

**T.C.
SAKARYA UYGULAMALI BİLİMLER ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

PROTEZ KOLUN SERVO MOTORLAR İLE HASSAS KONTROLÜ

YÜKSEK LİSANS TEZİ

Muhammed Salih SARIKAYA

Enstitü Anabilim Dalı : MEKATRONİK MÜHENDİSLİĞİ

Tez Danışmanı : Prof. Dr. Adnan DERDİYOK

AĞUSTOS 2020

T.C.
SAKARYA UYGULAMALI BİLİMLER ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

PROTEZ KOLUN SERVO MOTORLAR İLE HASSAS KONTROLÜ

YÜKSEK LİSANS TEZİ

Muhammed Salih SARIKAYA

Enstitü Anabilim Dalı : MEKATRONİK MÜHENDİSLİĞİ

Bu tez 13/08/2020 tarihinde aşağıdaki jüri tarafından oybirliği ile kabul edilmiştir.

JÜRİ	BAŞARI DURUMU
Jüri Başkanı: Prof. Dr. Adnan DERDİYOK	BAŞARILI
Üye: Doç. Dr. Mustafa Zahid YILDIZ	BAŞARILI
Üye: Doç. Dr. İrfan YAZICI	BAŞARILI

BEYAN

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

Muhammed Salih SARIKAYA

13/08/2020

TEŐEKKÖR

YÖksek lisans eęitimim boyunca deęerli bilgi ve deneyimlerinden yararlandığım, her konuda bilgi ve desteęini almaktan çekinmediğim, çalışmanın planlanmasından yazılmasına kadar tüm aşamalarında yardımlarını esirgemeyen, teşvik eden, aynı titizlikte beni yönlendiren deęerli danışman hocam Prof. Dr. Adnan DERDİYOK’a teşekkürlerimi sunarım.

Eęitim hayatım boyunca ve mevcut çalışmalarım süresince maddi ve manevi desteklerini esirgemeyen, her durumda yanımda olan aileme sonsuz teşekkürlerimi sunarım.

İÇİNDEKİLER

BEYAN.....	ii
TEŞEKKÜR	i
İÇİNDEKİLER	ii
KISALTMALAR	iv
SİMGELER	v
TABLolar LİSTESİ.....	vi
ŞEKİLLER LİSTESİ.....	vii
ÖZET.....	x
SUMMARY	xi
BÖLÜM 1. GİRİŞ	1
1.1. Motor Kontrol Uygulamaları ile İlgili Literatür Taraması.....	1
1.2. Derin Öğrenme ile İlgili Literatür Taraması	3
BÖLÜM 2. MATERYAL VE YÖNTEM.....	7
2.1. Servo Motorlar	7
2.2. Bulanık Mantık Kontrol	9
2.3. Yapay Sinir Ağları	11
2.3.1. Makine öğrenmesi.....	13
2.3.2. Derin öğrenme.....	13
2.4. Deneysel Sistem Tasarımı	20
BÖLÜM 3. ÖNERİLEN ALGORİTMALAR VE SONUÇLAR	28
3.1. Derin Öğrenme	28
3.2. Bulanık Resetlemeli PI Kontrolcü.....	28
3.3. Simülasyon Sonuçları.....	31
3.3.1. Protez kolun fleksiyon ve ekstansiyon hareketini gerçekleştiren servo motor için konum kontrolü sonuçları.....	31
3.4. Deneysel Sonuçlar	39
3.4.1. Protez kolun fleksiyon ve ekstansiyon hareketini gerçekleştiren servo motor için konum kontrolü sonuçları.....	39
3.4.2. Protez elin açma-kapama hareketini gerçekleştiren doğrusal eyleyici için konum kontrolü sonuçları	47

BÖLÜM 4. SONUÇLAR VE ÖNERİLER	54
KAYNAKLAR	58
ÖZGEÇMİŞ.....	62



KISALTMALAR

AA	: Alternatif Akım (Alternating Current)
DA	: Doğru Akım (Direct Current)
EMG	: Elektromiyografi
GPU	: Grafik İşlemci Birimi (Graphic Processing Unit)
ISIC	: Uluslararası Cilt Görüntüleme İş birliği (The International Skin Imaging Collaboration)
LQG	: Doğrusal Kuadratik Gauss (Linear Quadratic Gasussian)
LQR	: Doğrusal Kuadratik Regülatör (Linear Quadratic Regulator)
PID	: Oransal İntegral Türev (Proportional Integral Derivative)
PWM	: Dalga Genişlik Modülasyonu (Pulse-Width Modulation)
ReLU	:Doğrutulmuş Doğrusal Birim (Rectified Linear Unit)

SİMGELER

b	: Sönümlleme sabiti
de	: Hatanın değışimi
e	: Hata
E_a	: Zıt Elektromotor kuvveti
i	: Akım
J	: Atalet momenti
K_e	: Gerilim sabiti
K_t	: Moment sabiti
L_a	: Motor sargıların endüktansı
r	: Resetleme oranı
R_a	: Motor sargılarının direnci
T	: Üretilen moment
T_y	: Yük momenti
u	: Kontrol sinyalidir
u_p	: PI kontrolcünün ürettiğı sinyal
V_a	: Motora uygulanan gerilim
w	: Motorun hızı

TABLolar LİSTESİ

Tablo 2.1 : Kural tablosu	11
Tablo 2.2 : Aktivasyon fonksiyonları ve matematiksel ifadeleri.....	12
Tablo 2.3 : Doğrusal eyleyici özellikleri.	24
Tablo 2.4 : Ziegler-Nichols kapalı çevrim katsayı hesaplama tablosu.....	26
Tablo 3.1 : Bulanık resetleme oranı için kural tablosu.....	30
Tablo 4.1 : Referans sinyal olarak kare dalga sisteme uygulandığında simülasyon sonuçları.	55
Tablo 4.2 : Referans sinyal olarak sinüzoidal dalga sisteme uygulandığında simülasyon sonuçları.	55
Tablo 4.3 : Referans olarak step sinyal sisteme uygulandığında servo motor sonuçları.	56
Tablo 4.4 : Referans sinyal olarak sinüzoidal dalga sisteme uygulandığında servo motor sonuçları.....	56
Tablo 4.5 : Referans olarak step sinyal sisteme uygulandığında doğrusal eyleyicinin sonuçları.	56
Tablo 4.6 : Referans sinyal olarak sinüzoidal dalga sisteme uygulandığında doğrusal eyleyicinin sonuçları.	57

ŞEKİLLER LİSTESİ

Şekil 2.1 : Servo motor türleri.....	8
Şekil 2.2 : Alternatif akım servo motor temel çalışma prensibi.....	9
Şekil 2.3 : Bulanık mantık çalışma algoritması.	10
Şekil 2.4 : Üyelik fonksiyonu örneği.	10
Şekil 2.5 : Yapay sinir ağı temel yapısı.	12
Şekil 2.6 : Derin öğrenmenin, makine öğrenmesinin ve yapay zekanın ilişkisi.	14
Şekil 2.7 : Otomatik kodlayıcı mimarisi.	15
Şekil 2.8 : Kısıtlı boltzmann makine mimarisi.....	15
Şekil 2.9 : Temel tekrarlayan sinir ağı yapısı.....	16
Şekil 2.10 : Tekrarlamalı sinir ağının iç yapısı.	17
Şekil 2.11 : Tekrarlayan sinir ağı türleri.	17
Şekil 2.12 : Evrişim işlemi örneği.....	19
Şekil 2.13 : Maksimum havuzlama örneği.....	19
Şekil 2.14 : Ortalama havuzlama örneği.	20
Şekil 2.15 : Kullanılan servo motor.	21
Şekil 2.16 : Hat alıcı devresi (a) devre şeması, (b) üst görünüm.	22
Şekil 2.17 : Motor sürücü devresi (a) devre şeması, (b) üst görünüm.	23
Şekil 2.18 : Kullanılan doğrusal eyleyici	24
Şekil 2.19 : Doğru akım motorunun eşdeğer devresi.	24
Şekil 2.20 : EMG sinyal örneği.....	26
Şekil 2.21 : Deneysel sistem	27
Şekil 3.1 : Sistemin genel çalış blok diyagramı.	28
Şekil 3.2 : Bulanık resetlemeli PI kontrolcü yapısı.....	29
Şekil 3.3 : Hata (e) ve hatanın değişim oranının (de) üyelik fonksiyonları.	30
Şekil 3.4 : Bulanık resetleme oranı üyelik fonksiyonu.	30

Şekil 3.5 : Referans giriş olarak kare dalga uygulandığında sistemin cevabı (a) geleneksel bulanık mantık kontrol cevabı (b) geleneksel PI kontrolcü cevabı (c) bulanık resetlemeli PI kontrolcü cevabı.	32
Şekil 3.6 : Referans giriş olarak kare dalga uygulandığı zaman (a) geleneksel bulanık kontrolcü, (b) geleneksel PI kontrolcü ve (c) bulanık resetlemeli kontrolcünün ürettiği kontrol sinyali.	33
Şekil 3.7 : Referans giriş olarak sinüzoidal dalga uygulandığında sistem cevabı (a) geleneksel bulanık mantık kontrolcü cevabı, (b) geleneksel PI kontrolcü cevabı(b) bulanık resetlemeli PI kontrolcü cevabı.	34
Şekil 3.8 : Referans olarak sinüzoidal sinyal uygulandığı zaman (a) geleneksel bulanık kontrolcü, (b) geleneksel PI kontrolcü ve (c) bulanık resetlemeli PI kontrolcünün motora uygulamış olduğu kontrol sinyali.	35
Şekil 3.9 : Derin öğrenmenin ürettiği referans sinyali sisteme uygulandığı zaman (a) geleneksel bulanık kontrol cevabı, (b) geleneksel PI kontrol cevabı, (c) bulanık resetlemeli PI kontrol cevabı; (d) geleneksel bulanık kontrolcünün, (e) geleneksel PI kontrolcünün ve (f) bulanık resetlemeli PI kontrolcünün motora uyguladığı kontrol sinyali.	38
Şekil 3.10 : Bulanık mantık kontrolcü ile kontrol edilen servo motorun cevabı.	39
Şekil 3.11 : Referans olarak birim basamak uygulandığında sistem cevabı (a) geleneksel PI kontrolcü cevabı (b) bulanık resetlemeli PI kontrolcü cevabı.	40
Şekil 3.12 : Referans olarak kare dalga uygulandığında sistem cevabı (a) geleneksel PI kontrolcü cevabı (b) bulanık resetlemeli PI kontrolcü cevabı, (c) oluşan hataların tip 1 norm değeri.	42
Şekil 3.13 : Referans sinyal olarak kare dalga sinyal sisteme uygulandığında (a)geleneksel PI kontrolcünün ve (b) bulanık resetlemeli PI kontrolcünün sisteme uyguladığı kontrol sinyali.	43
Şekil 3.14 : Referans olarak sinüzoidal dalga uygulandığında sistem cevabı (a) geleneksel PI kontrolcü cevabı (b) bulanık resetlemeli PI kontrolcü cevabı, (c) oluşan hataların tip 1 norm değerleri.	44
Şekil 3.15 : Referans olarak sinüzoidal sinyal sisteme uygulandığı zaman (a) geleneksel PI kontrolcünün ve (b) bulanık resetlemeli PI kontrolcünün motora uygulamış olduğu kontrol sinyal.	45

Şekil 3.16 : Derin öğrenmenin ürettiği referans sinyali sisteme uygulandığı zaman (a) geleneksel PI kontrol cevabı, (b) bulanık resetlemeli PI kontrol cevabı; (c) geleneksel PI kontrolcünün ve (d) bulanık resetlemeli PI kontrolcünün motora uyguladığı kontrol sinyali.	47
Şekil 3.17 : Doğrusal eyleyici için referans olarak kare dalga uygulandığında sistem cevabı (a) geleneksel PI kontrolcü cevabı (b) bulanık resetlemeli PI kontrolcü cevabı, (c) oluşan hataların tip 1 norm değeri.....	48
Şekil 3.18 : Referans sinyal olarak kare dalga sisteme uygulandığı zaman (a) geleneksel PI kontrolcünün ve (b) bulanık resetlemeli PI kontrolcünün doğrusal eyleciye uygulamış olduğu kontrol sinyali.....	49
Şekil 3.19 : Doğrusal eyleyici için referans olarak sinüzoidal dalga uygulandığında sistem cevabı (a) geleneksel PI kontrolcü cevabı (b) bulanık resetlemeli PI kontrolcü cevabı, (c) oluşan hataların tip 1 norm değeri.	50
Şekil 3.20 : Referans sinyal olarak sinüzoidal sinyal sisteme uygulandığı zaman (a) geleneksel PI kontrolcünün ve (b) bulanık resetlemeli PI kontrolcünün doğrusal eyleyiciye uyguladığı kontrol sinyali.	51
Şekil 3.21 : Derin öğrenmenin ürettiği referans sinyal sisteme uygulandığında (a) geleneksel PI kontrol cevabı, (b) bulanık resetlemeli PI kontrol cevabı; (c) geleneksel PI kontrolcünün ve (d) bulanık resetlemeli PI kontrolcünün doğrusal eyleyiciye uyguladığı kontrol sinyali.	53

PROTEZ KOLUN SERVO MOTORLAR İLE HASSAS KONTROLÜ

ÖZET

Bu çalışmada, protez kol ve el hassas bir şekilde hareket edebilmesi için bir sistem tasarlanmıştır. Tasarlanan sistemde protez kolun ekstansiyon ve fleksiyon hareketleri için doğru akım servo motor, protez elin açılıp kapanması için doğrusal eyleyici kullanılmıştır. Derin öğrenme algoritmaları ile kaslardan alınan ham EMG verilerinin sınıflandırılması gerçekleştirilmiş. Bu sınıflandırmalar neticesinde elde edilen işaretler ile sistemde kullanılan aktüatörler kontrol edilmiştir. Aktüatörlerin kontrolü için bulanık resetlemeli PI kontrolcü önerilmiştir. Önerilen kontrolcüde geleneksel PI kontrolcünün cevabını iyileştirmek için bulanık resetleme yapısı geleneksel PI yapısına uyarlanmıştır. Resetleme işlemi geleneksel PI kontrolcünün integral hafızasını kısmi olarak resetlemektedir. Tasarlanan sistem simülasyon ortamında ve gerçek zamanlı olarak çalıştırılmıştır. Aktüatörlere sırasıyla geleneksel PI kontrolcü, geleneksel bulanık kontrolcü ve bulanık resetlemeli PI kontrolcüler uygulanmıştır. Aktüatörlere kare dalga ve sinüs dalga şeklinde referans sinyaller uygulanarak sonuçlar elde edilmiştir. Simülasyon ve deneysel sonuçlar incelendiğinde bulanık resetlemeli PI kontrolcü, geleneksel PI kontrolcüyle ve geleneksel bulanık kontrolcüyle karşılaştırıldığı zaman referans sinyali daha iyi bir şekilde takip ettiği ve daha gürbüz davrandığı gözlemlenmiştir.

Anahtar Kelimeler: Servo motor, derin öğrenme, bulanık resetlemeli PI kontrol

PRECISION CONTROL OF PROSTHETIC ARM WITH SERVO MOTORS

SUMMARY

In this study, a system has been designed to control the prosthetic arm and prosthetic hand in a similar way to humanoid features. In the designed system, a direct current servo motor has been used for the extension and flexion movements of the prosthetic arm and a linear actuator has been used to open and close the prosthetic hand. Classification of raw EMG data that take from the muscles has been realized with deep learning algorithms. Actuators used in the designed system have been controlled with this classification. Fuzzy resetting PI controller is proposed for the control of the actuators. To improve the response of conventional PI controller, proposed controller is occurred by adapted the fuzzy resetting structure to the conventional PI controller. The resetting structure partially resets the integral memory of the conventional PI controller. The designed system is run in simulation environment and in real time. The conventional PI controller, the conventional fuzzy logic controller and the fuzzy resetting PI controller have been applied to actuators. Results have been obtained by applying reference signal in the form of square wave and sine wave to actuators. Based on simulation and experimental results, it has been observed that the fuzzy resetting PI controller follows the reference signal better and more robust than the conventional PI controller and the conventional fuzzy logic controller.

Keywords: Servo motor, deep learning, fuzzy resetting PI control

BÖLÜM 1. GİRİŞ

Günümüzde mekanik hareketlerin büyük bir kısmını elektrik motorları gerçekleştirmektedir. Elektrik motorları elektrik enerjisini hareket enerjisine çevirirler. Robotik, havacılık, endüstriyel otomasyon, otomotiv alanlarında yaygın olarak kullanılan servo elektrik motorları son yıllarda biyomekatronik sistemler gibi hassas konum kontrolü gerektiren uygulamalarda yaygın olarak kullanılmaktadır. Biyomekatronik uygulamalarda öncelikle ham biyolojik sinyallerin sınıflandırılma ve özellik çıkarımı için işlenmesi gerekmektedir. Bunun içinde yaygın olarak derin öğrenme algoritmaları kullanılmaktadır. Daha sonra işlenen sinyaller bir servo motor kontrol sistemine verilerek biyomekatronik sistemin kontrolü gerçekleştirilmektedir.

Servo motor kontrolü ve biyomekatronik uygulamalar konusunda son yıllarda çok sayıda çalışma yapılmıştır. Bu çalışmalar güncel konulardan bulanık kontrol, kayan kipli kontrol, yapay sinir ağı tabanlı kontrol vs. teknikleri ön plana çıkmaktadır.

Biyolojik sinyallerin işlenmesinde ise yaygın olarak yapay sinir ağları kullanılmaktadır. Yapay sinir ağları ile ilgili uygulamalar ve akademik çalışmalar; tek katmanlı yapay sinir ağı algoritmasından çok katmanlı yapay sinir ağına ve çok katmanlı yapay sinir ağı algoritmalarından derin öğrenme algoritmalarına doğru ilerlemiştir.

Aşağıda son yıllarda servo motor ve derin öğrenme konularında yapılan bazı çalışmalar özetlenmiştir.

1.1. Motor Kontrol Uygulamaları ile İlgili Literatür Taraması

Zhu ve diğ. (2020) tarafından yapılan çalışmada fırçasız doğru akım motorunun konum kontrolü kayan kipli kontrolcü tasarlanarak gerçekleştirilmiştir. d-eksen voltajı vektör kontrol yöntemi ile kontrol edilmiştir. q-ekseni voltajı için ise radyan tabanlı fonksiyon sinir ağı kurallarına dayanan kayan kipli kontrolcü tasarlanmıştır.

Jalil ve diğ. (2019) tarafından gerçekleştirilen çalışmada doğru akım motorunun konum kontrolü için integralsiz model referans adaptif kontrolör yapısı uygulanmıştır. Bu çalışmada birkaç farklı yapıda gerçekleştirilen kontrolcülerin motor konum kontrolündeki cevapları karşılaştırılmıştır.

Maung ve diğ. (2018) tarafından yapılan çalışmada doğru akım motorunun açısız konum kontrolünde PID kontrolcü tasarlanmıştır. Tasarlanan kontrolcü ile motorun hassas konum kontrolünün gerçekleştirebilmesi için motorda gerçekleşen sürtünmeyi telafi edebilecek bir dengeleme yapısı kontrolcüye eklenmiştir.

Khan ve diğ. (2016) yaptıkları çalışmada doğru akım motorunun konum kontrolü için tekrarlayan referans girdilerine karşılık tekrarlayan kontrolcü yapısı önerilmiştir. Önerilen kontrolör yapısında hata ile bir periyod önceki hata karşılaştırılarak sonuç PID kontrolcüye girdi olarak verilmiştir.

Issa ve Abd (2018) tarafından gerçekleştirilen çalışmada doğru akım motorunun hız ve konum kontrolünü gerçekleştirmek için yapay sinir ağlarını kullanarak bir kontrolcü yapısı önerilmiştir. Adaptif ters sinir ağları adı verilen tasarlanmış kontrolcü yapısının hız ve konum cevapları ile PID kontrolcü yapısının hız ve konum cevapları karşılaştırılmıştır. Adaptif ters sinir ağları ile gerçekleştirilen kontrolcünün PID'den daha hassas bir kontrol gerçekleştirdiği belirtilmiştir.

Choudhary ve diğ. (2018) tarafından yapılan çalışmada simülasyon ortamında doğru akım motorunun konum kontrolü ve hız kontrolü için sırasıyla PID kontrolcü, kayan kipli kontrolcü, integral kayan kipli kontrolcü ve bulanık integral kayan kipli kontrolcü yapıları uygulanmıştır. Tasarlanan kontrolcüler arasından bulanık integral kayan kipli kontrolcünün daha iyi sonuçlar verdiği gözlemlenmiştir.

Morán ve Viera (2017) gerçekleştirdikleri çalışmada doğru akım motorunun konum kontrolü için PID kontrolör, bulanık PI ve bulanık PID tasarlamış ve tasarlanan kontrolcüler karşılaştırılmıştır. PID kontrolcü hızlı cevap verip yüksek aşım yaparak istenen değere ulaşmıştır. Bulanık PI kontrolcü aşım yapmayan daha yavaş istenen değere ulaşmıştır. Bulanık PID kontrolcü ise istenen değere yerleşme süresi olarak en iyi sonucu vermiş ve aşım olarak geleneksel PID kontrolcüye göre daha az aşım yapmıştır.

Chakraborty ve diğ. (2018) simülasyon ortamında doğru akım motorunun konum kontrolünü gerçekleştirmişlerdir. Modele uygulanan kontrolcü kesir dereceli PID

yapısıdır. Uygulanan kontrolcü yapısı ile PID kontrolcü yapısı karşılaştırılmıştır. Kesir dereceli PID kontrolcünün PID yapısına göre yerleşme süresi olarak, aşım değeri olarak ve kararlı duruma geçme süresi olarak daha iyi sonuçlar verdiği gösterilmiştir.

Qureshi ve diğ. (2016) yaptıkları çalışmada doğru akım servo motorun konum kontrolü simülasyon ortamında gerçekleştirilmiştir. Kontrolcü olarak kayan kipli kontrolcü tasarlanmıştır. Kayan kipli kontrolcü, PI kontrolcü ile karşılaştırılmıştır. Kontrolcülerin uygulandığı model hem yüksüz hem de yüklü bir şekilde simülasyonu gerçekleştirilmiştir. Kayan kipli kontrolcünün daha iyi sonuçlar verdiği gözlemlenmiştir.

Khanna ve Gaur (2017) tarafından yapılan çalışmada doğru akım motorunun konum kontrolü üzerine gerçekleştirilen çalışmada; doğru akım motoru simülasyon ortamında modellenmiş ve Model Tabanlı Kontrol yapısı uygulanmıştır.

Aravind ve diğ. (2017) yaptıkları çalışmada doğru akım motorunun konum kontrolü için doğrusal kuadratik gauss (Linear Quadratic Gaussian – LQG) yöntemine Genişletilmiş Kalman Filtreyi ekleyerek uygulanmıştır. Doğrusal kuadratik regülatör (Linear Quadratic Regulator – LQR) yöntemi ile karşılaştırılmış ve LQG'nin daha başarılı olduğunu gösterilmiştir.

1.2. Derin Öğrenme ile İlgili Literatür Taraması

Derin öğrenme; görüntü işleme, davranış sınıflandırma, cinsiyet tahmini, kanser tespiti gibi pek çok alanda kullanılmaktadır. Derin öğrenme ile ilgili ve derin öğrenmenin biyomedikal alanlara kullanılması ile ilgili son yıllarda yapılan bazı çalışmalar aşağıda özetlenmiştir.

Turhan ve Bilge (2019) tarafından gerçekleştirilen çalışmada süper çözünürlük ve ölçeklenebilir görüntü üzerine çalışma yapılmıştır. Yapılan çalışmada MINIST veri seti kullanılmıştır. MINIST veri seti 0-9 arasındaki rakamların el yazı ile yazılmış görüntülerinden oluşmaktadır. Derin öğrenme yöntemlerinden Üretici Çekişmeli Ağ ve Varyasyonel Otomatik Kodlayıcı modelleri temeline dayanan bir ağ modeli önerilmiştir.

Dandıl ve Polattimur (2019) tarafından yapılan çalışmada köpek davranışlarının tanınması üzerine bir çalışma gerçekleştirilmiştir. Derin öğrenme yapılarından evrişimsel sinir ağı modeli temeline dayanan daha hızlı bölgesel evrişimsel sinir ağı

modeli kullanılmıştır. İki farklı köpek üzerinden alınan video kayıtları ile veri seti hazırlanmıştır. Yapılan çalışmada köpeklerin ağız açma, dil çıkarma, koklama, kulak dikme, kuyruk sallama, oyun oynama davranışları incelenmiş ve bu davranışlar için sırasıyla %94,00, %98,00, %99,33, %99,33, %98,00, %98,67 sınıflandırma başarımları elde edilmiştir.

Gündüz ve Cedimoğlu (2019) tarafından yapılan çalışmada görüntü üzerinde cinsiyet tahmini üzerine çalışma gerçekleştirilmiştir. Derin öğrenme mimarilerinden evrimsel sinir ağları mimarisi kullanılmıştır. Model olarak yeni bir model geliştirilmiştir. Yeni geliştirilen model Alex Net ve VGG-16 modeli ile kıyaslanmıştır. Veri seti olarak Vikipedi görüntülerinden derlenmiş ve etiketlenmiş veri seti kullanılmıştır. Kıyaslama sonucunda geliştirilen modelin ise Alex Net'ten daha iyi bir performans sergilediği, VGG-16 modelinin en iyi performansı verdiği gözlemlenmiştir.

Doğan ve Türkoğlu (2018) tarafından gerçekleştirilen çalışmada yaprak sınıflandırma üzerine çalışma gerçekleştirilmiştir. Bu çalışmada derin öğrenme mimarilerinden evrimsel sinir ağı mimarisi kullanılmıştır. Veri seti olarak UCI-Machine Learning Repository veri tabanından elde edilen bir veri seti kullanılmıştır. Veri setinde yaklaşık 1900 etiketlenmiş örnek bulunmaktadır. Örnekleri aynalama ve tersleme işlemi ile 4 katına çıkartarak veri seti genişletilmiştir. Alex Net, Google Net, VGG-16, VGG-19 ve ResNet50 algoritmalarının doğruluk sonuçları kıyaslanmıştır. Doğruluk oranlarına göre sıralamanın Alex Net, ResNet50, VGG-16, VGG-19 ve Google Net şeklinde olduğunu belirtilmiştir.

Yıldız (2019) tarafından yapılan çalışmada Melanom türü cilt kanserinin tespiti üzerine çalışma gerçekleştirilmiştir. Bu çalışmada evrimsel sinir ağına ait farklı algoritmalar ve çok katmanlı sinir ağı, K-en yakın komşuluk, destek vektör makinası yöntemleri kullanılmıştır. Veri seti, ISIC (The International Skin Imaging Collaboration) tarafından elde edilen görüntülerden oluşmaktadır. Kıyaslamanın sonucunda K-en yakın komşuluk algoritması en düşük doğruluk sonuçlarını vermiştir. C4net Algoritması ise en iyi sonuçları veren algoritma olmuştur.

Alpaslan (2019) tarafından yapılan çalışmada meme kanserini görüntüler üzerinden derin öğrenme tarafından tanınması için yeni bir karar verme mekanizması üzerinde durulmuştur. Veri setini genişletmek için her bir görüntüyü 45 - 90 - 135 - 180 - 225 - 270 derece açılarda döndürülmüştür. Önerilen karar verme mekanizması aynı veri

setini kullanan farklı sınıflandırma çalışmaları ile karşılaştırılmıştır. Karşılaştırılan karar verme mekanizmaları arasında en yüksek performansa sahip olduğu gösterilmiştir.

Derin öğrenme ile el ve kol hareketlerinin, kaslardan alınan elektromiyografi sinyalleri kullanılarak sınıflandırılması üzerine yapılan çalışmalardan bazıları aşağıda verilmiştir.

Côté-Allard ve diğ. (2019) Elektromiyografi (EMG) sinyalleri üzerinden el hareketlerini sınıflandırmak üzerine çalışma yapmışlardır. EMG sinyali Myo armband (Thalmic Labs) cihazı ile cilt yüzeyinden alınmıştır. Myo Armband kullanılarak üç farklı veri seti oluşturulmuştur. Bunlardan bir tanesi ön eğitim için kullanılmıştır. Çalışmada derin öğrenme mimarilerinden üç tanesini ve yeni bir yöntem sunulmaktadır. İkinci ve üçüncü veri setleri ile bu dört farklı yöntem kıyaslanmıştır. Önerilen yöntemin doğruluk başarısını artırdığı ve gerçek zamanlı kullanımda bozulmaları azalttığı gösterilmiştir.

Tsinganos ve diğ. (2018) yaptıkları çalışmada elektromiyografi sinyalleri üzerinden hareket tanımlama için derin öğrenme yöntemleri kullanılmıştır. Gerçekleştirilen çalışmada evrişimsel sinir ağı mimarisi temeline dayanan bir algoritma önerilmiştir. Kullanılan veri seti 53 hareketten oluşan etiketlenmiş bir veri setidir. Aynı veri seti üzerinden daha önce yapılmış çalışmalar ile kendi çalışmaları karşılaştırılmıştır. Önerilen algoritma sonuçları, diğer çalışma sonuçlarına göre daha yüksek bir doğruluk sergilemiştir.

Baştürk ve diğ. (2017) tarafından yapılan çalışmada elektromiyografi sinyali üzerinden el hareketlerinin tahmini üzerine çalışılmıştır. Tahmin yöntemi olarak derin öğrenme yöntemi olan derin sinir ağı yapısı tercih edilmiştir. Veri seti UCI (Data Mining Repository of University of California) üzerinden elde edilmiştir. Veri setinde 6 el hareketi mevcuttur. Gerçekleştirilen çalışmada derin sinir ağı yapısı ile klasik sınıflandırma algoritmalarından destek vektör makinesi, karar ağacı, Navie Bayes yöntemleri karşılaştırılmaktadır. Karşılaştırma sonucunda doğruluk oranları yüksekten düşüğe doğru derin sinir ağı, destek vektör makinesi, Navie Bayes ve karar ağacı olduğu gösterilmiştir.

Ayaz ve diğ. (2017) tarafından yapılan çalışmada elektromiyografi sinyallerini sınıflandırmak için Yerel alıcı alanlar yöntemini ve Aşırı öğrenme makinesi yöntemi

kullanılmıştır. Aşırı öğrenme makinesi bir gizli katmandan oluşan ileri beslemeli bir sinir ağı modeli için geliştirilen bir öğrenme algoritmasıdır. Yerel Alıcı Alanlar yöntemi ise evrişimsel sinir ağı modeline benzer bir yapıdadır. Veri setinde altı harekete ait etiketlenmiş sinyaller mevcuttur. Zaman ve frekans alanlarında EMG sinyalinin öznitelikleri çıkartılmış ve önerilen ağ yapısı eğitilmiştir. Önerilen yapı aynı veri seti ile gerçekleştirilmiş başka bir çalışma ile kıyaslanmıştır. Karşılaştırılan çalışma yapay sinir ağı ile sınıflandırma gerçekleştirilmiş. Karşılaştırma sonucunda önerilen yapının sınıflandırma başarısının daha yüksek olduğu gösterilmiştir.

Xia ve diğ. (2018) tarafından gerçekleştirilen çalışmada elektromiyografi sinyalleri üzerinden kolun üç ekseninde gerçekleştirdiği hareketi tahmin etmek üzerine çalışılmıştır. EMG sinyallerini elde etmek için elektrotları omuzda bulunan kaslara yerleştirilmiştir. Veriler sekiz (üç bayan- beş erkek ve yaş Aralıkları 22-40 arasında) sağlıklı kişiden elde edilmiştir. Tahmin yöntemi olarak derin öğrenme kullanılmıştır. Evrişimsel sinir ağları ile tekrarlayan sinir ağlarının özellikleri birleştirerek bir yöntem önerilmiştir. Evrişimsel sinir ağlarının frekans alanında daha etkin olduğu ve tekrarlayan sinir ağlarının ise zaman alanında daha etkin özellikleri sunduğu belirtilmiştir. Önerilen yöntemin; evrişimsel sinir ağlarına ve geleneksel yöntemlerden destek vektör makinasına göre daha yüksek doğruluk ile tahmin ettiği ve daha dayanıklı olduğu gösterilmiştir.

Park ve Lee (2016) tarafından gerçekleştirilen çalışmada elektromiyografi sinyallerinden el hareketlerini tahmini gerçekleştirilmiştir. Veri seti olarak NinaPro veri seti kullanılmıştır. Veri setinde altı adet el hareketi mevcuttur. Tahmin yöntemi olarak evrişimsel sinir ağları mimarisi kullanılmıştır. Aynı veri seti ile destek vektör makinasında tahmin sonuçları elde edilmiştir. Kullanılan yöntem ile destek vektör makinası sonuçları kıyaslanmış ve evrişimsel sinir ağlarının doğruluk olarak daha iyi performans sergilediği gösterilmiştir.

Bu tez çalışması kapsamında yukarıda literatür özetinde belirtilen çalışmalar katkı sağlamak amacıyla bir protez kol için elde edilen biyolojik sinyallerin işlenmesinde derin öğrenme algoritması ve protez kolun hassas konum kontrolü içinde bulanık resetlemeli PI kontrolcü önerilmiştir. Önerilen algoritmalar hem simülasyon ortamında hem de uygulamalı olarak gerçekleştirilmiştir.

BÖLÜM 2. MATERYAL VE YÖNTEM

Bu tez çalışması kapsamında açısal ve çizgisel hareket gerçekleştiren eyleyiciler protez kolun hareketlerine uygulanmıştır. Kaslardan alınan EMG sinyaller derin öğrenme algoritması ile işlenerek kol hareketleri için referans sinyaller üretmiştir. Daha sonra üretilen referans sinyalleri sırası ile geleneksel PI, geleneksel bulanık kontrol, bulanık resetlemeli PI kontrol yapılarına uygulanarak protez kolun konum kontrolü gerçekleştirilmiştir. Aşağıda sırasıyla servo motorlar, bulanık kontrol, yapay sinir ağları ve derin öğrenme algoritmaları hakkında bilgi verilmiştir.

2.1. Servo Motorlar


Servo motorlar; hassas bir şekilde konum kontrolü yapılabilen değişken devirlere hızlı bir şekilde cevap verebilen, otomatik kontrol sistemlerinde çok kullanılan özel motorlardır (Akar, 2005, s.6)

Servo motorlar günümüzde pek çok alanda kullanılmaktadır. Yaygın tercih edilmesinin asıl sebebi motorun yüksek verimli olması ve kolay kontrol edilebilmesi başta olmak üzere aşağıdaki özelliklerden kaynaklanmaktadır (Doğan, 2009, s.5; Engin, 2018, s.8).

- Enkoder ile çalışmaktadır.
- Bir sürücü ile çalışmaktadır.
- Kullanım alanı çok geniştir.
- Düşük güçlü işlemciler tarafından rahatlıkla kontrol edilebilmektedir.
- Konum doğruluğu yüksektir.
- Hız doğruluğu yüksektir.
- Tork kararlılığı yüksektir.
- Yüklenebilme kapasitesi yüksektir.
- Dinamik performansı yüksektir.

Servo motorlar enkoder ve sürücü ile çalışmasının sonucunda çıkış bilgisi sürücüye verilerek kapalı çevrim bir sistem oluşturulmuş olur. Servo motorlar; alternatif akım motoru veya doğru akım motoru çeşitlerin birinden, konum sensöründen ve sürücüden oluşmaktadır (Engin, 2018, s.7).


Servo motorlar besleme gerilim cinslerine göre alternatif akım servo motorlar ve doğru akım motorlar olmak üzere ikiye ayrılır. Şekil 2.1’de servo motor türleri gösterilmektedir (Hancı, 2007, s.12).



Şekil 2.1 : Servo motor türleri.

Hareket mekanizması olarak alternatif akım elektrik motorları ile aynı özelliklere sahip olmasına rağmen AA servo motorlar farklı olarak konum belirleme sensörlerine sahiptir. Bu sensörler vasıtası ile motora açısal hassasiyetle dönme yeteneği kazandırılmış olur. Şekil 2.2’de alternatif akım servo motorunun çalışma prensibi gösterilmiştir (Hancı, 2007, s.22).

Asenkron servo motor ve senkron servo motor olmak üzere iki adet alternatif akım servo motor çeşidi vardır.



Şekil 2.2 : Alternatif akım servo motor temel çalışma prensibi.

Doğru akım servo motorlar üç kısımdan oluşmaktadır. Bunlar DA motor, geri besleme ünitesi ve sürücü modülüdür. Doğru akım motoru üzerine yerleştirilen konum sensörü ile motorun hareketi, konumu ve hız bilgisi geri besleme ünitesi üzerinden sürücüye aktarılmaktadır. Sürücü vasıtasıyla motorun konum ve hız kontrolleri gerçekleştirilebilmektedir.

Doğru akım servo motorlar temelde fırçalı DA servo motorlar ve fırçasız DA servo motorlar olmak üzere ikiye ayrılır. Tez kapsamında fırçalı DA servo motor kullanılmıştır. Kullanılan servo motorun detaylı bilgileri 2.4. Deneysel Sistem Tasarımı başlığı altında verilmiştir.


2.2. Bulanık Mantık Kontrol

Klasik kontrolcüler ile karmaşık sistemleri kontrol etmek zordur; çünkü karmaşık sistemi matematiksel olarak modellemek kolay değildir. Klasik sistemler kesin bilgiye dayalı bir yapıya sahiptir ve bu yapıda verilerinde eksiksiz olması gerekmektedir. Bulanık mantıkta ise sistemin matematiksel modeline ihtiyaç duymadan uzman görüş vasıtası ile sistem kontrol edilebilmektedir. Bu sebep ile bulanık mantık matematiksel modeli çıkartılamayan sistemlere, çok parametrelili sistemlere, doğrusal olmayan sistemlere rahatlıkla uygulanabilmektedir. Bulanık mantık üç aşamada gerçekleşmektedir. Bu aşamalar şekil 2.3’de gösterilmiştir.



Şekil 2.3 : Bulanık mantık çalışma algoritması.

Bulanık mantık çalışma algoritması sırası ile bulanıklaştırma, kurallar doğrultusunda çıkarım yapma ve durulaştırmadır. Bulanıklaştırma ve durulaştırma aşamalarında üyelik fonksiyonlarını kullanır. Şekil 2.4’de örnek bir üyelik fonksiyonu bulunmaktadır.



Şekil 2.4 : Üyelik fonksiyonu örneği.

Girdiler belirli bir aralığa ölçeklenir. Ölçeklenen girdi ifadesi bulunduğu değere göre üyelik derecesi alır. Şekil 2.4’de verilen üyelik fonksiyonu örneğine göre -0.2 girdi değeri, 0.2 üyelik derecesi ile N fonksiyonuna ve 0.8 üyelik derecesi ile Z fonksiyonuna aittir. Bu işlemler ile girdi ifadesi bulanıklaştırılır. Kuralara göre bir çıkartım yapılır. Çıktıya ait üyelik fonksiyonuna göre ve durulaştırma yöntemlerine göre bir çıktı değeri elde edilmiş olur. Tablo 2.1 de örnek bir kural tablosu verilmiştir.

Tablo 2.1 : Kural tablosu

		GİRDİ 1		
		N	Z	P
GİRDİ 2	N	N	N	Z
	Z	N	Z	P
	P	Z	P	P

Bulanık mantık kontrolde dilsel terimler kullanılmaktadır. Kullanılan yapı ‘eğer (if)..... ve/veya....., o halde (Then).....’ şeklindedir. Tablo 2.1 de verilen kural tablosuna göre örnek bir dilsel ifade: eğer GİRDİ-1 N ve GİRDİ-2 Z ise, o halde ÇIKTI N’dir. Geleneksel yöntemlerde kullanılan toplama, çıkarma, çarpma, bölme gibi matematiksel ifadeler bulanık mantıkta ve, veya, min, max operatörleri ile gerçekleştirilmektedir. Kuralları oluşturmak için uzman görüşüne ihtiyaç duyulmaktadır.

Tez kapsamında bulanık yapı kullanılarak resetleme oranı üretilmiştir. Geleneksel PI kontrolcü yapısına resetleme oranı uyarlanarak bulanık resetlemeli PI kontrolcü önerilmiştir. Resetleme oranının belirlenmesine yönelik bulanık yapı bölüm 3’te verilmiştir.


2.3. Yapay Sinir Ağları

Yapay zekâ el yazısını bilgisayar ortamına aktarma, davranış tanımlama, görüntü üzerinden cinsiyet tahmini, görüntü üzerinden yaprak türü ve bitki türü tanıma, insansız araçların kontrolü, kanser tespit etme, EMG verileri üzerinden hareket tahmini, biyonik el ve biyonik kol kontrolünü gerçekleştirmek gibi pek çok farklı alanda kullanılan bir yöntemdir. İnsan beynine benzer bir şekilde çalışabilmesi için programlanmaktadır. Öğrenme yeteneği, uyarlanabilme yeteneği, genelleme yeteneği, hesaplama gibi insan beyninin kullandığı özellikleri kullanır (Ayturan, 2019, s.15).

Yapay sinir ağları, insan beyninin özelliklerinden olan öğrenme yolu ile yeni bilgiler türetebilme, yeni bilgiler oluşturabilme ve keşfedebilme gibi yetenekleri herhangi bir

yardım almadan otomatik olarak gerçekleştirmek amacı ile geliştirilen bilgisayar sistemleridir (Öztemel, 2016, s.29).

Basit bir Yapay sinir ağının dört temel elemanı vardır. Bunlar Girdi, Ağırlıklar, Aktivasyon Fonksiyonu ve çıktıdır. Bu temel elamanlar şekil 2.5’de gösterilmiştir.



Şekil 2.5 : Yapay sinir ağı temel yapısı.

Yapay sinir ağlarında kullanılan bazı aktivasyon fonksiyonlar tablo 2.2’de verilmiştir (Aki,2019).

Tablo 2.2 : Aktivasyon fonksiyonları ve matematiksel ifadeleri.

Aktivasyon Fonksiyonu	Matematiksel İfade
Doğrusal Fonksiyon	$f(x) = x$
Basamak Fonksiyonu	$f(x) = \begin{cases} 0 & \text{if } x < 0 \\ 1 & \text{if } x \geq 0 \end{cases}$
Sigmoid Fonksiyonu	$f(x) = \sigma(x) = \frac{1}{e^{-x} + 1}$
Hiperbolik Tanjant Fonksiyonu	$f(x) = \tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$
ReLU	$f(x) = \begin{cases} 0 & \text{if } x < 0 \\ x & \text{if } x \geq 0 \end{cases}$
Leaky (sızıntı) ReLU	$f(x) = \begin{cases} 0.01x & \text{if } x < 0 \\ x & \text{if } x \geq 0 \end{cases}$
Swish Fonksiyonu	$f(x) = 2x\sigma(\beta x)$

Yapay sinir ağlarında girdi kısmına verilen veriler ile her girdiye ait olan ağırlık dediğimiz bir katsayı ile çarpılmaktadırlar. Toplama kısmındaki hücreye gelen bütün ağırlıkları ile

arpılmış veriler toplanır. Toplama hücresinde elde edilen bilgi yine toplama hücreğine ait olan katsayı ile arpılarak bir aktivasyon fonksiyonundan geilir. Aktivasyon fonksiyonundan bilgi getikten sonra girdi kısmına vermiş olduğumuz verilere ait olan ıktıyı elde edilmiş olur. ok katmanlı yapay sinir ağı modeline sahip yapay zeka alt dallarından birisi de makine öğrenmesidir.

2.3.1. Makine öğrenmesi

Makine öğrenmesi, bir veri içindeki girdiler ile ıktılar arasında ki ilişkiyi otomatik olarak tespit etme ve bu ilişkiyi kullanarak başka verileri tahmin etmek amaçlı veya karar vermek amaçlı kullanılan yöntemler olarak tanımlanır (Ayturan, 2019, s.16). Makine öğrenmesi, insan beyninin öğrenme işini bilgisayar tarafından yapılmasıdır. Makine öğrenmesi genel olarak tahmin etmek, sınıflandırmak ve kümelemek için gereken karmaşık algoritmaları tasarlamak için kullanılmaktadır (Patel, 2018). Makine öğrenmesinde üç katman vardır. Bunlar girdi katmanı, ara(gizli) katman ve ıktı katmanıdır.

Girdi katmanı; eğitilecek, tahmin edilecek veya karar verilecek olan verinin algoritmaya verildiği katmandır.

Ara katman; girdi katmanındaki veriler ağırlıklar ile arpılarak ara katmanda işlem görür. Ara katman modele bağılı olarak birden fazla olabilir. Ara katmandaki hücre sayısı veri setinden farklı olabilir. Birden fazla ara katman varsa bunlarda hücre sayıları birbirlerinden bağımsızdır.

ıkış katmanı; ara katmandan gelen bilginin ıktısını verir.

Makine öğrenmesi temelde iki adet öğrenme stratejisi bulunmaktadır. Bunlar denetimli öğrenme stratejisi ve denetimsiz öğrenme stratejisidir.

2.3.2. Derin öğrenme


Derin öğrenme, makine öğrenmesinin alt sınıfıdır. Derin öğrenme çok katmanlı yapay sinir ağı algoritmasına dayanmaktadır. Derin öğrenmede birden fazla ara katman bulunmaktadır. Derin öğrenme ismini gizli katman sayısının derinleşmesinden almaktadır (Eral, 2016, s.15). Bu katmanlar özellik ıkarma, dönüştürme vb. amaçlar için kullanılır. Birbiri ardınca gelen katmanlarda önceki katmanın ıktısı sonra gelen katmanın girdisi

olmaktadır (Şeker ve diğ. 2017). Derin öğrenme, makine öğrenmesinde elle çıkartılan verinin özelliklerini kendi algoritmaları ile çıkartmaktadır.

Yapay zekâ insan beyninden esinlendiğinden dolayı katman sayısı ve girdi sayısı artırılmak istenmektedir. Katman sayılarının artırılması ve düğüm sayılarının artırılması büyük hesaplama gücü gerektirir.

Derin öğrenmenin kullanımın yaygınlaşmasını teknolojik gelişmeler desteklemektedir. Teknolojik gelişmeler ile işlemci yetenekleri artırılmıştır. İşlemci yeteneklerinin artırılması ve GPU hesaplama işlemlerinde kullanılması ile kullanılan katman sayısı ve düğüm noktası sayısında artışa olanak sağlamıştır. Çok daha büyük veri setleri bu gelişmeler ile artık yapay zekada kullanılabilir olmuştur. Katman sayısının artırılması, düğüm noktası sayısının artırılması ve en önemlisi veri setinin büyümesi performansta çok büyük bir ilerleme kat etmiştir.

Şekil 2.6’de derin öğrenmenin, Makine öğrenmesinin ve yapay zekanın birbirileri arasındaki ilişki ve konuların kapsayıcılığı gösterilmiştir (Türkçetin, 2019, s.2).




Şekil 2.6 : Derin öğrenmenin, makine öğrenmesinin ve yapay zekanın ilişkisi.

Literatürde derin öğrenme için farklı mimari yapılar gözlenmektedir. Bunlardan en sık olarak kullanılanları otomatik kodlayıcılar, kısıtlı boltzmann makineleri, derin boltzmann makineleri, tekrarlayan sinir ağları ve evrimsel sinir ağlarıdır.

- **Otomatik kodlayıcılar**

Geleneksel makine öğrenmelerinde ham veri yerine veriden elde edilmiş öznitelikler sayesinde daha yüksek performanslar elde edilmiştir. Otomatik kodlayıcılar ise veriden


öznitelik çıkartmak amaçlı tasarlanmıştır (Türk, 2019). Otomatik kodlayıcılar aynı sayıda giriş ve çıkış hücrelerine sahiptir. Otomatik kodlayıcılar giriş verisine bir etiket atamak yerine giriş verisini tekrar oluşturmaktadır. Bu sebepten dolayı otomatik kodlayıcılar denetimsiz öğrenme yöntemine sahiptir. Genellikle ayırt edici özellikleri çıkartmak için gizli katmandaki hücre sayısı girdi katmanındaki hücre sayıdan daha azdır (Ravi ve diğ. 2017). Eğer girdi verisi çok büyük boyutlarda ise derin otomatik kodlayıcı oluşturmak için birbiri ardına bağlanır. Şekil 2.7’de otomatik kodlayıcı mimarisinin örneği verilmiştir (Ravi ve diğ. 2017).



Şekil 2.7 : Otomatik kodlayıcı mimarisi.

- **Kısıtlı boltzmann makineleri**

Kısıtlı boltzmann makineleri rastlantısal yapay sinir ağı olan boltzmann makinelerinin ilk çeşididir. Kısıtlı boltzmann makineleri özel dağılım yöntemleri ile rastlantısal birimler kullanılarak modellenmiştir. Öğrenme stratejisi, hatayı minimuma indirmek için ağırlıkları kademeli olarak değiştiren Gibbs öğrenmesini kullanır. Şekil 2.8’de kısıtlı boltzmann makine mimarisine bir örnek verilmiştir (Ravi ve diğ. 2017).




Şekil 2.8 : Kısıtlı boltzmann makine mimarisi.

Şekil 2.8’den görüldüğü üzere kısıtlı boltzmann makinesinde iki katman mevcuttur. Bunlardan birinci görünür katman, ikincisi ise gizli katman olarak isimlendirilmektedir. Kısıtlı boltzmann makinelerinin bir özelliği de hücreler arasında veri iletimi tek yönlü değil şekil 2.8’de gösterildiği gibi iki yönde iletim sağlamaktadır.

Kısıtlı boltzmann makinelerini öğrenme modülleri olarak kullanan literatürde Derin İnanç Ağları ve Derin Boltzmann Makineleri önerilmiştir (Ravi ve diğ. 2017).


- **Tekrarlayan sinir ağları**

Tekrarlayan sinir ağı, veri akışının analizini gerçekleştirebilen gizli katmanları içeren bir yapay sinir ağıdır. Tekrarlayan sinir ağlarında gizli katmandaki çıktılarından giriş birimlerine veya önceki gizli katmanlardaki giriş birimlerine geri beslemenin yapıldığı bir ağ yapısıdır (Aydın, 2019). Bir önceki hesaplanmış sonuç bir sonraki sonuç üzerinde etkilidir. Bu sebepten dolayı tekrarlayan sinir ağlarında yeni verinin çıkışı için hem geçmiş hem de yeni verinin girdisi kullanılır. Bundan dolayı genellikle tekrarlayan sinir ağlarının hafızaya sahip olduğu söylenmektedir (Ravi ve diğ. 2017). İnsan bir olay karşısında geçmişte yaşadığı başka olaylardan sonuçlar çıkartarak karar verir. İnsan yeni bir bilgiyi eski bilgiler ile harmanlayarak işler. İnsanın bu yaklaşımı ve öğrenme yöntemi tekrarlayan sinir ağlarının tasarlanmasına yön vermiştir. Şekil 2.9’da basit bir tekrarlayan sinir ağ yapısı gösterilmiştir. Burada x ile gösterilen girdi verisi h ile gösterilen çıktı verisi ve A ile gösterilen ise tekrarlayan sinir ağının iç yapısını temsil etmektedir.




Şekil 2.9 : Temel tekrarlayan sinir ağ yapısı.

Şekil 2.9’de A ile temsil edilen tekrarlayan sinir ağının iç yapısı açıldığı zaman şekil 2.10’de gösterilen yapıya sahiptir. Bu yapıda girdi verisinin zamana bağlı durumları girdi olarak verilmektedir.



Şekil 2.11’da bazı tekrarlamalı sinir ağ mimarileri gözükmektedir. Bunlar sırası ile kullanım yerlerine örnek verirsek; tek giriş tek çıkış genellikle çok katmanlı sinir ağı olarak kullanılmaktadır, tek giriş çok çıkış ise resim girdi verilip resmi metin olarak almak için kullanılabilir, çok girdi tek çıktı ise sınıflandırmak için kullanılabilir, çok girdi çok çıktı ise metin çevirilerde kullanılabilir (Güdelek, 2019).



- **Uzun-kısa süreli bellek ağları**

Uzun-kısa süreli bellek ağları, tekrarlayan sinir ağların bir çeşididir. Uzun-kısa süreli bellek ağları 1990’larda Schmidhuber ve Hochreiter tarafından veri setindeki uzun süreli ilişkileri öğrenmek amacı ile önerilmiştir. Uzun-kısa süreli bellek ağları uzun vadeli bağımlılık problemlerine çözüm olabilmesi için tasarlanmıştır (Aydın, 2019).

Uzun-kısa süreli bellek ağları gelen verileri unutmak veya tutmak için kapıları kullanır. Kapılar 0 ile 1 arasında çıkış vermektedir. Eğer çıkış 1'e yakınsa veri saklanır. Eğer çıkış 0'a yakınsa verinin girişten geçmesine izin vermez yani veriyi unuttur (Çakır, 2019).

Tekrarlayan sinir ağ mimarisinde çıkış verisini hesaplayabilmek için önceki zamanlara ait çıkışlar hesaplanmalıdır. Bu sebepten dolayı tekrarlayan sinir ağların eğitim süreçleri

paralleştirilmeye olanak sağlamıyor. Uzun-kısa süreli bellek ağlarının mimarisi, ileri beslemeli sinir ağ yapısından daha karmaşıktır. Bundan dolayı tekrarlayan sinir ağlarından daha fazla hesaplama gücü ve zaman gerektirir (Çakır,2019).

- **Evrişimsel sinir ağları**

1988 yılında Yann LeCun tarafın önerilen evrişimsel sinir ağları çok katmanlı yapay sinir ağlarının bir türüdür (Tümen ve diğ. 2017). Evrişimsel sinir ağları çoğunlukla görüntü sınıflandırmakta, nesne tanımakta kullanılmaktadır. Evrişimsel sinir ağları insan, hayvan, bitki, nesne vb. tanıma işlemleri, hastalık tespit etme gibi pek çok alanda kullanılmaktadır. Ses gibi zaman seri olarak alınan sinyaller görsel olarak verildiği zaman; dil işleme, biyomedikal gibi alanlarda evrişimsel sinir ağları kullanılabilmektedir.

Evrişimsel sinir ağları temelde dört katmandan oluşmaktadır. Bu katmanlar evrişim katmanı, havuzlama, aktivasyon ve tam bağlı katman olarak adlandırılmaktadır (Doğan, 2019).

- **Evrişim katmanı**

Evrişim katmanının temel amacı girdi olarak verilen görüntüden öznitelik çıkartmaktır. Uygulanan filtre matrisi görüntü matrisi üzerinde soldan sağa olacak şekilde belirlenen adım sayısı ile kaydırılarak üst üste çakışan elemanların çarpılarak toplanması sonucu yeni bir matris elde edilir. Bu işlem ile hem görüntüye ait ayırt edici öznitelikler çıkartılır hem de mevcut parametre sayısı ve hesaplama işlemi azaltılmış olur. Şekil 2.12’de örnek bir evrişim işlemi gösterilmiştir.

GİRDİ								FİLTRE			ÇIKTI				
1	2	0	2	0	2	1		1	0	1	-1	0	-12	-4	-7
2	3	4	2	3	2	2		0	1	0	2	-3	0	2	0
0	2	5	6	9	5	1		-1	0	-1	3	0	12	5	7
1	4	5	9	8	2	2					7	14	14	11	10
0	5	6	8	5	6	0					6	13	13	16	5
1	2	3	3	4	2	2									
2	1	0	2	1	0	1									

1	2	0	2	0	2	1		1	0	1	-1	0	-12	-4	-7
2	3	4	2	3	2	2		0	1	0	2	-3	0	2	0
0	2	5	6	9	5	1		-1	0	-1	3	0	12	5	7
1	4	5	9	8	2	2					7	14	14	11	10
0	5	6	8	5	6	0					6	13	13	16	5
1	2	3	3	4	2	2									
2	1	0	2	1	0	1									

Şekil 2.12 : Evrişim işlemi örneği.

○ Havuzlama katmanı

Evrişim katmanından sonra çoğunlukla havuzlama katmanı gelir. Havuzlama katmanının kullanım amacı ağ içerisinde bulunan hesaplama miktarını ve parametre büyüklüğünü azaltmaktır. Bu katmanda da bazı filtreleme fonksiyonları uygulanmaktadır. Maksimum havuzlama, ortalama havuzlama gibi fonksiyonlar kullanılmaktadır.

Maksimum havuzlama fonksiyonu 2x2 matris olarak kullanılacaksa, evrişim katmanından çıktı olarak alınan matrisin sol üst köşesinden başlayacak kaydırma işlemi sonucu filtre matris kesişmeyecek şekilde kaydırılır ve her 2x2 matris içerisinde en yüksek değerli eleman filtre sonu olarak havuzlama katmanının çıktısı olan matrise yazdırılır. Şekil 2.13’de maksimum havuzlamaya örnek verilmiştir.

GİRDİ						ÇIKTI		
1	2	0	2	0	2	3	4	3
2	3	4	2	3	2	4	9	9
0	2	5	6	9	5	5	8	6
1	4	5	9	8	2			
0	5	6	8	5	6			
1	2	3	3	4	2			

Şekil 2.13 : Maksimum havuzlama örneği.

Ortalama havuzlama fonksiyonunun kullanımında ise kaydırma işlemi aynı şekilde gerçekleştirilir ve her 2x2 matriste bulunan elemanlarının ortalaması havuzlama katmanının çıktısı olan matrise yazdırılır. Şekil 2.14’de ortalama havuzlamaya örnek verilmiştir.

GİRİDİ					
1	2	0	2	0	2
2	3	4	2	8	2
0	2	5	6	9	5
6	4	5	8	8	2
0	5	6	8	4	6
1	2	3	3	4	2

ÇIKTI		
2	2	3
3	6	6
2	5	4

Şekil 2.14 : Ortalama havuzlama örneği.

○ Aktivasyon katmanı

Aktivasyon katmanında havuzlama katmanından çıktı olarak elde edilen matris bir aktivasyon fonksiyonundan geçirilerek yapay sinir ağlarından eğitime hazır veriler haline getirilir. Bu katmanda çoğunlukla ReLU (rectified linear unit – doğrultulmuş doğrusal birim) aktivasyon fonksiyonu düşük hata oranı ile hızlı bir şekilde ağı eğitilmesini sağladığı için kullanılmaktadır (Doğan, 2019).

○ Tam bağlı katman

Tam bağlı katman kendinden önce gelen katmana tam olarak bağlıdır. Yapısal olarak geleneksel yapay sinir ağı yapısından oluşmaktadır. Bu katmana girdi verisi önceki katmanlardaki matrislerin tek boyuta indirgenmesi ile verilir. Tam bağlı katman evrişim işlemi sonucunda görüntüden ortaya çıkan öz nitelikler arasındaki ilişkiyi öğrenir. Tam bağlı katmanda girdi verisini sınıflandırabilmek için veriler bir aktivasyon fonksiyonundan geçilerek sınıf çıktısı verir.

Tez kapsamında kullanılan derin öğrenmenin girdi katmanı, gizli katman, çıkış katmanı ve kullanılan ağ çeşidine ait bilgiler bölüm 3’te verilmiştir.

2.4. Deneysel Sistem Tasarımı

Tez kapsamındaki çalışmalarda kullanılan protez kol ve el yapısı, insansı kontrole uygun bir sistem olarak tasarlanmıştır. Bu sistemde kolun fleksiyon ve ekstansiyon hareketi için

bir servo motor ve elin açılıp kapanma hareketi için bir doğrusal eyleyici kullanılarak gerçekleştirilmiştir. Bu hareketlerin yapılabilmesi için bir karar verme mekanizması gerekmektedir. Karar verme mekanizması olarak derin öğrenme algoritması tercih edilmiştir. Derin öğrenme algoritması ile insan vücudunda bulunan kaslardan alınan EMG verilerinden hangi hareketin gerçekleştirilmesi gerektiğine karar vermekte ve bu karara göre motor ve eyleyici için bir konum bilgisi üretmektedir. Bu işlemler doğrultusunda insan vücudundan alınan bilgiler ile protez kolun kontrolü gerçekleştirilmektedir.


- Kullanılan servo motor

Sistemde kullanılan servo motor Maxon Group firmasına ait fırçalı doğru akım motorudur. Motor 20W gücündedir. Motor; çalışma gerilimi 12V, yüksüz çektiği akım 68.1mA, maksimum çektiği akım 2.45A, sargı direnci 0.517 ohm, endüktans değeri 0.057mH, tork sabiti 0,0115, nominal torku 27.5mNm, rotor ataleti 14.5 gcm² parametrelerine sahiptir. Şekil 2.15’de kullanılan servo motor gösterilmektedir.




Şekil 2.15 : Kullanılan servo motor.

Motorun konum bilgisi ve hız bilgisini elde edebilmek için rotor mili üzerine enkoder yerleştirilmiştir. Enkoder milin bir tur dönmesi ile 1000 sayım gerçekleştirmektedir. Enkoder hat sürücüsüne sahip bir enkoderdir. Hat sürücüsü, enkoderin üretmiş olduğu A, B ve Z sinyallerini tersleyerek altı adet çıkış vermektedir. Konum bilgisini okumadan önce bir hat alıcısının yardımı ile sinyaller, terslenmiş sinyaller ile karşılaştırılarak gürültülerden elimine edilmiş olur. Kullanılan motorlarda enkoder modülünde hat sürücüsü mevcuttur. Hat sürücüsünden gelen bilgiyi okuyup kullanabilmek için hat alıcısının kullanıldığı devre Şekil 2.16’da gösterilmiştir.



(a)




(b)


Şekil 2.16 : Hat alıcı devresi (a) devre şeması, (b) üst görünüm.

Motorun torkunu yükseltmek için motor şaftı redüktör sistemi ile birleştirilmiştir. Redüktör sistemi gezegen dişlilerden oluşan 1/53 oranında dönüşüme sahip bir sistemdir. Bu redüktör sisteminin vasıtası ile nominal tork 1,45 Nm değerine yükselmiştir.

Motorların kontrolü için şekil 2.17’de gösterilen motor sürücü devresi hazırlanmıştır. Bu devre, bilgisayar tarafından üretilen kontrol sinyallerini kuvvetlendirerek motora uygulamaktadır. Kullanılan bu devre üzerinden motorun çektiği akım değeri ve gerilim değeri okunabilmektedir.



(a)



(b)

Şekil 2.17 : Motor sürücü devresi (a) devre şeması, (b) üst görünüm.

- Doğrusal eyleyici

Elin açılıp kapanması için doğrusal eyleyici kullanılmaktadır. Kullanılan doğrusal eyleyici Firgelli Marka L16 serisine ait bir üründür. Tablo 2.3’de doğrusal eyleyicinin

özellikleri bulunmaktadır. Şekil 2.18’de sistemde kullanılan doğrusal eyleyici gösterilmektedir.




Şekil 2.18 : Kullanılan doğrusal eyleyici

Tablo 2.3 : Doğrusal eyleyici özellikleri.

Firma	Firgelli
Model	L16
Kurs boyu	100
Dişli oranı	35:1
Maksimum hız	32 mm/s
Maksimum yükteki hız	16 mm/s
İtme kuvveti	50 N
Çekme kuvveti	31 N
Ağırlık	56 g
Çalışma gerilimi	0-12 VDA
Çalışma akımı	650 mA
Geri besleme	Potansiyometre

Şekil 2.19’da DA motorun eş değer devresi gösterilmektedir.



Şekil 2.19 : Doğru akım motorunun eşdeğer devresi.

DA motorun durum uzay modeli denklem 2.1 de verilmiştir.

$$\frac{d}{dt} \begin{bmatrix} i \\ w \end{bmatrix} = \begin{bmatrix} -\frac{R_a}{L_a} & -\frac{E_a}{L_a} \\ \frac{K_t}{J} & -\frac{b}{J} \end{bmatrix} \begin{bmatrix} i \\ w \end{bmatrix} + \begin{bmatrix} \frac{1}{L_a} \\ 0 \end{bmatrix} V_a + \begin{bmatrix} 0 \\ -\frac{1}{J} \end{bmatrix} T_y \quad (2.1)$$

V_a = Motora uygulanan gerilim

R_a = Motor sargılarının direnci

L_a = Motor sargıların endüktansı

E_a = Zıt Elektromotor kuvveti

K_e = Gerilim sabiti

T = Üretilen moment

J = Atalet momenti

b = Sönümlleme sabiti

T_y = Yük momenti

K_t = Moment sabiti

w = Motorun hızı

- Kullanılan veri toplama kartı

Gerçekleştirilen sistemde bilgisayar ile motorlar arasında veri iletişimi için kullanılan veri toplama kartı ile analog giriş-çıkış, enkoder girişi ve dijital giriş-çıkış sağlanmaktadır.

- PID parametrelerinin ayarlanması

PID kontrolcünün katsayılarını ayarlamak için Ziegler-Nichols yöntemi kullanılmıştır. Ziegler-Nichols yöntemiyle katsayıların ayarlanması için iki yöntem bulunmaktadır. Bu yöntemlerden birincisi sistemin açık çevrim cevabına bakılarak kontrolcü katsayıları hesaplanmaktadır. İkinci yöntemde ise kontrolcü katsayıları sistemin kapalı çevrimine bakılarak hesaplanmaktadır. Sistem bloğundan önce bulunan kontrolcü bloğundaki PID kontrolcünün integral ve türev kontrolcülleri kapatılarak sadece oransal kontrolcü ile ayar yapılır. Oransal kontrolcünün katsayısı K_p minimum değerden başlattırılarak sistem cevabı sürekli salınım yapana kadar artırılır. Sürekli salınım yaptığı değer kritik değerdir. Kritik


değerde elde edilen katsayı (K_k) ve sistem cevabındaki salınımın periyodu (T_k) ile aşağıda bulunan tablo 2.4 vasıtası ile PID katsayıları elde edilir.

Tablo 2.4 : Ziegler-Nichols kapalı çevrim katsayı hesaplama tablosu.

	K_p	K_i	K_d
P	$K_k/2$	-	-
PI	$K_k/2.2$	$1.2 K_p / T_k$	-
PID	$K_k/1.7$	$2 K_p / T_k$	$K_p T_k / 8$


- Derin öğrenmede kullanılan EMG veri seti

Motorların ulaşması gereken konum bilgileri EMG verisi vasıtası ile elde edilmiştir. Çalışmanın gerçekleştirilmesi için kullanılan EMG veri seti Google Datasearch üzerinden Kaggle'den elde edilmiştir (Url-1). Kullanılan EMG veri seti 8 adet yüzey EMG sensörü ile kayıt edilmiştir. Veriler 200 Hz de 4 sınıfa ait olacak şekilde 8 ardışık okuma ile kayıt edilmiştir. 8 sensör ve 8 ardışık kayıttan dolayı her bir sınıfı 64 veri temsil etmektedir. Her bir hareket 6 kez 20 saniye boyunca kayıt edilmiştir. Bu sebepten dolayı bir hareket sınıfa ait yaklaşık 3000 örnek bulunmaktadır. Bu veri seti derin öğrenme algoritmasında kullanılmıştır. Bir örneğe ait EMG sinyali şekil 2.20 de verilmiştir.



Şekil 2.20 : EMG sinyal örneği

Şekil 2.21’de deneysel sistem tasarımı verilmiştir.




Şekil 2.21 : Deneysel sistem

BÖLÜM 3. ÖNERİLEN ALGORİTMALAR VE SONUÇLAR

3.1. Derin Öğrenme

EMG verisini sınıflandırabilmek için derin öğrenme algoritması kullanılmıştır. Derin öğrenme mimarisi olarak Uzun-Kısa Süreli Bellek ağ yapısı tercih edilmiştir. Giriş katmanı 64 hücreden oluşmaktadır. Gizli katman sayısı 250 ve çıkış ise 4 hücreden oluşmaktadır. Veri setinde 11678 adet örnek bulunmaktadır. Bu örneklerden 10000'ini eğitim için 1678 tanesi ise ağa hiç gösterilmemiş olup test için kullanılmıştır. Ağın tahmin başarımı %95 civarlarındadır. Derin öğrenmeyi eğitmek için kullanılan verilerin hangi harekete ait olduğu ağa verilmektedir. Hareketler daha önce rakamlar (1,2,3,4) ile tanımlanmıştır. Derin öğrenme algoritması, girdi olarak verilen ham EMG verisine karşılık bu verinin hangi harekete ait olduğunu gösteren çıktıyı vermektedir. Şekil 3.1'de sistemin genel çalışma prensibi gösteren blok diyagramı verilmiştir.



Şekil 3.1 : Sistemin genel çalış blok diyagramı.


3.2. Bulanık Resetlemeli PI Kontrolcü

Servo motorların konum kontrolüne denetimci tasarlanmıştır. Geleneksel PI kontrolcünün cevabını iyileştirmek için bulanık resetleme yapısı PI kontrolcüye uyarlanmıştır. Tasarlanan kontrolcünün yapısı şekil 3.2'de gösterilmektedir.

Lee (1993) bulanık PI kontrolcünün integral hafızasını kısmi olarak resetlemek için bulanık resetleme oranı ile kontrolcü yapısı önerilmektedir. Bulanık PI kontrolcü ile karşılaştırıldığında aşım değerini ve yükselme zamanını düşürdüğü gösterilmiştir.

Literatürde benzer çalışmalar bulunmaktadır. Banos ve Vidal (2012) yaptıkları çalışmada PI+CI (clegg integrator) referans olarak birinci dereceden ölü zamanlı sistemler için bir

resetleme yapısı önerilmiştir. Sistem cevabında geçici durumun iyileştiği, aşım yüzdesinin düştüğü ve yerleşme süresinin azaldığı gözlemlenmiştir. Banos ve Vidal (2007) gerçekleştirilen çalışmada PI+CI kontrolcü yapısı ikinci dereceden ölü zamanlı sistemler için geliştirilmiştir. PI kontrolcünün integral terimi kısmı olarak resetlenmektedir. Sistemin geçici durum cevabının iyileştiği gözlemlenmiştir.




Şekil 3.2 : Bulanık resetlemeli PI kontrolcü yapısı.

Şekil 3.2’de görüldüğü gibi geleneksel PI kontrolcü yapısı modifiye edilmiştir. Denklem 3.1’de PI kontrolcünün ürettiği sinyal (u_p) ve denklem 3.2’de bulanık resetlemeli PI kontrolcünün ürettiği kontrol sinyali (u) ait matematiksel ifadeler verilmiştir.


$$u_p = k_p * e(t) + k_i \int e(t)dt \quad (3.1)$$

$$u(k) = ((1 - r) * u(k - 1)) + u_p \quad (3.2)$$

Denklem 3.2 de verilen (r) bulanık resetleme oranı, PI kontrolcünün ürettiği sinyal (u_p) ve u kontrol sinyalidir. Üretilen kontrol sinyali ile motor kontrol edilmektedir. Bulanık Resetleme oranı, hata ve hatanın değişimine bağlı olarak üretilen bir değerdir. Hata ve hatanın değişimine ait üyelik fonksiyonları şekil 3.3 de ve bulanık resetleme oranına ait üyelik fonksiyonu ise şekil 3.4’de verilmiştir.



Şekil 3.3 : Hata (e) ve hatanın değişim oranının (de) üyelik fonksiyonları.



Şekil 3.4 : Bulanık resetleme oranı üyelik fonksiyonu.

Tablo 3.1’de Bulanık resetleme oranının üretilmesi için önerilen kural tablosu verilmektedir.

Tablo 3.1 : Bulanık resetleme oranı için kural tablosu

		e		
		N	Z	P
de	N	MR	BR	MR
	Z	SR	SR	SR
	P	MR	BR	MR


Bulanık resetlemeli PI yapısının başarısını göstermek amacıyla protez kolun denetimini gerçekleştiren servo (daireysel ve doğrusal) eyleyicilere sırasıyla geleneksel PI, geleneksel bulanık kontrol ve önerilen bulanık resetlemeli PI yapısı hem simülasyon hem de deneysel ortamda uygulanmış ve ilgili sonuçlar kıyaslanmıştır. Bulanık kontrol için

literatürde yaygın olarak kullanılan 49 (7x7) kuraldan oluşan yapı kullanıldığından burada ayrıca detayları verilmemiştir (Gomes ve Rocco, 2012).


3.3. Simülasyon Sonuçları

3.3.1. Protez kolun fleksiyon ve ekstansiyon hareketini gerçekleştiren servo motor için konum kontrolü sonuçları


Motorun matematiksel modeline göre hazırlanmış simülasyon ortamında farklı kontrolcüler ve farklı referans değerleri için sonuçlar çıkartılmıştır. Şekil 3.5’de derin öğrenme algoritması ile elde edilmiş kare dalga giriş işareti için motor konum kontrol cevapları verilmiştir. Şekil 3.5(a)’da geleneksel bulanık kontrol cevabı, şekil3.5(b)’de geleneksel PI kontrolcünün cevabı ve şekil 3.5(c)’de Bulanık resetlemeli PI kontrolcünün cevapları gösterilmiştir.



(a)




(b)




(c)

Şekil 3.5 : Referans giriş olarak kare dalga uygulandığında sistemin cevabı (a) geleneksel bulanık mantık kontrol cevabı (b) geleneksel PI kontrolcü cevabı (c) bulanık resetlemeli PI kontrolcü cevabı.


Şekil 3.6’da referans giriş olarak derin öğrenme algoritması ile elde edilmiş kare dalga uygulandığı zaman (a) geleneksel bulanık kontrolcü, (b) geleneksel PI kontrolcü ve (c) bulanık resetlemeli PI kontrolcünün ürettiği kontrol sinyalleri verilmiştir.



(a)




(b)




(c)

Şekil 3.6 : Referans giriş olarak kare dalga uygulandığı zaman (a) geleneksel bulanık kontrolcü, (b) geleneksel PI kontrolcü ve (c) bulanık resetlemeli kontrolcünün ürettiği kontrol sinyali.


Derin öğrenme algoritmasından elde edilmemiş fakat protez yapının yumuşak hareketlerini test edebilmek için konum referansı olarak sinüzoidal giriş işareti sisteme uygulanarak kontrolcülerin cevapları şekil 3.7’de verilmiştir. Şekil 3.7(a)’da geleneksel bulanık mantık kontrolcünün, şekil 3.7(b)’de geleneksel PI kontrolcünün ve şekil 3.7(c)’de geleneksel PI kontrolcüde kullanılan parametrelere ile tasarlanan bulanık resetlemeli PI kontrolcü ile gerçekleştirilen konum kontrolüne ait grafik gösterilmiştir.



(a)




(b)



(c)


Şekil 3.7 : Referans giriş olarak sinüzoidal dalga uygulandığında sistem cevabı (a) geleneksel bulanık mantık kontrolcü cevabı, (b) geleneksel PI kontrolcü cevabı(b) bulanık resetlemeli PI kontrolcü cevabı.

Şekil 3.8’de referans giriş olarak sinüzoidal dalga uygulandığı zaman (a) geleneksel bulanık kontrolcü, (b) geleneksel PI kontrolcü ve (c) bulanık resetlemeli PI kontrolcünün motora uygulamış olduğu kontrol sinyali verilmiştir.




Şekil 3.8 : Referans olarak sinüzoidal sinyal uygulandığı zaman (a) geleneksel bulanık kontrolcü, (b) geleneksel PI kontrolcü ve (c) bulanık resetlemeli PI kontrolcünün motora uygulamış olduğu kontrol sinyali.


Gerçekleştirilen farklı kademelerdeki hareketlere ait derin öğrenme ile üretilmiş referans sinyalinin sisteme uygulanması ve sonuçları şekil 3.9’da verilmiştir. Şekil 3.9 (a) geleneksel bulanık kontrol, şekil 3.9(b) geleneksel PI kontrol ve şekil 3.9(c) bulanık resetlemeli PI kontrol cevapları verilmiştir. Şekil 3.9(d) geleneksel bulanık kontrolcü, şekil 3.9 (e) geleneksel PI kontrolcü ve şekil 3.9 (f) bulanık resetlemeli PI kontrolcünün motora uygulamış olduğu kontrol sinyalleri verilmiştir.




(a)




(b)




(c)



(d)



(e)



(f)

Şekil 3.9 : Derin öğrenmenin ürettiği referans sinyali sisteme uygulandığı zaman (a) geleneksel bulanık kontrol cevabı, (b) geleneksel PI kontrol cevabı, (c) bulanık resetlemeli PI kontrol cevabı; (d) geleneksel bulanık kontrolcünün, (e) geleneksel PI kontrolcünün ve (f) bulanık resetlemeli PI kontrolcünün motora uyguladığı kontrol sinyali.


Derin öğrenme algoritmasının üretmiş olduğu kare dalga sinyal referans olarak verildiği zaman geleneksel PI kontrolcü ile motor %3,7'lik bir aşım gerçekleştirmektedir. Referans değerinin değişiminden sonra motorun oturması gereken değer ile ilk kesişme süresi 0,21 sn ve %1'lik tolerans bandının içine ilk girdiği süre ise 0,38 sn'dir. Bulanık kontrolde %1'lik tolerans bandının içine yerleşme 0,41 sn'dir. Bulanık kontrol aşım değeri yaklaşık olarak %1.1'dir. Bulanık resetlemeli PI kontrolcü ile motor %1'lik bir aşım gerçekleştirmektedir. Referans değerinin değişiminden sonra motorun referans değeri ile ilk kesişme süresi 0.19 sn'dir. Maksimum aşım %1 gerçekleştirdiği için tepe zamanı aynı zamanda %1'lik tolerans bandının içine yerleşme süresidir ve 0,2 sn'dir.

Motorun takip etmesi için sinüs dalga şeklinde bir referans giriş işareti verildiği zaman PI kontrolcü ile motor referans değerini ortalama 0,07 saniye geriden ve ortalama %10 hata ile takip etmektedir. Bulanık kontrol yaklaşık olarak PI kontrole benzer bir şekilde cevap üretmektedir. Bulanık resetlemeli PI kontrolcü ile motor referans değerini ortalama 0,02 saniye geriden ve ortalama %3 hata ile takip etmektedir.

3.4. Deneysel Sonuçlar

3.4.1. Protez kolun fleksiyon ve ekstansiyon hareketini gerçekleştiren servo motor için konum kontrolü sonuçları


Servo motor ile protez kolun fleksiyon ve ekstansiyon hareketleri, doğrusal eyleyici ile elin açılıp kapanma hareketleri gerçekleştirilmiştir. Servo motorun ve doğrusal eyleyicinin konum kontrolleri için bulanık resetlemeli PI kontrolcü yapısı uygulanmış ve bu kontrolcü ile geleneksel bulanık kontrol ve geleneksel PI kontrolcü yapılarının cevapları karşılaştırılmıştır. Şekil 3.10’da Servo motorun geleneksel bulanık kontrolcü ile gerçekleştirilen konum kontrolünün cevabı gösterilmektedir. Motor aşım gerçekleştirmeden %1’lik tolerans bandının içine yerleşme süresi 1,74 saniyedir. Geleneksel bulanık mantık kontrolcünün gerçek zamanlı çalışmada çok yavaş kaldığı gözlemlenmiştir. Bu sebepten dolayı kare dalga ve sinüs dalga referans giriş uygulamalarına geleneksel bulanık mantık kontrolcü uygulanmamıştır.




Şekil 3.10 : Bulanık mantık kontrolcü ile kontrol edilen servo motorun cevabı.

Şekil 3.11’de motorun konum kontrolü için derin öğrenme algoritması ile elde edilmiş fleksiyon hareketini temsil eden birim basamak referans sinyale karşılık uygulanan kontrolcülerin cevapları verilmiştir. Şekil 3.11(a)’da geleneksel PI kontrolcünün ve şekil 3.11(b)’de bulanık resetlemeli PI kontrolcünün cevapları gösterilmiştir. Geleneksel PI kontrolcü ile motor kontrol edildiğinde motorun referans konum değerine ilk ulaşana kadar geçen süre 0,55 saniyedir. Servo motor %1,2’lik aşım gerçekleştirmektedir. Bu aşım değerine 0,64 saniyede ulaşmaktadır. %1’lik tolerans bandının içine yerleşme süresi 0,7 saniyedir. Bulanık resetlemeli PI kontrolcü ile servo motor kontrol edildiği zaman

aşım gerçekleşmemektedir. Motorun %1’lik tolerans bandının içine yerleşmesi için gereken süre 0,53 saniyedir.



(a)



(b)


Şekil 3.11 : Referans olarak birim basamak uygulandığında sistem cevabı (a) geleneksel PI kontrolcü cevabı (b) bulanık resetlemeli PI kontrolcü cevabı.

Şekil 3.12 (a)’da geleneksel PI kontrolcü ile ve şekil 3.12(b)’de bulanık resetlemeli PI kontrolcü ile kontrol edilen servo motorun, derin öğrenme algoritması ile elde edilmiş kare dalga şeklinde verilen referans konum bilgisine karşılık vermiş olduğu cevap gösterilmektedir. Referans sinyalinin değerinin değişiminden sonra geleneksel PI kontrolcü ve bulanık resetlemeli PI kontrolcü ile kontrol edilen motorun davranışı step sinyal ile aynıdır ve aynı değerlere ulaşmaktadır. Şekil 3.12(c) ‘de geleneksel PI kontrolcü ve bulanık resetlemeli PI kontrolcü ile oluşan hataların tip 1 normu verilmiştir. PI


kontrolcye ait norm deęer 272.85 ve bulanık resetlemeli PI kontrolcye ait norm deęeri 266.4696'dır. Tip 1 normun matematiksel karřılıęı denklem 3.3 ve denklem 3.4'de ifade edilmiřtir.

$$e = [a_1, a_2, a_3, \dots, a_n] \quad (3.3)$$


$$\|e\|_1 = \sum_{i=1}^n |a_i| \quad (3.4)$$



(a)




(b)




(c)

Şekil 3.12 : Referans olarak kare dalga uygulandığında sistem cevabı (a) geleneksel PI kontrolcü cevabı (b) bulanık resetlemeli PI kontrolcü cevabı, (c) oluşan hataların tip 1 norm değeri.

Servo motorun konum kontrolü için derin öğrenme algoritmasının ürettiği kare dalga referans sinyali sisteme verildiği zaman kontrolcülerin ürettiği kontrol sinyalleri şekil 3.13’de verilmiştir. Şekil 3.13(a) ‘da geleneksel PI kontrolcünün ve şekil 3.13(b)’de bulanık resetlemeli PI kontrolcünün motora uygulamış olduğu kontrol sinyalleri gösterilmektedir.




(a)




(b)

Şekil 3.13 : Referans sinyal olarak kare dalga sinyal sisteme uygulandığında (a)geleneksel PI kontrolcünün ve (b) bulanık resetlemeli PI kontrolcünün sisteme uyguladığı kontrol sinyali.


Derin öğrenme algoritması ile elde edilmemiş fakat dirsek hareketinin yumuşak bir şekilde gerçekleştirilebilmesini test etmek için sisteme sinüs dalga şeklinde referans sinyali uygulanmıştır. Şekil 3.14 (a)'da geleneksel PI kontrolcünün cevabı ve şekil 3.14 (b)'de bulanık resetlemeli PI kontrolcünün cevabı gösterilmektedir. Geleneksel PI kontrolcü ile hata en yüksek 0,16 değerine ve bulanık resetlemeli PI kontrolcü ile hata en yüksek 0,118 değerine ulaşmaktadır. Motorun ilk hareketinden sonra geleneksel PI kontrolcü ile hata değeri 0,063 ile -0,063 ve bulanık resetlemeli PI kontrolcü ile hata değeri 0,048 ile -0,048 arasında değişmektedir. Şekil 3.14 (c)'de oluşan hataların tip 1 norm değerleri verilmiştir. Geleneksel PI kontrolcü ile oluşan hatanın norm değeri 451.86 ve önerilen kontrolcü ile oluşan hatanın norm değeri 312.55'dir.



(a)




(b)




(c)

Şekil 3.14 : Referans olarak sinüzoidal dalga uygulandığında sistem cevabı (a) geleneksel PI kontrolcü cevabı (b) bulanık resetlemeli PI kontrolcü cevabı, (c) oluşan hataların tip 1 norm değerleri.

Servo motorun konum kontrolü için referans sinyal olarak sinüzoidal sinyal sisteme uygulandığı zaman şekil 3.15(a)'da geleneksel PI kontrolcünün ve şekil 3.15(b)'de bulanık resetlemeli PI kontrolcünün motora uygulamış olduğu kontrol sinyalleri gösterilmektedir.




(a)




(b)

Şekil 3.15 : Referans olarak sinüzoidal sinyal sisteme uygulandığı zaman (a) geleneksel PI kontrolcünün ve (b) bulanık resetlemeli PI kontrolcünün motora uygulamış olduğu kontrol sinyal.


Gerçekleştirilen farklı kademelerdeki hareketlere ait derin öğrenme ile üretilmiş referans sinyalinin sisteme uygulandığı zaman servo motor konum kontrol sonuçları şekil 3.16’da verilmiştir. Şekil 3.16 (a) geleneksel PI kontrol ve şekil 3.16(b) bulanık resetlemeli PI kontrol cevapları verilmiştir. Şekil 3.16(c) geleneksel PI kontrolcünün ve şekil 3.16(d) bulanık resetlemeli PI kontrolcünün motora uygulamış olduğu kontrol sinyalleri verilmiştir.




(a)



(b)



(c)




(d)


Şekil 3.16 : Derin öğrenmenin ürettiği referans sinyali sisteme uygulandığı zaman (a) geleneksel PI kontrol cevabı, (b) bulanık resetlemeli PI kontrol cevabı; (c) geleneksel PI kontrolcünün ve (d) bulanık resetlemeli PI kontrolcünün motora uyguladığı kontrol sinyali.

3.4.2. Protez elin açma-kapama hareketini gerçekleştiren doğrusal eyleyici için konum kontrolü sonuçları


Şekil 3.17’de derin öğrenme algoritması ile elde edilmiş olan kare dalga şeklindeki konum referans sinyaline, doğrusal eyleyiciye uygulanan kontrolcülerin cevapları verilmiştir. Şekil 3.17(a)’da geleneksel PI kontrolcünün cevabı ve şekil 3.17(b)’de bulanık resetlemeli PI kontrolcünün cevabı gösterilmektedir. Geleneksel PI kontrolcü ile doğrusal eyleyicinin kontrolü gerçekleştirildiği zaman hatanın sifıra ulaşması ve %1’lik tolerans bandının içine yerleşmesi 3,5 saniye içinde gerçekleşmemektedir. Bulanık resetlemeli PI kontrolcü ile kontrol yapıldığı zaman %1’lik tolerans bandının içine yerleşme süresi 0,92 saniyedir. Şekil 3.17(c)’de oluşan hataların tip 1 norm değerleri verilmiştir. Geleneksel PI kontrolcünün oluşturduğu hatanın norm değeri 903,75 ve bulanık resetlemeli PI kontrolcünün oluşturduğu hatanın norm değeri 855,24’dür.



(a)




(b)




(c)

Şekil 3.17 : Doğrusal eyleyici için referans olarak kare dalga uygulandığında sistem cevabı (a) geleneksel PI kontrolcü cevabı (b) bulanık resetlemeli PI kontrolcü cevabı, (c) oluşan hataların tip 1 norm değeri.

Doğrusal eyleyicinin konum kontrolü için referans sinyal olarak sisteme derin öğrenme algoritmasının ürettiği kare dalga verildiği zaman şekil 3.18(a)'da geleneksel PI kontrolcünün ve şekil 3.18(b)'de bulanık resetlemeli PI kontrolcünün motora uygulamış olduğu kontrol sinyalleri verilmektedir.



(a)




(b)


Şekil 3.18 : Referans sinyal olarak kare dalga sisteme uygulandığı zaman (a) geleneksel PI kontrolcünün ve (b) bulanık resetlemeli PI kontrolcünün doğrusal eyleciye uygulamış olduğu kontrol sinyali.

Derin öğrenme algoritması ile elde edilmemiş fakat protez elin açılma kapanma hareketlerinin yumuşak bir şekilde gerçekleştirilebilmesini test edebilmek için sinüs dalga şeklinde referans sinyali doğrusal eyleyiciye uygulanmıştır. Şekil 3.19(a)'da geleneksel PI kontrolcünün ve şekil 3.19(b)'de bulanık resetlemeli PI kontrolcünün cevapları verilmiştir. Geleneksel PI kontrolcü ile maksimum hata 0,061 değerine ve


bulanık resetlemeli PI kontrolcü ile maksimum hata 0,028 değerine ulaşmaktadır. Şekil 3.19 (c)'de oluşan hataların tip 1 norm değerleri verilmiştir. Geleneksel PI kontrolcünün oluşturduğu hatanın norm değeri 97,65 ve bulanık resetlemeli PI kontrolcünün oluşturduğu hatanın norm değeri 55,74'dür.



(a)




(b)




(c)

Şekil 3.19 : Doğrusal eyleyici için referans olarak sinüzoidal dalga uygulandığında sistem cevabı (a) geleneksel PI kontrolcü cevabı (b) bulanık resetlemeli PI kontrolcü cevabı, (c) oluşan hataların tip 1 norm değeri.

Doğrusal eyleyicinin konum kontrolü için referans sinyal olarak sinüzoidal sinyal sisteme uygulandığı zaman şekil 3.20(a)'da geleneksel PI kontrolcünün ve şekil 3.20(b)'de bulanık resetlemeli PI kontrolcünün motora uyguladığı kontrol sinyalleri verilmiştir.






(a)




(b)

Şekil 3.20 : Referans sinyal olarak sinüzoidal sinyal sisteme uygulandığı zaman (a) geleneksel PI kontrolcünün ve (b) bulanık resetlemeli PI kontrolcünün doğrusal eyleyiciye uyguladığı kontrol sinyali.

Gerçekleştirilen farklı kademelere ait hareketlerin tahminlerine göre derin öğrenme ile üretilmiş referans sinyalin sisteme uygulandığı zaman doğrusal eyleyicinin konum kontrol sonuçları şekil 3.21'da verilmiştir. Şekil 3.21 (a) geleneksel PI kontrol ve şekil 3.21(b) bulanık resetlemeli PI kontrol cevapları verilmiştir. Şekil 3.21(c) geleneksel PI kontrolcünün ve şekil 3.21(d) bulanık resetlemeli PI kontrolcünün motora uygulamış olduğu kontrol sinyalleri verilmiştir.





(d)

Şekil 3.21 : Derin öğrenmenin ürettiği referans sinyal sisteme uygulandığında (a) geleneksel PI kontrol cevabı, (b) bulanık resetlemeli PI kontrol cevabı; (c) geleneksel PI kontrolcünün ve (d) bulanık resetlemeli PI kontrolcünün doğrusal eyleyiciye uyguladığı kontrol sinyali.

BÖLÜM 4. SONUÇLAR VE ÖNERİLER

Tez kapsamındaki çalışmada bir protez kolun ve protez elin, insansı özelliklere benzer bir şekilde kontrol edilmesi amaçlanmıştır. Bu amaç doğrultusunda bir sistem tasarımı gerçekleştirilmiştir. Tasarlanan sistemde insanda karar verme mekanizması olan beyin yerine derin öğrenme algoritması kullanılmıştır. Derin öğrenme algoritmasının hangi hareketin gerçekleşmesine karar verebilmesi için girdi olarak insan kaslarından alınan ham EMG sinyalleri verilmektedir. Derin öğrenme algoritmasının sağladığı avantajlardan en önemlisi, ham EMG verisini algoritmaya girdi olarak vermeden önce özniteliklerini çıkarma ve veriyi işleme adımlarını uygulamadan sınıflandırma işlemini gerçekleştirmesidir. Sınıflandırma doğruluğunun yüksek oranlarda olması, büyük veri setleri ile çalışabilmesi, ezberleme işleminin önüne geçebilmek için kendi içinde bir algoritmasının olması vb. özellikler derin öğrenme algoritmasının tercih edilmesi için büyük avantaj sağlamaktadır. Eğitimi gerçekleştirilmiş derin öğrenme algoritması, EMG verisinin daha önce öğrendiği hareket sınıflarından hangisine ait olduğunu belirlemektedir. Bu bilgiye göre sistemde kullanılan aktüatör harekete başlayarak istenen konuma ulaşmaktadır. Aktüatörlerin hassas konum kontrolü için bulanık resetlemeli PI kontrolcü tasarlanmıştır. Geleneksel PI kontrolcünde sistem referans değerine ulaşana kadar integral kontrolcünün mevcut ve eski hataları toplama özelliğinden dolayı integral hafızası şişer. Bu durum sistem cevabında yüksek aşımara sebep olur. Bulanık resetlemeli PI kontrolcü, sistemin anlık olarak hata durumunu inceleyerek bir resetleme katsayısı üretir. Resetleme katsayısı ile geleneksel PI’da oluşan integral hafızasını kısmi olarak resetler ve sistemde oluşan aşımaların ve gecikmelerin önüne geçmiş olur. Geleneksel PI kontrolde parametrelerin ayarlanmasının zorluğu ve parametreler ayarlanırken yapılan ihmal ve varsayımlar göz önünde bulundurulduğunda Bulanık resetlemeli PI kontrolcünün bu durumları ve hassas ayarlanamayan parametreleri belli oranda tolere ettiği gözlemlenmiştir. Önerilen bulanık resetlemeli PI yapısının başarısını göstermek amacıyla protez kolun denetimini gerçekleştiren servo (dairese ve doğrusal) eyleyicilere sırasıyla geleneksel PI, geleneksel bulanık kontrol ve önerilen bulanık

resetlemeli PI yapısı hem simülasyon hem de deneysel ortamda uygulanmış ve ilgili sonuçlar kıyaslanmıştır. Tasarlanan sistemin çalışması simülasyon ortamında ve deneysel olarak gerçekleştirilmiştir. Tablo 4.1’de kare dalga referans sinyali için simülasyon sonuçları ve tablo 4.2’de sinüzoidal referans sinyali için simülasyon sonuçları kontrolcüler için karşılaştırılmıştır. Tablo 4.3 kare dalga referans sinyali için servo motorun deneysel sonuçları, tablo 4.4’de sinüzoidal referans sinyali için servo motorun deneysel sonuçları, tablo 4.5’de kare dalga referans sinyali için doğrusal eyleyicinin deneysel sonuçları ve tablo 4.6’da sinüzoidal referans sinyali için doğrusal eyleyicinin deneysel sonuçları kontrolcüler için karşılaştırılmıştır. Simülasyon ve deneysel sonuçlar incelendiği zaman geleneksel PI kontrolcü ve geleneksel bulanık mantık kontrolcüye göre bulanık resetlemeli PI kontrolcünün cevaplarının daha gülbüz sonuçlar edildiği gözlemlenmiştir.

Tablo 4.1 : Referans sinyal olarak kare dalga sisteme uygulandığında simülasyon sonuçları.

	Bulanık Kontrol	PI Kontrol	Bulanık resetlemeli PI kontrol
Referans sinyal ile ilk kesişme süresi(sn)	0.32	0.21	0.19
Aşım (%)	1.1	3.7	1
%1’lik bandın içine yerleşme süresi(sn)	0.41	0.38	0.20

Tablo 4.2 : Referans sinyal olarak sinüzoidal dalga sisteme uygulandığında simülasyon sonuçları.

	Bulanık Kontrol	PI Kontrol	Bulanık resetlemeli PI kontrol
En yüksek hata değeri	0.1858	0.1620	0.0735
Hatanın norm değeri	1171.15	1008.1	429.18

Tablo 4.3 : Referans olarak step sinyal sisteme uygulandığında servo motor sonuçları.

	PI Kontrol	Bulanık resetlemeli PI kontrol
Referans sinyal ile ilk kesişme süresi(sn)	0.55	-
Aşım (%)	1.2	-
%1'lik bandın içine yerleşme süresi(sn)	0.7	0.53
Hatanın norm değeri	272.75	266.46

Tablo 4.4 : Referans sinyal olarak sinüzoidal dalga sisteme uygulandığında servo motor sonuçları.

	PI Kontrol	Bulanık resetlemeli PI kontrol
En yüksek hata değeri	0.1610	0.1181
Hatanın norm değeri	451.86	312.55

Tablo 4.5 : Referans olarak step sinyal sisteme uygulandığında doğrusal eyleyicinin sonuçları.

	PI Kontrol	Bulanık resetlemeli PI kontrol
Referans sinyal ile ilk kesişme süresi(sn)	-	-
Aşım (%)	-	-
%1'lik bandın içine yerleşme süresi(sn)	-	0.92
Hatanın norm değeri	903.75	855.24

Tablo 4.6 : Referans sinyal olarak sinüzoidal dalga sisteme uygulandığında doğrusal eyleyicinin sonuçları.

	PI Kontrol	Bulanık resetlemeli PI kontrol
En yüksek hata değeri	0.061	0.028
Hatanın norm değeri	95.65	55.74

Gelecek çalışmalar için işlem kapasitesi daha yüksek işlemciler ile derin öğrenme algoritması daha kapsamlı olacak şekilde geliştirilebilir ve doğruluk oranı %95'in üstüne çıkartılabilir. Çevrimiçi çalışacak bir şekilde sistem tekrar tasarlanabilir. Çevrimiçi çalıştırıldığı zaman daha fazla hareket sınıfı oluşturularak farklı hareketler protez yapılar ile gerçekleştirilebilir. Protez yapılar, el ve kas rehabilitasyonu için kullanılacak şekilde tasarlanabilir. Protez yapı endüstriyel amaçlı tasarlanarak insanın zorlanacağı çalışmalarda kullanılabilir. Protez kolun daha yüksek serbestlik dereceli yapılarına yönelik kontrolcü yapıları geliştirilebilir. Bu amaçla güncel kontrol yaklaşımları olan H_∞ kontrol, kayan kipli kontrol, model öngörülü kontrol vb. denetleyici yapıları kullanılabilir.

KAYNAKLAR

- Akar, M. (2005). *Bulanık mantık yöntemiyle bir servo motorun kontrolü ve geleneksel yöntemlerle karşılaştırılması*. (Yüksek lisans tezi). Marmara Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Aki, K. (2019). *Derin öğrenme tabanlı sürücüsüz araç sistemleri*. (Yüksek lisans tezi). Bursa Uludağ Üniversitesi, Fen Bilimleri Enstitüsü, Bursa.
- Alpaslan, N. (2019). Meme kanseri tanısı için derin öznitelik tabanlı karar destek sistemi. *Selçuk Üniversitesi Mühendislik, Bilim ve Teknoloji Dergisi*, 7(1), 213-227.
- Aravind, M. A., Saikumar, N., & Dinesh, N. S. (2017). Optimal position control of a DC motor using LQG with EKF. In *2017 international conference on mechanical, system and control engineering (ICMSC)* (pp. 149-154). IEEE.
- Ayaz, F., Ari, A., & Hanbay, D. (2017). Classification of EMG signals by LRF-ELM. In *2017 International Artificial Intelligence and Data Processing Symposium (IDAP)* (pp. 1-6). IEEE.
- Aydın, O. (2019). *Derin öğrenme ile karar verme süreçleri*. (Doktora tezi). Mimar Sinan Güzel Sanatlar Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Ayturan, Y.A. (2019). Derin öğrenme ile havadaki partikül madde konsantrasyonu tahmini. (Yüksek lisans tezi). Konya Ticaret Odası Karatay Üniversitesi, Fen Bilimleri Enstitüsü, Konya.
- Banos, A., & Vidal, A. (2012). Design of reset control systems: the PI+ CI compensator. *Journal of Dynamic Systems, Measurement, and Control*, 134(5).
- Banos, A., & Vidal, A. (2007, June). Design of PI+ CI Reset Compensators for second order plants. In *2007 IEEE International Symposium on Industrial Electronics* (pp. 118-123). IEEE.
- Baştürk, A., Yüksel, M. E., Çalışkan, A., & Badem, H. (2017). Deep neural network classifier for hand movement prediction. In *2017 25th Signal Processing and Communications Applications Conference (SIU)* (pp. 1-4). IEEE.
- Chakraborty, S., Roy, S., & Mondal, U. (2018). Fractional-Order Controller for the Position Control of a DC Motor. In *2018 IEEE Applied Signal Processing Conference (ASPCON)* (pp. 1-3). IEEE.

- Choudhary, K., Qureshi, M. S., & Singh, B. (2018). Position Control of DC Servo Motor using Improved Sliding Mode Control Techniques. *International Journal of Applied Engineering Research*, 13(8), 15-19.
- Côté-Allard, U., Fall, C. L., Drouin, A., Campeau-Lecours, A., Gosselin, C., Glette, K., ... & Gosselin, B. (2019). Deep learning for electromyographic hand gesture signal classification using transfer learning. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 27(4), 760-771.
- Çakır, B. (2019). *Zero-day attack detection with deep learning*. (Yüksek lisans tezi). Orta Doğu Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Ankara.
- Dandıl, E., & Polattimur, R. (2020). Daha hızlı bölgesel evrimsel sinir ağları ile köpek davranışlarının tanınması ve takibi. *Journal of the Faculty of Engineering & Architecture of Gazi University*, 35(2).
- Doğan, F., & Türkoğlu, İ. (2018). Derin öğrenme algoritmalarının yaprak sınıflandırma başarımlarının karşılaştırılması. *Sakarya University Journal of Computer and Information Sciences*, 1(1), 10-21.
- Doğan, Z. (2009). *Alternatif akım servo motorun farklı kontrol yöntemleri ile hız kontrolü*. (Yüksek lisans tezi). Marmara Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Doğan, M. (2019). *Bitkilerde görülen hastalıkların derin öğrenme yöntemleriyle tespiti ve sınıflandırılması*. (Yüksek lisans tezi). Yalova Üniversitesi, Fen Bilimleri Enstitüsü, Yalova.
- Engin, S. (2018). *Grup servo motorların deadbeat kontrolü*. (Yüksek lisans tezi). Gazi Üniversitesi, Fen Bilimleri Enstitüsü, Ankara.
- Eral, M. (2016). *Deep learning approach for laboratory mice grimace scaling*. (Yüksek lisans tezi). Orta Doğu Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Ankara.
- Gomes, W., & Rocco, E. M. (2012, June). Design of a fuzzy PID controller for application in satellite attitude control system. In *Proc. Workshop on Space Engineering and Technology* (pp. 1-8).
- Güdelek, M. (2019). *Zaman serisi analiz ve tahmini: derin öğrenme yaklaşımı*. (Yüksek lisans tezi). TOBB Ekonomi ve Teknoloji Üniversitesi, Fen Bilimleri Enstitüsü, Ankara.
- Gündüz, G., & Cedimoğlu, İ. H. (2019). Derin Öğrenme Algoritmalarını Kullanarak Görüntüden Cinsiyet Tahmini. *Sakarya University Journal of Computer and Information Sciences*, 2(1), 9-17.
- Hancı, O. (2007). *Servo motorlar ve örnek bir uygulama tasarımı*. (Yüksek lisans tezi). Marmara Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Hinton, G. E., Osindero, S., & Teh, Y. W. (2006). A fast learning algorithm for deep belief nets. *Neural computation*, 18(7), 1527-1554.

- Issa, A. H., & Abd, A. N. (2018). Adaptive Inverse Neural Network Based DC Motor Speed and Position Control Using FPGA. *Diyala Journal of Engineering Sciences*, 11(3), 71-78.
- Jalil, M. H. A., Hamdan, R., Abd Latif, S. A. F., Ngadengon, R., Abd Kadir, H., Noh, F. H. M., & Kasuan, N. (2019). Model Reference Adaptive Controller without Integral (MRACWI) for Position Control of DC Motor. *Applications of Modelling and Simulation*, 3(1), 18-27.
- Khan, S., Paul, A., Sil, T., Basu, A., Tiwari, R., Mukherjee, S., ... & Sengupta, A. (2016). Position control of a DC motor system for tracking periodic reference inputs in a data driven paradigm. In *2016 International Conference on Intelligent Control Power and Instrumentation (ICICPI)* (pp. 17-21). IEEE.
- Khanna, A., & Gaur, T. (2017). Model predictive control of DC motor model in matlab. *International Journal of Scientific & Engineering Research*, 8(4), 82-85.
- Lee, J. (1993). On methods for improving performance of PI-type fuzzy logic controllers. *IEEE transactions on fuzzy systems*, 1(4), 298-301.
- Maung, M. M., Latt, M. M., & Nwe, C. M. (2018). DC Motor Angular Position Control using PID Controller with Friction Compensation. *International Journal of Scientific and Research Publications*, 8(11), 149.
- Morán, M. E. F., & Viera, N. A. P. (2017). Comparative study for DC motor position controllers. In *2017 IEEE Second Ecuador Technical Chapters Meeting (ETCM)* (pp. 1-6). IEEE.
- Öztemel, E. (2016). Yapay sinir ağları. *PapatyaYayincılık, Istanbul*.
- Park, K. H., & Lee, S. W. (2016). Movement intention decoding based on deep learning for multiuser myoelectric interfaces. In *2016 4th International Winter Conference on Brain-Computer Interface (BCI)* (pp. 1-2). IEEE.
- Patel, D.(2018). Different from of machine leraning.*DigitalVidya*, Erişim tarihi 25.02.2020, <https://www.digitalvidya.com/blog/forms-of-machine-learning/>
- Qureshi, M. S., Swarnkar, P., & Gupta, S. (2016,). Assessment of DC servo motor with sliding mode control approach. In *2016 IEEE First International Conference on Control, Measurement and Instrumentation (CMI)* (pp. 351-355). IEEE.
- Ravi, D., Wong, C., Deligianni, F., Berthelot, M., Andreu-Perez, J., Lo, B., & Yang, G. Z. (2017). Deep learning for health informatics. *IEEE journal of biomedical and health informatics*, 21(1), 4-21.
- Şeker, A., Diri, B., & Balık, H. H. (2017). Derin öğrenme yöntemleri ve uygulamaları hakkında bir inceleme. *Gazi Mühendislik Bilimleri Dergisi*, 3(3), 47-64.
- Tsinganos, P., Cornelis, B., Cornelis, J., Jansen, B., & Skodras, A. (2018, September). Deep Learning in EMG-based Gesture Recognition. In *PhyCS* (pp. 107-114).

- Turhan, C. G., & Bilge, H. Ş. (2020). Çekişmeli üretici ağ ile ölçeklenebilir görüntü oluşturma ve süper çözünürlük. *Journal of the Faculty of Engineering & Architecture of Gazi University*, 35(2).
- Tümen, V., Söylemez, Ö. F., & Ergen, B. (2017, September). Facial emotion recognition on a dataset using convolutional neural network. In *2017 International Artificial Intelligence and Data Processing Symposium (IDAP)* (pp. 1-5). IEEE.
- Türk, Ö. (2019). *EEG işaretlerinden epilepsi türlerinin sınıflandırılmasında skalogram tabanlı derin öğrenme yaklaşımı*. (Doktora tezi). Dicle Üniversitesi, Fen Bilimleri Enstitüsü, Diyarbakır.
- Türkçetin, A.Ö. (2019). *Akciğer kanserinin tespit edilmesinde derin öğrenme algoritmalarının kullanılması*. (Yüksek lisans tezi). Isparta Uygulamalı Bilimler Üniversitesi, Lisansüstü Eğitim Enstitüsü, Isparta.
- Xia, P., Hu, J., & Peng, Y. (2018). EMG-based estimation of limb movement using deep learning with recurrent convolutional neural networks. *Artificial organs*, 42(5), E67-E77.
- Yıldız, O. (2019). Derin öğrenme yöntemleriyle dermoskopi görüntülerinden melanom tespiti: Kapsamlı bir çalışma. *Journal of the Faculty of Engineering & Architecture of Gazi University*, 34(4).
- Zhu, W., Chen, D., Du, H., & Wang, X. (2020). Position control for permanent magnet synchronous motor based on neural network and terminal sliding mode control. *Transactions of the Institute of Measurement and Control*, 0142331219893799.
- Url-1 <https://datasetsearch.research.google.com/search?query=https%3A%2F%2Fwww.kaggle.com%2Fkyr7plus%2Femg-4%2Fversion%2F2&docid=0%2FkYShS3WZdTVk5tAAAAAA%3D%3D>, erişim tarihi 11.10.2019.

ÖZGEÇMİŞ

Ad-Soyad : Muhammed Salih SARIKAYA
Doğum Tarihi ve Yeri : 01.08.1994 - VAN
E-posta : salihsarikaya@subu.edu.tr

ÖĞRENİM DURUMU:

- **Lise** : 2012, Adil Karaağaç Anadolu Meslek Lisesi, Endüstriyel Otomasyon Bölümü, Mekatronik Dalı
- **Lisans** : 2017, Sakarya Üniversitesi, Teknoloji Fakültesi, Mekatronik Mühendisliği Bölümü

MESLEKİ DENEYİM:

- 2018 yılında Sakarya Uygulamalı Bilimler Üniversitesinde araştırma görevlisi olarak göreve başladı.