturur. Aktivasyon fonksiyonu çıktıları verileri anlamlandırabilmek için kullanılan bir yapıdır. Genellikle non-linear fonksiyonlar seçilmektedir.(Taşar, 2016) Bunun en önemli

sebebi lineer bir modele non-lineer bir fonksiyon uygulanırsa YSA'lar için önemli bir kavram olan ve değerinin düşük olması istenen hata oranını azaltmayı, yani sistemin türevlenebilir olmasını mümkün kılar. Sigmoid, tanh, relu en çok kullanılan aktivasyon fonksiyonlarından bazılarıdır.

İfade edilen yapay sinir nöronlarının birbirine bağlanmasıyla oluşan YSA'lar bir giriş katmanı ardından gizli katman ve bir çıkış katmanından oluşmaktadır. Girdi olarak verilecek değer kadar nöronu bulan giriş katmanındaki girdi verisi bir işleme uğramadan gizli katmana aktarılır. Tasarlanan modele bağlı olarak birden fazla gizli katman ya da farklı sayıda nöron bulunabilir. Gizli katmanda anlamlandırılan bilgi çıkış katmanına iletilerek ağı çıktılar üretilir. Geri beslemeli bir ağda ağırlık değerlerinin güncellenmesi için çıktılar tekrar ağa gönderilir. (Taşar, 2016)


Temelde 3 farklı YSA mimarisi mevcuttur. Bunlar; tek katmanlı ileri beslemeli ağ, çok katmanlı ileri beslemeli ağ ve tekrarlayan ağdır. Buradaki tekrarlayan sinir ağları 3.7.1'de ayrıntılı ifade edilmiştir. Tek katmanlı ağlar, giriş katmanında hesaplama yapılmadığından bu katmanın sayılmadığı giriş doğrudan bir çıkış nöron katmanına bağlıdır. (Haykin, 2017)

Çok katmanlı ileri beslemeli bir sinir ağında giriş sinyalleri çıkışa verilmeden önce bir veya daha fazla gizli katmandaki nöronlardan aktarılacak ağı çıktısı elde edilir. Giriş sinyalleri ilk gizli katmana uygulandıktan sonra elde edilen sonuçlar çıkış olan son katmanın girişleridir. Şekil 3.11'de gösterildiği gibi ağı her katmanındaki nöronların girişleri bir önceki katmanın çıkış sinyalini almaktadır.(Haykin, 2017) Çok Katmanlı Algılayıcı (MLP) ileri beslemeli yapay sinir ağlarının bir sınıfıdır. MLP ağları en az 3 düğüm katmanından oluşmaktadır. Şekil 3.24'teki gibi MLP giriş düğümleri hariç diğer katmanları aktivasyon fonksiyonu kullanmaktadır.

Giriş Katmanı**Kaynak Düğümler****Gizli Katman Nöronları****Çıkış Katmanı Nöronları**

Şekil 3.24.Gizli Katmana Sahip İleri Beslemeli Bir Ağ

Geri beslemeli yapay sinir ağlarında (GBYSA) ise bir hücrenin çıktısı hem kendinden sonra gelen hücrenin katmanına hem de kendinden önceki katmanda ya da kendi katmanında bulunan diğer bir hücreye girdi olarak verilebilir. Bu yapı GBYSA'na doğrusal olmayan bir dinamik kazandırmaktadır. GBYSA'da nöronların bağlantı şekillerinin YSA'nın farklı davranış ve yapılar kazanmasını sağladığı ifade edilmiştir. (Taşar, 2016) Amaç ağdaki ağırlıkların her birini güncellemek ve bu sayede gerçek çıktının hedef çıktıya daha yakın olmasına neden olmasını sağlamaktır. MLP sinir ağında eğitim için geri yayılım kullanılmaktadır.



Şekil 3.25.Hata Sinyallerinin Geri Yayılmasıyla Sinyal Akış Grafiği

Genel olarak Şekil 3.25 ‘de j. Nöron tarafında üretilen fonksiyon sinyallerinin ($v_{1-m_l}(n)$) sonuçları geri yayılım ile ağırlığın toplam hataya etkisi bulunur ve ağırlık güncellemesi yapılır. (Haykin, 2017)


3.12.2.Derin Öğrenme Yöntemi

Geleneksel sEMG tabanlı örüntü sınıflandırmada anlamlı girdi verisi oluşturabilmek ve sınıflandırma yapan bir sinir ağını tasarlamak önemli aşamalardandır. Geleneksel makine öğrenme algoritmaları yerine derin öğrenme teknikleri bu çalışmada sEMG sinyalinden dirsek eklem açısı tahmini için kullanılmıştır. sEMG sinyalinin sıralı doğasından dolayı uzamsal bilgilerini yakalayabilen ve öğrenmede başarılı olan derin öğrenme tekniği tekrarlayan sinir ağı BiLSTM tasarlanmıştır. Tasarlanan derin öğrenme yöntemine genel bakış aşağıdaki başlıklarda sunulmuştur.

3.12.3. Tekrarlayan Sinir Ağları

Tekrarlayan veya Yinelenen Sinir Ağı (RNN), 1986 yılında David Rumelhart'ın çalışmalarına dayanan bir derin öğrenme sınıfıdır. (Pedrycz & Chen, 2020) RNN genel olarak birimler arasındaki bağlantıların yönlendirilmiş bir döngü oluşturduğu, derin öğrenmede yaygın olarak kullanılan bir yapay sinir ağı sınıfıdır. İleri beslemeli sinir ağlarının aksine, RNN'ler giriş belleğini girdilerin rastgele dizilerini işlemek için kullanabilmektedir. (Şeker et al., 2017) Sistemde geri döngü bildirimleri bulunan RNN, sıralı verileri işlemede, zamana bağlı, belirli bir sırayla giden ya da çok değişkenli dizi tahmini gibi bir diziden başka bir diziye tahmin problemlerinde, giriş ve çıkış arasındaki ilişkiyi kurabilmektedir. Veri noktaları arasında bağımsızlık sağlayan standart sinir ağlarının aksine, RNN'ler veriler arasındaki sıralı ve zaman bağımlılıklarını etkin bir şekilde yakalar. Bu nedenle, video analizi, görüntü altyazısı, doğal dil işleme (NLP) ve müzik analizi gibi problemlerde bir çözüm olmaktadır. (Pedrycz & Chen, 2020)

RNN ile ilgili en tanımlayıcı özelliklerden biri parametre paylaşımıdır. Parametre paylaşımı olmadan, bir model, bir dizideki her veri noktasını temsil etmek için benzersiz parametreler tahsis eder ve bu nedenle, değişken uzunluk dizileri hakkında çıkarımlar yapamaz. Bu kısıtlamanın yanı sıra RNN girişteki veriyi bir önceki çıktı bilgisi ile ilişkilendirerek sınıflandırma ya da tahmin yapar. Bir önceki çıktı ile ilişkilendirilmesi short time memory kavramı ile ifade edilmiştir ve bu durum çıktının bir sonraki katman için hafızada saklı kalmasını sağlamaktadır. (DATAI Team, 2020) Şekil 3.26'da RNN topolojik yapısı gösterilmektedir.



Şekil 3.26. RNN Ağ Yapısı

RNN'ler genellikle geleneksel çok katmanlı ağ mimarisini, bitişik düğümleri veya zaman adımlarını bağlayan döngülerin eklenmesiyle artırır. Bu döngüler, yakın geçmişten veri noktalarına göre eldeki mevcut veri noktasının özelliklerini değerlendirmek için kullanılan ağın dahili belleğini oluşturur. Girişler ile çıkışlar ve kayıp arasındaki eşlemeleri göstermek için bir hesaplama grafiği kullanılır. Grafiğin bir olaylar zinciri halinde açılması, ağ içindeki parametre paylaşımının net bir resmini sağlar. Yineleme ilişkileri için genelleştirilmiş bir denklem ile ifade edilirse denklem 3.13'deki gibidir:


$$s^{(t)} = f(s^{(t-1)}) \quad (3.13)$$

Burada s^t , $t-1$ ile gösterilen bir önceki zaman adımına bağlı olan sistemin durumunu göstermektedir. Bu denklem biraz daha ayrıntılı ifade edilirse:

$$h^t = f(h^{t-1}, x^t) \quad (3.14)$$

Denklem 3.14'da yer alan h^t şimdiki durumu temsil etmek için kullanılmıştır ve x^t belirli bir zaman örneğinden gelen girdiyi belirtmektedir. h^t 'nin önemi, t'ye kadar olan geçmiş girdi dizisinin görevle ilgili yönlerinin bir temsili olmasıdır. (Şekil 3.27) Burada her düğüm bir zaman örneğiyle ilişkilendirilmiştir. (Pedrycz & Chen, 2020)

RNN, veriler arasındaki sıralı bağımlılıkları parametre paylaşımıyla etkin bir şekilde yakalamaktadır. Girişteki her veri grubunu ayrı ele almaz. Yakın geçmişteki veri noktalarına göre mevcut veri noktasının özelliklerini değerlendirerek bir bellek oluşturur ve bu şekilde çıkarım yapar. (Pedrycz & Chen, 2020)



Şekil 3.27.RNN için Katlanmamış Bir Hesaplama Grafiği


RNN mimarilerinin bazı önemli eksikleri bulunmaktadır. Teorik olarak RNN yapıları, bilgileri uzun süre hatırlayabilir ancak pratikte bu her zaman geçerli değildir. Özellikle kaybolan gradyana eğilimli yapıdadır. Referanslar arasındaki boşluk küçük kalırsa, RNN bilgi bitlerine atıfta bulunmak için iyi çalışır. RNN'nin zarar görmeye başladığı nokta, referans verilen veriler arasındaki boşluğun artması

ve RNN'nin bu veriler arasında her zaman bağlantı kuramamasıdır. Uzun Kısa Süreli Bellek (LSTM) bu sorunları gidermek için önerilen geleneksel RNN mimarisinin varyantıdır. LSTM mimarisi, kaybolan gradyana karşı koymak için sabit birim ağırlıklara sahip tekrarlayan kenarları kullanmaktadır.(Pedrycz & Chen, 2020)

3.12.4. LSTM Ağ Yapısı

Uzun Kısa Vadeli Bellek (LSTM), rastgele aralıklarla değerleri hatırlayan en yaygın RNN mimarisidir. İlk olarak 1997 yılında Hochreiter ve Schmidhuber tarafından tanıtılmıştır. Geleneksel RNN'lerin sıkıntıya düştüğü uzun vadeli bağımlılık sorunundan kaçınarak gradyen kaybolma problemini çözümleyerek tahminler yapmak için iyi çalıştığı ifade edilmiştir.(Pedrycz & Chen, 2020)

Kaybolan gradyan problemi, gradyan inişi, geri yayılımla birlikte bir optimizasyon algoritması olarak kullanıldığında ortaya çıkmaktadır. (Hochreiter, 1997:Pedrycz & Chen, 2020'den) Bağımlılıklar arasında boşluk boyutları arttıkça, hata gradyanları katlanarak yok olur ve bir ağın eğitiminin çok yavaş olmasına, hatta bazen öğrenememesine neden olabilmektedir. Bunun için sık kullanılan optimizasyonlardan Stokastik gradyan inişinde, gradyan, zincir kuralı ile geri yayılım kullanılarak gradyan, ağırlıklara göre kayıp fonksiyonunun kısmi türeviyle hesaplanır. Stokastik gradyan inişini kullanarak, ağın parametrelerini optimize etmek için yalnızca bir eğitim örneği kullanılır ve ağı eğitme süresini önemli ölçüde azaltır.(Pedrycz & Chen, 2020)




Şekil 3.28. RNN Zincir Yapısı

Ağdaki parametrelerde yapılan güncellemeler zincir kuralı kullanılarak uygulanır. Zincir kuralıyla, gradyanlar, ağıın önüne doğru ilerledikçe, her düğümden alınan ağırlığa göre maliyet fonksiyonunun türevinin ürünü olarak hesaplanır. Gradyan daha sonra işlevlerin ağırlıklarını önceki düğümlerden güncellemek için kullanılır. Katmanlar arasındaki zaman bağımlılığı arttıkça, ağırlığa ilişkin "gözden kaybolan" küçük düzeltmeler nedeniyle ağırlıklar yalnızca marjinal olarak güncellenir. (Şekil 3.28) Eğer gradyan birden küçük değere sahipse, gradyan, ağıın geri yayılmasıyla üssel olarak küçük hale gelir; öğrenme ile çarpıldıklarında oranları daha da küçülür. Ağırlıklar eğitim için bir ağ kurarken başlangıçta rastgele bir sayıya ayarlandığından, başlangıçta daha büyük kayıplara sahip olma eğilimindedirler, bu da ağırlıklar yalnızca marjinal olarak ayarlandığından, kaybolan gradyan problemi sorununun birleştirebilir. LSTM hücre yapısı ve kapıları bu sorunu çözer. (Pedrycz & Chen, 2020)

LSTM, önceki durumlardan bilgi olarak uzun girdi dizilerini öğrenip hatırlayabilen bir yapıya sahiptir. LSTM mimarisi kritik bileşenleri olan giriş,

unutma, çıkış kapılarına, bellek hücresine ve aktivasyon fonksiyonlarına sahiptir. (Chen et al., 2019) LSTM'in farklı varyasyonları vardır, ancak hepsi ağırlıklı olarak bu bilinen üç kapıyı içermektedir. Bellek hücresinin içeriği giriş kapıları tarafından modüle edilir ve kapıları unuttur. Bu kapıların her ikisinin de kapalı olduğunu varsayarsak, hafıza hücresinin içeriği bir zaman adımı ve sonraki arasında değişmeden kalacaktır. Geçiş yapısı, bilginin birçok zaman adımında tutulmasına izin verir ve sonuç olarak gradyanların birçok zaman adımı boyunca akmasına izin verir. Bir LSTM ağının katlanmamış grafiği, bir katmandan diğerine geçen verilerin, doğrusal etkileşimler ile giriş ve unutma kapıları kullanılarak her katmandan geçerken biraz değiştirildiği bir konveyör bandı olarak düşünülebileceği belirtilmiştir. (Pedrycz & Chen, 2020)



Şekil 3.29.Bir LSTM Biriminin Kapıları

Şekil3.29 bir LSTM gizli katman yapısı gösterilmektedir. Burada h_{t-1} bir önceki katmandan gelen çıktı bilgisidir. x_t , giriş verisi ile birlikte hafıza yoluna ($C_{t-1} - C_t$) ve diğer tüm kapılara bağlanmaktadır. Unutma kapısı, bilgiyi hücre durumundan çıkarmaktan sorumludur ve amacı, hangi bilginin artık yararlı olmadığını ve unutulabileceğini belirlemektir. Şimdiki giriş olan $x_{(t)}$ 'yi ve önceki hafıza hücresinden gelen gizli durum $h_{(t-1)}$ olan 2 girdiyi almaktadır. Girişler ağırlık matrisleriyle çarpılır ve bir sapma eklenir. Bundan sonra bir sigmoid işlevi uygulanır; sigmoid işlevi, hangi değerlerin tutulacağına ve hangilerinin atılacağına karar vermekten sorumludur. Bu işlev 0 ile 1 arasında değerlere sahip bir vektör çıkarmaktadır. 0, unutma geçidinin bilgiyi tamamen unutmak istediğini belirtirken, 1 çıkışı, unutma geçidinin tüm bilgi parçasını hatırlamak istediğini göstermektedir. Giriş kapısı ise 2 adımlı bir süreci içermektedir. Hücre durumuna hangi yeni bilgilerin ekleneceğine karar vermekten sorumludur. Unutma geçidine benzer şekilde, $h_{(t-1)}$ ve $x_{(t)}$ 'ye bir sigmoid işlevi uygulanır. Bir hiperbolik tanjant fonksiyonu, -1 ile 1 arasında değişen tüm olası değerlerin bir vektörünü oluşturmaktadır. Bu vektör, hücre durumuna eklenebilecek aday değerleri gösterir. Son olarak çıkış kapısı, 3 adımlı bir işlemde çıktı olarak hücre durumundan yararlı bilgileri seçer. İlk adımda, hücre durumuna hiperbolik bir teğet işlevi uygulanır ve -1'den 1'e kadar ölçeklenmiş değerlere sahip bir vektör oluşturulur. Adım 2, $h_{(t-1)}$ ile $x_{(t)}$ ve sigmoid işlevini kullanmaktır. Son adımda, adım 2'deki düzenleyici filtre adım 1'deki vektörle çarpılarak bir sonraki hücreye bir çıktı ve gizli durum üretilir. (Pedrycz & Chen, 2020) Ağ, LSTM'yi kullanarak herhangi bir uzun vadeli bağımlılığı en aza indirebilir ve 1000 adımı aşan veri referanslarındaki boşlukları kapatabilir. (attention-dikkat mekanizması ile) (Hochreiter ve ekibi, 2018; Pedrycz & Chen, 2020'den) Önceki bilgi hafızada tutulduğu için bu ağ yapısı uzun vadeli öğrenme sağlamaktadır. Kaybolan gradyan problemini çözümlenmeyi birimdeki tanh fonksiyonu mümkün kılmaktadır. Bu sayede güncellenen verileri

anlamlandırabilmek için değişimin türevi sıfıra uzun bir süre yaklaşmaz ve geri yayılım sağlanarak öğrenme sürdürülür.

$$f_t = \sigma_g(W_f y_t + U_f h_{t-1} + \beta_f) \quad (3.15)$$

$$i_t = \sigma_g(W_i y_t + U_i h_{t-1} + \beta_i) \quad (3.16)$$

$$O_t = \sigma_g(W_o y_t + U_o h_{t-1} + \beta_o) \quad (3.17)$$

$$h_t = O_t \circ \sigma_h(c_t) \quad (3.18)$$

$$C_t = f_t \circ \sigma_{t-1} + i_t \circ \sigma_c(W_c y_t + U_c h_{t-1} + \beta_c) \quad (3.19)$$


Şekil 3.29'daki LSTM biriminin kapıları ve bu kapılara ait ağırlık matrisleri denklem 3.15-3.19 arasında gösterildiği gibi bir ilişkiye sahiptir. Bir LSTM katmanında i_t t. zamanındaki girişi, f_t unutma kapısını, c_t hafıza kapısını, h_t bir sonraki birime aktarılacak çıktı bilgisini ifade etmektedir. W, U ve β katmandaki kapılara bağlı ağırlık matrisi ve bias değerleridir.

3.12.5.BiLSTM Ağ Yapısı

BiLSTM fikri, sekans verilerini iki ayrı gizli katmanla hem ileri hem de geri yönde işleyen çift yönlü (bidirectional) RNN'den gelmektedir. (Schuster & Paliwal, 1997) Giriş dizisinin tüm zaman adımlarının mevcut olduğu problemlerde, Çift Yönlü LSTM'ler giriş dizisinde bir LSTM yerine iki tane çalıştırmaktadır. Birincisi olduğu gibi giriş dizisi üzerinde ve ikincisi giriş dizisinin ters bir kopyası üzerindedir. Bu, ağa ek bağlam sağlayabilir ve sorunla ilgili daha hızlı ve hatta daha eksiksiz öğrenmeyi mümkün kılabilir. (Graves ve ekibi, 2003) Fonem sınıflandırması (Graves ve ekibi 2003) ve konuşma tanıma (Graves ve ekibi 2013:

Cui ve diğerleri, 2018'den) gibi birçok alanda çift yönlü ağların tek yönlü ağlardan önemli ölçüde daha iyi olduğu kanıtlanmıştır. BiLSTM'ler iki gizli katmanı aynı çıktı katmanına bağlamaktadır. (Graves ve ekibi, 2003) Bir ileri LSTM katmanı ve bir geri LSTM katmanı içeren katlanmamış (unfolded) bir BiLSTM katmanının yapısı Şekil 3.30'da gösterilmiştir. İleri katman çıktı dizisine ait olan $\vec{h}$, T-n zamanından T-1 zamanına kadar pozitif sıralı girdiler kullanarak yinelemeli olarak hesaplanmaktadır. Aynı şekilde geriye doğru katmandaki çıktı dizisi $\tilde{h}$ içinde T-n ile T-1 arasındaki ters girişler kullanılarak hesaplanmaktadır. Hem ileri hem de geri katman çıktıları standart LSTM güncelleme denklemleri ile hesaplanır. (Denklem 3.15–3.19) BiLSTM katmanı, her bir ögenin denklem 3.20 kullanılarak hesaplandığı bir çıktı vektörü olan, Y_T 'yi oluşturmaktadır. Buradaki σ , iki çıktı dizisini birleştirmek için kullanıldığı ifade edilmiştir. LSTM katmanına benzer şekilde, bir BiLSTM katmanının son çıktısı, $Y_T = [y_{T-n}, \dots, y_{T-1}]$ bir vektörle temsil edilebilir. Buradaki son terim hız tahmini alınırken bir sonraki yineleme için tahmin edilen hızdır.(Cui et al., 2018)

$$y_t = \sigma(\vec{h}, \tilde{h}) \quad (3.20)$$




Şekil 3.30. Çift Yönlü LSTM Mimarisinin 3 Ardışık Adımı (Cui et al., 2018)

3.13. Tasarlanan MLP Modeli

Dirsek ekleminin açılı tahmini için model, MathWorks tarafından geliştirilen MATLAB 2019a paketinde oluşturulmuş ve testi yapılmıştır. Zaman düzleminin sınıflandırma ve tahmindeki başarılı etkileri göz önüne alınarak açılı tahmini için MLP ağına 4 zaman özelliği (RMS, MAV, WL, VAR) ve varyans hariç 3 zaman özelliği verilmiştir. Değişik öznetelik sayıları ve gizli katmanlarındaki farklı nöron sayıları olan ağlar oluşturulmuştur.


Bu zaman özellikleri daha önceki Bölüm 3.11.'de ifade edilmiştir.

Levenberg Marquardt metodu kullanılarak MATLAB'da MLP ağı oluşturulmuştur. Açılı tahmini için çıkış katmanı dahil 3 gizli katmanlı ve katmanlarda sırasıyla 11 ve 5 nöron olan, 6 girişli ve 1 çıkış katmanına sahip MLP ağı tasarlanmıştır. (Şekil 3.31) Aktivasyon fonksiyonu ilk katmanda tansig sonrakilerde pureline olarak seçilmiştir. Hedef ve minimum gradyen 10^{-5} , öğrenme oranı 0,003 olarak belirlenmiştir. 1000 epoch ile eğitim tamamlanmıştır.




Şekil 3.31.Dirsek Eklem Açısı Tahmini İçin Oluşturulan MLP Ağı


Sinir ağlarına verilmek üzere oluşturulan eğitim verisi 280 örneğe bölünmüş ve ardından sEMG işaretinin 3 zaman özellik vektörü elde edilmiştir. Bu 3 zaman özelliği de biceps ve triceps işaretleri için ayrı ayrı oluşturulmuştur. Şekil 3.32’de, biceps ve triceps kas işaretlerinin ortalama mutlak değeri (MAV), dalga formu uzunluğu (WL) ve ortalama karekök (RMS) değerlerinin grafikleri gösterilmiştir. 4 özellikli işaret verisi ise Şekil 3.33 ve 34’te gösterilmektedir. Şekil 3.33 biceps işaretini ve işarete ait 4 zaman özelliği olan ortalama mutlak değer (MAV), dalga formu uzunluğu (WL), ortalama karekök (RMS) ve varyans (VAR) grafiklerinden oluşmaktadır. Şekil 3.34’te triceps işaretinin ve bu 4 zaman özelliğinin grafikleri gösterilmektedir. Burada işaretin ve özellik vektörlerinin tümü değil, tümünü temsil eden bir kısmı gösterilmiştir.



Şekil 3.32. MLP Eğitim Verisinin 3 Öznelik Grafiği




Şekil 3.33. MLP Eğitim Verisinin Biceps İşareti ve 4 Farklı Özniteliğinin Grafiği




Şekil 3.34. MLP Eğitim Verisinin Triceps İşareti ve 4 Farklı Özniteliğinin Grafiği

Eğitim verisindeki açı bilgisi modelde hedef olarak tanımlanmıştır. Kas işaretleri ile eşzamanlı alınan açı bilgisi MLP ağ modeline radyan cinsinden verilmiştir. Şekil 3.35'te hedef eklem açısının bir kısmının grafiği gösterilmektedir.




Şekil 3.35. MLP Hedef Eklem Açı İşareti



Şekil 3.36. MLP Regresyon Grafiği


Ağın eğitimini doğrulamak için ağ çıktıları ve hedefler arasındaki ilişkiyi gösteren regresyon grafiği, şekil 3.36'da gösterilmiştir. Bu grafiğe göre kesikli çizgi, en iyi sonucu temsil ederken düz mavi çizgi ağın tahmin ettiği çıktıları ve hedefler arasındaki en uygun doğrusal regresyon çizgisini ifade etmektedir. Şekil 3.37'de MLP ağının eğitim performans grafiği gösterilmiştir. Bu grafiğe göre modelin 1000 eğitim dönemi (epoch) boyunca ortalama kare hatası 0.036031'dir.




Şekil 3.37. MLP Eğitiminin Performans Grafiği

3.14. Tasarlanan Derin Öğrenme BiLSTM Modeli

Tasarlanan modeli eğitmek üzere ilk olarak hazırlanan eğitim verisi cross validation tekniği ile %70 eğitim %30 doğrulama (validation) verisi olarak bölünmüştür. Çapraz doğrulama olarak bilinen bu yöntem bir algoritmanın eğitim görmediği yeni veri kümeleri üzerinde tahminlerde bulunma performansını değerlendirmek için kullanılmaktadır. Bu tekniğin en yaygın kullanılanlarından bir olan holdout ile bölünme sağlanmıştır. Holdout verileri rastgele olarak eğitim ve doğrulama için belirtilen oranın tam olarak iki alt grubuna böler. Şekil 3.38’de eğitim veri grafiği ve Şekil 3.39’da doğrulama veri grafiği gösterilmektedir. Sırasıyla biceps ve triceps işaretleri ile eklem açısı yer almaktadır.




Şekil 3.38. LSTM Ağ Modeli İçin Eğitim Verisi



Şekil 3.39. LSTM Ağ Modeli İçin Doğrulama Verisi


Eğitim ve doğrulama verileri 280 örneğe bölünmüş ve tasarlanan modele girdi olarak verilmek üzere biceps ve triceps işareti hazır hale getirilmiştir. Şekil 3.40'ta hedef eklem açısı grafiği gösterilmektedir. Farklı kasılma türleri ve ağırlıkların işaretleri birleştirildiğinden grafiğin ilk kısmındaki açı bilgisi izokinetik kasılma türünü, sonlara doğru olan açı bilgisi ise izotonik kasılmayı ifade etmektedir. Açı sinyalinin istatistiksel olarak kas işaretleriyle ilişkilendirilebilmesi ve hesaplamalar yapılabilmesi adına normalize edildikten sonra modele verilmiştir. Şekil 3.39'da normalize edilmiş hedef eklem açısı gösterilmektedir. Grafikteki işaretler sırasıyla izokinetik ve izotonik kasılmayı takip etmektedir. Normalizasyon işlemi denklem 3.21'deki gibi minmax normalizasyon ile yapılmıştır. Açı bilgisi, eğitmek amaçlı hedef olarak kullanılmıştır. Model test edilirken açı bilgisi kullanılmaz yalnızca sEMG işaret bilgisinin değişken ortalama değerleri ve tepe kılıf değerleri verilerek tahmini çıktı elde edilmektedir.




Şekil 3.40. Normalize Edilmiş Hedef Eklem Açısı

$$X_{norm} = \frac{X - \min(X)}{\max(X) - \min(X)} \quad (3.21)$$

Akhundov ve ekibinin EMG ile sınıflandırmada yaptığı çalışmada sinyallerin pozitif tepe kılıf değerlerini almasına benzer şekilde, (Akhundov et al., 2019) giriş için sEMG sinyallerinin pozitif-negatif tepe kılıf değeri çıkarılmıştır. (Şekil 3.41) Salınan bir sinyalin uç ana hatlarını gösteren bu değerler ile sEMG sinyallerinin değişken ortalama değerleri bir dizi olarak bu çalışma için oluşturulan BiLSTM modeline giriş sinyali olarak verilmiştir. (Şekil 3.42)




Şekil 3.41. LSTM Eğitim Verisinin Giriş Sinyalleri Ortalamasının Tepe Kılıf Değerleri



Şekil 3.42. Dirsek Eklem Açısı Tahmini İçin Oluşturulan LSTM Ağ

Verilerden öğrenen bir model tasarlanırken kullanılan algoritma ya da bazı parametreler uygulamayı veya problemi modele uyarlamak adına tasarlayan kişi tarafından belirlenmektedir. Buna göre dirsek eklem açısı tahmini için tasarlanan model 6 girişli, 3 BiLSTM katmanından oluşmakta ve katmanlarda sırasıyla 400-300-400 gizli birim bulunmaktadır. Aşırı uyumu gidermek için ilk iki katmanda %50'lik bir dropout işlemi yapılmıştır. Her katmandan sonra RELU aktivasyon fonksiyonu eklenmiştir. Tamamen bağlı katman (FCL) ardından regresyon katmanına bağlanarak model bir açı tahmini yapmaktadır. Şekil 3.43'te oluşturulan ağ mimarisi ve genel katman şeması ayrıntılı olarak gösterilmektedir.

	Name	Type	Activations	Learnables
1	sequenceinput Sequence input with 6 dimensions	Sequence Input	6	-
2	bilstm_1 BiLSTM with 400 hidden units	BiLSTM	800	InputWeights 3200×6 RecurrentWe... 3200×... Bias 3200×1
3	Relu1 ReLU	ReLU	800	-
4	dropout_1 50% dropout	Dropout	800	-
5	bilstm_2 BiLSTM with 300 hidden units	BiLSTM	600	InputWeights 2400×... RecurrentWe... 2400×... Bias 2400×1
6	Relu2 ReLU	ReLU	600	-
7	dropout_2 50% dropout	Dropout	600	-
8	bilstm_3 BiLSTM with 400 hidden units	BiLSTM	800	InputWeights 3200×... RecurrentWe... 3200×... Bias 3200×1
9	Relu3 ReLU	ReLU	800	-
10	fc 1 fully connected layer	Fully Connected	1	Weights 1×800 Bias 1×1
11	regressionoutput mean-squared-error	Regression Output	-	-



Şekil 3.43. Derin Öğrenme BiLSTM Ağ Mimarisi Katmanları (MATLAB)

3.15. Derin Ağ Modeli Optimizasyonu ve Hiperparametreler

Tasarlanan modelde katmanlar esas işi yapan iskelet kısımdır. Ancak eğitim sırasında modeli uygulamaya göre revize eden önemli bir kısım parametreler vardır. Hiperparametre olarak adlandırılan bu yapılar veri setine göre değişiklik gösterirler. Buna göre her eğitim döneminde (epoch) eğitim ve doğrulama verileri shuffle seçeneği ile karıştırılmıştır. Her 15 epoch'ta bir güncellenen Öğrenme oranı ilk olarak 0.01 belirlenmiştir. Mini grup boyutu (minibatchsize) 128, düzenleştirme faktörü (L2 regularization) 0.000002, gradyan eşiği (GradientThreshold) 0.0005 ve epoch sayısı 100 olarak ayarlanmıştır.


Burada başarılı bir eğitim sağlamak adına optimizasyon kavramı da önemli bir yer tutmaktadır. Derin Öğrenme modellerinde çıktı ve hedef değer arasındaki fark olan hatanın minimum olması hedeflenmektedir. Bu amaçla optimizasyon için gradyen inişini esas alan teknikler kullanılmaktadır. (Kurt, 2018) Bu tekniklerden Adaptif Momentum Optimizer (ADAM) tasarlanan modelde kullanılmıştır. ADAM, RMSProp gibi öğrenme katsayısını eğimin değerine göre güncellemenin yanı sıra momentum değişikliklerini de ön bellekte saklayarak ağırlıklarda güncelleme sağlamaktadır. (Kurt, 2018) Bu sayede ağırlıkları güncellerken yerel minimuma takılmadan türevlenebilmesini yani modelin öğrenebilmesini sağlar.

4. BULGULAR VE TARTIŞMA


Bu bölümde Derin Öğrenme ve Çok Katmanlı Algılayıcı sinir ağı ile tasarlanan modellerin performansı sunulmuştur. Bunun için ilk olarak hazırlanan test verisinin grafikleri gösterilmiş ardından modelin açılı tahmin grafikleri verilmiştir. Grafikler tüm sonuçların yerine sonuç gruplarını temsil etmektedir.

4.1. Çok Katmanlı Algılayıcı Modeli Dirsek Eklem Açılı Tahmini Deneysel Sonuçları


Dirsek eklemine açılı tahmini için model, MathWorks tarafından geliştirilen MATLAB 2019a paketinde oluşturulmuş ve testi yapılmıştır. Zaman düzleminin sınıflandırma ve tahmindeki başarılı etkileri göz önüne alınarak açılı tahmini için MLP ağına 4 zaman özelliği (RMS, MAV, WL, VAR) ve varyans hariç 3 zaman özelliği verilmiştir. Değişik öznitelik sayıları ve gizli katmanlarındaki farklı nöron sayıları olan ağlar oluşturulmuştur. Şekil 4.1’de biceps kasının sEMG işareti ve 3 zaman alanı özniteliği (MAV, WL, RMS) çizilmiştir. Şekil 4.2’de triceps kasının sEMG işareti ve 3 zaman alanı özniteliğinin (MAV, WL, RMS) grafiği gösterilmektedir.




řekil 4.1. MLP Test Verisinin Biceps İřareti ve Öznitelik Grafiđi




Şekil 4.2. MLP Test Verisinin Triceps İşareti ve Öznitelik Grafiği




Şekil 4.3. Dirsek Eklem Test Açısı Verisi ve MLP Ağının Tahmin Grafiği -1



Şekil 4.4. Dirsek Eklem Test Açık Verisi ve MLP Ağının Tahmin Grafiği -2



řekil 4.5. Dirsek Eklem Test Açı Verisi ve MLP Ağının Tahmin Grafiđi -3



Şekil 4.6. Dirsek Eklem Test Açısı Verisi ve MLP Ağının Tahmin Grafiği -4

Şekil 4.3, 4.4, 4.5 ve 4.6 eğitilen MLP ağının test açısını tahmin etme grafiğidir. Şekil 4.3'teki grafiğin ilk kısımları serbest el ile yapılan izokinetik hareketi temsil eder ve Şekil 4.5 serbest el ile yapılan izotonik hareketi, 0,5 kg ağırlık ile yapılan izokinetik ve izotonik hareketi göstermektedir. Şekillerde bulunan grafiklerin hepsinde bu kasılma türlerinin farklı ağırlıkları ve modelin bunları tahmin etmesi mevcuttur. Çizelge 4.1'deki 3 ile 4 zaman özniteliği ve gizli katmanlı MLP modellerinin performans sonuçları gösterilmektedir.


Çizelge 4.1. MLP Ağ Sonuçları

MLP				
Lr 0.003 Epoch 1000	Test Verisi İçin			
Öznitelik Sayısı	Nöron -Katman Sayısı	MAPE	RMSE	Doğruluk %
3 (rms,mav,wl)	11-5	0,091	15,12	90,9
4 (rms,mav,wl.var)	11-5	0,095	15,36	90,5
3 (rms,mav,wl)	11-11-8	0,1018	19,2	89,8
4 (rms,mav,wl.var)	11-11-8	0,0991	17,6	90,09


4.2. Derin Öğrenme Modeli ile Dirsek Eklem Açısı Tahmini Deneysel Sonuçları

Dirsek eklem tahmini için MATLAB 2019a paketinde tasarlanan derin öğrenme BiLSTM ağı eğitimi sonrasında test verisi ile tahmini açı değerleri bulunmuştur. MLP ağına sunulan test verisi kıyaslama için Derin öğrenme ağına da sunulmuştur. Şekil 4.7'de test verisi gösterilmiştir. Grafikte sırasıyla biceps, triceps, dirsek eklem açısı gösterilmektedir. MLP ağındaki gibi test verisinin VAR, RMS, WL özellikleri verilmemiş işaretin 280 örneğe bölünerek değişken ortalama değerleri ve tepe kılıf değerleri verilmiştir. Grafikteki dirsek eklem açısı test sürecinde verilmez. Yalnızca biceps ve triceps işaretlerinin değişken ortalama değerleri (Şekil 4.8) ve tepe kılıf değerleri verilerek ağın tahmini bu dirsek eklem test açısı ile kıyaslanır. Şekil 4.9'da biceps ve triceps işaretinin tepe kılıf değerleri gösterilmiştir. Grafikte alt ve üst tepe değerleri ayrı ayrı çizilmiştir.


Sinyallerin değişken ortalama değerlerini ve tepe kılıf değerlerini giriş alan Derin Öğrenme modelinin açısı tahmini Şekil 4.10'da gösterilmiştir. Bu grafik normalize edilmiş çıktıları sunmaktadır. Kırmızı çizgi üst ekstremite dirsek eklemi test açısının normalize edilmiş hali iken, yeşil çizgi BiLSTM modelin tahmin ettiği normalize açı değerleridir. Denormalize edildikten sonraki tahmin grafiği ise şekil 4.11, 4.12 ve 4.13'de gösterilmiştir. Bu grafikler farklı kasılma türü ve ağırlığına göre birleştirilen işaretlerin tahminlerini göstermektedir. Şekil 4.11'deki grafiğin ilk kısımları serbest el ile yapılan izokinetik hareketi temsil eder ve devamı 1 kg ağırlık ile yapılan izotonik hareketi göstermektedir. Şekil 4.12 ve 13'te bu kasılma türlerinin farklı ağırlıklar ile olduğu ve modelin bunları tahmin ettiği grafikler sunulmuştur.




Şekil 4.7. LSTM İçin Test Verisi İşaretleri




řekil 4.8. LSTM Test Verisi Giriř Sinyalleri Ortalaması ve Normalize Hedef Açısı




Şekil 4.9. LSTM Test Verisi için Değişken Ortalamanın Tepe Kılıf Değerleri- Giriş Sinyalleri




řekil 4.10. Normalize Test Verisi ve Derin Öğrenme Modelinin (LSTM) Tahmin Grafiğı



Şekil 4.11.Test Açısı ve Derin Öğrenme Modelinin Tahmini -1



Şekil 4.12. Test Açısı ve Derin Öğrenme Modelinin Tahmini -2



Şekil 4.13. Test Açısı ve Derin Öğrenme Modelinin Tahmini -3

Çizelge4.2’de önerilen BiLSTM ağı ile LSTM ağının performans sonuçları gösterilmektedir. Burada verinin bölünme oranı, gizli katman sayısı her iki ağ içinde aynı seçilmiştir. Çizelge 4.3’te ise katman sayısına göre doğruluk sonuçları gösterilmiştir. Model 2’den farklı olarak Model 6, 4 katmanlı her katmanında 300 gizli birim bulunan ağ yapısına sahiptir.

Çizelge 4.2. LSTM ve BiLSTM Ağ Performansı

Derin Öğrenme				
	Test RMSE	Test MAPE	Test Mae	Doğruluk (%)
Model 2 (BiLSTM)	15,4	0,1005	11,3	89,95
Model 3 (LSTM)	19,5	0.137	15,7	86.3

Çizelge 4.3. Katman Sayısına Göre BiLSTM Ağının Sonuçları

Derin Öğrenme (BiLSTM)			
	Katman Sayısı	Test Verisi RMSE	Doğruluk (%)
Model 2	3	15,4	89,95
Model 6	4	17,9	87,5

Çizelge 4.4 önerilen modelin eğitim sürecinde başarıyı arttırmak adına yapılan veri bölünmesi oranlarının kıyaslanmasını göstermektedir.


Çizelge 4.4.Üç Katmanlı BiLSTM Ağında Farklı Bölünme Oranına Göre Sonuçlar

Derin Öğrenme (BiLSTM)			
	Bölünme Oranı (%)	Test Verisi RMSE	Doğruluk (%)
Model 2	70-30	15,4	89,95
Model 2	80-20	19,4	88,02


Çizelge 4.5.Üç Katmanlı BiLSTM Ağında Farklı Dropout Sonuçları

Derin Öğrenme (BiLSTM)			
	Dropout	Test Verisi RMSE	Doğruluk (%)
Model 2	Yok	19,4	86,71
Model 2	%20	17,5	88,37
Model 2	%50	15,4	89,95


Son olarak MLP ve BiLSTM ağlarının kıyaslamalı açt tahminleri gerçekt ölçüm test açısı ile Şekil 4.14, 4.15, 4.16ve 4.17’de verilmiştir.




Şekil 4.14. Test Verisi ve Farklı Sinir Ağlarının Tahmin Kıyaslama Grafiği -1



Şekil 4.15. Test Verisi ve Farklı Sinir Ağlarının Tahmin Kıyaslama Grafiği -2



Şekil 4.16. Test Verisi ve Farklı Sinir Ağlarının Tahmin Kıyaslama Grafiği -3



Şekil 4.17. Test Verisi ve Farklı Sinir Ağlarının Tahmin Kıyaslama Grafiği -4

5. SONUÇLAR VE ÖNERİLER

Bu çalışma, rehabilitasyon amaçlı sistemlerde noninvaziv sEMG kullanan yapay sinir ağları ile açılı tahmini yapmak ve sonuçlarını değerlendirmek için yapılmıştır. 2000’li yıllardan bu yana özellikle görüntü işlemede popüler hale gelen Derin Öğrenme mimarisinin, üst ekstremitede dirsek eklem açılı tahminini, sinyalin değişken ortalama değerleri ve tepe kılıf değerleri ile yapılabilmesi hedeflenmiştir. Bu amaçla, bir diziden başka bir diziye tahmin gibi sıralı verileri işleme avantajından dolayı RNN ‘nin bir varyantı olan BiLSTM mimarisi ile bir model tasarlanmıştır. Geleneksel sinir ağlarından Çok Katmanlı Algılayıcı (MLP) ile kıyaslanması yapılmıştır.

RNN tabanlı BiLSTM sinir ağı ile tasarlanan modelin, yaklaşık 122 derecelik dirsek eklem açılı aralığına göre ortalama mutlak hatası (MAE) %9,23 iken doğruluğu 89,95% olarak hesaplanmıştır. Eğitim datasının %80-20 yerine %70-30 olarak bölünmesi daha başarılı sonuç vermiştir. Aşırı öğrenmeyi önlemek için kullanılan dropout katmanı modele %50 olarak eklenmesi sonuçları olumlu etkilemiştir. Çizelge 4.2’deki modellerin her ikisi, izometrik hareketi tahmin etmede izotonik hareketi tahmin etmeye göre daha düşük başarı göstermiştir.

MLP ile tasarlanan modelin yaklaşık 122 derecelik dirsek eklem açılı aralığına göre ortalama mutlak hatası (MAE) %8,6 ve %90,9 doğruluğa ulaştığı hesaplanmıştır. Buna göre açılı tahmini için oluşturulan diğer modellerden daha yüksek doğruluk elde etmiştir. (Çizelge 4.1)

Düşük genlikli ve rastgele işaretler olan EMG sinyalinin öznelilikleri ve hangi özneliliklerin verildiği yapay sinir ağının tahmini için önem arz ettiği ve farklı günlerde alınan kas bilgisinin gerçek insan hareketlerinde gerçekçi tahmin edilmesinde önemli bir rol oynadığı görülmektedir.

Derin öğrenme yapılarındaki optimizasyon ayarının modelin performansında önemli bir ölçüt olduğu görülmüştür. Optimizasyon ayarları ile

ağın doğruluğunu ve sağlamlığını arttırabileceği ve derin öğrenme mimarisinin sEMG sinyalleri için bir çözüm olabileceği söylenebilir.

Özetle, üst ekstremitede yapılan açı tahmin çalışmalarına göre 3 öznitelik kullanan geleneksel sinir ağı MLP kadar, sinyalin değişken ortalama değerini ve tepe kılıf değerini kullanan RNN mimarisi de iyi doğruluğa ulaşmıştır. Bu sonuçlar neticesinde derin öğrenme yönteminin ilerde bir üst ekstremita rehabilitasyon sisteminde hareket kontrolü için daha az özellik kullanarak başarılı bir kullanım potansiyeli oluşturacağı açıktır. Özellikle tasarlanan yapının doğruluğunu ve sağlamlığını arttırmak adına CNN-LSTM gibi hibrit bir yaklaşımın ilerde çalışılması bu alana katkı sağlayacaktır.

KAYNAKLAR

- Alyea, H. N., 2010. Surface Electromyography Applied to Physical Rehabilitation and Biomechanics. *Journal of Chemical Education*, 43(10).
- Amado Laezza, R., 2018. Deep neural networks for myoelectric pattern recognition-An implementation for multifunctional control. Chalmers University Of Technology, Sweden, Yüksek Lisans Tezi.
- Bourns, 2015. AMS22B Non-Contacting Analog Rotary Position Sensor. BORURNS ABD.
<https://www.bourns.com/docs/product-datasheets/ams22b.pdf>
- Chen, Y., Yu, S., Ma, K., Huang, S., Li, G., Cai, S., & Xie, L., 2019. A continuous estimation model of upper limb joint angles by using surface electromyography and deep learning method. *IEEE Access*, 7, 174940-174950.
- Chowdhury, R. H., Reaz, M. B., Ali, M. A. B. M., Bakar, A. A., Chellappan, K., & Chang, T. G., 2013. Surface electromyography signal processing and classification techniques. *Sensors*, 13(9), 12431-12466.
- Cui, Z., Ke, R., Pu, Z., & Wang, Y., 2018. Deep bidirectional and unidirectional LSTM recurrent neural network for network-wide traffic speed prediction. *arXiv preprint arXiv:1801.02143*.
- DATA Team, 2020. Deep Learning ve Python: A'dan Z'ye Derin Öğrenme (5), Bölüm 7: Recurrent Neural Network (RNN) <https://www.udemy.com/course/deep-learning-ve-python-adan-zye-derin-ogrenme-5/>
- Day, S., 2002. Important factors in surface EMG measurement. Bortec Biomedical Ltd publishers, 1-17.
- Eroğlu, D. A., & Baysal, C. V., 2018. REAL TIME ELBOW JOINT ANGLE ESTIMATION USING sEMG SIGNALS. *Ç.Ü Fen ve Mühendislik Bilimleri Dergisi*, 48(2), 123–154.

- Haykin, S. 2017. *Neural Networks and Learning Machines*. Upper Saddle River, New Jersey.938s.
- Hochreiter, S., & Schmidhuber, J., 1997. Long short-term memory. *Neural computation*, 9(8), 1735-1780.
- Hu, Y., Wong, Y., Wei, W., Du, Y., Kankanhalli, M., & Geng, W., 2018. A novel attention-based hybrid CNN-RNN architecture for sEMG-based gesture recognition. *PloS one*, 13(10), e0206049.
- Hudgins B., Parker P. and Scott R., 1993. A New Strategy for Multifunction Myoelectric Control. *IEEE Trans. Biomed. Eng.* 40 (1), pp. 82-94.
- Güvenç, S. A., Ulutaş, M., & Demir, M., 2014, April. Pattern Recognition Based Analysis Of Arm EMG Signals And Classification With Artificial Neural Networks. In 2014 22nd Signal Processing and Communications Applications Conference (SIU) (pp. 2209-2212). IEEE.
- Karlık, B., Kocyigit, Y., & Fidan, C. B., 2005, May. Comparison Of Signal Processing Methods Used For Classification Of EMG Signals. In *Proceedings of the IEEE 13th Signal Processing and Communications Applications Conference*, 2005. (pp. 507-509). IEEE.
- Konrad, P., 2005. The ABC of EMG. A practical introduction to kinesiological electromyography, 1(2005), 30-5.
- Kurt, F., 2018. Evrişimli Sinir Ağlarında Hiper Parametrelerin Etkisinin İncelenmesi.Hacettepe Üniversitesi, Yüksek Lisans Tezi
- Kwon, S., & Kim, J., 2011. Real-Time Upper Limb Motion Estimation From Surface Electromyography And Joint Angular Velocities Using An Artificial Neural Network For Human-Machine Cooperation. *IEEE Transactions on Information Technology in Biomedicine*, 15(4), 522–530.
- Ma, X., Liu, Y., Song, Q., & Wang, C., 2020. Continuous Estimation of Knee Joint Angle Based on Surface Electromyography Using a Long Short-Term Memory Neural Network and Time-Advanced Feature. *Sensors*, 20(17), 4966.

- Mamikoglu, U., Nikolakopoulos, G., Pauelsen, M., Varagnolo, D., R ijezon, U., & Gustafsson, T. (2016, June). Elbow joint angle estimation by using integrated surface electromyography. In 2016 24th Mediterranean Conference on Control and Automation (MED) (pp. 785-790). IEEE.
- Nazmi, N., Abdul Rahman, M. A., Yamamoto, S. I., Ahmad, S. A., Zamzuri, H., & Mazlan, S. A. (2016). A review of classification techniques of EMG signals during isotonic and isometric contractions. *Sensors*, 16(8), 1304.
- Pedrycz, W., & Chen, S. M. (Eds.), 2020. Deep Learning: Concepts and Architectures. Springer.
- Phinyomark, A., Limsakul, C., & Phukpattaranont, P., 2009. A novel feature extraction for robust EMG pattern recognition. *Journal Of Computing*, 1(1), arXiv preprint arXiv:0912.3973.
-  ahin,  ., 2010. Rehabilitasyonda izokinetik de erlendirmeler. *Cumhuriyet Medical Journal*, 32(4), 386-396.
-  eker, A., Diri, B., & Balık, H. H., 2017. Derin   renme y ntemleri ve uygulamaları hakkında bir inceleme. *Gazi M hendislik Bilimleri Dergisi (GMBD)*, 3(3), 47-64.
- Serbest, K., & ELDO AN, O., 2014.  skelet kaslarının yapısı ve biyomekani i. *Akademik Platform M hendislik ve Fen Bilimleri Dergisi*, 2(3), 41-51.
- Soderberg, G. L., & Cook, T. M., 1984. Electromyography in biomechanics. *Physical Therapy*, 64(12), 1813-1820.
- Stegeman, D., & Hermens, H., 2007. Standards for surface electromyography: The European project Surface EMG for non-invasive assessment of muscles (SENIAM). Enschede: Roessingh Research and Development, 108-12.
- TA AR, B., 2016. EMG sinyalleri ile  ok fonksiyonlu protez el sim lat r n n kontrol /Control of the multifunctional prosthetic hand simulator via EMG signals. Fırat  niversitesi, Doktora Tezi

- Van der Kooij, H., Koopman, B., & van der Helm, F. C. (2008). Human Motion Control. Reader For Delft University Course Wb2407 And Twente University Course, 115047, 211-220.
- Wang, J., Hao, Q., Xi, X., Cao, J., Xue, A., & Wang, H., 2020. Estimation of Continuous Joint Angles of Upper Limb Based on sEMG by Using GA-Elman Neural Network. Mathematical Problems in Engineering, 2020.



ÖZGEÇMİŞ

İlk ve orta öğrenimini Tuncay Küçüközer İlköğretim Okulu'nda, lise öğrenimini Elazığ Lisesi'nde tamamladı. Çukurova Üniversitesi Biyomedikal Mühendisliği'ni 2012-2017 yıllarında bitirdi. Çukurova Üniversitesi'nin aynı bölümünde 2017'de tezli yüksek lisansa başladı. Bir buçuk yıl uyku ve solunum cihazları üzerine çalışan İCE Medikal'de teknik servis sorumlusu olarak çalıştı.

