

**ELEKTROMİYOGRAFİ SİNYALLERİ İLE İNSAN
KOLUNUN HAREKETİNİN TAHMİN EDİLMESİ**

**PREDICTING THE MOVEMENT OF THE HUMAN ARM
BY ELECTROMYOGRAPHY SIGNALS**

TAYFUN GÜRLEVİK

Dr. Öğr. Üyesi SERDAR ARITAN

Tez Danışmanı

Hacettepe Üniversitesi

Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliğinin

Bilgisayar Grafîği Anabilim Dalı için Öngördüğü

Yüksek Lisans Tezi olarak hazırlanmıştır.

2022

TAYFUN GÜRLEVİK'in hazırladığı “ELEKTROMİYOGRAFİ SİNYALLERİ İLE İNSAN KOLUNUN HAREKETİNİN TAHMİN EDİLMESİ” adlı bu çalışma aşağıdaki jüri tarafından **BİLGİSAYAR GRAFİĞİ ANABİLİM DALI'nda YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Prof. Dr. Sadettin KİRAZCI

Başkan

Dr. Öğr. Üyesi Serdar ARITAN

Danışman

Prof. Dr. Haşmet GÜRÇAY

Üye

Prof. Dr. Fatih YAŞAR

Üye

Dr. Öğr. Üyesi Arif Mithat AMCA

Üye

Bu tez Hacettepe Üniversitesi Bilişim Enstitüsü tarafından **YÜKSEK LİSANS TEZİ** olarak / /..... tarihinde onaylanmıştır.

Prof. Dr. Arif ALTUN

Bilişim Enstitüsü Müdürü

Eşim, kızım ve oğluma...

ETİK

Hacettepe Üniversitesi Fen Bilimleri Enstitüsü, tez yazım kurallarına uygun olarak hazırladığım bu tez çalışmasında,

- tez içindeki bütün bilgi ve belgeleri akademik kurallar çerçevesinde elde ettiğimi,
- görsel, işitsel ve yazılı tüm bilgi ve sonuçları bilimsel ahlak kurallarına uygun olarak sunduğumu,
- başkalarının eserlerinden yararlanılması durumunda ilgili eserlere bilimsel normlara uygun olarak atıfta bulunduğumu,
- atıfta bulunduğum eserlerin tümünü kaynak olarak gösterdiğimi,
- kullanılan verilerde herhangi bir değişiklik yapmadığımı,
- ve bu tezin herhangi bir bölümünü bu üniversite veya başka bir üniversitede başka bir tez çalışması olarak sunmadığımı

beyan ederim.

___ / ___ / 2022

TAYFUN GÜRLEVİK

YAYINLANMA FİKRİ MÜLKİYET HAKKLARI BEYANI

Enstitü tarafından onaylanan lisansüstü tezimin/raporumun tamamını veya herhangi bir kısmını, basılı (kağıt) ve elektronik formatta arşivleme ve aşağıda verilen koşullarla kullanıma açma iznini Hacettepe üniversitesine verdiğimi bildiririm. Bu izinle Üniversiteye verilen kullanım hakları dışındaki tüm fikri mülkiyet haklarım bende kalacak, tezimin tamamının ya da bir bölümünün gelecekteki çalışmalarda (makale, kitap, lisans ve patent vb.) kullanım hakları bana ait olacaktır.

Tezin kendi orijinal çalışmam olduğunu, başkalarının haklarını ihlal etmediğimi ve tezimin tek yetkili sahibi olduğumu beyan ve taahhüt ederim. Tezimde yer alan telif hakkı bulunan ve sahiplerinden yazılı izin alınarak kullanması zorunlu metinlerin yazılı izin alarak kullandığımı ve istenildiğinde suretlerini Üniversiteye teslim etmeyi taahhüt ederim.

Yükseköğretim Kurulu tarafından yayınlanan “*Lisansüstü Tezlerin Elektronik Ortamda Toplanması, Düzenlenmesi ve Erişime Açılmasına İlişkin Yönerge*” kapsamında tezim aşağıda belirtilen koşullar haricince YÖK Ulusal Tez Merkezi / H. Ü. Kütüphaneleri Açık Erişim Sisteminde erişime açılır.

- Enstitü / Fakülte yönetim kurulu kararı ile tezimin erişime açılması mezuniyet tarihimden itibaren 2 yıl ertelenmiştir.
- Enstitü / Fakülte yönetim kurulu gerekçeli kararı ile tezimin erişime açılması mezuniyet tarihimden itibaren ay ertelenmiştir.
- Tezim ile ilgili gizlilik kararı verilmiştir.

..... / /

(İmza)

TAYFUN GÜRLEVİK

ÖZET

ELEKTROMİYOGRAFİ SİNYALLERİ İLE İNSAN KOLUNUN HAREKETİNİN TAHMİN EDİLMESİ

Tayfun GÜRLEVİK

Yüksek Lisans, Bilgisayar Grafiği Ana Bilim Dalı

Tez Danışmanı: Dr. Öğr. Üyesi Serdar ARITAN

Eylül 2022, 73 Sayfa

Elektromiyografi (EMG) sinyalleri ile insan kolunun hareketinin tahmin edilmesi, biyomekanik, tıp, robotik başta olmak üzere birçok bilim alanının ilgi konusu olmuştur. Fakat literatürdeki çalışmalar genellikle koldaki eklem açılarının tek serbestlik derecesinde tahmin edilmesine yöneliktir. Bu tez çalışmasında, EMG sinyalleri ile kolun omuz ve dirsek eklemlerinin 6 serbestlik derecesinde dönüş açılarını tahmin eden bir yapay sinir ağı modelinin oluşturulması amaçlanmıştır. Yapay sinir ağını eğitmek amacıyla, uzuv kaybı olmayan deneklerin kol ve omuz bölgesindeki kaslardan (Biceps, Triceps, Anterior Deltoid, Posterior Deltoid, Pectoralis Major ve Trapez) elden edilen EMG sinyalleri ve deneyler sırasındaki hareketlerin optik hareket yakalama sistemi vasıtasıyla hesaplanan açılarla oluşturulan bir veri seti oluşturulmuştur. Oluşturulan veri seti ile çok katmanlı yapay sinir ağı ve uzun kısa vadeli hafıza (LSTM) yapısındaki modeller eğitilmiştir. Elde edilen bulgular sonucunda LSTM yapay sinir ağı modellerinin, çok katmanlı yapay sinir ağı modellerine göre daha iyi sonuç verdiği görülmüştür.

Anahtar Kelimeler: EMG, sinir ağları, LSTM, Hareket Tahmini, regresyon

ABSTRACT

PREDICTING THE MOVEMENT OF THE HUMAN ARM BY ELECTROMYOGRAPHY SIGNALS

Tayfun GÜRLEVİK

Master of Science, Department of Computer Graphics

Supervisor: Dr. Lecturer Serdar ARITAN

September 2022, 73 Pages

Predicting the movement of the human arm by using electromyography (EMG) signals has been the subject of interest in many fields of science, including biomechanics, medicine and robotics. However, studies in the literature generally focus on estimating joint angles in the arm in a single degree of freedom. In this thesis, it is aimed to create an artificial neural network model that predicts the rotation angles of the shoulder and elbow joints of the arm at 6 degrees of freedom. In order to train the artificial neural network, data sets were formed with EMG signals obtained from the muscles in the arm and shoulder region (biceps, triceps, anterior deltoid, posterior deltoid, pectoralis major and trapezius) of subjects without limb loss and the angles calculated by the optical motion capture system of the movements during the experiments. Neural network models in multilayer perceptron and long short-term memory (LSTM) structure were trained with obtained datasets. It is found that, LSTM artificial neural network models overperform the multi-layer artificial neural network models.

Keywords: EMG, neural networks, LSTM, motion prediction, regression

TEŐEKKÜR

Tez alıőmam boyunca bana yol gsteren, bilimsel anlamda ufkumu geniőleten deęerli danıőmanım Dr. ęretim Üyesi Serdar ARITAN'a teőekkür ederim.

Tez alıőmam boyunca ihtiyacım olan her anda yardımlarını esirgemeyen Ar.Gör. Nihat Őükrü ÖZGÖREN'e teőekkür ederim.

Her zaman beni destekleyen eőim Dilara GÜRLEVİK'e, hayatımın neőe kaynaęı olan kızım Asya GÜRLEVİK'e ve yakın zamanda aramıza katılacak olan oęlum Rüzgâr GÜRLEVİK'e teőekkür ederim.

İÇİNDEKİLER

ÖZET.....	i
ABSTRACT.....	ii
TEŞEKKÜR.....	iii
İÇİNDEKİLER.....	iv
ŞEKİLLER DİZİNİ.....	vii
ÇİZELGELER DİZİNİ.....	ix
SİMGELER VE KISALTMALAR.....	xii
1. ARAŞTIRMA PROBLEMİNİN TANIMLANMASI.....	1
1.1. Genel Bakış ve Motivasyon.....	1
1.2. Araştırma Soruları.....	2
1.3. Tez Çalışmasının Organizasyonu.....	2
2. GENEL BİLGİLER.....	4
2.1. EMG Sinyali.....	4
2.2. Kolun Anatomisi ve Kolu Hareket Ettiren Kaslar.....	7
2.2.1. İki Başlı Kol Kası(Biceps).....	7
2.2.2. Üç Başlı Kol Kası (Triceps).....	8
2.2.3. Deltoid Kası.....	9
2.2.4. Pectoralis Major Kası.....	10
2.2.5. Trapez Kası.....	10
2.3. Yapay Sinir Ağları.....	11
2.3.1. Çok Katmanlı Yapay Sinir Ağları.....	11
2.3.2. LSTM Ağları.....	13
2.4. Literatürdeki Çalışmalar.....	14
3. METOD VE YÖNTEM.....	19

3.1.	Katılımcılar	19
3.2.	Veri Toplama İşlemi	19
3.3.	Verilerin Hazırlanması	23
3.3.1.	Hareket Yakalama Verilerinin İşlenmesi.....	23
3.3.2.	EMG Verilerinin İşlenmesi	23
3.3.3.	Özellik Çıkartma İşlemi.....	25
3.3.4.	Eğitim ve Test Verilerinin Hazırlanması	27
3.3.5.	Özellik Seçimi.....	28
3.4.	Yapay Sinir Ağı Modellerinin Belirlenmesi	29
3.5.	Yapay Sinir Ağlarının Performansının Değerlendirilmesi.....	30
3.5.1.	Ortalama Kare Hatası (MSE).....	30
4.	BULGULAR.....	31
4.1.	2 Boyutta Hareket Tahminleri.....	31
4.1.1.	Çok Katmanlı Yapay Sinir Ağı Tahminleri.....	31
4.1.2.	LSTM Yapay Sinir Ağı Tahminleri.....	36
4.1.3.	2 Boyutta Hareket Tahminleri İçin Özellik Seçimi	42
4.1.4.	Seçilmiş Özellikler Veri Seti ile Çok Katmanlı Yapay Sinir Ağı Tahminleri 42	
4.1.5.	Seçilmiş Özellikler Veri Seti ile LSTM Yapay Sinir Ağı Tahminleri.....	46
4.2.	3 Boyutta Hareket Tahminleri.....	49
4.2.1.	Çok Katmanlı Yapay Sinir Ağı Tahminleri	49
4.2.2.	LSTM Yapay Sinir Ağı Tahminleri.....	52
4.2.3.	3 Boyutta Hareket Tahminleri İçin Özellik Seçimi	55
4.2.4.	Seçilmiş Özellikler Veri Seti ile Çok Katmanlı Yapay Sinir Ağı Tahminleri 55	
4.2.5.	Seçilmiş Özellikler Veri Seti ile LSTM Yapay Sinir Ağı Tahminleri.....	59
4.3.	Yapay Sinir Ağı Modellerinin İstatistiksel Analizleri	62

4.3.1. 2 Boyutta Hareket için Yapay Sinir Ağı Modellerinin Performans Karşılaştırması.....	62
4.3.2. 3 Boyutta Hareket için Yapay Sinir Ağı Modellerinin Performans Karşılaştırması.....	65
5. SONUÇ ve TARTIŞMA	69
6. KAYNAKÇA	71

ŞEKİLLER DİZİNİ

Şekil 2.1 Galvani'nin 1974 ve 1977'de yaptığı metal olmaksızın bir hayvan bacağındaki elektrik iletimi ile kasılmanın gerçekleştiğini gösterir görseller [3].....	5
Şekil 2.2 Motor ünitesi[4].....	6
Şekil 2.3 Motor üniteleri, kas aksiyon potansiyeli ve girişim paterni[5].....	6
Şekil 2.4 Biceps olarak da bilinen iki başlı kol kası[6]	7
Şekil 2.5 Biceps kaslarının dönüşü. Tirbuşon ile mantarı şişeden çıkarma esnasında oluşan önkol dönüşü ve eklemdeki bükülmede kullanılan biceps hareketi. İlk önce mantar çevrilir (dış rotasyon), sonra mantar çekilir (bükülme)[6]	8
Şekil 2.6 Triceps olarak da bilinen üç başlı kol kası[6].....	9
Şekil 2.7 Deltoid kasın 3 bölümü[6].....	9
Şekil 2.8 Pektoralis majör kasın iki kısmı	10
Şekil 2.9 Trapez kası.....	11
Şekil 2.10 Çok katmanlı yapay sinir ağı	12
Şekil 2.11 Tek hafıza hücresine sahip bir LSTM hafıza bloğu	13
Şekil 3.1 Boyutlu deney düzeneği	20
Şekil 3.2 Deney başlangıcı ve sonunda T duruşu	20
Şekil 3.3 EMG sensörleri ve işaretleyicilerin yerleştirilmesi	21
Şekil 3.4 Blade yazılımında tetiklenme anının görüntülenmesi	22
Şekil 3.5 Tetiklenme zamanının EMG verisinde bulunması	22
Şekil 3.6 Deney düzeneği şematik görünüm	23
Şekil 3.7 Fourier dönüşümü sonrasında EMG spektrumları.....	24
Şekil 3.8 Filtrelenmiş ve ham EMG verisi	25
Şekil 4.1 20 ms zaman penceresinde çok katmanlı yapay sinir ağı modeli ile Grup4 veri setinin tahminleri	33
Şekil 4.2 50 ms zaman penceresinde çok katmanlı yapay sinir ağı modeli ile Grup4 veri setinin tahminleri	34
Şekil 4.3 100 ms zaman penceresinde çok katmanlı yapay sinir ağı modeli ile Grup4 veri setinin tahminleri	35
Şekil 4.4 2 boyutlu hareket için 20ms zaman penceresinde Grup4 veri seti ile eğitilmiş LSTM yapay sinir ağı tahminleri.....	37
Şekil 4.5 2 boyutlu hareket için 50ms zaman penceresinde Grup4 veri seti ile eğitilmiş LSTM yapay sinir ağı tahminleri.....	39

Şekil 4.6 2 boyutlu hareket için 100ms zaman penceresinde Grup4 veri seti ile eğitilmiş LSTM yapay sinir ağı tahminleri	41
Şekil 4.7 Komşuluk Bileşeni Analizine göre 2 boyutta hareket için EMG özelliklerinin ağırlıkları	42
Şekil 4.8 Özellik seçilimi yapılarak 100ms zaman penceresinde 400 ve 200 nöron sayılarına sahip Grup4 veri seti ile eğitilmiş çok katmanlı yapay sinir ağı tahminleri ...	45
Şekil 4.9 Özellik seçilimi yapılarak 100 ms zaman penceresinde katmanlarında 300'er nöron sayısına sahip Grup4 veri seti ile eğitilmiş LSTM yapay sinir ağı tahminleri.....	48
Şekil 4.10 3 Boyutu hareket için 100 ms zaman penceresinde Grup4 veri setinin çok katmanlı yapay sinir ağı tahminleri	51
Şekil 4.11 LSTM yapay sinir ağı ile 3 boyutta hareket için Grup4 veri seti ile yapılmış tahminler.....	54
Şekil 4.12 Komşuluk Bileşeni Analizine göre 3 boyutta hareket için EMG özelliklerinin ağırlıkları	55
Şekil 4.13 100ms zaman penceresinde 200 ve 100 nöron sayılarına sahip Grup4 veri seti ile eğitilmiş 3 boyutlu hareket için çok katmanlı yapay sinir ağı tahminleri	58
Şekil 4.14 100ms zaman penceresinde özellik seçilimi yapılarak, 3 boyutlu hareket için, katmanlarında birinci katmanında 200, ikinci katmanında 100 nöron bulunan Grup4 veri seti ile eğitilmiş LSTM yapay sinir ağı tahminleri.....	61
Şekil 4.15 2 Boyutlu hareket için çok katmanlı yapay sinir ağı ve LSTM modellerinin performanslarının karşılaştırılması.....	62
Şekil 4.16 3 Boyutlu hareket için çok katmanlı yapay sinir ağı ve LSTM modellerinin performanslarının karşılaştırılması.....	66

ÇİZELGELER DİZİNİ

Çizelge 3.1 Katılımcıları özellikleri.....	19
Çizelge 3.2 Zaman Etki Alanında EMG Sinyal Özellikleri.....	26
Çizelge 3.3 Eğitim ve test verilerini oluşturan katılımcılar	28
Çizelge 3.4 Yapay sinir ağlarında kullanılan nöron sayıları.....	30
Çizelge 4.1 20 ms zaman penceresinde çok katmanlı yapay sinir ağı tahmin performansları.....	31
Çizelge 4.2 50 ms zaman penceresinde çok katmanlı yapay sinir ağı tahmin performansları.....	32
Çizelge 4.3 100 ms zaman penceresinde çok katmanlı yapay sinir ağı tahmin performansları.....	32
Çizelge 4.4 20 ms zaman penceresinde 2 boyutlu deney için LSTM tahmin performansları	36
Çizelge 4.5 50 ms zaman penceresinde 2 boyutlu deney için LSTM tahmin performansları	38
Çizelge 4.6 100 ms zaman penceresinde 2 boyutlu deney için LSTM tahmin performansları.....	40
Çizelge 4.7 20 ms zaman penceresinde seçilmiş özellikler ile 2 boyutta hareket için çok katmanlı yapay sinir ağı tahmin performansları	43
Çizelge 4.8 50 ms zaman penceresinde seçilmiş özellikler ile 2 boyutta hareket için çok katmanlı yapay sinir ağı tahmin performansları	43
Çizelge 4.9 100 ms zaman penceresinde seçilmiş özellikler ile 2 boyutta hareket için çok katmanlı yapay sinir ağı tahmin performansları	44
Çizelge 4.10 20 ms zaman penceresinde seçilmiş özellikler ile 2 boyutta hareket için LSTM yapay sinir ağı tahmin performansları.....	46
Çizelge 4.11 50 ms zaman penceresinde seçilmiş özellikler ile 2 boyutta hareket için LSTM yapay sinir ağı tahmin performansları.....	47
Çizelge 4.12 100 ms zaman penceresinde seçilmiş özellikler ile 2 boyutta hareket için LSTM yapay sinir ağı tahmin performansları.....	47
Çizelge 4.13 20 ms zaman penceresinde 3 boyutlu hareket için çok katmanlı yapay sinir ağı tahmin performansları.....	49
Çizelge 4.14 50 ms zaman penceresinde 3 boyutlu hareket için çok katmanlı yapay sinir ağı tahmin performansları.....	50

Çizelge 4.15 100 ms zaman penceresinde 3 boyutlu hareket için çok katmanlı yapay sinir ağı tahmin performansları	50
Çizelge 4.16 20 ms zaman penceresinde 3 boyutlu hareket için LSTM tahmin performansları	52
Çizelge 4.17 50 ms zaman penceresinde 3 boyutlu hareket için LSTM tahmin performansları	53
Çizelge 4.18 100 ms zaman penceresinde 3 boyutlu hareket için LSTM tahmin performansları	53
Çizelge 4.19 20 ms zaman penceresinde seçilmiş özellikler ile 3 boyutta hareket için çok katmanlı yapay sinir ağı tahmin performansları.....	56
Çizelge 4.20 50 ms zaman penceresinde seçilmiş özellikler ile 3 boyutta hareket için çok katmanlı yapay sinir ağı tahmin performansları.....	56
Çizelge 4.21 100 ms zaman penceresinde seçilmiş özellikler ile 3 boyutta hareket için çok katmanlı yapay sinir ağı tahmin performansları.....	57
Çizelge 4.22 20 ms zaman penceresinde seçilmiş özellikler ile 3 boyutta hareket için LSTM yapay sinir ağı tahmin performansları	59
Çizelge 4.23 50 ms zaman penceresinde seçilmiş özellikler ile 3 boyutta hareket için LSTM yapay sinir ağı tahmin performansları	60
Çizelge 4.24 100 ms zaman penceresinde seçilmiş özellikler ile 3 boyutta hareket için LSTM yapay sinir ağı tahmin performansları	60
Çizelge 4.25 Çok katmanlı yapay sinir ağı ve LSTM modellerinin performans ortalamalarının t-Test analizi	63
Çizelge 4.26 Özellik seçimi işlemi sonucunda yapay sinir ağı modelleri performans ortalamalarının t-Test analizleri	64
Çizelge 4.27 Çok katmanlı yapay sinir ağı performansının farklı zaman pencereleri için Anova Testi	64
Çizelge 4.28 LSTM modeli için 100ms zaman penceresindeki tahminlerin, 20ms ve 50ms zaman penceresindeki tahminler ile istatistiksel t-Testi.....	65
Çizelge 4.29 Çok katmanlı yapay sinir ağı ve LSTM modellerinin 3 boyutlu deney için performans ortalamalarının t-Test analizi	67
Çizelge 4.30 Özellik seçimi işleminin 3 boyutlu hareket tahminlerinde etkisinin istatistiksel analizi	67
Çizelge 4.31 Farklı zaman pencerelerinin 3 boyutlu hareket tahminlerinde çok katmanlı yapay sinir ağı performansına etkisi.....	68

Çizelge 4.32 Farklı zaman pencerelerinin 3 boyutlu hareket tahminlerinde LSTM yapay sinir ağı performansına etkisi.....	68
--	----

SİMGELER VE KISALTMALAR

Kısaltmalar

IMU	Atalet Ölçüm Birimi (Inertial Measurement Unit)
EMG	Elektromiyografi
ÇKYSA	Çok katmanlı yapay sinir ağı
LSTM	Uzun Kısa Vade Hafıza (Long short term memory)
NCA	Komşuluk Bileşenleri Analize (Neighbourhood components analysis)
MSE	Ortalama Kare Hatası
S	Denek (Subject)
ms	Milisaniye

1. ARAŞTIRMA PROBLEMİNİN TANIMLANMASI

1.1. Genel Bakış ve Motivasyon

İnsan vücudunun hareketlerinin dijital ortama aktarılması; bilgisayar grafiği, animasyon, biyomekanik ve tıp gibi birçok bilim dalının ortak ilgi alanlarındandır. Bu amaçla günümüzde optik kameralar veya atalet ölçüm birimi (Inertial Measurement Unit (IMU)) sensör tabanlı sistemler kullanılmaktadır. Bu yöntemlere alternatif olarak, elektromiyografi (EMG) sinyalleri ile hareketin tahmini de dahil olmak üzere literatürde birçok farklı yöntem geliştirilmiştir. EMG sinyalleri ile hareket tahmini konusundaki çalışmaları incelendiğinde, bu çalışmaların çoğunluğunun izometrik kasılmaların sınıflandırılması ya da tek serbestlik derecesinde dirsek veya dizin dönme açısının regresyon ile tahmin edilmesi şeklinde olduğu görülmektedir. İnsan kolunda bulunan omuz ve dirsek eklemleri, belirli sınırlar dahilinde de olsa dönme açısından 6 serbestlik derecesine sahip bir sistemdir. Bu tez çalışması sonucunda elde edilecek olan yapay zekâ modeli üst ve alt kol açılarını 6 serbestlik derecesinde tahmin edebilecektir.

Bu amaçla, sağlıklı ve herhangi bir uzuv kaybı olmayan deneklerden eş zamanlı olarak toplanan EMG sinyalleri ve hareket bilgileri, yapay sinir ağı modelinin eğitilmesi için kullanılmıştır. EMG sinyalleri ve bu sinyallerden elde edilen özellikler yapay sinir ağına girdi verileri olarak kullanılırken, hareket yakalama sisteminden elde edilen üst ve alt kolun dönüş bilgileri ise çıktı olarak kullanılmıştır. Oluşturulan veri setleri ile farklı yapılarda yapay sinir ağı modelleri geliştirilmiş ve geliştirilen modellerin performansları analiz edilmiştir.

Eğitilmiş yapay sinir ağı modeli sayesinde; sporcu performansı analizi, biyomedikal, biyomekanik gibi alanlarda sıklıkla kullanılan EMG sinyalleri ile herhangi bir hareket yakalama sistemine gerek kalmadan kişilerin kol hareketlerinin tahmin edilebilmesi mümkün olacaktır. Benzer bir şekilde, kol kısmı ampute edilmiş kişilerin kullandığı EMG sinyalleri ile kontrol edilebilen robotik protezlerde, bu çalışmada geliştirilen model uygulandığı takdirde, protezin hareketleri kullanıcıların doğal hareketlerine uyum sağlayabilecektir.

1.2. Araştırma Soruları

Tez çalışmasının temel amacını açıklayan araştırma sorusu şu şekilde özetlenmiştir:

- İnsan kol ve omuz bölgesindeki kaslardan elde edilen EMG sinyalleri ile eğitilmiş bir yapay sinir ağı modelinin, üst ve alt kolun dönüş açılarını tahmin edilebilmesi mümkün müdür?

Bu sorunun çözümünde kullanılan yöntemde aşağıda sıralanan diğer sorulara da cevap aranmıştır:

- Çok katmanlı yapay sinir ağı modeli ve LSTM yapay sinir ağı modelinin tahmin etme performansları birbirinden anlamlı olarak farklılık göstermekte midir?
- EMG sinyallerinin özelliklerinin çıkartılması sırasında seçilen farklı pencere aralıklarının tahminlerde anlamlı bir etkisi var mıdır?
- Komşuluk Bileşenleri Analizi (NCA) yöntemi ile özellik seçimi işlemi neticesinde eğitilen yapay sinir ağı modelinin tahminlerinde özellik seçimi işleminin anlamlı bir etkisi var mıdır?

1.3. Tez Çalışmasının Organizasyonu

Tez çalışmasının genel hatları aşağıdaki şekilde özetlenmiştir:

Bölüm 2’de EMG sinyalinin yapısı hakkında genel bilgiler sunulmuştur. Kolun anatomisi ve kolu hareket ettiren kasların yapısı ve çalışma prensipleri ile ilgili genel bilgiler sunulmuştur. Tez çalışmasında kullanılan yapay sinir ağı modellerinden çok katmanlı yapay sinir ağı ve LSTM ağı hakkında özet bilgi verilmiştir. Son olarak, literatürde EMG sinyali ve EMG sinyaliyle hareket tahmini yapmaya çalışan akademik çalışmalar incelenmiştir.

Bölüm 3’te deneye katılan katılımcıların antropometrik özellikleri özetlenerek, EMG veri toplama işlemi ve hareket yakalama sistemi vasıtasıyla veri toplanmasının prosedürü açıklanmıştır. Toplanan verilerin yapay sinir ağının eğitilmesinde kullanılacak şekle dönüştürülmesi işlemi açıklanmıştır.

Bölüm 4’te ilk olarak iki boyutta harekette tahmin yapılmıştır. Daha sonra özellik seçme işlemi yapılmıştır. Özellik seçme işlemi sonrasında en yüksek ağırlığa sahip özellikten oluşan eğitim seti ile tekrar tahmin yapılmıştır. Aynı yöntem kolun üç boyuttaki hareketi için de yapılmıştır.


Elde edilen bulgular dođrultusunda Bölüm 5'te oluşturulan yapay sinir ađı modellerinin tahmin performansları karşılaştırılmış, literatürdeki benzer çalışmaların sonuçları ile tez çalışması birlikte değerlendirilerek benzerlik ve farklılıklar belirtilmiştir. Son olarak ileride araştırılmasında fayda görülen konular belirtilmiştir.

2. GENEL BİLGİLER

2.1. EMG Sinyali


Biyomedikal sinyal, fiziksel bir deęişkeni temsil eden herhangi bir organdan elde edilen elektrik sinyali anlamına gelir. Bu sinyal genlięi, frekansı ve fazı ile tanımlanabilen bir zaman fonksiyonudur. EMG kasların nörolojik aktivitelerle kasılması sırasında ürettięi elektrik akımlarını ölçen biyomedikal sinyal tipi olarak tanımlanabilir. Kasların kasılma ve rahatlama aktivitelerinin sinir sistemi tarafında sürekli kontrol edilmektedir. Bu sebeple EMG sinyali kasların anatomik ve fizyolojik özelliklerine baęlı olarak deęişmektedir. Söz konusu sinyal elektromiyografi anlamına gelmekle birlikte literatürde miyoelektrik aktivite olarak da anılabilir[1, 2]

Elektromiyografinin (EMG) erken dönem gelişimi, elektriğin keşfiyle bağlantılıdır denilebilir. Son üç yüzyılda Galvani, Adrian, Denny-Brown, Larrabee ve Lambert'in önemli yayınları gözden geçirildiğinde EMG'nin tarihsel sürecinin anlaşılması mümkündür. Bir hayvan vücuduna elektrik verilmesinin ardından sinirlerin ve kasların elektrik üretebildiği fark edilmiştir. 1770'li yıllarda Galvani isimli bilim insanı, hayvana ait kas dokusu elektrikle uyarıldığında kasılma gerçekleştiğini ispatlamıştır. 1929'da bir başka bilim insanı Adrian, eş merkezli iğne elektrotlarını amplifikatöre ile hoparlöre bağlayarak tek bir motor ünitesi potansiyelini kaydeden bir yöntemi geliştirmiştir. 1938 yılında ise Denny-Brown, kas seğirmesi potansiyellerini tanımlayarak söz konusu unsurları ritim bozukluklarından ayırmıştır. İkinci Dünya Savaşı'nın sonlarına doğru Larrabee, savaş kurbanlarının sağlıklı ve yaralı sinirlerindeki bileşik kas aksiyon potansiyelini ölçmeye başlamıştır. Konuya ilişkin en önemli gelişme küçük biyoelektrik akımları yükseltebilen ekipmanın icat edilmesi ile 20. Yüzyılın başlarında yaşanmıştır. İkinci Dünya Savaşı sırasında ve sonrasında önemli bilimsel ve teknik ilerlemelerin gerçekleşmesi ile sinir yaralanmaları olan geniş bir hasta popülasyonunun incelenmiştir [3].




Şekil 2.1 Galvani'nin 1974 ve 1977'de yaptığı metal olmaksızın bir hayvan bacağındaki elektrik iletimi ile kasılmanın gerçekleştiğini gösterir görseller [3]

EMG temel fizyolojik ve biyomekanik çalışmaların yanı sıra, uygulamalı araştırma, fizyoloji/rehabilitasyon, spor eğitimi ve insan vücudunun endüstriyel ürünler ya da çalışma koşulları etkileşimlerinin incelenmesinde kullanılmaktadır. Bu noktada EMG'nin çalışma prensibinin açıklanabilmesi için **motor ünite**, **kas aksiyon potansiyeli**, **gürültü**, **sinyal gürültü oranı** gibi terimlerinde bilinmesi gerekir. **Motor ünite**, hareket kontrolünün temel nörofizyolojik birimidir. **Motor ünite** aksonlarca donatılmış kas lifleri ile birlikte bir motor nöron içerir. Motor havuzu olarak da bilinen belirli bir kasın motor nöronlarının hücre gövdeleri, merkezi sinir sistemi içindeki spinal ya da kranial motor çekirdeği etrafında yığın olarak toplanmıştır. Bir motor nöron ateşlendiğinde oluşan aksiyon potansiyeli kas lifleri üzerinde akson boyunca yayılır. Bu durum her kas lifinde benzer aksiyon potansiyelinin yayılması ile sonuçlanır. Tek bir motor ünitenin tüm liflerindeki aksiyon potansiyellerinin toplamı **kas aksiyon potansiyeli** olarak tanımlanmakla birlikte elektromiyografinin temelini oluşturur (Şekil 2.2, Şekil 2.3). Sonuç olarak elektromiyografideki kas aksiyon potansiyeli ile merkezi sinir sistemindeki motor nöronun ateşlenmesi doğrudan ilişkilidir[4, 5].



Şekil 2.2 Motor ünitesi[4]

Motor üniteleri



Şekil 2.3 Motor üniteleri, kas aksiyon potansiyeli ve girişim paterni[5]

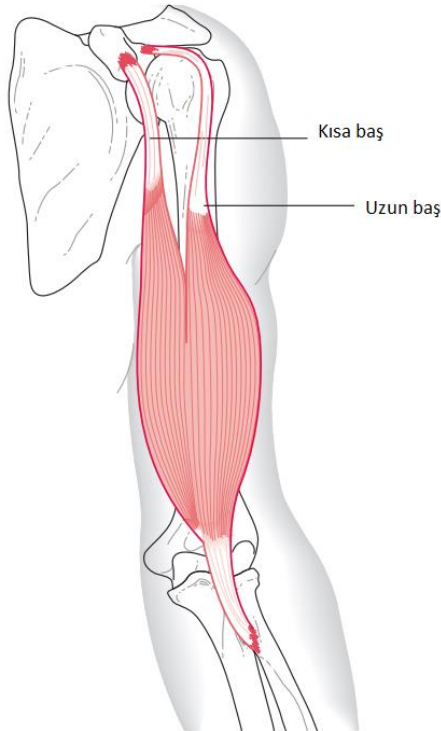
Gürültü ise talep edilen EMG sinyalinin parçası olmayan elektrik sinyalleri olarak tanımlanır. EMG sinyalinin tespit edilmesi ve kaydedilmesinde, sinyalin doğruluğunu etkileyen iki ana unsur vardır. Bunlardan birincisi, sinyal-gürültü oranıdır. Diğer unsur, sinyalin bozulması olarak tanımlanır. EMG sinyalindeki herhangi bir frekans bileşeninin göreceli katkısı değişmemelidir[1].

Kas sinyali elde etmek için girişimsel (invaziv) ve girişimsel olmayan (invaziv olmayan) iki tip elektrot kullanılmaktadır. EMG doğrudan deri üzerine monte edilmiş elektrotlardan alındığında, sinyal derinin altındaki kaslarda meydana gelen tüm kas lifi aksiyon potansiyellerinin bileşiminden oluşmaktadır. Bu aksiyon potansiyelleri rastgele aralıklarla meydana gelmekte olup herhangi bir anda EMG sinyalinde pozitif veya negatif voltaj olabilir. Tez çalışmasında girişimsel olmayan yüzey EMG metodu kullanılmıştır[1, 2].

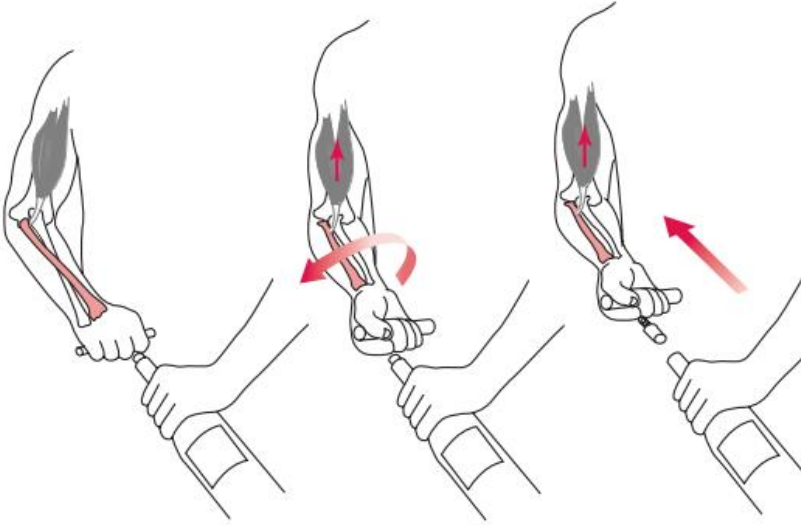
2.2. Kolun Anatomisi ve Kolu Hareket Ettiren Kaslar

2.2.1. İki Başlı Kol Kası(Biceps)

İki başlı kol kasının, adından da anlaşılacağı gibi iki başı vardır ve kolda bulunur. Kas genellikle biceps olarak adlandırılır (Şekil 2.4). Her iki kafa da kürek kemiğine yapışır. Her iki başın tendonları da omuz ekleminin önden geçtiğinden, biceps kasları omuz fleksiyonuna yardımcı olur, ancak asıl işlevi dirsektedir. İki kafa, birleştikten sonra kolun ön yüzeyini kaplayan ortak bir kas göbeği oluşturur. İki başlı kol kası, dirsek eklemi öne doğru yaydığı için özellikle orta aralıkta iyi bir dirsek bükücüdür. Önkol kemiğine eğik olarak tutunduğu için önkolun dönüşüne katkıda bulunur. Biceps kasının dönme hareketini anlamak için onu bir tirbuşon gibi düşünmek gerekir (Şekil 2.5). Önkol içe bükülürken, radyal tüberosite arka tarafa doğru medial olarak daha fazla döndürülür. Aslında, biceps kasının tendonu içe büküm pozisyonunda yarıçapın çevresini kısmen sarar. Dönüş sırasında, biceps kası kasılır ve esasen ön kolu açar. Dirsek yaklaşık 90 derece bükümdeyken dönüş için en etkili olduğu pozisyondadır ve dirsek geriliyken etkinliğini kaybeder. Bunun nedeni, 90 derecede, kasın moment kolunun uzun olmasıdır; bu nedenle açılma kuvveti de en yüksek seviyesindedir. Dirsek uzatıldıkça moment kolu ve açılma kuvveti azalır, dengeleyici kuvvet artar [6].



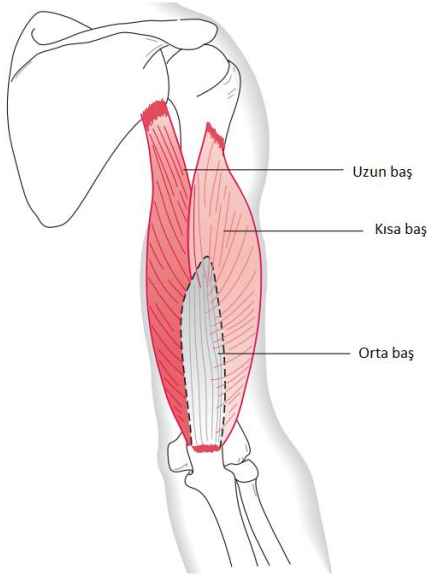
Şekil 2.4 Biceps olarak da bilinen iki başlı kol kası[6]



Şekil 2.5 Biceps kaslarının dönüşü. Tirbuşon ile mantarı şişeden çıkarma esnasında oluşan önkol dönüşü ve eklemdaki bükülmede kullanılan biceps hareketi. İlk önce mantar çevrilir (dış rotasyon), sonra mantar çekilir (bükülme)[6]

2.2.2. Üç Başlı Kol Kası (Triceps)

Üç başlı kol kası, yaygın olarak triceps olarak adlandırılır (Şekil 2.6). Bu kas kolun arkasında bulunur ve arka kolun tüm kas kütleini oluşturur. Uzun kafa, kürek kemiğinin başında bulunan ve kol kemiğinin başı ile bir araya gelerek omuz eklemine oluşturan oyuk alt kenarından gelir ve diğer iki kafaya katılmak için teres minör kası ile teres majör kası arasında iner. Yan kafa, büyük tüberkülün altındaki kol kemiğinin arka yüzeyine yanal olarak tutturulur. Orta baş, uzun ve yan başların derinliklerinde uzanır ve yan başın altında arka yüzeyin çoğuna bağlanır. Üç baş bir araya gelerek kas göbeğini oluşturur. Dirseği oldukça dik bir şekilde yaydığı için dirsek gerilmesinde çok etkilidir. Döner kemiğe eki olmadığı için içe ve dışa bükülmede rol oynayamaz.



Şekil 2.6 Triceps olarak da bilinen üç başlı kol kası[6]

2.2.3. Deltoid Kası

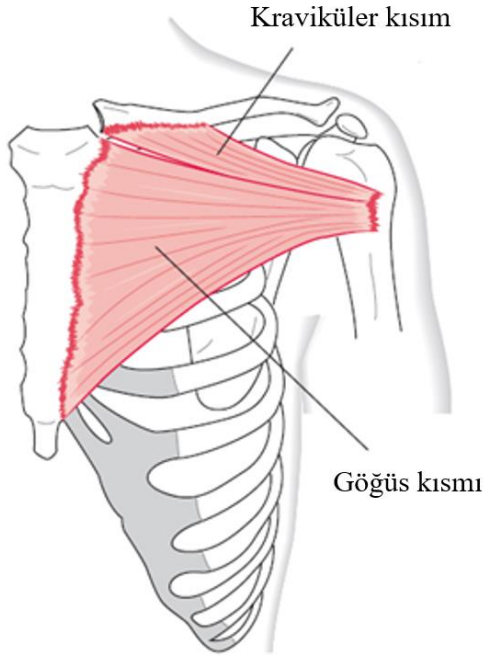
İnsan omzunu üçgen şeklinde çevreleyen ve omuz fonksiyonlarında oldukça önemli bir rol oynayan deltoid kası temelde kolun dışa doğru hareket etmesini sağlayan itici kas olarak tanımlanmaktadır. Temelde; anterior deltoid, lateral (middle) deltoid ve posterior deltoid olarak adlandırılan 3 bölümden oluşur. Omuz hareketinde oynadığı etkin rol sebebiyle, deltoid yırtıklar diğer majör kas yırtılmalarına oranla omuz fonksiyonunu daha da tehlikeye atabilir[7-9].



Şekil 2.7 Deltoid kasın 3 bölümü[6]

2.2.4. Pectoralis Major Kası

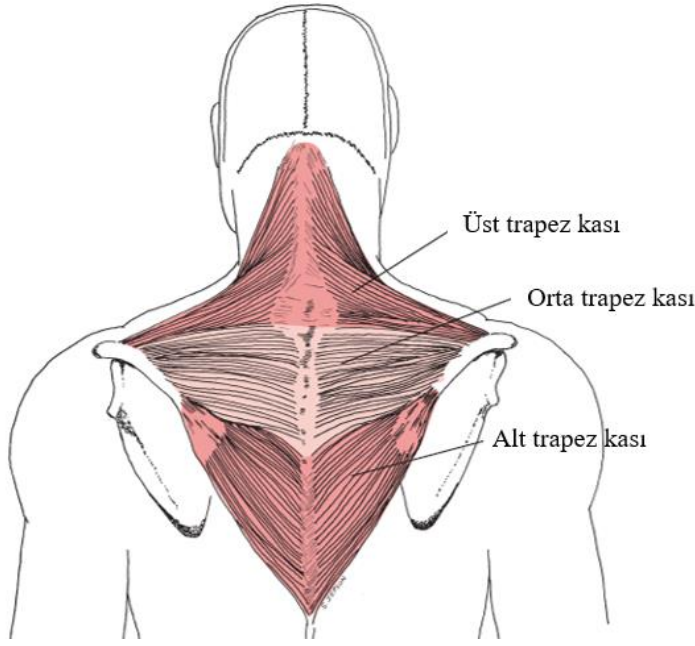
Pektoralis majör adından da anlaşılacağı gibi göğsün büyük bir kasıdır. Deltoid kasın altında uzanan distal bağlantısı dışında yüzeyseldir. Bu kas eklemi medialden laterale anterior yüzeyde çaprazladığı için omuz eklemine yaklaştırılması ve orta rotasyonunda etkilidir. Bu kasın proksimal ekleri ve farklı çekme hatları nedeniyle kraviküler ve göğüs kısmı (Şekil 2.8) olarak ikiye ayrılır[10, 11].



Şekil 2.8 Pektoralis majör kasın iki kısmı

2.2.5. Trapez Kası

Trapez her sağ ve sol taraftan bakıldığında elmas şeklindeki büyük yüzeysel bir kاستır. Sırtın üst arka kısmı ile boynun arkasını örter. Fonksiyon olarak üst orta ve alt olarak üç bölüme ayrılır. Bu ayırım üç farklı çekme hareketinde (yukarı, içeri ve aşağı) farklı kas hareketleri oluşmasından kaynaklanır. Trapez kasının üç bölümü de kürek kemiğini çekmek için birlikte çalışır[12, 13].



Şekil 2.9 Trapez kası

2.3. Yapay Sinir Ağları

Makine öğrenmesi algoritmalarından bir olan yapay sinir ağları, biyolojik sinir sistemine benzer bir yapıda, katman veya katmanlarındaki sinir hücrelerinin (nöron) birbirleri ile bağlantılı olduğu bir yapıya sahiptir. Tek nörondan oluşan ilk basit yapay sinir ağı modeli, Rosenbatt tarafından 1958 yılında yayımlanan “The Perceptron” adlı çalışmasında yayımlanmıştır [14]. Tek bir katmandan oluşan matematiksel ilk yapay sinir ağı modeli ise B.Widrow tarafından 1960 yılında oluşturulmuştur [15]. Tek katmanlı yapay sinir ağlarının doğrusal olmayan problemlerde çalışmayacağı Minsky ve Papert tarafından 1969 yılında yayımlanan kitabında [16] kanıtlandıktan sonra, uzun süre yapay sinir ağları konusundaki gelişmeler yavaşlamıştır. Rumelhart ve McClelland tarafından 2 katmanlı bir yapay sinir ağının doğrusal olmayan problemlerde de çözüm üretebileceğinin gösterilmesi ile birlikte yapay sinir ağları alanındaki çalışmalar tekrar hız kazanmıştır [17].

2.3.1. Çok Katmanlı Yapay Sinir Ağları

B. Widrow ve N.H. Nguyen tarafından 1990 yılında geliştirilen çok katmanlı yapay sinir ağları modeli [18], geri yayılma (back propagation) algoritmasını kullanarak yapay sinir ağlarının doğrusal olmayan problemlerin çözümünü mümkün kılmıştır. Bu algoritma, ağırlıklar kümesini ortalama kare hatasını (Eşitlik (1)) minimize ederek bulmaya çalışır.

Burada $y(X)$ ağıın son katmanındaki çıktı vektörü, $d(X)$ ağıın tahmin vektörüdür. Tek bir algılayıcı için, y_m m algılayıcısının çıktısı ve $s_m(X)$ sigmoid fonksiyonu olmak üzere, benzer şekilde m'inci algılayıcı için bir “eşdeğer hata” tanımlamak (Eşitlik(2)) mümkündür. Diğer katmanlardaki m'inci algılayıcı için “eşdeğer hata” Eşitlik(3)'deki gibi ifade edilmektedir. Eşitlik (3)'teki j indeksi m'inci algılayıcıya girdi olarak bağlı olan diğer algılayıcının indeksini ifade etmektedir, w_{jm} m çıktı algılayıcısına bağlı j'inci girdi algılayıcısı arasındaki bağlantının ağırlığını göstermektedir.


$$J = E(\|d(X) - y(X)\|^2) \quad (1)$$

$$\delta_m = (d_m(X) - y_m(X))f'(s_m(X)) \quad (2)$$

$$\delta_m = f'(s_m(X)) \sum_j \delta_j w_{jm} \quad (3)$$

$$w_{mi,new} = w_{mi,old} + 2\mu\delta_m x_k \quad (4)$$


Her bir ağırlık Eşitlik (4) vasıtasıyla sürekli güncellenir. Burada i, m algılayıcısına girdi olarak bağlı tüm algılayıcıların indekslerini ifade etmektedir. μ değeri ise tasarımcı tarafından ayarlanan, yakınsama hızını etkileyen bir katsayıdır.



Şekil 2.10 Çok katmanlı yapay sinir ağı

2.3.2. LSTM Ağları

Yapısal olarak yinelenen sinir ağlarına(RNN) benzeyen LSTM sinir ağları, RNN modellerinin zayıf noktası olarak bilinen bağlam boşluklarının tahmin edilmesi amacıyla Hochreiter ve Schmidhuber tarafından geliştirilmiştir[19]. LSTM ağlarında önceki durum ile girdi bilgisini tutan hafıza hücreleri bulunur. Bu hafıza hücreleri hangi verinin tutulacağı veya unutulacağına karar vererek, bir sonraki döngüde önceki durumu mevcut hafıza hücresindeki veri ile giriş verisini birleştirerek uzun vadeli bağımlılıkların ortadan kalkmasına imkan sağlamaktadır. Şekil 2.11’de basit yapısı gösterilen LSTM hafıza hücresinde, girdi kapısı (i_t), unutma kapısı(f_t), ve çıktı kapısı(o_t), girdi vektörü (x_t), gizli katman vektörü (h_t), çıktı vektörü (y_t) ile ifade edilmiştir.



Şekil 2.11 Tek hafıza hücresine sahip bir LSTM hafıza bloğu

Gizli katmandaki h vektörü (Eşitlik (10)), tüm LSTM hücrelerinin çıktılarını içermektedir. Eşitlik (5) ve Eşitlik (6)’de hesaplama yöntemi verilen t zamanında veya zaman adımıdaki unutma ve girdi kapıları, sırasıyla f_t ve i_t olarak gösterilmiştir. T zamanında veya zaman adımıdaki girdi hafıza hücresi olan c_t , $t-1$ zamanındaki bilgiyi barındıran hafıza hücresi c_{t-1} ile sürekli güncellenmektedir (Eşitlik (8)). Çıktı kapısı olan o_t değeri ise Eşitlik (9) vasıtasıyla hesaplanır. Burada σ sigmoid aktivasyon

fonksiyonunu, W_f^T , W_i^T , W_c^T , W_o^T , girdi ağırlıklarını, U_f^T , U_i^T , U_c^T ve U_o^T tekrarlanan (recurrent) ağırlıkları ve b_f , b_i , b_c , b_o ise sapmaları ifade etmektedir.

$$f_t = \sigma(W_f^T h_{t-1} + U_f^T x_t + b_f) \quad (5)$$

$$i_t = \sigma(W_i^T h_{t-1} + U_i^T x_t + b_i) \quad (6)$$

$$c'_t = \tanh(W_c^T h_{t-1} + U_c^T x_t + b_c) \quad (7)$$

$$c_t = f_t \circ c_{t-1} + i_t \circ c'_t \quad (8)$$

$$o_t = \sigma(W_o^T h_{t-1} + U_o^T x_t + b_o) \quad (9)$$

$$h_t = o_t \circ \tanh(c_t) \quad (10)$$

2.4. Literatürdeki Çalışmalar

Protez kol tasarımı, modern tıbbın uzun zamandır önemli araştırma konularından biri olmuştur. Uzuvarlarının tamamını veya belli bir bölümünü kaybeden kişiler bu protez kollar ile günlük yaşamlarına devam edebilmekle birlikte özellikle dirsek eklemının kontrolünün zor olmasından dolayı elektrikli protezlerde sıkıntılar yaşamaktadırlar. Eklemi hareket ettirebilmek için gereken aşırı dikkat ve hareketlerin doğal olmayan bir şekilde kontrolü ampute kişilerin şikayetlerinin başında gelmektedir[20]. EMG sinyalleri ile çalışan protez tasarımında bir diğer sorun ise, normal durumda kasılma ile hareketi sağlayacak kas veya kasların ampütasyon işleminden dolayı bulunmamasıdır. Sinir transferi ameliyatı ile ampute edilmiş uzuv üzerindeki kastaki motor ünitelerine bağlı sinirler başka bir hedef kas grubuna bağlanarak, kişinin bu uzuvları sanki varmış gibi elektrik sinyalleri oluşturabildiği gözlemlenmiştir[21, 22].

Özellikle son yıllarda bilgisayarların veri işleme güçlerindeki artışla beraber yapay zekâ uygulamaları da farklı alanlarda kendine yer bulmaktadır. EMG sinyalleri ile uzuvların hareketlerinin sınıflandırılması amacıyla birçok bilimsel çalışma mevcut iken uzuvların gerçek zamanlı kinematik bilgilerini tahmin eden yapay zekâ uygulamaları nispeten daha azdır.

EMG sinyalleri ile bir yapay zekâ modelinin eğitilebilmesi için, elde edilen sinyal değerlerinin matematiksel olarak anlamlı değerlere dönüştürülmesi gerekmektedir. Kaslardaki hareket, kuvvet ve moment gibi fiziksel ifadelerin anlamlandırılmasında EMG sinyallerinin matematiksel özellikleri kullanılmaktadır. Bu matematiksel özellikler sayesinde yapay sinir ağları hedeflenen değerler ile aradaki bağıntıyı öğrenebilmektedir. Yapay sinir ağı için eğitim veri kümesi içerisindeki özellik sayısı arttıkça yapay sinir ağının eğitim süreci de artmaktadır. Bu nedenle hedef değer ile eğitim verisindeki giriş elemanlarının arasında en iyi korelasyonu sağlayan özelliklerin bulunması önem arz etmektedir. J. C. Chen ve arkadaşları, alt ekstremitede diz açılarının EMG sinyalleri aracılığı ile tahmin edilebilmesi amacıyla eğitilen yapay sinir ağı modellerinde özellik sayısının derin öğrenme yöntemleri ile azaltılmasını araştırmış ve geliştirdikleri yöntemin PCA(Principal Components Analysis) yöntemine göre daha iyi sonuç verdiğini göstermişlerdir[23]. D. Karabulut ve arkadaşları, 3 serbestlik derecesine sahip olan bir robotik kola uygulanan 10-70 N arasındaki kuvvetleri, deneklerin kol kaslarından elde edilen EMG sinyalleri ile tahmin etmeye çalıştıkları çalışmada, zaman penceresi 500 ms alınarak elde edilen EMG özelliklerinden, RMS ve IEMG özelliklerinin tahmin ediciliğinin diğer EMG özelliklerine kıyasla daha yüksek olduğu saptanmıştır[24]. Bu çalışmalar doğrultusunda, EMG sinyalleri ile bir yapay zekâ modeli eğitirken optimum sayıda özelliğin eğitim verisi içerisinde bulundurulması gerektiği görülmektedir. W. Yang ve arkadaşları tarafından geliştirilen, özellikle sınıflandırma problemleri için kullanılan bir özellik seçici algoritması olan “Komşuluk Bileşenleri Analizi” (Neighborhood Component Analysis, NCA), B. Amankwaa-Kyeremeh ve arkadaşları tarafından regresyon problemlerine uygulanabilecek şekilde uyarlanarak elde edilen tahmin ediciler ile regresyon problemlerinde daha iyi sonuç alındığı ortaya konmuştur[25, 26]. Bu tez çalışmasında da tahmin edici özelliklerin bulunabilmesi amacıyla NCA algoritması kullanılmıştır.

S. I. Benchabane ve arkadaşları zaman etki alanında hesaplanan EMG sinyal özellikleri için eşik değerlerinin değişen durumlara (yorulma gibi) göre kendiliğinden güncellenmesi için bir hesaplama yöntemi geliştirmişler ve elde edilen eşik değer güncelleme yöntemi ile tekrar hesaplanan EMG özelliklerinin eldeki parmak hareketlerini daha iyi bir doğruluk derecesi ile sınıflandırdığı saptanmıştır. Sağlam uzuvlara sahip altı erkek denekten elde edilen sinyaller 100 ms uzunluğundaki zaman pencerelerine bölünerek, her

bir pencere için sinyalin hareketli ortalamasına göre deęişen bir eşik deęer hesaplanmıřtır. Bu eşik deęer, sinyalin geldięi parmaęın açık veya kapalı durumda olduęunu hesaplayan bir fonksiyonda kullanılarak eldeki parmakların hareket durumları hesaplanmaktadır. Geliřtirilen bu yeni yöntem, deneklerin parmaklarının konumunu 89,6% gibi yüksek bir doęruluk ile sınıflandırmayı bařarmıřtır. alıřma sonucunda, önceden eęitilmiş bir yapay zeka modelinin aksine, gerek zamanlı olarak hesaplanan bir fonksiyon ile, hesaplama yükünün az olduęu bir EMG kontrollü protez el tasarımının mümkün olduęu vurgulanmıřtır [27].

Üst kolda bulunan kasların EMG sinyalleri ve omuz açıları ile dirsek eklem açısını tahmin etmeęe alıřtıkları alıřmada A. Akhtar ve arkadařları, sekiz saęlam ve üç adet de hedef kas canlandırma ameliyatı geirmiş ampute kiřilerden elde ettikleri veriler ile zaman gecikmeli sinir aęı modellemesi ile kol eklem açılarını tahmin etmeye alıřmıřlardır. Kontrol grubu olarak kullandıkları ampute kiřilerin kol eklem açılarının, saęlam uzuvlara sahip kiřilerden elde edilen EMG verileri ile tahmin edilebildięi görölmüştür. EMG sinyallerinin omuz oryantasyon deęerleri ile tahmin edici bir faktör olarak kullanılmasıyla dirsek açılarını tahmin etmede daha iyi sonuç alındıęı belirtilmiřtir[28]. X. Chen ve arkadařları, el, kol ve omuzdan aldıkları EMG sinyalleri ile deneklerin gerekleřtirdięi 6 farklı hareketin sınıflandırmasını Bayes sınıflandırma algoritması ile saęlamıřlardır [29].

A. Au. ve R. Kirsch, kol ve omuzda bulunan 6 kastan elde ettikleri EMG sinyalini kullanarak zaman gecikmeli yapay sinir aęları ile omuz ve dirsek açısını tahmin etmeye alıřmıřlardır. Bu alıřmada kolun katı cisim rotasyon deęerleri bir optik hareket yakalama sistemi ile hesaplanmış, EMG sinyalleri ile optik hareket yakalama sisteminin veri örnekleme hızları birbirlerine eřitlenerek bir eęitim verisi elde edilmiřtir. Zaman gecikmeli yapay sinir aęında elde edilen EMG ve rotasyon verileri eřit zaman pencerelerine (825 ms) bölünerek; farklı miktarlardaki ardışık zaman pencereleri, yapay sinir aęına veri giriři olarak beslenmiřtir. Elde edilen tahmin sonuçları ile deneysel veriler karřılařtırıldıęında rotasyon bilgilerinin tahmininde hata oranının en az 10,7% ve en fazla 23,4% olduęu görölmüştür [30].

A. Foroutannia ve arkadaşları robotik kontrollü bir dış iskeletin parçalarının pozisyonlarını bacak kaslarından elde edilen EMG sinyalleri ile tahmin etmek amacıyla LSTM modelini kullanmışlardır. Böylece farklı yürüme hızlarında denek ile dış iskeletin daha uyumlu hareket etmesi sağlandığı vurgulanmıştır[31].

Olasılığa dayalı bir model olan Gauss Karışım Modeli ile kol dış iskeletinin ileri ve geri hareketlerini sınıflandırmak amacıyla EMG sinyallerinin kullanıldığı çalışmada E. Trigili ve arkadaşları, ileri ve geri hareketleri sırasıyla 89,3% ve 60,9% doğrulukla tahmin etmeyi başarmışlardır. Çalışmada kullanılan 14 adet zaman etki alanındaki EMG sinyal özelliğinden en fazla korelasyona sahip özellikler ile yapılan modelin tahminleri istatistiksel olarak anlamlı bir fark yaratmamıştır [32].

D. P. Yang ve H. Liu, el bileğinin 3 serbestlik derecesinde dönme hareketinin EMG sinyalleri ile tahmin etmeğe çalıştıkları çalışmada, EMG sinyalleri 50 ms aralıklar ile etiketlenerek özellikleri çıkartılmıştır. Hazırlanan düzenekte bileğe sabitlenmiş bir lazer ışık kaynağından çıkan birbirine dik ışık demetlerinin oluşturduğu koordinat ekseninin dönüş değeri, eğitilecek yapay zeka modelinin hedef değerleri olarak belirlenmiştir[33].

Hiyerarşik projeksiyonlu regresyon yöntemi ile Y. Chen ve arkadaşları dirsek açısını tahmin ettikleri çalışmada, deneklere hafif ağırlık kaldırma ve bardaktan su içme hareketlerini yaptırırken, koldan elde ettikleri EMG sinyalleri ve IMU sensöründen elde ettikleri ivme verileri ile dirsek açılarını tek serbestlik derecesinde kaydetmişlerdir. Hiyerarşik projeksiyonlu regresyon modelinde her bir EMG sinyali ve buna karşılık gelen açı, mikro düzeyde bir regresyon modeli olarak kabul edilmektedir. Belirlenen eşik değer ve varyansın üzerinde kalan model bir iç düğüm noktası haline gelerek alt düğüm noktaları da kümeleme yöntemi ile hesaplanmıştır. Test edilen EMG verileri bu ağaç üzerinde aranarak en yakın komşu regresyon algoritması ile tahmin edilen açı değeri hesaplanmıştır[34].

D. Bu ve arkadaşları, EMG sinyallerinin görüntü verilerini kullanarak geliştirdikleri Yolo v4 algoritması vasıtasıyla kol hareketlerini ortalama 80,7% hassasiyet ile doğru bir şekilde sınıflandırmayı başarmışlardır[35]. Bu çalışma EMG verilerinin görselinin bile kol hareketlerinin tahmininde ne kadar önemli bir etken olduğunu göstermektedir. EMG

sinyalleri ile hareket tahmini için yapay sinir ağı dışında ileri dinamik modellemeleri de kullanılmaktadır.

D. L. Crouch ve H. Huang çalışmasında, optik hareket yakalama sistemleri ve EMG sensörleri ile tek bir denek için kol üzerindeki 4 kastan elde ettikleri veriler ile OpenSIM aracılığı ile oluşturdukları modelde ileri dinamik analizi yaparak dirsek açısını $12,8 \pm 2,5^\circ$ hata ile tahmin etmeyi başarmışlardır [36].

İnsan vücudunun simetrik yapısı, vücudun sağlam bir uzvundan elde edilen verilerin ampute uzvundaki verileri oluşturulmasına da imkân vermektedir. A. Cimolato ve arkadaşları alt ekstremitede sağlam bacaktan elde ettikleri EMG ve IMU sensör verileri ampute bacadaki kas sinyallerinin oluşturulmasında kullanmışlardır. Elde edilen model ile kişiye özel, doğal kas hareketleri ile çalışan bir protezin oluşturulabileceği ve EMG sinyallerinden hareket tahmininin yanı sıra diğer uzuvlardaki sinyal değerlerinin de oluşturulmasında kullanılabileceği gösterilmiştir [37].

M. A. García-Vellisca ve arkadaşları, EMG ve IMU sensörleri ile donatılmış özel bir eldivenin kullanıldığı çalışmada, 17 farklı kastan elde edilen sinyaller ile parmak açılarını tahmin etmek amacıyla Uzun Kısa Vade Hafıza (Long Short Term Memory, LSTM) algoritması kullanılarak 2 farklı model geliştirilmiştir. Birinci modelde her EMG verisinden sadece hareketli ortalama değeri, diğer model de ise her EMG verisinden hareketli ortalama, sıfır geçişi ve varyans özellikleri olmak üzere toplam 51 adet özellik girdi olarak kullanılmıştır. Elde edilen sonuçlarda LSTM yönteminin tek bir özellik ile dahi verimli sonuç verdiği ortaya konmuştur [38].

3. METOD VE YÖNTEM

3.1. Katılımcılar

Kolunda herhangi bir sağlık problemi olmayan 21-41 yaş arası 3 erkek ve 3 kadın, sağlıklı gönüllü çalışmaya katılmıştır. Katılımcıların antropometrik özellikleri Çizelge 3.1’de verilmiştir.

Çizelge 3.1 Katılımcıları özellikleri

	Ortalama \pm Standart Sapma	
Yaş(yıl)	26.67	7.67
Boy(cm)	170.33	6.24
Kilo(kg)	63.17	12.95

3.2. Veri Toplama İşlemi

Katılımcıların 2 boyutlu düzlemde yapılacak hareketlerde, ağırlığı sürtünmeden ve yerçekiminden bağımsız hareket ettirebilmeleri için 20 cm x 20 cm ölçülerinde tekerlekli ahşap platform oluşturulmuş ve ortasına 20 cm uzunluğunda bir tutma kolu Şekil 3.1’de görüldüğü gibi eklenmiştir. Katılımcılar T duruşu ile başladıkları deneylerde, tetikleme lambasının yanmasını takiben bir sandalyeye oturarak ve üzerinde ağırlık bulunan hareketli platformu sağ kollarını kullanarak 40 saniye boyunca ileri-geri hareket ettirmişlerdir. Deney süresinin tamamlanmasının ardından tekrar T duruşuna geçerek hareket yakalama işlemi sonlandırılmıştır (Şekil 3.2). Her deney arasında katılımcıların en az 20 saniye dinlenmesine olanak sağlanmıştır.



Şekil 3.1 Boyutlu deney düzeneği




Şekil 3.2 Deney başlangıcı ve sonunda T duruşu

Hareket yakalama işlemi kızılötesi ışık vasıtasıyla yüksek hızda görüntü kaydedebilen kameralar vasıtasıyla gerçekleştirilmiştir (Vicon, Birleşik Krallık). Optik hareket yakalama sistemi insan vücudunu tanımlayabilmek için iskeletin tepe noktasını belden başlatmaktadır. Bu nedenle, deneyin konusu gereği sadece kol hareketlerini yakalamak için de olsa, deneklere işaretleyiciler bel hizasından başlanarak sağ kol bileğine kadar Vicon iskelet şablonuna uyacak şekilde yerleştirilmiştir. Katılımcıların üst gövde ve sağ koluna toplam 18 adet işaretleyici yerleştirilerek (Şekil 3.3) elde edilen görüntüler Blade

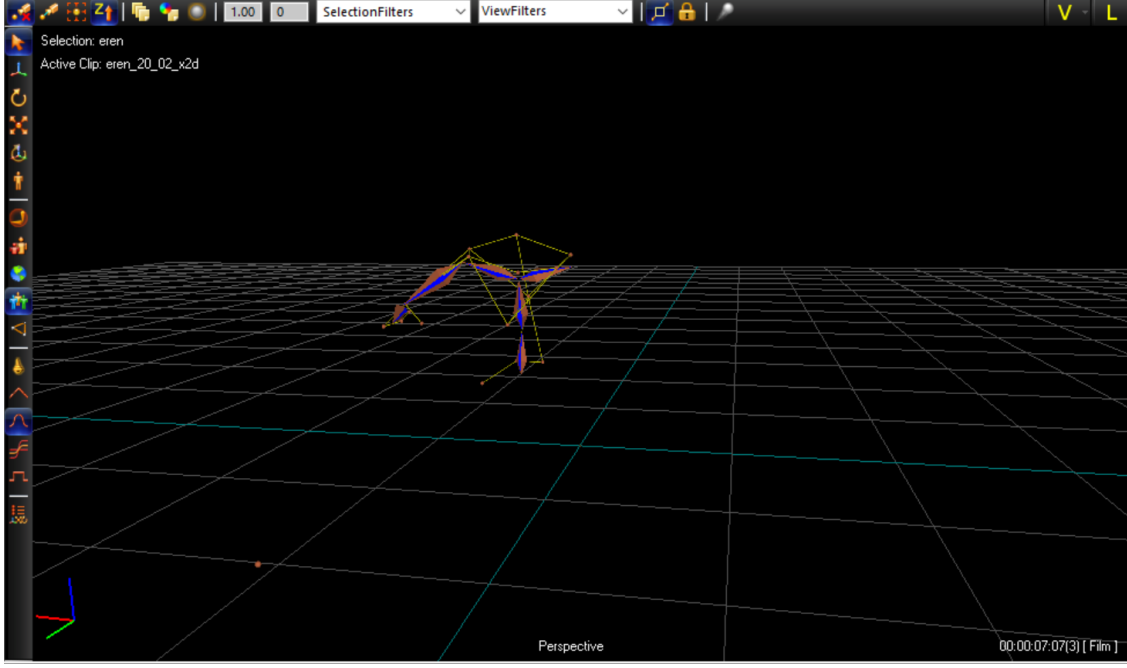
2.6.1 yazılımıyla (Vicon, Birleşik Krallık) tüm iskelet sisteminden deney sırasında kullanılmayan işaretleyiciler çıkartılıp Blade programı vasıtasıyla çözümlenerek katılımcıların kol dönüş bilgileri Matlab (Mathworks, Amerika Birleşik Devletleri) ortamına aktarılmıştır.

EMG ölçümleri için 8 kanaldan kayıt yapabilen Bagnoli EMG sistemi (Delsys, Amerika Birleşik Devletleri) kullanılmıştır. Deneyler sırasında kol kaslarındaki (Biceps, Triceps, Anterior Deltoid, Posterior Deltoid, Trapez) elektriksel değişimler 6 adet yüzeysel EMG sensörü ile 1000 Hz örnekleme frekansında elde edilmiştir (Şekil 3.3). Elde edilen elektriksel analog değerler NI USB-6210 (National Instruments, Amerika Birleşik Devletleri) dijital dönüştürücü vasıtasıyla Matlab ortamına aktarılmıştır.

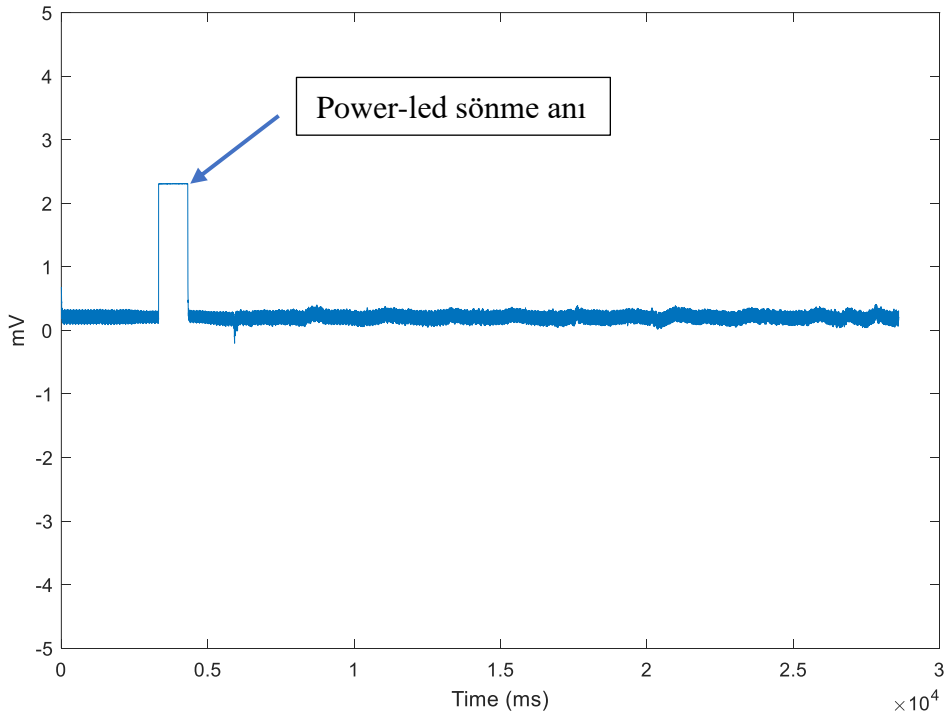


Şekil 3.3 EMG sensörleri ve işaretleyicilerin yerleştirilmesi

Hareket yakalama görüntüleri ile EMG verilerinin senkronizasyonu amacıyla, Arduino R3 mikroşlemci (Arduino, İtalya) ve 1 Watt gücündeki kızılötesi power-led ile bir tetikleyici düzeneği oluşturulmuştur. Düzenek bir buton ile tetiklenerek hem power-led'e hem de Bagnoli EMG sistemine aynı anda sinyal göndermektedir. Böylece kızılötesi ışık saçan power-led, hareket yakalama sistemi tarafından işaretleyici olarak görülmektedir (Şekil 3.4). Power-led'in sönmeye anı deneyin başlangıç noktası kabul edilerek EMG verileri ile senkronizasyon sağlanmıştır (Şekil 3.5).




Şekil 3.4 Blade yazılımında tetiklenme anının görüntülenmesi



Şekil 3.5 Tetiklenme zamanının EMG verisinde bulunması

Deney düzeneğinin şematik görünümü Şekil 3.6'da verilmiştir.



Şekil 3.6 Deney düzeneği şematik görünüm

Kolun 3 boyutta hareket ve EMG verilerinin toplanması işlemi, hareketli platform ve ağırlık olmaksızın 2 boyutlu deney düzeneğine benzer şekilde, katılımcının T duruşuyla başlayıp bitirdiği ve tetikleyici lambasının yanmasından itibaren 40 saniye boyunca sandalyede oturur halde, yemek yeme, su içme, kitap okuma, gözlük takıp çıkartma, saate bakma, yazı yazma gibi günlük hayattan hareketleri karışık sıra ile tekrarlaması ile yapılmıştır. Katılımcıların her deney arasında en az 20 saniye dinlenmesine olanak sağlanmıştır.

3.3. Verilerin Hazırlanması

3.3.1. Hareket Yakalama Verilerinin İşlenmesi

Kızılötesi kameralar ile yakalanan işaretleyiciler Blade yazılımında etiketlenerek iskelet oluşturma işlemi yapılmıştır. İskeletin üst kol ve alt kol rotasyon değerleri kızılötesi kamera üreticisi tarafından sağlanan Datastream SDK (Vicon, Birleşik Krallık) yardımcı yazılımı ile Matlab ortamına 240 kare/saniye frekansında aktarılmıştır.

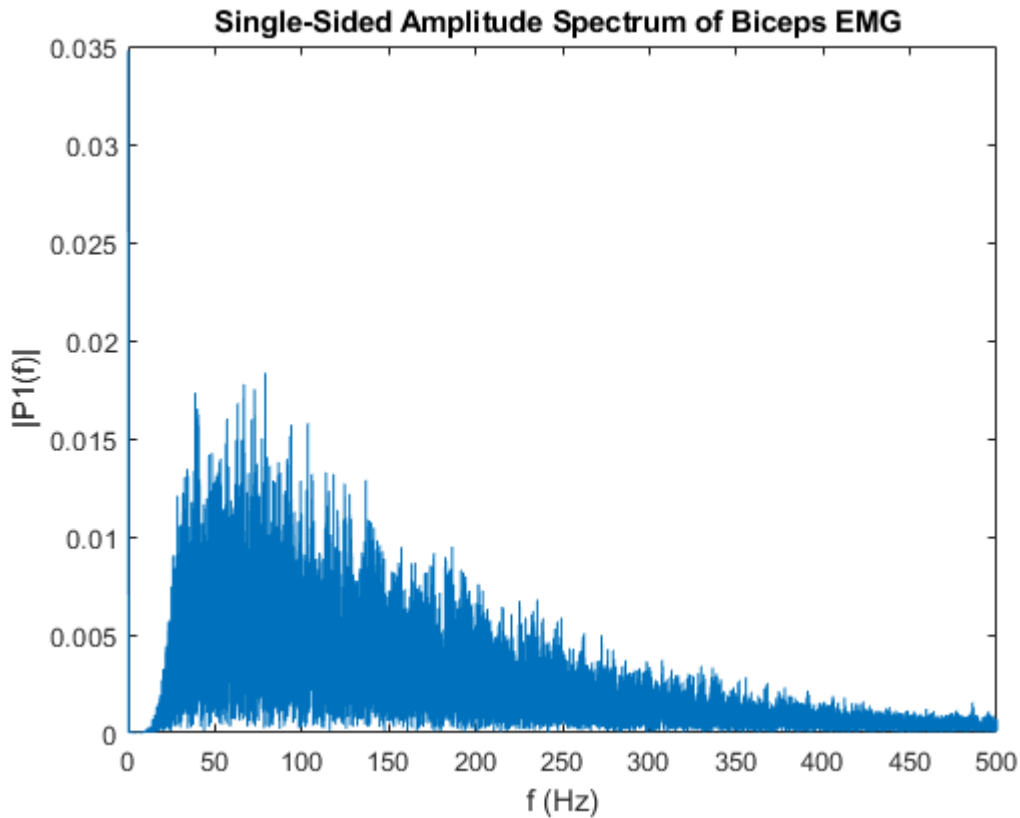
3.3.2. EMG Verilerin İşlenmesi

NI USB 6210 vasıtasıyla Matlab ortamına aktarılan EMG verileri ilk önce ortalamaları sifira yaklaşacak şekilde düzeltilmiş (detrend) ve tetikleyici kanalındaki elektrik sinyalinin maksimum değerine sahip aralık bulunmuş, bu aralığın son indisi, tetikleyici lambanın söndüğü zaman değerine denk geldiğinden bu zamandan önceki EMG verileri silinerek hareket yakalayıcı sistem ile aynı anda başlayan veriler elde edilmişlerdir.

Bütün deneylerde EMG veri toplama işlemi bittikten sonra hareket yakalama işlemi sonlandırıldığından hareket verilerinin uzunluğu EMG verilerinin uzunluğuna eşitlenmiştir. Hareket yakalama sistemi ile EMG verilerinin örneklem frekanslarının farklı olmasından dolayı, 240 kare/saniye örneklem frekansındaki hareket verileri 1000 kare/saniye örneklem hızına dönüştürülmüştür.


Her bir katılımcının 2 boyutlu ve 3 boyutlu deneylerdeki EMG verilerinden her bir kasın maksimum EMG değeri bulunarak EMG verileri bu maksimum değere bölünmüş, böylece verilerin $[-1,1]$ aralığında normalize edilmesi sağlanmıştır.

EMG sinyallerinin gürültüden arındırılması amacıyla öncelikle sinyalin Fourier Dönüşüm Analizi (Şekil 3.7) yapılmıştır.



Şekil 3.7 Fourier dönüşümü sonrasında EMG spektrumları

EMG sinyalleri 10 - 400 (bandpass) Hz aralığında ikinci dereceden Butterworth filtre uygulanarak gürültüden arındırılmıştır (Şekil 3.8).



Şekil 3.8 Filtrelenmiş ve ham EMG verisi

3.3.3. Özellik Çıkartma İşlemi

Ham veriyi temsil edebilecek şekilde verinin sayısal özelliklere dönüştürülmesi işlemi, özellik çıkarma (feature extraction) şeklinde adlandırılmaktadır. Özellikle makine öğrenmesi uygulamalarında ham veri yerine sayısal özelliklerin kullanılması daha iyi sonuç vermektedir.

EMG sinyallerinin özellikleri zaman etki alanında (time domain), frekans etki alanında (frequency domain) ve zaman-frekans etki alanında çıkartılabilmektedir. A. Phinyomark ve arkadaşları tarafından yayımlanan çalışmada 37 farklı EMG sinyali özelliği irdelenmiş olup, zaman etki alanındaki EMG sinyali özelliklerinin makine öğrenmesi yöntemlerinde diğer özelliklere göre daha iyi sonuç verdiği ortaya konmuştur [39]. Bu tez çalışmasında hem hesaplama aşamasında herhangi bir dönüşüme gerek kalmaması hem de biyomedikal ve mühendislik uygulamalarında yaygınlıkla kullanılması nedeniyle zaman etki alanındaki özellikler kullanılmıştır. Tez çalışması boyunca yapılan deneylerden elde edilen EMG verilerinden özellik çıkarma işlemi için kullanılan zaman frekans etki alanındaki özellikler ve hesaplama yöntemleri Çizelge 3.2’de verilmiştir.

Çizelge 3.2 Zaman Etki Alanında EMG Sinyal Özellikleri

EMG Sinyal Özelliği	Hesaplama Yöntemi	Açıklama
Bütünleşmiş EMG (Integrated EMG)	$IEMG = \sum_{k=1}^N emg_k $	(11) Kaslardaki kasılmanın başlangıcı ile ilgili bir sayısal özelliktir.
Ortalama Mutlak Değer (Mean Absolute Value)	$MAV = \frac{1}{N} \sum_{k=1}^N emg_k $	(12) Karakteristik olarak IEMG özelliğine benzemektedir. Robotik protez kol kontrolü için yaygın kullanılan EMG sinyal özellikleri arasındadır.
Ortalama Karekök (Root Mean Square)	$RMS = \left(\sqrt{\sum_{k=1}^N emg_k^2} \right) / N$	(13) Sabit kuvvet altında ve yorulma göstermemiş kasın kasılması ile ilgili bir sayısal özelliktir.
Dalga Boyu	$WL = \sum_{k=1}^{N-1} emg_{k+1} - emg_k $	(14) Dalga boyu EMG sinyalinin karmaşıklığının bir ölçütü olarak ifade edilebilir.
Ortalama Genlik Değişimi (Average Amplitude Change)	$DAMV = \frac{1}{N-1} \sum_{k=1}^{N-1} emg_{k+1} - emg_k $	(15) Dalga boyunun ortalamasıdır.
Varyans	$VAR = \frac{1}{N-1} \sum_{k=1}^N emg_k^2$	(16) Sinyal gücü ile ilişkilidir.
Sıfır Geçiş (Zero Crossing)	$ZC = \sum_{k=1}^N sgn(-emg_k emg_{k+1})$ $sgn(x) = \begin{cases} 1, & x \geq \text{eşik değeri} \\ 0, & x < \text{eşik değeri} \end{cases}$	(17) Sinyalin frekans bilgilerini zaman etki alanında içeren özelliktir. Gürültü

			ve voltaj dalgalanmalarından kaynaklanan hataların giderilmesi amacıyla eşik değeri kullanılmaktadır.
Wilson Genliği (Wilson Amplitude)	$WAMP = \sum_{k=1}^{N-1} f(emg_k - emg_{k+1})$ $f(x) = \begin{cases} 1, & x \geq \text{eşik değeri} \\ 0, & x < \text{eşik değeri} \end{cases}$	(18)	Sıfır geçişi gibi frekans bilgilerini barındıran bir özelliktir. Kasın motor ünite hareket potansiyeli ve kasılma kuvveti ile ilgilidir.
Basite Kare Integral (Simple Square Integral)	$SSI = \frac{1}{N} \sum_{k=1}^N emg_k^2$	(19)	EMG sinyalinin enerjisi ile ilgilidir.
Log Detector	$LOG = e^{\frac{1}{N} \sum_{k=1}^N \log(x_k)}$	(20)	Kasın kasılma kuvveti ile alakalıdır.

Her bir katılımcının EMG verileri 20 ms, 50ms ve 100 ms genişliğinde zaman pencerelerine bölünerek zaman etki alanındaki özellikleri çıkartılmıştır. Aynı şekilde rotasyon değerleri de EMG verilerinde kullanılan zaman pencerelerine bölünmüş, zaman penceresindeki rotasyon değerlerinin ortalamaları yapay sinir ağı eğitiminde çıktı değeri olarak Matlab ortamında kaydedilmiştir.

3.3.4. Eğitim ve Test Verilerinin Hazırlanması

Katılımcıların her deney sırasında oluşturdukları EMG verilerinden elde edilen özellikler ve hareket yakalama verileri 20ms, 50 ms ve 100 ms pencere bölümlerinde hesaplanarak Matlab ortamında kaydedilmiştir. Katılımcılardan 5 tanesi eğitim, 1 tanesi test verisi olacak şekilde gruplanarak eğitim ve test verileri Çizelge 3.3'te gösterildiği gibi oluşturulmuştur.

Çizelge 3.3 Eğitim ve test verilerini oluşturan katılımcılar

Eğitim Verisi Katılımcılar	Matlab Dosya Adı(.mat)	Test Verisi	Matlab Dosya Adı(.mat)
S1+S2+S3+S4+S5	Train1	S6	Test1
S1+S2+S3+S4+S6	Train2	S5	Test2
S1+S2+S3+S5+S6	Train3	S4	Test3
S1+S2+S4+S5+S6	Train4	S3	Test4
S1+S3+S4+S5+S6	Train5	S2	Test5
S2+S3+S4+S5+S6	Train6	S1	Test6

3.3.5. Özellik Seçimi

Makine öğrenmesi algoritmalarında eğitim verisi olarak kullanılan özellikler eğer hedef verisi ile yeterli korelasyon sağlamıyorsa bu durum kullanılan makine öğrenmesi algoritmasının tahmin etme performansını olumsuz etkilemektedir. Bu nedenle EMG sinyallerinden elde edilen özelliklerin, hedef veri ile korelasyonları incelenmesi ve düşük korelasyona sahip özelliklerin veri kümesine dışında tutulması gerekmektedir.

Çok boyutlu veriler ile regresyon problemlerinde özellik seçimi yapmak amacıyla W. Yang ve arkadaşları Komşuluk Bileşeni Özellik Seçimi (Neighborhood Component Feature Selection) isimli bir yöntem geliştirmişlerdir. Amankwaa-Kyeremeh, B. ve arkadaşları bu yöntemi regresyon problemleri ile çalışacak şekilde geliştirmişlerdir[25, 26]. Bu yöntemle göre; S eğitim verisi seti, d boyutlu x özellik vektörü ve y hedef değerlerinden oluşan bir küme olarak tanımlanmaktadır. N gözlem sayısını belirtmektedir.

$$S = \{(x_1, y_1), \dots, (x_i, y_i), \dots, (x_N, y_N)\} \quad (21)$$

S kümesi içerisinde rastgele bir x_j ve buna karşılık gelen hedef değer olan y_j noktası seçilir. Özelliklerin ağırlıkları stokastik gradyan inişi algoritmasını kullanan $f(w)$ fonksiyonu ile güncellenir.

$$f(w) = \sum_i \sum_j y_{ij} P_{ij} - \lambda \sum_{r=1}^d w_r^2 \quad (22)$$

Burada,

$$P_{ij} = \frac{\exp\left(\frac{D_w(x_i, x_j)}{\sigma}\right)}{\sum_{k \neq i} \exp\left(\frac{D_w(x_i, x_k)}{\sigma}\right)} \quad (23)$$

P_{ij} , x_i veri noktasının diğer bir x_j noktasını kendi en yakın komşuluğu olarak seçme olasılığıdır. Amaç, en yakın komşuluk regresyonunu optimize eden özellik alt kümesini sağlayan ağırlık vektörünü (w) bulmaktır. x_i ve x_j veri noktaları arasındaki ağırlıklı uzaklık:

$$D_w(x_i, x_j) = \sum_{r=1}^d w_r^2 |x_{ir} - x_{jr}| \quad (24)$$

Eşitliğiyle hesaplanmaktadır. Burada w_r , r 'nci özelliğin ağırlığıdır.

Tez çalışmasında regresyon problemlerinde komşuluk bileşeni özellik seçimi için Matlab ortamında fsrnca fonksiyonu kullanılmıştır.

3.4. Yapay Sinir Ağı Modellerinin Belirlenmesi

Üst ve alt kol dönüş değerlerinin EMG özellikleri ile tahmin edilebilmesi amacıyla 2 gizli katmana sahip çok katmanlı yapay sinir ağı modeli oluşturulmuştur. Çok katmanlı yapay sinir ağında en iyi sonucun hangi nöron sayısında elde edileceğini tespit edebilmek amacıyla 10 farklı nöron kombinasyonu denenmiştir.

LSTM yapay sinir ağı için 2 adet LSTM katmanına sahip bir model oluşturulmuş ve 10 farklı nöron sayısı kombinasyonu denenmiştir. Oluşturulan yapay sinir ağı modelleri için kullanılan nöron sayıları Çizelge 3.4'te verilmiştir. Her iki yapay sinir ağı modeli için optimizasyon fonksiyonu olarak "adam" algoritması seçilmiştir. LSTM yapay sinir

ağında modelin veriyi ezberlemesini (overfitting) önlemek amacıyla katmanlar arasında 0,3 oranında dropout katmanını kullanılmıştır.

Çizelge 3.4 Yapay sinir ağlarında kullanılan nöron sayıları

Gizli Katman 1- Nöron Sayısı	Gizli Katman 2 – Nöron Sayısı
100	100
200	100
200	200
300	100
300	200
300	300
400	100
400	200
400	300
400	400

3.5. Yapay Sinir Ağlarının Performansının Değerlendirilmesi

3.5.1. Ortalama Kare Hatası (MSE)

Tez çalışmasında çözülmeye çalışılan problem bir regresyon problemi olduğundan, elde edilen modellerin tahmin performansları Eşitlik (25) ile hesaplanmıştır.

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_{t,i}^2 - y_{p,i}^2) \quad (25)$$

Burada; n, test verisi içerisindeki toplam açılı sayısını, y_t tahmin edilmeye çalışılan gerçek test değerini, y_p ise modelin tahmin değerini ifade etmektedir.

4. BULGULAR

4.1. 2 Boyutta Hareket Tahminleri

4.1.1. Çok Katmanlı Yapay Sinir Ağı Tahminleri

Çok katmanlı yapay sinir ağı modelleri ile yapılan tahminler ve modellerin MSE değerleri, 20ms, 50 ms ve 100 ms zaman pencereleri için sırasıyla Çizelge 4.1, Çizelge 4.2 ve Çizelge 4.3'te verilmiştir.

Çizelge 4.1 20 ms zaman penceresinde çok katmanlı yapay sinir ağı tahmin performansları

Gizli Katman 1- Nöron Sayısı	Gizli Katman 2- Nöron Sayısı	MSE					
		Grup1	Grup2	Grup3	Grup4	Grup5	Grup6
100	100	6.37166	0.47165	0.60425	0.11410	2.58781	0.39775
200	100	10.17735	0.37901	0.68405	0.11011	2.88168	0.38892
200	200	15.28591	0.47829	0.55603	0.10626	2.84223	0.42278
300	100	6.34843	0.31514	0.58598	0.11070	2.70874	0.36703
300	200	20.37226	0.46973	0.70177	0.11363	2.76655	0.53504
300	300	9.78782	0.34143	0.66549	0.11268	2.62567	0.61635
400	100	14.51711	0.31292	0.73921	0.10599	2.68521	0.41441
400	200	20.60206	0.47415	0.64333	0.11362	2.48530	0.36495
400	300	13.07332	1.02654	0.75103	0.12214	2.92330	0.69830
400	400	34.39418	0.33423	0.79749	0.11215	3.05534	0.63869
Ortalama:		15.09301	0.46031	0.67286	0.11214	2.75618	0.48442

Çizelge 4.2 50 ms zaman penceresinde çok katmanlı yapay sinir ağı tahmin performansları


Gizli Katman 1- Nöron Sayısı	Gizli Katman 2- Nöron Sayısı	MSE					
		Grup1	Grup2	Grup3	Grup4	Grup5	Grup6
100	100	15.91716	0.45989	0.83213	0.11411	2.74325	0.59694
200	100	8.57724	0.66280	0.70276	0.11426	2.64071	0.36185
200	200	13.74921	0.63127	0.83074	0.14490	3.13180	0.43214
300	100	16.20006	0.34725	0.66477	0.11922	2.56039	0.70113
300	200	14.31800	0.64566	0.79896	0.14607	2.72867	0.43431
300	300	10.19453	0.71489	1.09979	0.12503	2.48011	0.85967
400	100	8.57094	0.48158	0.75245	0.12010	2.84740	0.44755
400	200	12.68692	0.69925	0.80702	0.12991	2.66865	0.42097
400	300	17.74032	0.89076	1.28772	0.13576	2.58255	0.63208
400	400	39.05167	1.18630	1.59884	0.12463	2.79230	0.64482
Ortalama:		15.70060	0.67196	0.93752	0.12740	2.71759	0.55315

Çizelge 4.3 100 ms zaman penceresinde çok katmanlı yapay sinir ağı tahmin performansları

Gizli Katman 1- Nöron Sayısı	Gizli Katman 2- Nöron Sayısı	MSE					
		Grup1	Grup2	Grup3	Grup4	Grup5	Grup6
100	100	18.94434	0.58301	1.01851	0.09601	2.58913	0.95549
200	100	9.26079	0.56177	0.78425	0.11917	2.62677	0.81343
200	200	11.73112	1.01250	1.17654	0.13170	3.10000	0.65608
300	100	13.14483	0.29998	0.84206	0.14800	2.76797	0.82141
300	200	24.75436	0.67545	1.08257	0.13629	4.47650	0.77624
300	300	13.31537	0.86500	1.70418	0.18438	3.93666	1.01890
400	100	14.18088	0.60840	1.48778	0.12205	3.12487	1.22851
400	200	16.14110	0.50524	0.92744	0.16515	3.28298	1.25055
400	300	11.54623	1.02183	1.48180	0.22303	2.95972	1.26902
400	400	15.52948	1.59347	1.44518	0.18769	3.24612	0.76858
Ortalama:		14.85485	0.77267	1.19503	0.15135	3.21107	0.95582

20 ms zaman penceresindeki tahmin performansları değerlendirildiğinde Grup4 veri setinin en düşük MSE değerine (0.10599) sahip olduğu görülmektedir.

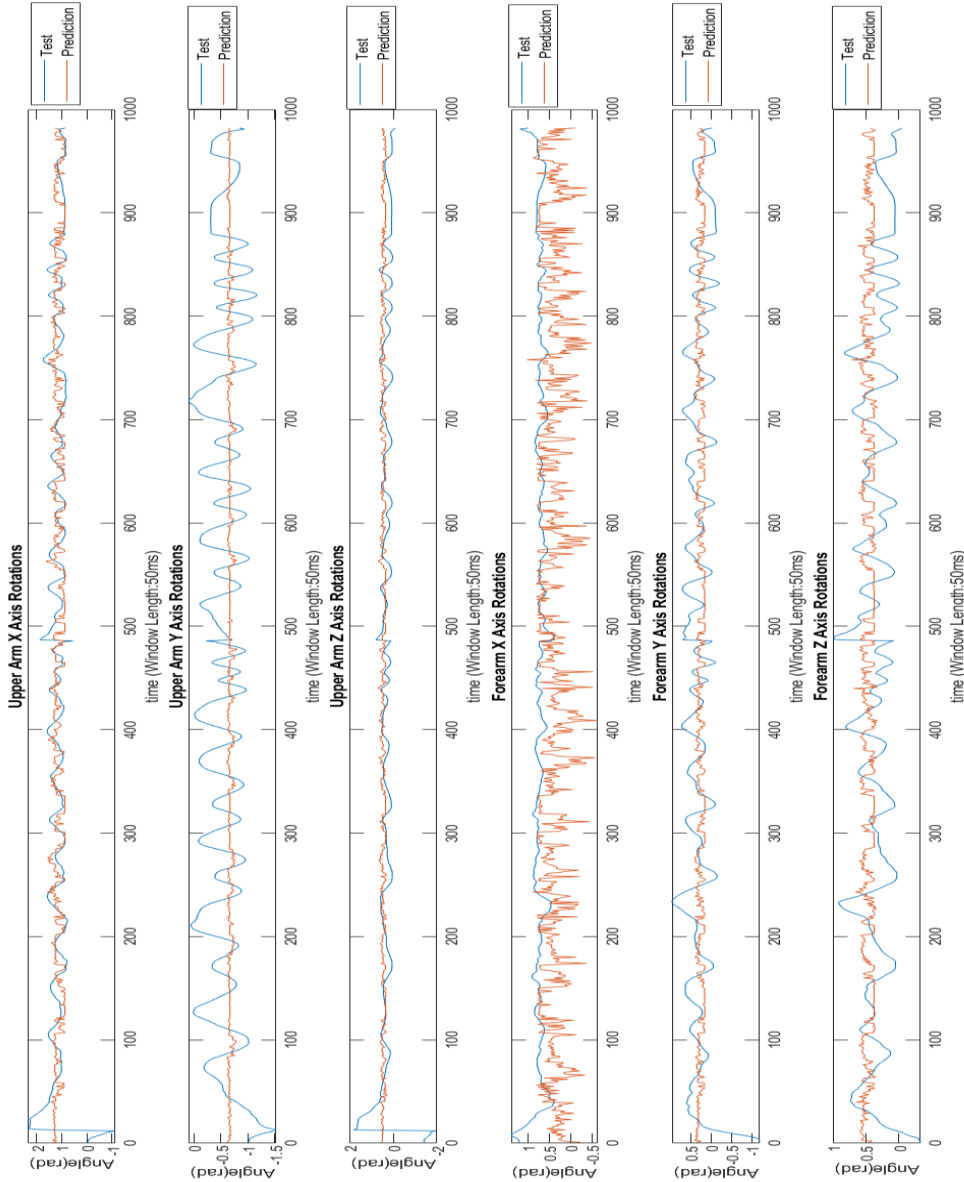
20 ms zaman penceresinde Grup4 veri seti ile oluşturulan, birinci gizli katmanında 400, ikinci gizli katmanında 100 nöron bulunan çok katmanlı yapay sinir ağı modelinin tahmin ve test sonuçları Şekil 4.1’de grafik olarak verilmiştir.



Şekil 4.1 20 ms zaman penceresinde çok katmanlı yapay sinir ağı modeli ile Grup4 veri setinin tahminleri

50 ms zaman penceresindeki tahmin performansları değerlendirildiğinde Grup4 veri setinin en düşük MSE değerine (0.11411) sahip olduğu görülmektedir.

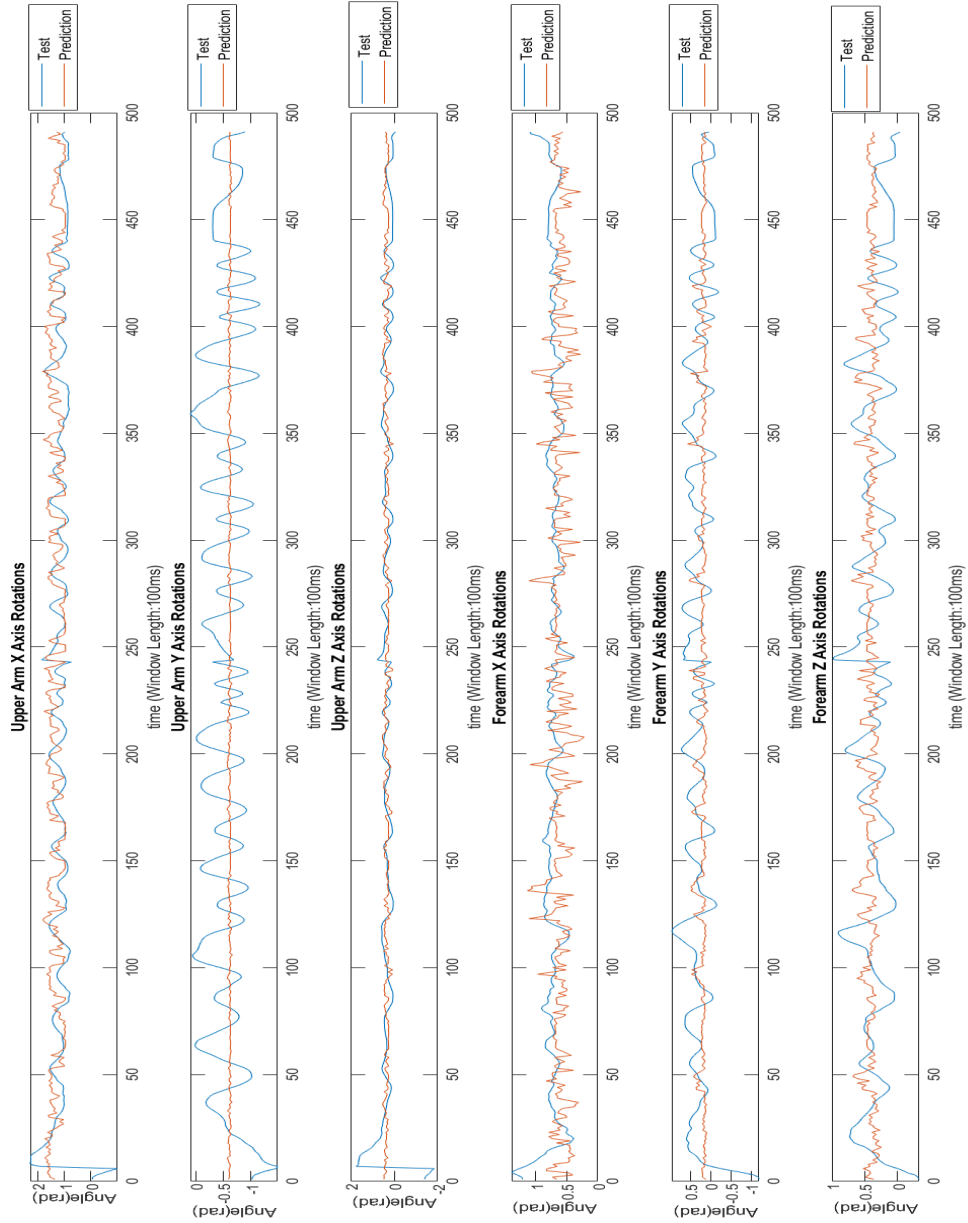
50 ms zaman penceresinde Grup4 veri seti ile oluşturulan, birinci gizli katmanında 100, ikinci gizli katmanında 100 nöron bulunan çok katmanlı yapay sinir ağı modelinin tahmin ve test sonuçları Şekil 4.2’de grafik olarak verilmiştir.



Şekil 4.2 50 ms zaman penceresinde çok katmanlı yapay sinir ağı modeli ile Grup4 veri setinin tahminleri

100 ms zaman penceresindeki tahmin performansları değerlendirildiğinde Grup4 veri setinin en düşük MSE değerine (0.09601) sahip olduğu görülmektedir.

100 ms zaman penceresinde Grup4 veri seti ile oluşturulan, birinci gizli katmanında 100, ikinci gizli katmanında 100 nöron bulunan çok katmanlı yapay sinir ağı modelinin tahmin ve test sonuçları Şekil 4.3'te grafik olarak verilmiştir.



Şekil 4.3 100 ms zaman penceresinde çok katmanlı yapay sinir ağı modeli ile Grup4 veri setinin tahminleri

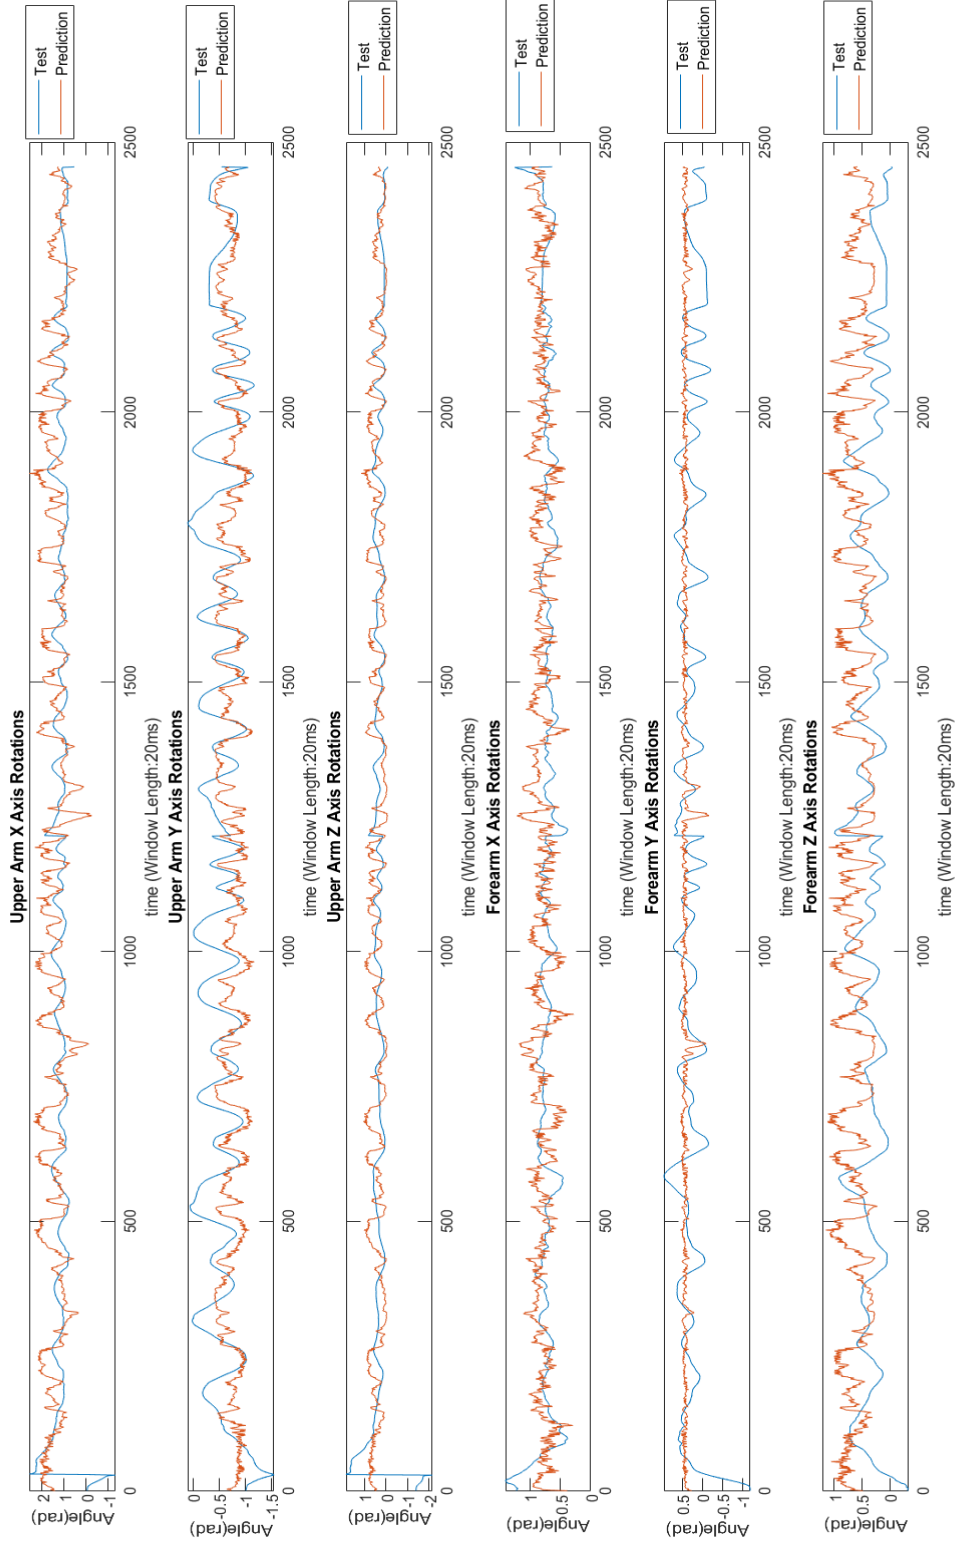
4.1.2. LSTM Yapay Sinir Ağı Tahminleri

LSTM yapay sinir ağı modelleri ile yapılan tahminler ve modellerin MSE değerleri 20ms, 50 ms ve 100 ms zaman pencereleri için sırasıyla Çizelge 4.4, Çizelge 4.5, Çizelge 4.6’da verilmiştir.

Çizelge 4.4 20 ms zaman penceresinde 2 boyutlu deney için LSTM tahmin performansları

Gizli Katman 1- Nöron Sayısı	Gizli Katman 2- Nöron Sayısı	MSE					
		Grup1	Grup2	Grup3	Grup4	Grup5	Grup6
100	100	2.08225	0.67497	3.85175	0.35342	3.38267	1.00700
200	100	1.17953	0.48346	3.40838	0.18221	3.08641	0.71809
200	200	1.98879	1.06587	6.39922	0.39844	3.59808	0.91612
300	100	1.53645	0.48781	4.57951	0.14849	3.00504	0.70742
300	200	1.74562	0.63145	4.91108	0.37771	2.98567	0.93437
300	300	2.10583	0.84261	7.34250	0.22053	3.49486	0.99720
400	100	1.28262	0.35138	5.30491	0.16161	2.61787	0.53521
400	200	1.11660	0.53552	5.21483	0.16501	2.70921	0.80600
400	300	1.35602	0.59127	5.15791	0.23731	2.90358	0.96159
400	400	1.51147	0.47472	6.17723	0.38200	3.19255	0.87785
Ortalama:		1.59052	0.61391	5.23473	0.26267	3.09759	0.84609

LSTM yapay sinir ağı ile 20 ms zaman penceresinde 2 boyutlu hareket için en iyi tahmin (MSE=0,14849), birinci katmanında 300, ikinci katmanında 100 LSTM hücresi bulunan model tarafından gerçekleştirilmiştir. Elde edilen model ile yapılan tahminler Şekil 4.4’te verilmiştir.




Şekil 4.4 2 boyutlu hareket için 20ms zaman penceresinde Grup4 veri seti ile eğitilmiş LSTM yapay sinir ağı tahminleri

Çizelge 4.5 50 ms zaman penceresinde 2 boyutlu deney için LSTM tahmin performansları

LSTM Katman 1- Nöron Sayısı	LSTM Katman 2- Nöron Sayısı	MSE					
		Grup1	Grup2	Grup3	Grup4	Grup5	Grup6
100	100	2.24869	0.47845	2.72114	0.36644	3.68970	0.84790
200	100	1.08466	0.25789	4.07534	0.47486	3.44890	0.43176
200	200	1.24523	0.39786	3.50133	0.51453	3.91065	0.48055
300	100	1.17891	0.22371	2.77065	0.19312	3.00946	0.59782
300	200	1.15982	0.30382	2.31830	0.32436	2.94858	0.47321
300	300	1.09044	0.36993	4.75279	0.32634	3.12327	0.57181
400	100	1.10234	0.26335	2.52563	0.17810	3.23251	0.48050
400	200	0.98358	0.26417	3.60835	0.14943	2.92766	0.36574
400	300	1.04158	0.34636	4.72423	0.21352	2.94573	0.47361
400	400	0.98638	0.23511	4.13212	0.13109	3.81734	0.42071
Ortalama:		1.21216	0.31406	3.51299	0.28718	3.30538	0.51436

LSTM yapay sinir ağı ile 50 ms zaman penceresinde 2 boyutlu hareket için en iyi tahmin (MSE=0.13109), birinci katmanında 400, ikinci katmanında 400 LSTM hücresi bulunan model tarafından gerçekleştirilmiştir. Elde edilen model ile yapılan tahminler Şekil 4.5'te verilmiştir.




Şekil 4.5 2 boyutlu hareket için 50ms zaman penceresinde Grup4 veri seti ile eğitilmiş LSTM yapay sinir ağı tahminleri

Çizelge 4.6 100 ms zaman penceresinde 2 boyutlu deney için LSTM tahmin performansları

LSTM Katman 1- Nöron Sayısı	LSTM Katman 2- Nöron Sayısı	MSE					
		Grup1	Grup2	Grup3	Grup4	Grup5	Grup6
100	100	0.98890	0.19127	3.74580	0.15288	3.03114	0.69445
200	100	0.88937	0.25522	1.89834	0.11468	3.17051	1.03544
200	200	0.82400	0.62359	4.49160	0.13455	3.07687	0.43380
300	100	0.85831	0.22274	2.78824	0.10733	3.20814	0.43870
300	200	1.10260	0.30052	1.48121	0.12005	2.73968	0.70116
300	300	0.99046	0.21599	3.93044	0.10784	3.22910	0.31348
400	100	1.12667	0.18717	2.05696	0.14100	2.90656	0.28024
400	200	1.00970	0.22344	3.16316	0.12552	2.72717	0.30333
400	300	1.26592	0.18984	2.83340	0.08307	3.20527	0.30933
400	400	1.10180	0.18595	3.61615	0.07698	2.63683	0.52754
Ortalama:		1.01577	0.25957	3.00053	0.11639	2.99313	0.50375

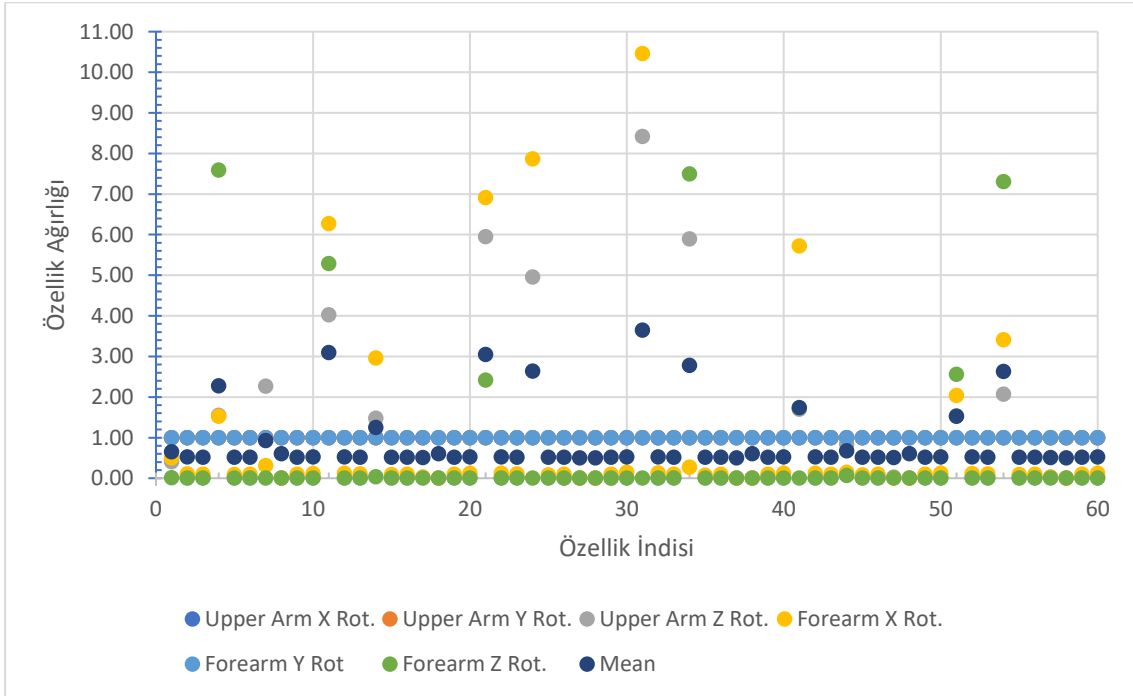
LSTM yapay sinir ağı ile yapılan tahminler sonucunda elde edilen MSE değerleri incelendiğinde Grup4 için 400'er adet nöron sayısına sahip iki LSTM katmanlı yapay sinir ağının 100 ms zaman penceresinde hesaplanmış EMG özellikleri ile en iyi tahmini (MSE=0.07698) yaptığı görülmektedir (Şekil 4.6).



Şekil 4.6 2 boyutlu hareket için 100ms zaman penceresinde Grup4 veri seti ile eğitilmiş LSTM yapay sinir ağı tahminleri

4.1.3. 2 Boyutta Hareket Tahminleri İçin Özellik Seçimi

2 boyutta deneylerde tüm deneklerden elde edilen EMG sinyal özellikleri ve kolun dönme açıları Komşuluk Bileşen Analizi yapılarak veri setinde yer alan EMG özelliklerinin ağırlıkları Matlab ortamında “Machine Learning Toolbox” içerisinde bulunan fsnrca fonksiyonu ile hesaplanmıştır. Veri setinde çıktı olarak altı adet dönüş bilgisi bulunduğundan her bir dönme açısı için özellik ağırlıkları ayrı ayrı hesaplanmış (Şekil 4.7), bütün dönme açıları ortalama 0,9’dan büyük ağırlığa sahip özellikler eğitim veri setinde tutulmuştur. Bu özellikler; Biceps (WL ve ZC), Triceps(IEMG ve WL), Anterior Deltoid(IEMG ve WL), Posterior Deltoid(IEMG ve WL), Pectoralis Major(IEMG) ve Trapez(IEMG ve WL) özellikleridir.



Şekil 4.7 Komşuluk Bileşeni Analizine göre 2 boyutta hareket için EMG özelliklerinin ağırlıkları

4.1.4. Seçilmiş Özellikler Veri Seti ile Çok Katmanlı Yapay Sinir Ağı Tahminleri

Çok katmanlı yapay sinir ağı modelleri için özellik seçimi uygulandıktan sonra yapılan tahminler ve modellerin MSE değerleri, 20ms, 50 ms ve 100 ms zaman pencereleri için sırasıyla Çizelge 4.7, Çizelge 4.8 ve Çizelge 4.9’da verilmiştir.

Çizelge 4.7 20 ms zaman penceresinde seçilmiş özellikler ile 2 boyutta hareket için çok katmanlı yapay sinir ağı tahmin performansları

Gizli Katman 1- Nöron Sayısı	Gizli Katman 2- Nöron Sayısı	MSE					
		Grup1	Grup2	Grup3	Grup4	Grup5	Grup6
100	100	9.20962	0.58823	0.34780	0.16160	3.69151	0.51652
200	100	37.93926	0.45754	0.33486	0.26044	3.61211	0.56972
200	200	5.03457	0.96560	0.84464	0.22816	3.71778	0.44262
300	100	6.96671	0.38562	0.25858	0.17077	3.07021	0.51699
300	200	18.15855	0.44213	0.25458	0.14658	2.97721	0.50511
300	300	23.03498	0.70533	0.28404	0.16937	3.12517	0.59894
400	100	8.27985	0.39089	0.23165	0.13124	2.81882	0.63274
400	200	23.88962	0.35913	0.29342	0.19499	5.04895	0.53923
400	300	18.56660	0.59916	0.30157	0.13505	3.63418	0.52837
400	400	9.50371	1.43562	0.45989	0.11695	3.66260	0.94279
Ortalama:		16.05835	0.63293	0.36110	0.17151	3.53586	0.57930


Çizelge 4.8 50 ms zaman penceresinde seçilmiş özellikler ile 2 boyutta hareket için çok katmanlı yapay sinir ağı tahmin performansları

Gizli Katman 1- Nöron Sayısı	Gizli Katman 2- Nöron Sayısı	MSE					
		Grup1	Grup2	Grup3	Grup4	Grup5	Grup6
100	100	29.54478	0.53842	0.29982	0.13208	2.22698	1.45895
200	100	10.73839	0.89662	0.22423	0.12966	3.71543	0.83210
200	200	18.86570	0.86628	0.38430	0.16792	3.78527	0.80392
300	100	23.59388	1.02860	0.31319	0.11805	3.62899	0.75564
300	200	13.24161	1.13852	0.60570	0.23420	3.79773	1.28242
300	300	12.31436	0.93131	0.89818	0.26014	3.53096	1.35912
400	100	6.94987	0.63950	0.42018	0.14890	3.12144	0.77493
400	200	15.52291	2.45811	0.81243	0.16350	2.94642	0.73809
400	300	25.11403	2.11059	0.58343	0.15444	5.29681	0.71618
400	400	17.32785	1.79449	0.80787	0.24869	6.00707	1.68945
Ortalama:		17.32134	1.24024	0.53493	0.17576	3.80571	1.04108

Çizelge 4.9 100 ms zaman penceresinde seçilmiş özellikler ile 2 boyutta hareket için çok katmanlı yapay sinir ağı tahmin performansları

Gizli Katman 1- Nöron Sayısı	Gizli Katman 2- Nöron Sayısı	MSE					
		Grup1	Grup2	Grup3	Grup4	Grup5	Grup6
100	100	7.22101	1.08799	0.34323	0.25651	3.18911	0.78290
200	100	7.96514	0.92543	0.71604	0.12591	3.92514	1.05466
200	200	11.87376	1.29495	0.60610	0.30327	3.17266	1.27778
300	100	9.16288	0.75135	0.39432	0.14845	2.96548	0.49296
300	200	15.17463	0.71200	0.59131	0.23970	2.52546	1.38516
300	300	18.25511	1.53478	1.39742	0.25669	4.40045	0.73268
400	100	8.19880	0.50480	0.61184	0.18822	3.01759	0.54245
400	200	26.94451	1.44287	1.35027	0.10745	2.86516	1.17290
400	300	21.05895	1.88064	0.67949	0.21022	5.56114	0.87932
400	400	18.40321	2.65224	1.99678	0.21914	6.26788	2.12855
Ortalama:		14.42580	1.27870	0.86868	0.20556	3.78901	1.04494

Özellik seçimi işleminden sonra yapılan tahminlerde en düşük MSE değeri (0.10745) 100 ms zaman penceresindeki, Grup4 veri seti ile oluşturulmuş EMG özellikleri için birinci gizli katmanında 400, ikinci gizli katmanında 200 adet nöron bulunan çok katmanlı yapay sinir ağında elde edilmiştir (Şekil 4.8).



Şekil 4.8 Özellik seçilimi yapılarak 100ms zaman penceresinde 400 ve 200 nöron sayılarına sahip Grup4 veri seti ile eğitilmiş çok katmanlı yapay sinir ağı tahminleri

4.1.5. Seçilmiş Özellikler Veri Seti ile LSTM Yapay Sinir Ağı Tahminleri

LSTM yapay sinir ağı modelleri için özellik seçimi uygulandıktan sonra yapılan tahminler ve modellerin MSE değerleri, 20ms, 50 ms ve 100 ms zaman pencereleri için sırasıyla Çizelge 4.10,Çizelge 4.11 ve Çizelge 4.12’de verilmiştir.

Çizelge 4.10 20 ms zaman penceresinde seçilmiş özellikler ile 2 boyutta hareket için LSTM yapay sinir ağı tahmin performansları

LSTM Katman1- Nöron Sayısı	LSTM Katman2- Nöron Sayısı	MSE					
		Grup1	Grup2	Grup3	Grup4	Grup5	Grup6
100	100	1.65192	1.18474	4.21803	0.46857	3.89140	3.60310
200	100	1.81392	1.04399	4.04863	0.65966	3.09838	3.66094
200	200	2.54802	1.72443	4.58495	0.58938	3.32797	4.60130
300	100	2.31058	0.84990	4.59377	0.46256	2.97221	3.65279
300	200	2.65934	1.81001	4.78512	0.55277	3.41558	3.12133
300	300	2.59413	1.65316	6.54198	0.49360	3.48820	4.78258
400	100	1.85970	0.82040	5.22276	0.56792	2.73838	3.59086
400	200	2.40143	1.17865	4.50179	0.41810	3.21911	2.57424
400	300	2.38536	1.60537	3.35191	0.46126	3.21940	3.84110
400	400	2.56690	1.38583	7.04737	0.52399	3.52169	3.59078
Ortalama:		2.27913	1.32565	4.88963	0.51978	3.28923	3.70190

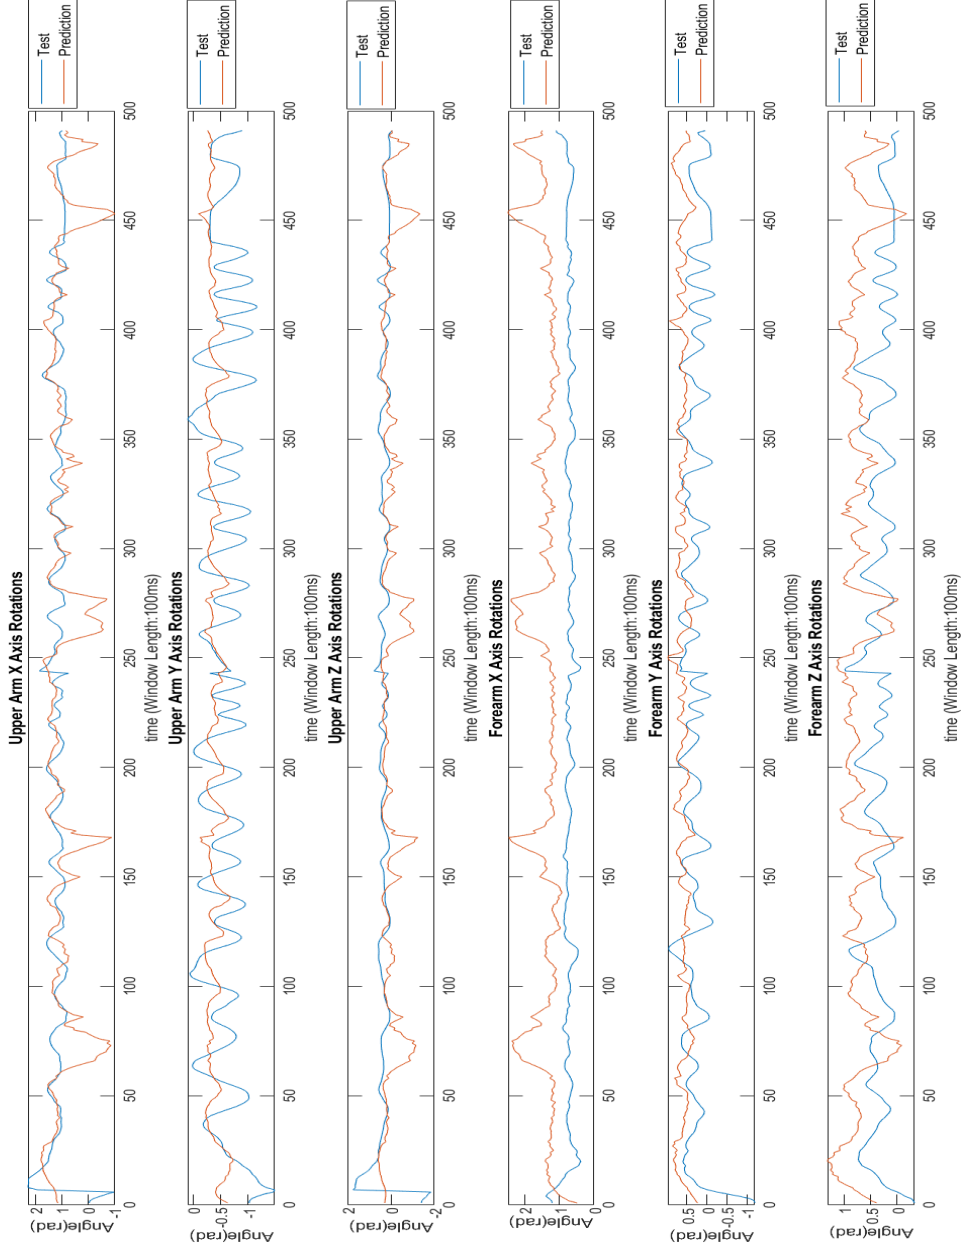
Çizelge 4.11 50 ms zaman penceresinde seçilmiş özellikler ile 2 boyutta hareket için LSTM yapay sinir ağı tahmin performansları

LSTM Katman1- Nöron Sayısı	LSTM Katman2- Nöron Sayısı	MSE					
		Grup1	Grup2	Grup3	Grup4	Grup5	Grup6
100	100	2.01379	1.77990	1.09317	0.65961	4.01002	2.89421
200	100	2.30847	2.37954	2.27945	0.55361	3.66217	3.07710
200	200	2.94407	2.26893	6.86333	0.82018	4.65874	4.56939
300	100	2.80613	2.22444	0.96858	0.67780	3.62818	2.88568
300	200	2.83411	2.42849	1.09911	0.71720	4.30378	3.58801
300	300	3.56289	1.99479	0.80946	0.65708	4.81006	3.60005
400	100	2.57591	2.06566	2.88568	0.47593	3.77156	3.18872
400	200	2.17522	1.78156	1.32571	0.74153	3.76546	3.56828
400	300	3.07382	1.66869	1.28323	0.66951	4.32904	3.03857
400	400	2.77814	1.62215	1.02744	0.68085	4.36300	3.15819
Ortalama:		2.70725	2.02141	1.96352	0.66533	4.13020	3.35682

Çizelge 4.12 100 ms zaman penceresinde seçilmiş özellikler ile 2 boyutta hareket için LSTM yapay sinir ağı tahmin performansları

LSTM Katman1- Nöron Sayısı	LSTM Katman2- Nöron Sayısı	MSE					
		Grup1	Grup2	Grup3	Grup4	Grup5	Grup6
100	100	2.36202	1.66867	7.05566	0.64026	4.22216	2.26151
200	100	2.15602	1.58063	2.67145	0.71236	5.43265	1.44016
200	200	2.14529	2.01151	1.18075	0.70651	4.62053	1.92501
300	100	1.87882	0.84824	0.70494	0.60553	3.81047	1.38267
300	200	2.22123	1.33192	0.74914	0.41785	3.93884	2.28285
300	300	2.24300	1.71087	0.57773	0.28362	4.67832	1.70385
400	100	2.16656	1.12002	0.54655	0.38540	3.39866	1.01957
400	200	2.00044	0.99172	0.48089	0.46256	3.70955	0.98908
400	300	1.85908	1.00077	0.45575	0.32177	4.21251	1.13122
400	400	2.31449	0.70514	0.58301	0.36841	3.46662	0.84075
Ortalama:		2.13470	1.29695	1.50059	0.49043	4.14903	1.49767

Özellik seçimi işleminden sonra yapılan tahminlerde en düşük MSE değeri (0.28362) 100 ms zaman penceresindeki EMG özellikleri için birinci gizli katmanında, 300 ikinci gizli katmanında 300 adet nöron bulunan LSTM yapay sinir ağında elde edilmiştir (Şekil 4.9).



Şekil 4.9 Özellik seçilimi yapılarak 100 ms zaman penceresinde katmanlarında 300'er nöron sayısına sahip Grup4 veri seti ile eğitilmiş LSTM yapay sinir ağı tahminleri

4.2. 3 Boyutta Hareket Tahminleri

4.2.1. Çok Katmanlı Yapay Sinir Ağı Tahminleri

Çok katmanlı yapay sinir ağı modelleri ile yapılan tahminler ve modellerin MSE değerleri, 20ms, 50 ms ve 100 ms zaman pencereleri için sırasıyla Çizelge 4.13, Çizelge 4.14 ve Çizelge 4.15'te verilmiştir.

Çizelge 4.13 20 ms zaman penceresinde 3 boyutlu hareket için çok katmanlı yapay sinir ağı tahmin performansları

Gizli Katman 1- Nöron Sayısı	Gizli Katman 2- Nöron Sayısı	MSE					
		Grup1	Grup2	Grup3	Grup4	Grup5	Grup6
100	100	16.52824	0.89111	0.93869	0.72021	2.24672	1.52878
200	100	5.50489	0.88841	0.98080	0.60262	2.39553	1.02522
200	200	10.26795	0.93991	0.85939	0.64435	2.30336	1.04658
300	100	6.18983	0.92020	0.95621	0.80561	2.32656	1.04653
300	200	12.12440	0.91197	0.98458	0.78012	2.30796	2.10607
300	300	8.45862	0.92400	1.05762	0.75302	2.67919	0.87674
400	100	10.32409	0.91063	0.94311	0.99234	2.28628	0.91630
400	200	13.23588	0.90809	1.14360	0.86661	2.33130	1.19011
400	300	10.34256	0.90459	0.93680	0.78943	2.76815	1.28687
400	400	20.98836	0.91671	0.83390	0.83849	2.73375	1.56902
Ortalama:		11.39648	0.91156	0.96347	0.77928	2.43788	1.25922

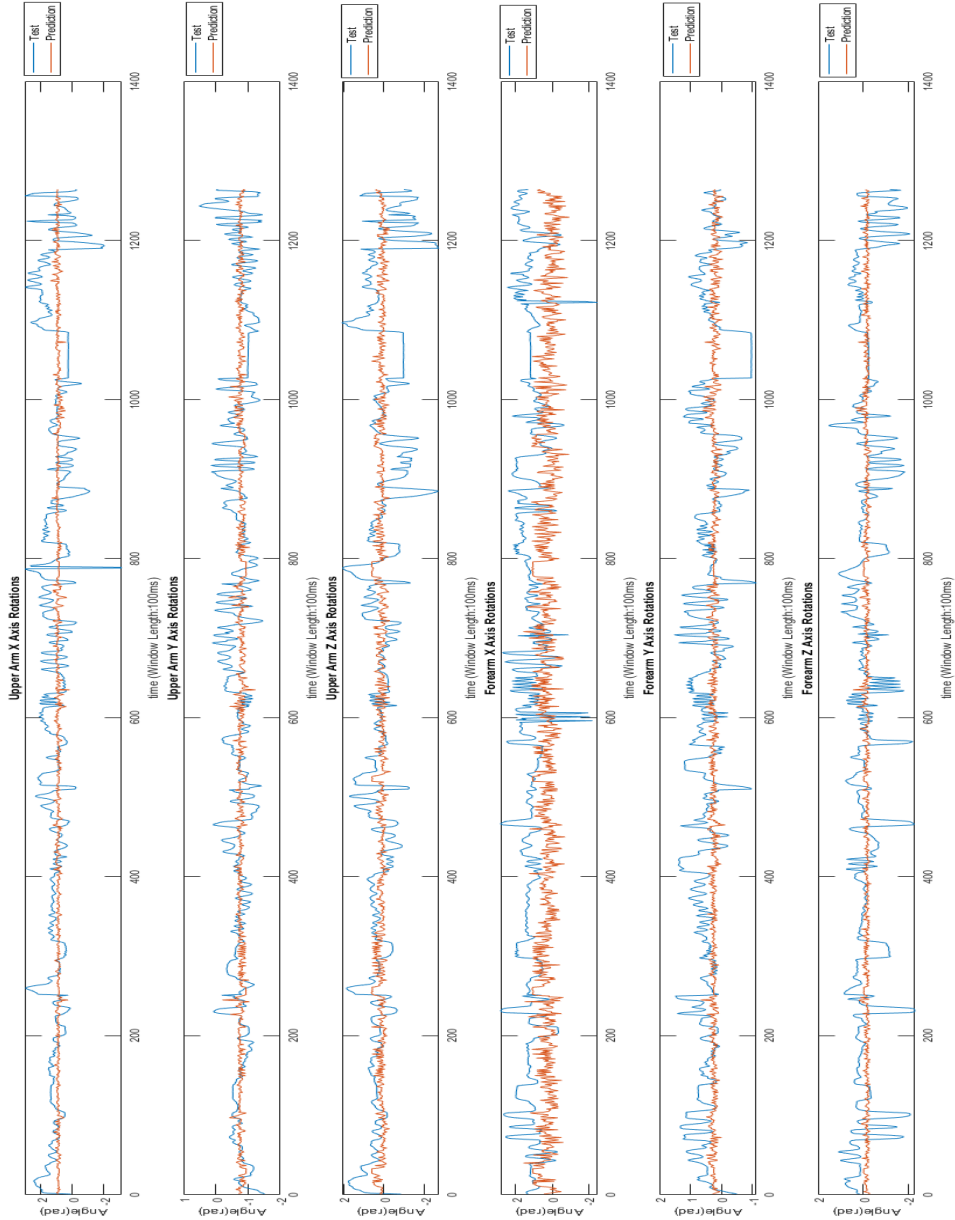
Çizelge 4.14 50 ms zaman penceresinde 3 boyutlu hareket için çok katmanlı yapay sinir ağı tahmin performansları

Gizli Katman 1- Nöron Sayısı	Gizli Katman 2- Nöron Sayısı	MSE					
		Grup1	Grup2	Grup3	Grup4	Grup5	Grup6
100	100	8.17567	0.90880	0.97345	0.98587	2.31802	1.09838
200	100	5.82248	0.97420	1.06621	1.00676	2.38473	1.05987
200	200	17.08674	0.94073	1.01830	0.71760	2.90562	1.52501
300	100	5.35778	0.90772	0.95985	1.02102	2.31462	0.76272
300	200	22.93030	0.98286	1.29339	0.94641	2.44427	1.34633
300	300	15.15158	0.91527	1.00071	1.15767	2.43300	1.56606
400	100	8.85064	0.90064	1.00546	0.85946	2.38026	1.20058
400	200	16.31493	0.97275	1.30517	0.93572	2.27956	2.37852
400	300	20.30636	0.96985	1.36890	0.86686	2.60248	1.24851
400	400	23.01115	0.95022	1.22836	0.71833	2.98665	1.29660
Ortalama:		14.30076	0.94230	1.12198	0.92157	2.50492	1.34826

Çizelge 4.15 100 ms zaman penceresinde 3 boyutlu hareket için çok katmanlı yapay sinir ağı tahmin performansları

Gizli Katman 1- Nöron Sayısı	Gizli Katman 2- Nöron Sayısı	MSE					
		Grup1	Grup2	Grup3	Grup4	Grup5	Grup6
100	100	8.13425	0.86319	0.91402	0.56878	2.23562	0.92142
200	100	10.08796	0.86199	0.87158	0.69731	2.13748	1.14922
200	200	16.79227	0.97378	1.11314	0.72330	2.67107	2.08849
300	100	11.91672	1.01768	1.20741	0.67691	2.45636	0.97858
300	200	9.53407	0.94807	1.20988	0.92084	2.28589	3.66819
300	300	35.33176	1.00923	1.47931	0.93521	2.31518	1.86718
400	100	5.46994	0.90786	1.05081	0.67302	2.19686	1.09659
400	200	12.51016	0.90725	1.61741	0.77471	2.17137	1.84295
400	300	21.31518	1.03149	1.72776	1.20966	3.01272	2.21716
400	400	63.40721	1.04387	1.13878	1.47801	3.07393	2.03159
Ortalama:		19.44995	0.95644	1.23301	0.86578	2.45565	1.78614

Çok katmanlı yapay sinir ağları ile yapılan tahminler incelendiğinde en düşük MSE değerine birinci ve ikinci gizli katmanında 100'er adet nöron bulunan, 100 ms zaman penceresinde EMG özellikleri ile eğitilmiş Grup4 veri seti ile yapılan tahminlerin (Şekil 4.10) en düşük hataya (MSE=0.56878) sahip olduğu görülmektedir.



Şekil 4.10 3 Boyutu hareket için 100 ms zaman penceresinde Grup4 veri setinin çok katmanlı yapay sinir ağı tahminleri

4.2.2. LSTM Yapay Sinir Ağı Tahminleri

LSTM yapay sinir ağı modelleri ile yapılan tahminler ve modellerin MSE değerleri 20ms, 50 ms ve 100 ms zaman pencereleri için sırasıyla Çizelge 4.16, Çizelge 4.17 ve Çizelge 4.18’de verilmiştir.

Çizelge 4.16 20 ms zaman penceresinde 3 boyutlu hareket için LSTM tahmin performansları

Gizli Katman 1- Nöron Sayısı	Gizli Katman 2- Nöron Sayısı	MSE					
		Grup1	Grup2	Grup3	Grup4	Grup5	Grup6
100	100	2.16186	1.31801	2.42802	1.00388	3.54981	0.54846
200	100	1.98757	1.50289	2.86473	1.25278	3.28545	0.84402
200	200	1.68801	1.53479	3.61929	1.16153	3.14427	1.08311
300	100	1.24943	1.31563	3.05288	1.49255	3.14956	0.73136
300	200	1.86091	1.47454	3.07546	1.36516	3.07238	0.62471
300	300	1.38321	1.71397	2.34569	0.76629	3.63457	0.74880
400	100	1.18306	1.55326	2.22828	1.09165	3.21192	0.67268
400	200	1.73731	1.37201	3.44043	1.14982	3.35915	0.71899
400	300	1.47933	1.48574	3.15956	1.06655	3.37715	0.69620
400	400	1.45867	1.64833	3.69816	1.34939	3.32229	0.63622
Ortalama:		1.61894	1.49192	2.99125	1.16996	3.31065	0.73045


Çizelge 4.17 50 ms zaman penceresinde 3 boyutlu hareket için LSTM tahmin performansları

LSTM Katman 1- Nöron Sayısı	LSTM Katman 2- Nöron Sayısı	MSE					
		Grup1	Grup2	Grup3	Grup4	Grup5	Grup6
100	100	1.88244	1.61309	3.44676	0.49274	2.65866	1.17661
200	100	1.30603	1.12011	2.11811	0.44367	2.76328	0.65345
200	200	1.44470	1.33449	3.02707	0.42435	3.10717	0.59563
300	100	1.13601	1.42895	1.96572	0.98098	2.74904	0.53044
300	200	1.69323	1.36567	2.33824	1.26945	2.64573	0.58897
300	300	1.62667	1.21780	2.37573	0.48786	2.98191	0.55491
400	100	1.52189	1.09571	2.48589	1.25762	2.62954	0.53742
400	200	1.39511	1.22386	2.59765	0.45944	2.68719	0.58310
400	300	1.78369	1.18793	2.40466	1.75004	2.46548	0.60894
400	400	1.75285	1.25719	2.02249	1.18397	2.95772	0.52574
Ortalama:		1.55426	1.28448	2.47823	0.87501	2.76457	0.63552

Çizelge 4.18 100 ms zaman penceresinde 3 boyutlu hareket için LSTM tahmin performansları

LSTM Katman 1- Nöron Sayısı	LSTM Katman 2- Nöron Sayısı	MSE					
		Grup1	Grup2	Grup3	Grup4	Grup5	Grup6
100	100	2.64705	1.17583	3.20782	1.39824	2.63366	0.56078
200	100	2.41934	1.02520	1.55403	0.46213	2.34629	0.53772
200	200	1.35632	1.23740	2.55756	0.40479	2.52082	0.60447
300	100	1.85268	1.01475	1.39500	0.37971	2.21952	0.57382
300	200	2.23608	1.23299	2.36431	0.43476	2.32603	0.51661
300	300	1.26852	1.28999	1.72551	1.43409	2.33477	0.57511
400	100	1.71169	0.97964	1.42628	0.40272	2.41599	0.56950
400	200	1.16851	0.99193	2.52189	0.39181	2.23740	0.54506
400	300	2.43673	1.14643	2.22518	0.39418	2.48643	0.55250
400	400	1.93471	0.99652	2.51117	0.40951	2.16709	0.52487
Ortalama:		1.90316	1.10907	2.14887	0.61119	2.36880	0.55604

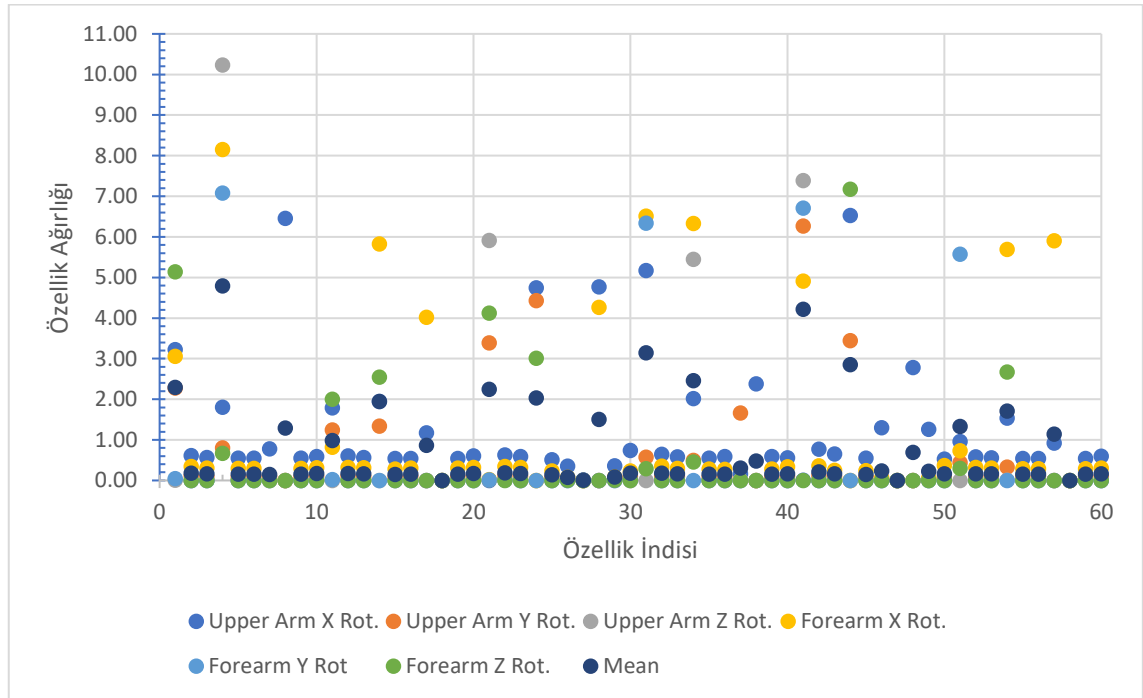
LSTM yapay sinir ağı ile yapılan tahminler incelendiğinde en düşük MSE değerine birinci gizli katmanında 300 ve ikinci gizli katmanında 100 adet nöron bulunan, 100 ms zaman penceresinde EMG özellikleri ile eğitilmiş Grup4 veri seti ile yapılan tahminlerin (Şekil 4.11) en düşük hataya (MSE=0.37971) sahip olduğu görülmektedir.



Şekil 4.11 LSTM yapay sinir ağı ile 3 boyutta hareket için Grup4 veri seti ile yapılmış tahminler

4.2.3. 3 Boyutta Hareket Tahminleri İçin Özellik Seçimi

3 boyutta deneylerde tüm deneklerden elde edilen EMG sinyal özellikleri ve kolun dönme açıları Komşuluk Bileşen Analizi yapılarak veri setinde yer alan EMG özelliklerinin ağırlıkları Matlab ortamında “Machine Learning Toolbox” içerisinde bulunan fsrnca fonksiyonu ile hesaplanmıştır. Veri setinde çıktı olarak altı adet dönüş bilgisi bulunduğundan her bir dönme açısı için özellik ağırlıkları ayrı ayrı hesaplanmış (Şekil 4.12), bütün dönme açıları ortalama 0,9’dan büyük ağırlığa sahip özellikler eğitim veri setinde tutulmuştur. Bu özellikler; Biceps (IEMG, WL, WAMP), Triceps(IEMG ve WL), Anterior Deltoid(IEMG, WL ve WAMP), Posterior Deltoid(IEMG ve WL), Pectoralis Major(IEMG ve WL) ve Trapez(IEMG, WL ve ZC) özellikleridir.



Şekil 4.12 Komşuluk Bileşeni Analizine göre 3 boyutta hareket için EMG özelliklerinin ağırlıkları

4.2.4. Seçilmiş Özellikler Veri Seti ile Çok Katmanlı Yapay Sinir Ağı Tahminleri

Çok katmanlı yapay sinir ağı modelleri için özellik seçimi uygulandıktan sonra 3 boyutlu hareket için yapılan tahminler ve modellerin MSE değerleri, 20ms, 50 ms ve 100 ms zaman pencereleri için sırasıyla Çizelge 4.19, Çizelge 4.20 ve Çizelge 4.21’de verilmiştir.

Çizelge 4.19 20 ms zaman penceresinde seçilmiş özellikler ile 3 boyutta hareket için çok katmanlı yapay sinir ağı tahmin performansları

Gizli Katman 1- Nöron Sayısı	Gizli Katman 2- Nöron Sayısı	MSE					
		Grup1	Grup2	Grup3	Grup4	Grup5	Grup6
100	100	12.15032	0.85756	0.82463	0.86532	2.35454	1.13567
200	100	13.99067	0.87477	0.86812	0.88962	2.77678	1.24274
200	200	8.03691	0.91611	0.69145	0.96160	2.55491	0.83988
300	100	11.74921	0.88597	0.89213	0.56565	2.42234	1.17145
300	200	5.09086	0.86824	0.67967	0.69772	2.92736	1.51832
300	300	11.41307	0.91187	0.80960	0.60594	2.57742	1.46476
400	100	6.07703	0.86835	0.85886	0.58650	2.43630	1.42819
400	200	18.22960	0.91249	0.79147	0.70342	2.58605	1.62148
400	300	22.13056	0.86318	0.70427	0.56905	2.34970	1.50434
400	400	14.13672	0.89440	1.06814	0.61655	2.59916	1.03422
Ortalama:		12.30049	0.88529	0.81883	0.70614	2.55846	1.29610

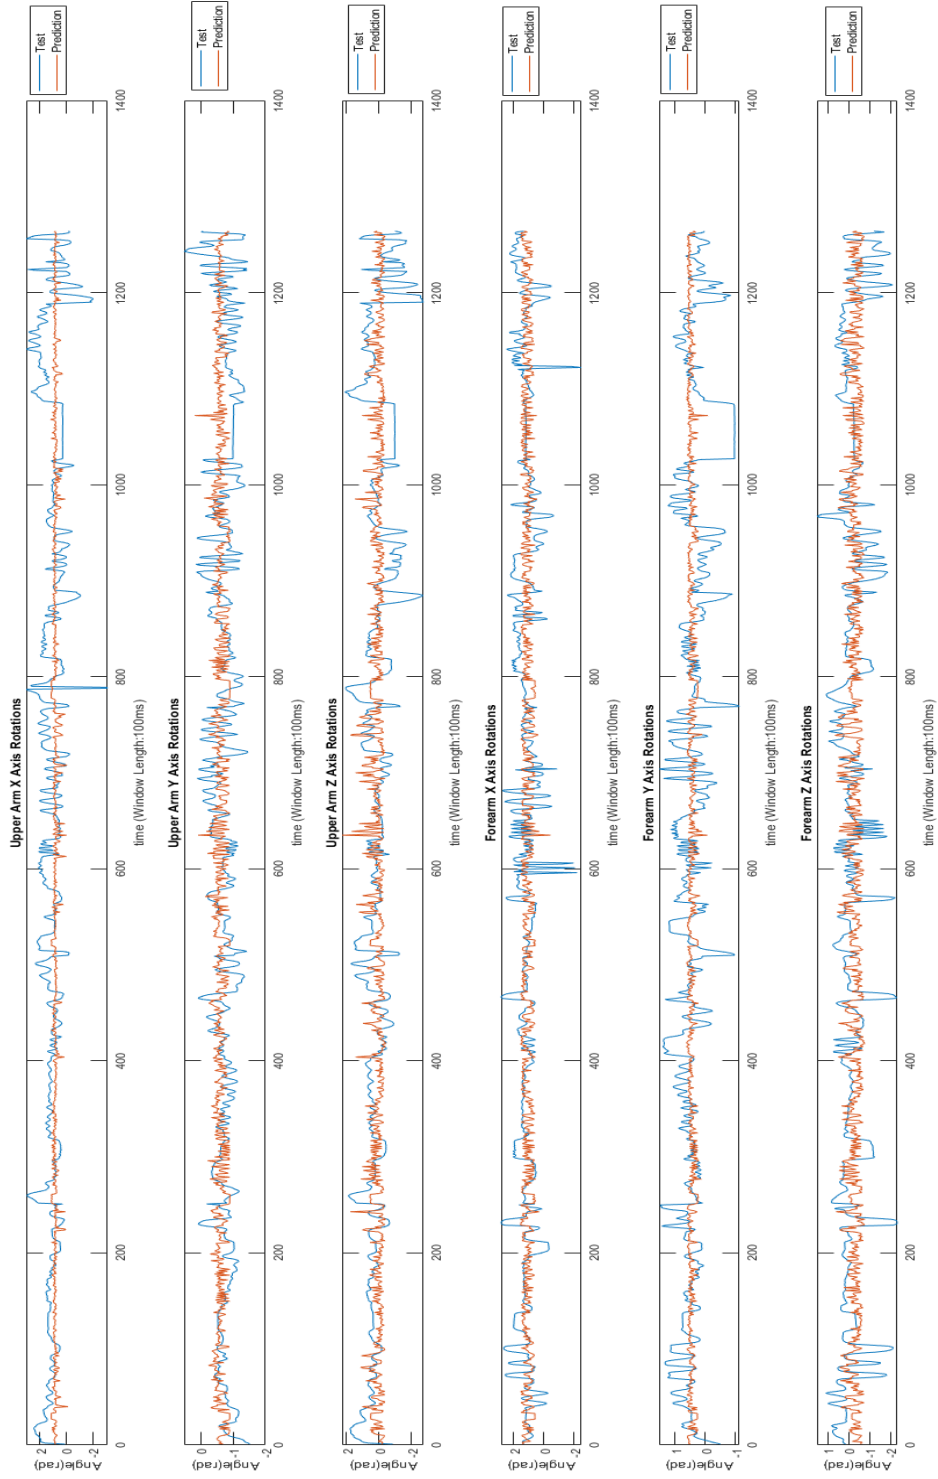
Çizelge 4.20 50 ms zaman penceresinde seçilmiş özellikler ile 3 boyutta hareket için çok katmanlı yapay sinir ağı tahmin performansları

Gizli Katman 1- Nöron Sayısı	Gizli Katman 2- Nöron Sayısı	MSE					
		Grup1	Grup2	Grup3	Grup4	Grup5	Grup6
100	100	18.75221	0.83218	0.73693	0.99560	2.30879	0.92493
200	100	9.45128	0.85203	1.10050	0.58132	2.18725	1.25892
200	200	13.61178	0.91051	0.86374	0.71002	2.69370	1.69860
300	100	12.42743	0.87476	0.85429	0.56226	2.71394	1.64157
300	200	13.63452	0.89209	0.99859	0.59084	2.64624	1.35721
300	300	11.02325	0.88959	0.86502	0.90888	3.31247	0.93687
400	100	5.33010	0.86200	0.98187	0.58186	2.58773	0.97249
400	200	8.38713	0.91909	1.03345	0.66230	2.79230	1.13535
400	300	24.46857	0.98127	0.96789	0.87992	3.03883	1.94991
400	400	17.20938	0.90994	1.05282	0.74596	2.62527	1.60055
Ortalama:		13.42957	0.89235	0.94551	0.72190	2.69065	1.34764

Çizelge 4.21 100 ms zaman penceresinde seçilmiş özellikler ile 3 boyutta hareket için çok katmanlı yapay sinir ağı tahmin performansları

Gizli Katman 1- Nöron Sayısı	Gizli Katman 2- Nöron Sayısı	MSE					
		Grup1	Grup2	Grup3	Grup4	Grup5	Grup6
100	100	5.59743	0.84035	0.65112	0.55495	2.32532	1.31709
200	100	11.91625	0.87397	0.92752	0.42578	2.13520	1.56228
200	200	16.59194	0.89999	1.40521	0.53336	2.54090	1.00228
300	100	7.28378	0.87609	0.87963	0.69074	2.79724	1.68736
300	200	17.45579	0.87476	1.00961	0.56350	2.50959	1.46996
300	300	25.38312	0.88904	0.96669	1.01762	3.33057	1.91735
400	100	7.00193	0.87630	0.90821	0.51790	2.42137	0.87389
400	200	18.65666	0.93300	2.01235	0.81379	2.49534	1.46855
400	300	21.19826	1.00648	1.30412	0.74889	3.45371	2.41711
400	400	30.17963	0.90540	1.34803	0.85451	2.93878	3.64349
Ortalama:		16.12648	0.89754	1.14125	0.67210	2.69480	1.73594

Özellik seçimi işleminden sonra yapılan tahminlerde en düşük MSE değeri (0.42578) 100 ms zaman penceresindeki, Grup4 veri seti ile oluşturulmuş EMG özellikleri için birinci gizli katmanında 200, ikinci gizli katmanında 100 adet nöron bulunan çok katmanlı yapay sinir ağında elde edilmiştir (Şekil 4.13).



Şekil 4.13 100ms zaman penceresinde 200 ve 100 nöron sayılarına sahip Grup4 veri seti ile eğitilmiş 3 boyutlu hareket için çok katmanlı yapay sinir ağı tahminleri

4.2.5. Seçilmiş Özellikler Veri Seti ile LSTM Yapay Sinir Ağı Tahminleri

LSTM yapay sinir ağı modelleri için özellik seçimi uygulandıktan sonra yapılan tahminler ve modellerin MSE değerleri, 20ms, 50 ms ve 100 ms zaman pencereleri için sırasıyla Çizelge 4.22, Çizelge 4.23 ve Çizelge 4.24'te verilmiştir.

Çizelge 4.22 20 ms zaman penceresinde seçilmiş özellikler ile 3 boyutta hareket için LSTM yapay sinir ağı tahmin performansları

LSTM Katman1- Nöron Sayısı	LSTM Katman2- Nöron Sayısı	MSE					
		Grup1	Grup2	Grup3	Grup4	Grup5	Grup6
100	100	1.86653	1.75977	3.46066	1.81351	3.37568	1.34119
200	100	1.20766	1.43150	2.57518	0.70825	3.96736	0.80810
200	200	2.19204	1.23559	1.83479	1.00159	4.04797	0.89867
300	100	1.23685	1.60860	1.46469	1.44771	3.20688	0.73777
300	200	2.08068	1.34281	4.07245	1.51654	3.83041	0.84837
300	300	1.85359	1.41657	3.42487	1.64652	3.95914	0.74076
400	100	1.77243	1.30109	3.26734	0.72920	2.64314	0.88927
400	200	1.66381	1.47150	2.25652	1.36391	3.11593	0.90955
400	300	1.58333	1.25922	2.80514	1.09233	3.56641	0.91506
400	400	2.24140	1.52901	5.13660	0.91476	2.94507	1.90935
Ortalama:		1.76983	1.43557	3.02982	1.22343	3.46580	0.99981

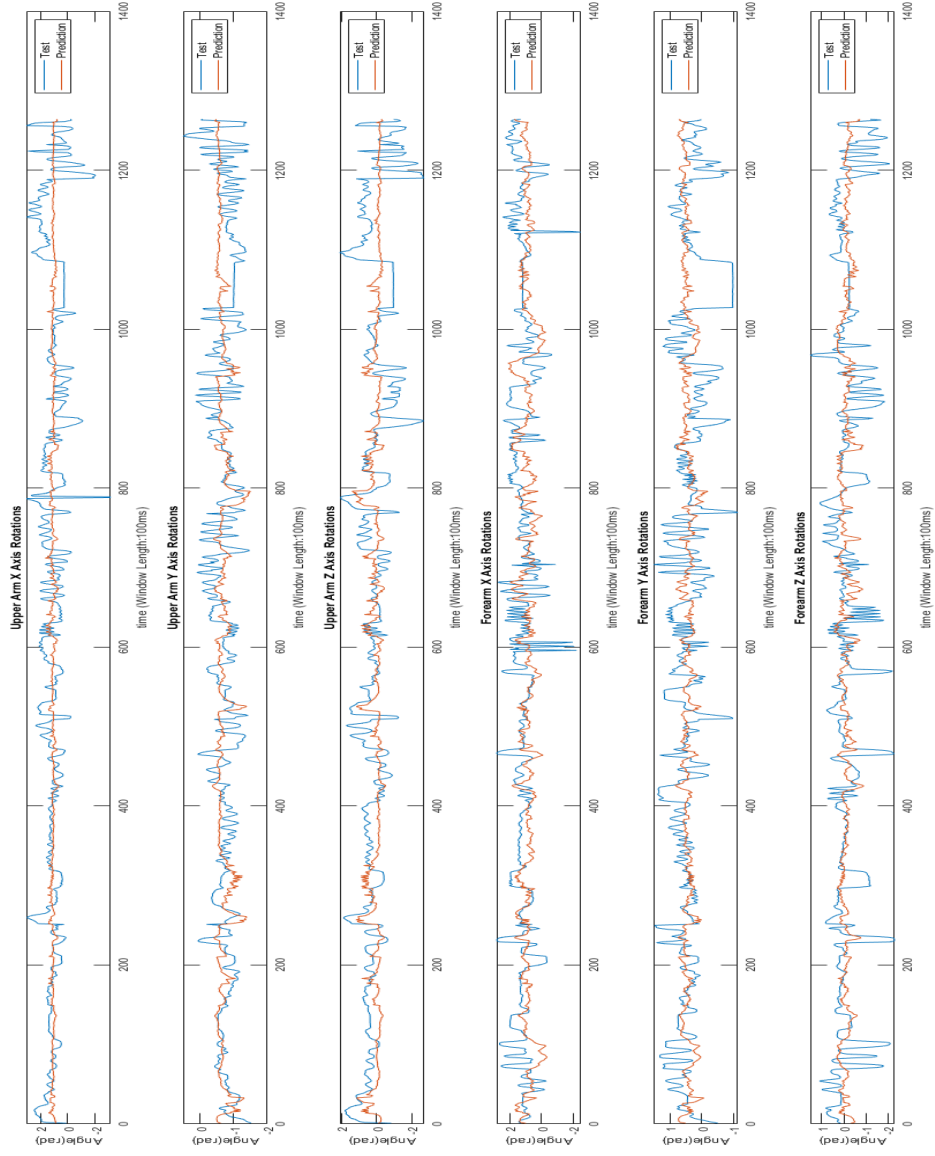
Çizelge 4.23 50 ms zaman penceresinde seçilmiş özellikler ile 3 boyutta hareket için LSTM yapay sinir ağı tahmin performansları

LSTM Katman1- Nöron Sayısı	LSTM Katman2- Nöron Sayısı	MSE					
		Grup1	Grup2	Grup3	Grup4	Grup5	Grup6
100	100	1.34201	1.26681	3.71410	0.63875	3.21381	0.72685
200	100	1.44103	1.23438	2.80330	0.98253	3.00040	0.66978
200	200	2.04008	1.56501	1.86090	0.82560	2.46013	0.75348
300	100	1.27803	1.09734	2.46277	0.55329	2.27552	0.65836
300	200	2.25449	1.22236	1.62400	0.62451	2.86698	0.61529
300	300	1.23712	1.16386	1.52981	0.73819	2.69057	0.61043
400	100	1.17476	1.01394	2.35292	0.60624	2.29260	0.74822
400	200	1.20107	1.29442	0.67546	0.47956	2.92765	0.64234
400	300	1.08934	1.21081	1.57899	0.54255	2.84171	0.62235
400	400	1.86032	1.31449	1.97932	0.58992	2.33204	0.60195
Ortalama:		1.49182	1.23834	2.05816	0.65811	2.69014	0.66490

Çizelge 4.24 100 ms zaman penceresinde seçilmiş özellikler ile 3 boyutta hareket için LSTM yapay sinir ağı tahmin performansları

LSTM Katman1- Nöron Sayısı	LSTM Katman2- Nöron Sayısı	MSE					
		Grup1	Grup2	Grup3	Grup4	Grup5	Grup6
100	100	3.78588	1.23214	3.43816	0.56326	2.62085	0.76734
200	100	2.61345	1.14707	3.16066	0.43446	2.25562	0.58450
200	200	2.26797	1.29455	1.87480	0.74556	2.39058	0.59632
300	100	2.55527	0.97294	2.11962	0.59184	2.32725	0.59542
300	200	1.45795	1.35973	2.46228	1.03145	2.29826	0.59216
300	300	2.53043	1.13585	2.46065	0.54795	2.26183	0.59139
400	100	1.65512	1.15902	2.36900	0.49334	2.02655	0.58698
400	200	1.75975	1.00518	2.43961	0.56527	2.39575	0.65040
400	300	1.15367	1.07470	2.10059	1.14800	2.22877	0.60803
400	400	1.38908	1.09784	2.46514	1.37733	2.26763	0.55834
Ortalama:		2.11686	1.14790	2.48905	0.74985	2.30731	0.61309

Özellik seçimi işleminden sonra yapılan tahminlerde en düşük MSE değeri (0.43446) 100 ms zaman penceresindeki EMG özellikleri için birinci gizli katmanında 200, ikinci gizli katmanında 100 adet nöron bulunan LSTM yapay sinir ağında elde edilmiştir (Şekil 4.14).

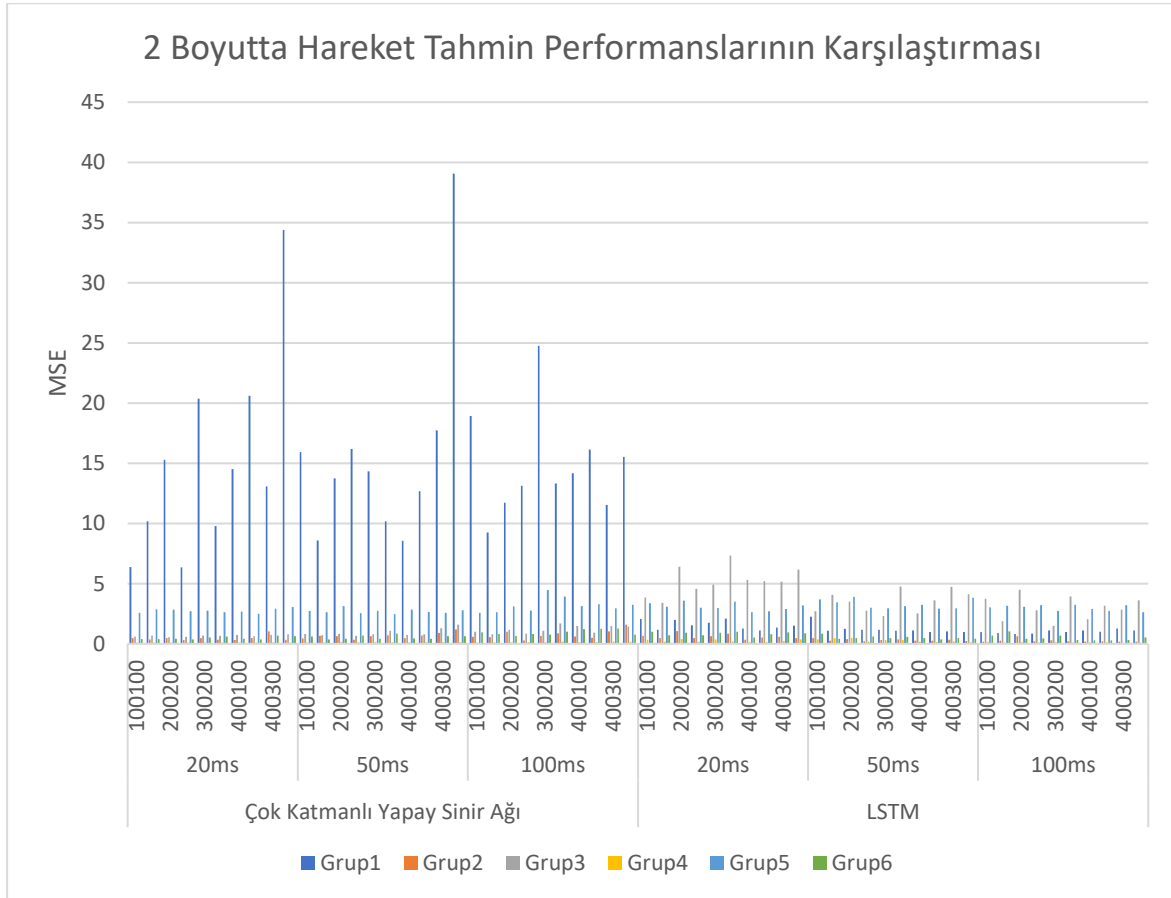


Şekil 4.14 100ms zaman penceresinde özellik seçilimi yapılarak, 3 boyutlu hareket için, katmanlarında birinci katmanında 200, ikinci katmanında 100 nöron bulunan Grup4 veri seti ile eğitilmiş LSTM yapay sinir ağı tahminleri

4.3. Yapay Sinir Ağı Modellerinin İstatiksel Analizleri

4.3.1. 2 Boyutta Hareket için Yapay Sinir Ağı Modellerinin Performans Karşılaştırması

Çok katmanlı yapay sinir ağları ve LSTM yapay sinir ağları ile yapılan tahminlerin performansları Şekil 4.15'te grafik olarak özetlenmiştir. Buna göre LSTM yapay sinir ağları 2 boyutlu hareket tahmininde çok katmanlı yapay sinir ağına göre daha iyi tahminlerde bulunduğu görülmektedir. Çok katmanlı yapay sinir ağlarında en başarısız tahminlerin yapıldığı Grup1 veri setinde 20 ms, 50 ms ve 100 ms zaman aralıklarında sırasıyla ortalama 15.0931, 15.7006 ve 14.85485 MSE değerlerine ulaşılırken, LSTM yapay sinir ağları ile bu değerler aynı sırayla 1.59052, 1.21216, 1.01577 seviyelerine düşmeyi başarmıştır. Genel olarak tüm grupların veri setlerinden elde edilen tahminlerin MSE ortalamasına bakıldığında, LSTM yapay sinir ağlarının (ort: 1.59338) çok katmanlı yapay sinir ağlarına göre (ort:3.41266) yaklaşık 2 kat daha iyi tahminlerde bulunduğu görülmektedir (Şekil 4.15).



Şekil 4.15 2 Boyutlu hareket için çok katmanlı yapay sinir ağı ve LSTM modellerinin performanslarının karşılaştırılması

Çok katmanlı yapay sinir ağı ve LSTM modellerinin MSE değerleri istatistiksel olarak incelendiğinde (Çizelge 4.25), iki modelin MSE ortalamalarının istatistiksel olarak anlamlı fark oluşturduğu görülmektedir ($p=0.00015<0.05$).

Çizelge 4.25 Çok katmanlı yapay sinir ağı ve LSTM modellerinin performans ortalamalarının t-Test analizi

t-Test: Ortalamalar İçin İki Örnek

	<i>ÇKYSA</i>	<i>LSTM</i>
Ortalama	3.412662611	1.593376889
Varyans	37.32449489	2.404867656
Gözlem	180	180
	-	
Pearson Korelasyonu	0.004823625	
Öngörülen Ortalama Farkı	0	
df	179	
t Stat	3.867963593	
P(T<=t) tek-uçlu	7.67459E-05	
t Kritik tek-uçlu	1.6534108	
P(T<=t) iki-uçlu	0.000153492	
t Kritik iki-uçlu	1.973305434	

Özellik seçilimi yapılarak gerçekleştirilen tahminler için yapılan istatistik analizinde (Çizelge 4.26) çok katmanlı yapay sinir ağı modelinde NCA metodu ile özellik seçimi işleminin tahmin performanslarının ortalamasında istatistiksel olarak anlamlı bir fark oluşturmadığı ($p=0.613843>0.05$), LSTM modeli için ise özellik seçimi işleminin istatistiksel olarak anlamlı fark oluşturduğu ($p=0.00003<0.05$) görülmektedir. Fakat NCA metodu ile özellik seçilimi işlemi LSTM modellerinin tahmini olumsuz yönde etkilediği görülmektedir (Çizelge 4.26).

Çizelge 4.26 Özellik seçimi işlemi sonucunda yapay sinir ağı modelleri performans ortalamalarının t-Test analizleri

t-Test: Ortalamalar için iki Örnek

	ÇKYSA	ÇKYSA_FS	LSTM	LSTM_FS
Ortalama	3.412663	3.726155	1.59338	2.328845
Varyans	37.32449	41.85546	2.40487	2.26066
Gözlem	180	180	180.00000	180
Pearson Korelasyonu	0.125823		-0.13391	
Öngörülen Ortalama Farkı	0		0.00000	
df	179		179.00000	
t Stat	-0.50548		-4.29015	
P(T<=t) tek-uçlu	0.306921		0.00001	
t Kritik tek-uçlu	1.653411		1.65341	
P(T<=t) iki-uçlu	0.613843		0.00003	
t Kritik iki-uçlu	1.973305		1.97331	

Çok katmanlı yapay sinir ağlarının MSE performans değerleri 20ms, 50ms ve 100ms zaman pencerelerinde gruplandırılarak yapılan istatistiksel analiz (Çizelge 4.27) sonucunda, farklı zaman pencerelerinde istatistiksel olarak anlamlı bir fark oluşmadığı görülmektedir ($p=0.97169>0.05$).

Çizelge 4.27 Çok katmanlı yapay sinir ağı performansının farklı zaman pencereleri için Anova Testi

Anova: Tek Etken

ÖZET

Gruplar	Say	Toplam	Ortalama	Varyans
ÇKYSA_20ms	60	195.7893	3.263154	40.08626
ÇKYSA_50ms	60	207.0822	3.451369	43.03419
ÇKYSA_100ms	60	211.4079	3.523464	30.08153

ANOVA

Varyans Kaynağı	SS	df	MS	F	P-değeri	F ölçütü
Gruplar						
Arasında	2.16768	2	1.08384	0.028723	0.97169	3.047012
Gruplar İçinde	6678.917	177	37.73399			
Toplam	6681.085	179				

LSTM yapay sinir ağlarının MSE performans değerleri 20ms, 50ms ve 100ms zaman pencerelerinde gruplandırılarak yapılan istatistiksel analizleri (

Çizelge 4.28) sonucunda, 100 ms zaman penceresinde yapılan tahminlerin ortalamasının, 20 ms ve 50 ms zaman penceresindeki tahmin ortalamalarından anlamlı bir şekilde farklılık göstermektedir ($p < 0.05$).

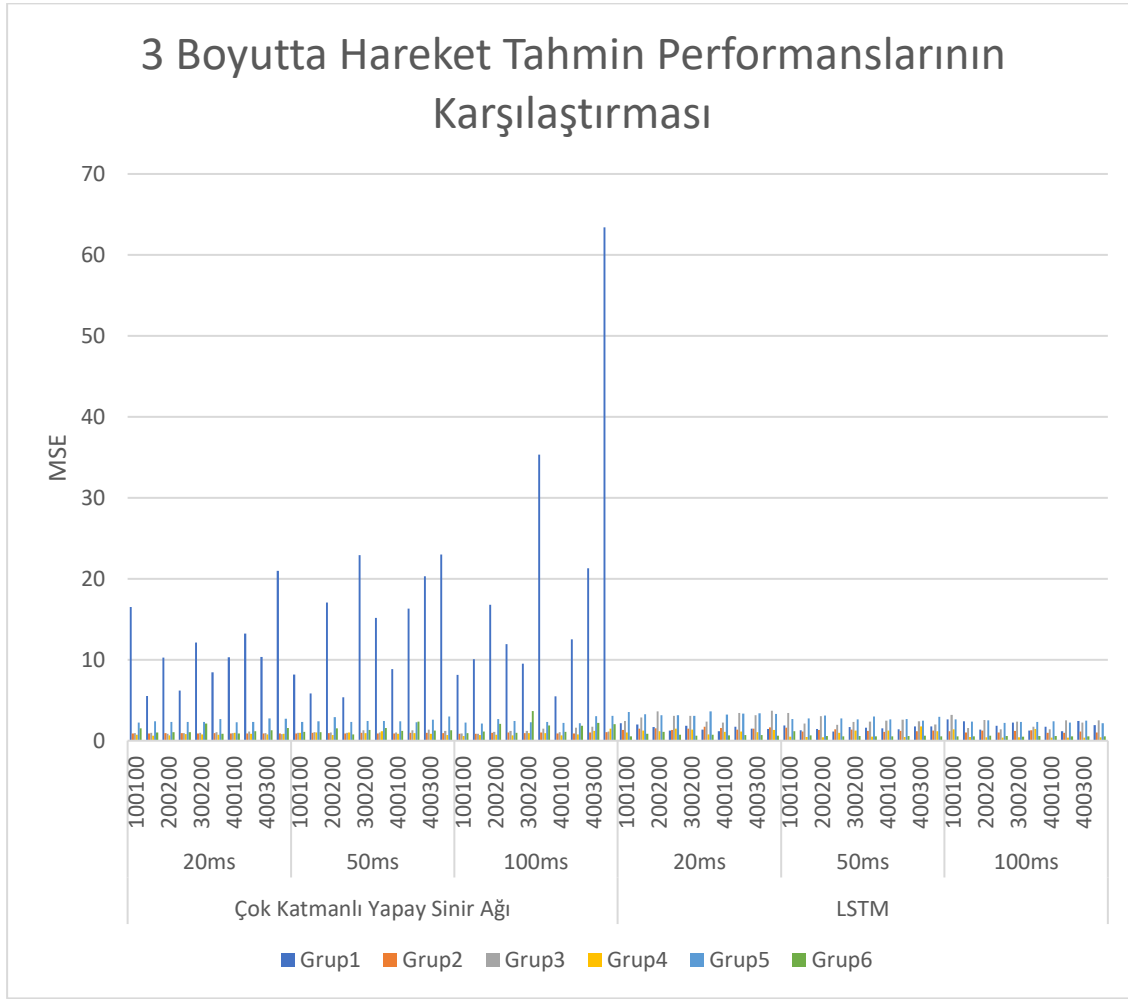
Çizelge 4.28 LSTM modeli için 100ms zaman penceresindeki tahminlerin, 20ms ve 50ms zaman penceresindeki tahminler ile istatistiksel t-Testi

t-Test: Ortalamalar İçin İki Örnek

	<i>LSTM_20ms</i>	<i>LSTM_100ms</i>	<i>LSTM_50ms</i>	<i>LSTM_100ms</i>
Ortalama	1.94092	1.314857	1.524356	1.314857
Varyans	3.32569	1.684918	2.078953	1.684918
Gözlem	60.00000	60	60	60
Pearson Korelasyonu	0.89582		0.933479	
Öngörülen Ortalama Farkı	0.00000		0	
df	59.00000		59	
t Stat	5.52824		3.124859	
P(T<=t) tek-uçlu	0.00000		0.001379	
t Kritik tek-uçlu	1.67109		1.671093	
P(T<=t) iki-uçlu	0.00000		0.002758	
t Kritik iki-uçlu	2.00100		2.000995	

4.3.2. 3 Boyutta Hareket için Yapay Sinir Ağı Modellerinin Performans Karşılaştırması

Çok katmanlı yapay sinir ağları ve LSTM yapay sinir ağları ile 3 boyutlu hareket için yapılan tahminlerin performansları Şekil 4.16’te grafik olarak özetlenmiştir. Buna göre LSTM yapay sinir ağları, 2 boyutlu hareket tahminine benzer şekilde, çok katmanlı yapay sinir ağına göre daha iyi tahminlerde bulunduğu görülmektedir. Çok katmanlı yapay sinir ağlarında en başarısız tahminlerin yapıldığı Grup1 veri setinde 20 ms, 50 ms ve 100 ms zaman aralıklarında sırasıyla ortalama 11.3965, 14.3007 ve 19.4499 MSE değerlerine ulaşılırken, LSTM yapay sinir ağları ile bu değerler aynı sırayla 1.6189, 1.5543, 1.90316 seviyelerine düşmeyi başarmıştır. Genel olarak tüm grupların veri setlerinden elde edilen tahminlerin MSE ortalamasına bakıldığında, LSTM yapay sinir ağlarının (ort: 1.64458) çok katmanlı yapay sinir ağlarına göre (ort: 3.64637) 2 kattan fazla iyi tahminlerde bulunduğu görülmektedir (Şekil 4.16).



Şekil 4.16 3 Boyutlu hareket için çok katmanlı yapay sinir ağı ve LSTM modellerinin performanslarının karşılaştırılması

Çok katmanlı yapay sinir ağı ve LSTM modellerinin performans ortalamaları, 2 boyutta harekete benzer şekilde, istatistiksel olarak anlamlı fark (Çizelge 4.29) oluşturmaktadır ($p=0.00007 < 0.05$).

Özellik seçilimi yapılarak oluşturulan veri setleri ile eğitilen modellerin performans değerleri, özellik seçilimi yapılmadan eğitilen modeller ile karşılaştırıldığında (Çizelge 4.30), hem çok katmanlı yapay sinir ağlarında hem de LSTM yapay sinir ağlarında istatistiksel olarak anlamlı bir fark olmadığı görülmektedir.

Çizelge 4.29 Çok katmanlı yapay sinir ağı ve LSTM modellerinin 3 boyutlu deney için performans ortalamalarının t-Test analizi

t-Test: Ortalamalar için İki Örnek

	ÇKYSA	LSTM
Ortalama	3.64636988	1.644577735
Varyans	47.51076747	0.810104374
Gözlem	180	180
Pearson Korelasyonu	0.063236611	
Öngörülen Ortalama Farkı	0	
df	179	
t Stat	3.895317061	
P(T<=t) tek-uçlu	6.91849E-05	
t Kritik tek-uçlu	1.6534108	
P(T<=t) iki-uçlu	0.00013837	
t Kritik iki-uçlu	1.973305434	

Çizelge 4.30 Özellik seçimi işleminin 3 boyutlu hareket tahminlerinde etkisinin istatistiksel analizi

t-Test: Ortalamalar için İki Örnek

	ÇKYSA	ÇKYSA_FS	LSTM	LSTM_FS
Ortalama	3.64637	3.436724	1.644577735	1.674989
Varyans	47.51077	29.49897	0.810104374	0.90648
Gözlem	180	180	180	180
Pearson Korelasyonu	0.865615		0.821673511	
Öngörülen Ortalama Farkı	0		0	
df	179		179	
t Stat	0.805339		0.734776777	
P(T<=t) tek-uçlu	0.210846		0.231718486	
t Kritik tek-uçlu	1.653411		1.6534108	
P(T<=t) iki-uçlu	0.421693		0.463436972	
t Kritik iki-uçlu	1.973305		1.973305434	

Farklı zaman pencere uzunluklarının (20 ms, 50 ms ve 100 ms), çok katmanlı yapay sinir ağlarında herhangi bir anlamlı farklılığa sebep olmadığı görülmektedir (Çizelge 4.31). Fakat LSTM modellerinin tahminlerinde zaman penceresi büyüdükçe tahmin performans değeri de artmaktadır (Çizelge 4.32).

Çizelge 4.31 Farklı zaman pencerelerinin 3 boyutlu hareket tahminlerinde çok katmanlı yapay sinir ağı performansına etkisi

Anova: Tek Etken

ÖZET

<i>Gruplar</i>	<i>Say</i>	<i>Toplam</i>	<i>Ortalama</i>	<i>Varyans</i>
ÇKYSA_20ms	60	177.479	2.957983	18.15033
ÇKYSA_50ms	60	211.3979	3.523299	31.04816
ÇKYSA_100ms	60	267.4697	4.457828	93.77741

ANOVA

<i>Varyans Kaynağı</i>	<i>SS</i>	<i>df</i>	<i>MS</i>	<i>F</i>	<i>P-değeri</i>	<i>F ölçütü</i>
Gruplar						
Arasında	68.84921	2	34.4246	0.722316	0.487052	3.047012
Gruplar içinde	8435.578	177	47.65863			
Toplam	8504.427	179				

Çizelge 4.32 Farklı zaman pencerelerinin 3 boyutlu hareket tahminlerinde LSTM yapay sinir ağı performansına etkisi

Anova: Tek Etken

ÖZET

<i>Gruplar</i>	<i>Say</i>	<i>Toplam</i>	<i>Ortalama</i>	<i>Varyans</i>
LSTM_20ms	60	113.1317	1.885529	0.977808
LSTM_50ms	60	95.92084	1.598681	0.714744
LSTM_100ms	60	86.97143	1.449524	0.665348

ANOVA

<i>Varyans Kaynağı</i>	<i>SS</i>	<i>df</i>	<i>MS</i>	<i>F</i>	<i>P-değeri</i>	<i>F ölçütü</i>
Gruplar						
Arasında	5.892597	2	2.946298	3.748631	0.025441	3.047012
Gruplar içinde	139.1161	177	0.785967			
Toplam	145.0087	179				

5. SONUÇ ve TARTIŞMA

Bu tez çalışmasında EMG sinyallerinden elde edilen özellikler ile üst ve alt kolun dönüş değerlerini tahmin eden bir yapay sinir ağı modeli üretilmeye çalışılmıştır. Elde edilen bulgular doğrultusunda, modellerin tahmin performansları karşılaştırıldığında LSTM modelinin, çok katmanlı yapay sinir ağına göre daha iyi tahminlerde bulunduğu görülmektedir. Özellikle 2 boyutlu hareket deneyinde neredeyse optik hareket yakalama sistemine yakın tahminler gözlemlenirken, 3 boyutlu hareket için tahminlerin doğruluğu azalmaktadır. Tez çalışmasındaki deneyler sırasında EMG sinyalleri dirsek ile bilek arasındaki herhangi bir kastan veri toplanmamıştır. Alt kolun kendi yerel z eksenini etrafında dönüşünü sağlayan kasların dirsek ile bilek arasında bulunmasından dolayı, özellikle alt kol dönüş değerlerinin tahminlerinde hatalar meydana geldiği görülmektedir. Bu hatayı azaltmak adına, A. Akhtar ve arkadaşlarının çalışmasına [28] benzer şekilde omuz eklemine dönüş değerinin, alt kol dönüş değerini tahmin etmede bir tahmin edici olarak kullanılabilir.

Deneklerinin hareket alanı 2 boyutlu hareket deneyinde deney düzeneği ile kısıtlanarak daha kontrollü bir deney verisi toplanmıştır. Fakat 3 boyutlu hareket deneyinde deneklerden rastgele sırayla günlük hayattan hareketler yapmaları istenmiştir. Bu durum 3 boyutlu deney tahminlerinin daha kötü olmasına sebebiyet vermiş olabilir. Deneklerin hareketlerinin bir düzenek ile 3 boyutlu harekette de sınırlandırılarak veri toplanması, elde edilen modelin tahminlerinde olumlu yönde etki yapabilir.

Yapay sinir ağının tahmin hassasiyetinin artırılması, eğitim veri setinin daha fazla denek ve daha uzun süreli deneyler ile zenginleştirilmesiyle de mümkün olabilir.

Farklı zaman pencerelerinde elde edilen modellerin etkinliği karşılaştırıldığında, çok katmanlı yapay sinir ağlarında herhangi bir farklılık görünmezken, LSTM modellerinin daha uzun zaman pencerelerinde daha iyi tahminler yaptığı görülmektedir. S. I. Benchabane ve arkadaşlarının el hareketlerini sınıflandırarak tahmin ettikleri çalışmada da 100 ms genişliğinde zaman penceresi kullanılarak başarılı sonuca ulaşılmıştır[27]. Tez çalışmasında da en başarılı tahminler 100 ms zaman penceresinde elde edilen özellikler ile LSTM modeli tarafından üretilmiştir.

Literatürde EMG sinyalleri ile kolun hareketinin tahmin edildiği çalışmalar çoğunlukla hareketin sınıflandırılması yönündedir. Kolun hareketinin sürekli olarak incelendiği regresyon probleminin çözümünü içeren çalışmalarda ise, kol hareketi tek serbestlik

derecesinde incelenmiştir. Tez çalışması sonucunda yapılan tahminler kolun 6 serbestlik derecesinde açılarını içerdiğinden, tahminlerin doğruluğunun literatürdeki diğer çalışmalar ile kıyaslanması mümkün olmamaktadır. Tahmin edilen açı sayısının fazlalığına rağmen elde edilen modeller, en düşük 0.07698 ortalama hata karesine ulaşmayı başarmıştır. Bu değer literatürdeki tek serbestlik derecesinde tahmin yapan diğer çalışmalara yakındır.

Tez çalışmasında elde edilen EMG özellikleri, komşuluk bileşenleri analizi (NCA) algoritmasıyla özellik seçilimi işleminden geçirilmiş fakat elde edilen daraltılmış veri seti ile eğitilmiş modellerin performansında herhangi bir iyileşme görülmemiştir. Bu durum NCA algoritmasının tek çıktısı olan regresyon problemlerine göre geliştirilmiş olmasından kaynaklanıyor olabilir. NCA algoritmasının birden çok çıktısı olan regresyon problemlerine göre uyarlanabilirse özellik seçilimi işleminde etkinliği de artabilir.

Gelecekte Yapılabilecek Çalışmalar

Tez çalışmasında, yapay sinir ağları vasıtasıyla EMG sinyallerinden hareket bilgileri üretilmeye çalışılmıştır. Buna benzer olarak, hareket bilgilerinin yapay sinir ağına girdi, EMG sinyalleri de çıktı olarak kullanıldığı bir yapay sinir ağı ile, harekete bağlı olarak EMG sinyali üretmek de mümkün olabilir.

Kolun hareketlerinin 3 boyutta ve 6 serbestlik derecesinde dönüşünün tahmin edilebilmesi amacıyla, deneklerin hareket alanının, hızının kontrol altında tutulduğu bir deney düzeneği ile veri toplanması, elde edilecek modelin tahmin performansına etkisi araştırılabilir.

Tez çalışması sonucunda ortaya çıkan tahmin edici model, ampute kişilerden elde edilecek EMG sinyalleri ile bir robotik kolun veya protezin çalıştırılması sağlanarak modelin günlük hayatta kullanımında test edilebilir.

6. KAYNAKÇA

- [1] M.B.I. Reaz, M.S. Hussain, F. Mohd-Yasin, Techniques of EMG signal analysis: detection, processing, classification and applications, *Biological Procedures Online*, 8 (2006) 11-35.
- [2] N. Massó, F. Rey, D. Romero, G. Gual, Surface electromyography applications in the sport, *ApuntsMed Esport*, 45 (2010).
- [3] M. Kazamel, P.P. Warren, History of electromyography and nerve conduction studies: A tribute to the founding fathers, *Journal of Clinical Neuroscience*, 43 (2017) 54-60.
- [4] P. Konrad, *The ABC of EMG, A Practical Introduction to Kinesiological Electromyography*, USA, 2005.
- [5] H.M. Sussman, R.J. Hanson, P.F. MacNeilage, Studies of single motor units in the speech musculature: methodology and preliminary findings, *J Acoust Soc Am*, 51 (1972) 1372-1374.
- [6] L.S. Lippert, *Clinical Kinesiology and Anatomy*, 4 ed., F. A. Davis Company, USA, 2006.
- [7] A. Elzanie, M. Varacallo, *Anatomy, Shoulder and Upper Limb, Deltoid Muscle*, StatPearls, StatPearls Publishing
- Copyright © 2022, StatPearls Publishing LLC., Treasure Island (FL), 2022.
- [8] S.L. Peterson, G.M. Rayan, Shoulder and upper arm muscle architecture, *J Hand Surg Am*, 36 (2011) 881-889.
- [9] T. Moser, J. Lecours, J. Michaud, N.J. Bureau, R. Guillin, É. Cardinal, The deltoid, a forgotten muscle of the shoulder, *Skeletal Radiology*, 42 (2013) 1361-1375.
- [10] B. Ejnisman, C.V. Andreoli, P.S. Belangero, W.R. Komatsu, D.C. Hipolide, A.C. Pochini, Electromyography of the Pectoralis Major Muscle after Surgical Reconstruction of Chronic Tendon Rupture, *Rev Bras Ortop (Sao Paulo)*, 56 (2021) 31-35.
- [11] D. Rodríguez-Ridao, J.A. Antequera-Vique, I. Martín-Fuentes, J.M. Muyor, Effect of Five Bench Inclinations on the Electromyographic Activity of the Pectoralis Major, Anterior Deltoid, and Triceps Brachii during the Bench Press Exercise, *Int J Environ Res Public Health*, 17 (2020).
- [12] P.R. Camargo, D.A. Neumann, Kinesiological considerations for targeting activation of scapulothoracic muscles - part 2: trapezius, *Braz J Phys Ther*, 23 (2019) 467-475.
- [13] M. Badura, M. Grzonkowska, M. Baumgart, M. Szpinda, Quantitative Anatomy of the Trapezius Muscle in the Human Fetus, *Adv Clin Exp Med*, 25 (2016) 605-609.
- [14] F. Rosenblatt, The perceptron: A probabilistic model for information storage and organization in the brain, *Psychological Review*, 65 (1958) 386-408.
- [15] S.U.S.E.L.S.S.E. Laboratory, B. Widrow, U.S.O.o.N. Research, U.S.A.S. Corps, U.S.A. Force, U.S. Navy, Adaptive "adaline" Neuron Using Chemical "memistors.", 1960.
- [16] M. Minsky, S. Papert, *Perceptrons*, M.I.T. Press, Oxford, England, 1969.
- [17] Rumelhart, D. E, J. McClelland, J. L, *Parallel distributed processing: explorations in the microstructure of cognition. Volume 1. Foundations*, 1986.
- [18] D.H. Nguyen, B. Widrow, Neural networks for self-learning control systems, *IEEE Control Systems Magazine*, 10 (1990) 18-23.
- [19] S. Hochreiter, J. Schmidhuber, Long Short-Term Memory, *Neural Computation*, 9 (1997) 1735-1780.
- [20] D.J. Atkins, D.C.Y. Heard, W.H. Donovan, Epidemiologic Overview of Individuals with Upper-Limb Loss and Their Reported Research Priorities, *JPO: Journal of Prosthetics and Orthotics*, 8 (1996) 2-11.

- [21] K.D. Bergmeister, M. Aman, S. Muceli, I. Vujaklija, K. Manzano-Szalai, E. Unger, R.A. Byrne, C. Scheinecker, O. Riedl, S. Salminger, F. Frommlet, G.H. Borschel, D. Farina, O.C. Aszmann, Peripheral nerve transfers change target muscle structure and function, *Science Advances*, 5 (2019) eaau2956.
- [22] J.E. Cheesborough, L.H. Smith, T.A. Kuiken, G.A. Dumanian, Targeted muscle reinnervation and advanced prosthetic arms, *Semin Plast Surg*, 29 (2015) 62-72.
- [23] J.C. Chen, X.D. Zhang, Y. Cheng, N. Xi, Surface EMG based continuous estimation of human lower limb joint angles by using deep belief networks, *Biomedical Signal Processing and Control*, 40 (2018) 335-342.
- [24] D. Karabulut, F. Ortes, Y.Z. Arslan, M.A. Adli, Comparative evaluation of EMG signal features for myoelectric controlled human arm prosthetics, *Biocybernetics and Biomedical Engineering*, 37 (2017) 326-335.
- [25] B. Amankwaa-Kyeremeh, Greet, C., Zanin, M., Skinner, W. and Asamoah, R. K., Selecting key predictor parameters for regression analysis using modified Neighbourhood Component Analysis (NCA) Algorithm, *Proceedings of 6th UMaT Biennial International Mining and Mineral Conference Tarkwa, Ghana*, 2020.
- [26] W. Yang, K.Q. Wang, W.M. Zuo, Neighborhood Component Feature Selection for High-Dimensional Data, *Journal of Computers*, 7 (2012) 161-168.
- [27] S.I. Benchabane, N. Saadia, A. Ramdane-Cherif, Novel algorithm for conventional myocontrol of upper limbs prosthetics, *Biomedical Signal Processing and Control*, 57 (2020) 101791.
- [28] A. Akhtar, N. Aghasadeghi, L. Hargrove, T. Bretl, Estimation of distal arm joint angles from EMG and shoulder orientation for transhumeral prostheses, *J. Electromyogr. Kinesiol.*, 35 (2017) 86-94.
- [29] X. Chen, A. Ke, X. Ma, J.P. He, Ieee, SoC-based Architecture for Robotic Prosthetics Control using Surface Electromyography, *8th International Conference on Intelligent Human-Machine Systems and Cybernetics (IHMSC) Zhejiang Univ, Hangzhou, PEOPLES R CHINA*, 2016, pp. 134-137.
- [30] A.T.C. Au, R.F. Kirsch, EMG-Based prediction of shoulder and elbow kinematics in able-bodied and spinal cord injured individuals, *Ieee Transactions on Rehabilitation Engineering*, 8 (2000) 471-480.
- [31] A. Foroutannia, M.R. Akbarzadeh-T, A. Akbarzadeh, A deep learning strategy for EMG-based joint position prediction in hip exoskeleton assistive robots, *Biomedical Signal Processing and Control*, 75 (2022) 15.
- [32] E. Trigili, L. Grazi, S. Crea, A. Accogli, J. Carpaneto, S. Micera, N. Vitiello, A. Panarese, Detection of movement onset using EMG signals for upper-limb exoskeletons in reaching tasks, *Journal of NeuroEngineering and Rehabilitation*, 16 (2019) 45.
- [33] D.P. Yang, H. Liu, An EMG-Based Deep Learning Approach for Multi-DOF Wrist Movement Decoding, *Ieee Transactions on Industrial Electronics*, 69 (2022) 7099-7108.
- [34] Y. Chen, X. Zhao, J. Han, Hierarchical projection regression for online estimation of elbow joint angle using EMG signals, *Neural Computing and Applications*, 23 (2013) 1129-1138.
- [35] D. Bu, S. Guo, H. Li, sEMG-Based Motion Recognition of Upper Limb Rehabilitation Using the Improved Yolo-v4 Algorithm, *Life*, 12 (2022) 64.
- [36] D.L. Crouch, H. Huang, Musculoskeletal model predicts multi-joint wrist and hand movement from limited EMG control signals, *2015 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, 2015, pp. 1132-1135.
- [37] A. Cimolato, G. Milandri, L.S. Mattos, E.D. Momi, M. Laffranchi, L.D. Michieli, Hybrid Machine Learning-Neuromusculoskeletal Modeling for Control of Lower Limb

- Prosthetics, 2020 8th IEEE RAS/EMBS International Conference for Biomedical Robotics and Biomechatronics (BioRob), 2020, pp. 557-563.
- [38] M.A. García-Vellisca, A. Matran-Fernandez, R. Poli, L. Citi, Hand-movement Prediction from EMG with LSTM-Recurrent Neural Networks, 2021 Global Medical Engineering Physics Exchanges/Pan American Health Care Exchanges (GMEPE/PAHCE), 2021, pp. 1-5.
- [39] A. Phinyomark, P. Phukpattaranont, C. Limsakul, Feature reduction and selection for EMG signal classification, *Expert Systems with Applications*, 39 (2012) 7420-7431.