

T.C.
GÜMÜŞHANE ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

MAKİNE MÜHENDİSLİĞİ ANA BİLİM DALI

YAPAY SİNİR AĞLARI İLE DESTEKLENMİŞ JİROSKOPİK ROBOT
STABİLİZASYONU: DERİN ÖĞRENME YAKLAŞIMI

YÜKSEK LİSANS

Hamza BAYRAKTAR

MAYIS-2026
GÜMÜŞHANE



**T.C.
GÜMÜŞHANE ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

MAKİNE MÜHENDİSLİĞİ ANA BİLİM DALI

**YAPAY SİNİR AĞLARI İLE DESTEKLENMİŞ JİROSKOPİK ROBOT
STABİLİZASYONU: DERİN ÖĞRENME YAKLAŞIMI**

**GYROSCOPIC ROBOT STABILIZATION ENHANCED WITH ARTIFICIAL
NEURAL NETWORKS: A DEEP LEARNING APPROACH**

YÜKSEK LİSANS

Hamza BAYRAKTAR

**MAYIS-2026
GÜMÜŞHANE**



**T.C.
GÜMÜŞHANE ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

MAKİNE MÜHENDİSLİĞİ ANA BİLİM DALI

**YAPAY SİNİR AĞLARI İLE DESTEKLENMİŞ JİROSKOPİK ROBOT
STABİLİZASYONU: DERİN ÖĞRENME YAKLAŞIMI**

**GYROSCOPIC ROBOT STABILIZATION ENHANCED WITH ARTIFICIAL
NEURAL NETWORKS: A DEEP LEARNING APPROACH**

YÜKSEK LİSANS

Hamza BAYRAKTAR

Danışman: Doç. Dr. Faruk ÜNKER

**MAYIS-2026
GÜMÜŞHANE**

KABUL VE ONAY

Doç. Dr. Faruk ÜNKER danışmanlığında, **Hamza BAYRAKTAR** tarafından hazırlanan “**Yapay Sinir Ağları ile Desteklenmiş Jiroskopik Robot Stabilizasyonu: Derin Öğrenme Yaklaşımı**” isimli bu çalışma, 07/05/2026 tarihinde yapılan lisansüstü tez savunma sınavı sonucunda **Oy Birliği** ile başarılı bulunarak jürimiz tarafından **Yüksek Lisans Tezi** olarak kabul edilmiştir.

.....
Prof. Dr. İsmet SEZER (Başkan)

.....
Doç. Dr. Faruk ÜNKER (Danışman)

.....
Dr. Öğr. Üyesi İsmail ÖZEN (Üye)

Lisansüstü tez savunma sınavında başarılı bulunarak kabul edilen bu tezin ciltlenmiş hali, /..... /..... tarihli ve / sayılı Enstitü Yönetim Kurulu toplantısında görüşülmüş ve tez yazım kılavuzuna uygun bulunarak onaylanmıştır.

Prof. Dr. Duygu ÖZDEŞ
Enstitü Müdürü

BİLİMSEL ETİĞE UYGUNLUK BEYANI

Yüksek Lisans Tezi olarak hazırladığım olduğum “**Yapay Sinir Ağları ile Desteklenmiş Jiroskopik Robot Stabilizasyonu: Derin Öğrenme Yaklaşımı**” isimli bu tezimin, tamamen kendi çalışmam olduğunu, her alıntıya kaynak gösterdiğimi, alıntı yaptığım tüm çalışmaları kaynakçada belirttiğimi ve Gümüşhane Üniversitesi'nin lisanslı kullanıcısı olduğum intihal yazılım programı ile Lisansüstü Eğitim Enstitüsü'nün belirlediği kıstaslara uygun olarak raporladığımı taahhüt ederim. Tezimin kâğıt ve elektronik kopyalarının Gümüşhane Üniversitesi Lisansüstü Eğitim Enstitüsü arşivinde saklanmasına izin verdiğimi onaylarım.

Lisansüstü Eğitim ve Öğretim Yönetmeliği'nin ilgili maddeleri uyarınca gereğinin yapılmasını arz ederim.

07/05/2026

.....
Hamza BAYRAKTAR

TEŐEKKÜR

Bu tez alıőmasının hazırlanması s¼recinde bilgi, deneyim ve deęerli y¼nlendirmeleriyle katkı saęlayan danıőman hocam Do. Dr. Faruk ÜNKER'e teőekk¼r ederim. Ayrıca alıőmamı deęerlendirerek g¼r¼ő ve ¼nerileriyle katkıda bulunan j¼ri ¼yeleri Prof. Dr. İsmet SEZER ve Dr. ¼ęr. Üyesi İsmail ÖZEN'e teőekk¼rlerimi sunarım.

Hamza BAYRAKTAR
G¼M¼ŐHANE – 2026

ÖZET

Bu çalışma, iki tekerlekli jiroskopik bir robotun dinamik kararlılığını ve adaptasyon kabiliyetini artırmak amacıyla, Doğrusal Kuadratik Regülatör (LQR) ile Yapay Sinir Ağlarını (YSA) birleştiren özgün bir hibrit kontrol mimari sunmaktadır. Doğası gereği yüksek derecede doğrusal olmayan ve kararsız bir yapıya sahip olan iki tekerlekli sistemler, özellikle Kontrol Moment Jiroskopu (CMG) disk hızındaki değişimlerden doğrudan etkilenmekte; bu durum geleneksel statik kontrolcülerin dayanıklılığını (robustness) sınırlamaktadır.

Önerilen yöntem, farklı operasyonel disk hızları için hesaplanan optimal LQR kazanç matrisleri (K) üzerinde eğitilen bir YSA modelini kontrol döngüsüne entegre etmektedir. Geliştirilen hibrit sistem, anlık disk hızı verilerini işleyerek gerekli katsayıları dinamik olarak kestirmekte ve sistemin değişken koşullara gerçek zamanlı uyum sağlamasına olanak tanımaktadır. Simülasyon sonuçları, bu yaklaşımın statik LQR kontrolcülere kıyasla yerleşme süresi ve aşım miktarı açısından üstün performans sergilediğini ve sistem dinamiklerindeki belirsizliklere karşı dayanıklılığı önemli ölçüde artırdığını kanıtlamaktadır.

Deterministik kontrolün hassasiyeti ile derin öğrenmenin esnekliğini sentezleyen bu çalışma, arama-kurtarma ve gözetleme gibi karmaşık ortamlarda görev yapan otonom robotik platformlar için ölçeklenebilir ve güvenilir bir kontrol stratejisi sunmaktadır.

Anahtar Kelimeler: Doğrusal kuadratik regülatör (LQR), Jiroskopik stabilizasyon, İki tekerlekli robotlar, İnsansız kara araçları, Yapay sinir ağları

SUMMARY

This study presents a novel hybrid control architecture that integrates Linear Quadratic Regulator (LQR) control with Artificial Neural Networks (ANN) to enhance the dynamic stability and adaptability of a two-wheeled gyroscopic robotic platform. Due to their inherently high-order nonlinear and unstable nature, two-wheeled systems face significant balancing challenges in unpredictable operational environments, particularly under varying Control Moment Gyroscope (CMG) disk speeds. Such variations fundamentally alter the system dynamics, limiting the robust performance of traditional static control methods.

To overcome these constraints, the proposed approach incorporates an ANN model, trained on optimal LQR gain matrices (K) calculated for diverse operational disk speeds, into the feedback control loop. The developed hybrid system processes real-time disk speed data to dynamically estimate the required LQR coefficients, enabling the robot to adapt to varying conditions in real-time. Simulation results demonstrate that this hybrid architecture outperforms static LQR controllers in terms of settling time and overshoot, significantly increasing robustness against parametric uncertainties.

By synthesizing the precision of deterministic control with the flexibility of deep learning, this research contributes a scalable hybrid control strategy to the autonomous robotics literature. While validated on a combat robot prototype, the framework is highly applicable to a broad range of fields, including search-and-rescue, border surveillance, and autonomous navigation in hazardous environments.

Keywords: Quadratic regulator (LQR), Gyroscopic stabilization, Linear Two-wheeled robots, Unmanned ground vehicles (UGV), Artificial neural networks (ANN)

İÇİNDEKİLER

KABUL VE ONAY.....	III
BİLİMSEL ETİĞE UYGUNLUK BEYANI.....	IV
TEŞEKKÜR.....	V
ÖZET.....	VI
SUMMARY.....	VIII
İÇİNDEKİLER.....	IX
TABLolar DİZİNİ.....	X
ŞEKİLLER DİZİNİ.....	XI
EKLER DİZİNİ.....	XII
SİMGELER VE KISALTMALAR DİZİNİ.....	XIII
1. GİRİŞ.....	1
2. SİSTEM TANIMLAMA	4
2.1. Jiroskopik İki Tekerlekli Robot İçin Hareket Denklemleri	6
3. LQR-KONTROLCÜ TASARIMI	11
4. SİNİR AĞI TABANLI KONTROLCÜ TASARIMI.....	17
5. LQR KATSAYILARINDAN EĞİTİLMİŞ SİNİR AĞINA DAYALI SONUÇLAR.....	28
5.1 LQR ve Sinir Ağı Kontrol Algoritmaları için Karşılaştırmalar	28
5.2 Robotun Değişen CMG Disk Hızlarıyla Sabit Kuvvet Altındaki Yanıt Analizi.....	29
5.3 Robotun Değişen CMG Disk Hızlarıyla Ateşleme Yüğü Darbeleri Altındaki Yanıt Analizi.....	31
5.4 Klasik ve Gelişmiş Kontrol Stratejileri ile Karşılaştırmalı Analiz.....	35
6. SONUÇ.....	36
KAYNAKÇA	38
EKLER	41
ÖZGEÇMİŞ	47

TABLolar DİZİNİ

Tablo 1. Silahlı jiroskopik robotun fiziksel özellikleri	5
Tablo 2. Sinir ağı eğitim sonuçları yorumu	23

ŞEKİLLER DİZİNİ

Şekil 1. Dönüş hızına (ε) sahip iki tekerlekli bir robotun fiziksel modeli	4
Şekil 2. Kontrol torku (τ_{gimbal}) etkisi altındaki jiroskopik iki tekerlekli robot	6
Şekil 3. Bir silah sistemiyle entegre edilmiş jiroskopik iki tekerlekli robotun yandan görünümü	6
Şekil 4. $F=120$ N sabit geri tepmeye maruz kalan $\alpha=0$ rad silah açısı ile $\varepsilon = 2$ rad/s and $\Omega = 2000$ rad/s için RecurDyn ve teorik simülasyonların karşılaştırılması ($\tau_{\text{gimbal}} = 0$ N)	9
Şekil 5. $F=120$ N sabit geri tepmeye maruz kalan $\alpha=0$ rad silah açısı ile $\varepsilon = 2$ rad/s ve $\Omega=4000$ rad/s için RecurDyn ve teorik simülasyonların karşılaştırılması ($\tau_{\text{gimbal}} = 0$ N)	10
Şekil 6. Simulink–RecurDyn GCoSim eş-simülasyonu ile çift CMG kontrol ve anahtarlama mimarisinin blok diyagramı	15
Şekil 7. $F=120$ N sabit geri tepmeye maruz kalan $\alpha=0$ rad silah açısı ile $\varepsilon = 2$ rad/s ve $\Omega = 4000$ rad/s için kontrolsüz mafsalsal ($\tau_{\text{gimbal}} = 0$ N) ve LQR kontrollü ($\tau_{\text{gimbal}} = -Kx$) mafsalsal simülasyonlarının karşılaştırılması.	16
Şekil 8.>NNLQR kapalı çevrim kontrol diyagramı	17
Şekil 9. Izgara araması (Grid Search) ile belirlenen optimize edilmiş sinir ağı yapısı	19
Şekil 10. Tahmin hassasiyeti	20
Şekil 11. NN (Sinir Ağı) yapısı	21
Şekil 12. NN'nin eğitim performansı	24
Şekil 13. NN'nin öğrenim aşaması	25
Şekil 14. Regresyon	26
Şekil 15. Eğitim, doğrulama ve test veri setleri için hata histogramı	27
Şekil 16. $F=120$ N sabit geri tepmeye ve $\varepsilon = 2$ rad/s dönüş hızına maruz kalan, silah açısı $\alpha=0$ rad ile $\Omega = 4000$ rad/s'de LQR kontrollü ve Sinir Ağı (>NNLQR) simülasyonlarının karşılaştırılması. ($K_{\text{LQR}} = [-594.6 \quad -18.5 \quad -213.1 \quad 2.1]$ and $K_{\text{>NNLQR}} = [-676.4 \quad -17.11 \quad -208.2 \quad 0.9]$)	29

- Şekil 17. $F=120$ N sabit geri tepmeye ve $\varepsilon = 2 \cos 2.5t$ rad/s dönüş hızına maruz kalan, silah açısı $\alpha=0$ rad ile $\Omega = 2000+1000\sin 2.5t$ rad/s'de LQR kontrollü ve Sınır Ağı (NNLQR) simülasyonlarının karşılaştırması. ($\Omega = 2000$ rad/s ve $\varepsilon = 2$ rad/s ile LQR kontrolcüsü için $K_{LQR} = [-769.3 \ -65.1 \ -272.4 \ 3.0]$ seçilmiş ve sabitlenmiştir, bu arada K_{NNLQR} test sırasında sisteme uyum sağlamak için değişmektedir.)31
- Şekil 18. Geri tepme kuvvetinin sürekli ateşleme hızı (Oğuz vd., 2026).32
- Şekil 19. $F = F_{recoil}$ geri tepmesine ve $\varepsilon = 2 \cos 2.5t$ rad/s dönüş hızına maruz kalan, silah açısı $\alpha=0.25(1 - \cos 2.5t)$ rad ile $\Omega = 2000+1000\sin 2.5t$ rad/s'de Sınır Ağı (NNLQR) simülasyonları. (K_{NNLQR} test sırasında sisteme uyum sağlamak için değişirken.)34

EKLER DİZİNİ

Ek 1. Matlab Kodları	41
----------------------------	----

SİMGELER VE KISALTMALAR DİZİNİ

F_{recoil}	: Ateşleme kaynaklı geri tepme kuvveti
I_{bx}, I_{by}, I_{bz}	: Gövde asal atalet momentleri
I_{cx}, I_{cy}, I_{cz}	: Silah sistemi asal atalet momentleri
I_{fx}, I_{fy}, I_{fz}	: Dış mafsalsal asal atalet momentleri
I_{gx}, I_{gy}, I_{gz}	: İç mafsalsal asal atalet momentleri
I_o	: Her bir volanın kütle eylemsizlik momenti
I_p	: Her bir volanın kendi eksenine etrafındaki dönüş eylemsizliği
I_{wx}, I_{wy}	: Tekerlek asal atalet momentleri
K_1, K_2, K_3, K_4	: LQR kazanç bileşenleri
R_b	: Ana gövdenin kütle merkezinin uzunluğu
R_c	: Silah taretinin kütle merkezi uzaklığı
R_g	: Her bir jiroskobun viraj alma yarıçapı
R_w	: Her bir tekerleğin viraj alma yarıçapı
m_b	: Robot ana gövde kütlesi
m_c	: Top / Silah sistemi kütlesi
m_d	: Her bir volanın (flywheel) kütlesi
m_f	: Her bir dış mafsalsal (gimbal) kütlesi
m_g	: Her bir iç mafsalsal (gimbal) kütlesi
m_w	: Her bir tekerleğin kütlesi
T_{toplam}	: Robotik platformun toplam kinetik enerjisi
V_{toplam}	: Sistem bileşenlerinin toplam potansiyel enerjisi
$\dot{\theta}$: İç mafsalsal (gimbal) açısal hızı
τ_{gimbal}	: Robotik platformun toplam kinetik enerjisi
$\dot{\phi}$: Robot gövdesinin açısal hızı
ADALINE	: Uyarlanabilir Doğrusal Eleman (<i>Adaptive Linear Element</i>)
ANN	: Yapay Sinir Ağları (<i>Artificial Neural Networks</i>)
ARE	: Cebirsel Riccati Denklemi (<i>Algebraic Riccati Equation</i>)
CARE	: Sürekli Zaman Cebirsel Riccati Denklemi (<i>Continuous-time Algebraic Riccati Equation</i>)
CMG	: Kontrol Moment Jiroskopu (<i>Control Moment Gyroscope</i>)

d	: Dinamik modeldeki afin (sabit) terim vektörü
g	: Yerçekimi ivmesi
GCoSim	: RecurDyn–Simulink eş-simülasyonu (General Co-Simulation)
HJB	: Hamilton-Jacobi-Bellman Denklemleri
LQR	: Doğrusal Kuadratik Regülatör (<i>Linear Quadratic Regulator</i>)
MEX	: MATLAB Yürütülebilir Dosyası (MATLAB Executable)
MLP	: Çok Katmanlı Algılayıcı (Multi Layer Perceptron)
MSE	: Ortalama Kare Hata (Mean Squared Error)
NN	: Sinir Ağı (Neural Network)
NNLQR	: Yapay Sinir Ağı Tabanlı Doğrusal Kuadratik Regülatör
PID	: Oransal-İntegral-Türevsel denetleyici (Proportional-Integral-Derivative)
QRNET	: Sinir Ağı Destekli LQR Kontrol Yaklaşımı
r	: Robot tekerleklerinin yarıçapı
RBF	: Radyal Tabanlı Fonksiyon Sinir Ağları (<i>Radial Basis Function</i>)
RecurDyn	: Recursive Dynamic Analysis Program
RPM	: Dakikadaki Atış/Dönüş Sayısı (Rounds Per Minute / Revolutions Per Minute)
UGV	: İnsansız Kara Aracı (<i>Unmanned Ground Vehicle</i>)
YSA	: Yapay Sinir Ağı
μ	: Sönümlenme (damping) parametresi (Levenberg-Marquardt)
Ω	: Volanın dönme/açısal hızı
A	: Durum-uzay modeline ait durum matrisi
B	: Durum-uzay modeline ait girdi matrisi
F	: Silah taretine uygulanan geri tepme yükü / ani kuvvet
J	: Performans indeksi (maliyet fonksiyonu)
K	: LQR geri besleme kazanç matrisi
P	: Riccati çözüm matrisi
Q	: Durum ağırlık matrisi
R	: Kontrol ağırlık katsayısı
T	: Toplam kinetik enerji
V	: Toplam potansiyel enerji
u	: Kontrol girdisi
x	: Durum vektörü
α	: Silahın yunuslama (kafa) açısı

- ε : Robotun kendi ekseni etrafındaki dönüş hızı
- θ : Kontrol Moment Jiroskopu (CMG) iç mafsal (gimbal) açısı
- φ : Robot gövdesinin dikey eksenle yaptığı eğilme/yunuslama açısı

1. GİRİŞ

Son yıllarda, robotik alanında, yüksek derecede kararlılık ve dinamik uyarlanabilirlik sunabilen otonom sistemlere olan ilgi ivme kazanmaktadır. Doğrusal Kuadratik Regülatör (LQR) kontrolü, kontrol maliyetlerinin minimizasyonu ve doğrusal sistemlerde kararlı dinamik yanıtlar elde edilmesindeki etkinliği nedeniyle, robotik ve kontrol mühendisliği uygulamalarında yaygın bir biçimde tercih edilmektedir. LQR kontrol stratejileri, sistem performansı ile enerji verimliliği arasında optimal bir denge kurarak geri besleme kontrolü üretebilmekte; bu özelliğiyle hassas denetimin zorunlu olduğu platformlar için temel teşkil etmektedir (Çetin ve Ünker, 2024).

Özellikle dar alanlarda, manevra yapma ve yön değişimlerine süratle tepki verme kabiliyetleriyle karakterize edilen iki tekerlekli robotlar, sivil ulaşımdan kişisel mobiliteye, savunma sanayisinden muharebe sahası lojistiğine kadar geniş bir yelpazede incelenmektedir. Özellikle askeri robotik platformlarda (muharebe robotları) denge ve dinamik kararlılığın korunması hayati öneme sahiptir. Bu sistemler, operasyonel görevleri esnasında yüksek etkili dış kuvvetlere, ani momentum değişimlerine ve stabil olmayan zorlu arazi koşullarına maruz kalmaktadır (Çetin ve Ünker, 2024 ; Ünker, 2023). İki tekerlekli robot platformları, doğaları gereği sahip oldukları kararsız (inherently unstable) yapıları nedeniyle, öngörülemeyen çevresel bozucu etkiler altında dahi dengeyi koruyabilecek karmaşık kontrol stratejilerinin geliştirilmesi açısından kritik bir araştırma alanı teşkil etmektedir (Ünker, 2023; Ünker, 2022). Bu tür dinamik ve zorlayıcı koşullar altında sistemin bütünlüğünü koruması ancak gelişmiş ve adaptif kontrol algoritmalarının entegrasyonu ile mümkündür.

Kontrol Moment Jiroskopları (CMG) ve jiroskopik stabilizatörler gibi ileri seviye teknolojilerin geliştirilmesi, bu mekanizmaların kara, hava ve deniz araçlarında ve sivil yapılarda yaygın bir biçimde kullanımına olanak tanımıştır (Ünker, 2023; Ünker, 2020). Bu sistemler, istenmeyen titreşimlerin sönümlenmesi, dinamik kararlılığın artırılması ve mekanik platformların operasyonel verimliliğinin maksimize edilmesi amacıyla jiroskopik presesyon (devinme) momentinden aktif olarak yararlanmaktadır. Mühendislik uygulamalarında jiroskoplar, yalnızca birer ölçüm enstrümanı (sensör) değil, aynı zamanda dinamik kontrol sistemlerinin aktif aktüatör bileşenleridir. Bir jiroskobun çalışma prensibinin temelinde, dış torklara karşı direnç göstererek dönüş ekseninin ataletsel referans çerçevesine (inertial frame of reference) göre sabit bir yönelimde kalmasını sağlayan açısız momentumun korunumu ilkesi yer almaktadır.

Doğrusal Kuadratik Regülatör (LQR) gibi geleneksel kontrol mekanizmaları, sistem kararlılığının sağlanması ve tepki süresinin optimizasyonunda oldukça etkilidir; ancak bu yöntemler, öngörülemeyen veya dinamik olarak değişen operasyonel koşulların üstesinden gelmek için gerekli olan adaptif esneklikten yoksun kalabilmektedir (Nghii vd., 2021). LQR'nin sabit kazançlı yapısı, sistem parametrelerinin nominal değerlerden saptığı durumlarda performans kaybına yol açabilmektedir.

Örneğin literatürde, Radyal Tabanlı Fonksiyon (RBF) Sinir Ağları ile entegre edilen LQR kontrolcülerin, özellikle sistemin denge noktasından uzaklaştığı durumlarda sistematik sapmaları ve dış bozucu etkileri sönmüleyerek, ters sarkaç gibi yüksek dereceden doğrusal olmayan (non-linear) sistemleri dengelemedeki etkinliği kanıtlanmıştır. Benzer şekilde, ADALINE tabanlı yaklaşımlar gibi uyarlanabilir (adaptive) kontrol stratejilerinin, bozucu etkilere karşı dinamik yanıtlar üretebildiği ve özellikle yüksek dereceli doğrusal olmayan dinamiklerde, geleneksel LQR yöntemlerine kıyasla çok daha yüksek bir operasyonel esneklik sunduğu ortaya konmuştur (Gautam, 2016).

Ancak karmaşık ve yapılandırılmamış operasyonel ortamlarda LQR'nin yapısal sınırlamaları belirgin hale gelmektedir. Literatürdeki QRNET gibi hibrit kontrol yaklaşımları, yüksek boyutlu Hamilton-Jacobi-Bellman (HJB) denklemlerinin çözümünde yapay sinir ağlarından yararlanarak LQR mekanizmasını desteklemekte, böylece doğrusal olmayan sistemlerde dayanıklılığı ve kararlılığı önemli ölçüde artırmaktadır (Nakamura-Zimmerer vd., 2021). LQR'nin temel kısıtı, döner ters sarkaç gibi sistemler üzerinde de gözlemlendiği üzere, sistemin yalnızca belirli bir çalışma noktası civarındaki doğrusallaştırılmış (linearized) modeline dayanmasıdır. Bu durum, sistemin denge noktasından uzaklaştığı doğrusal olmayan rejimlerde veya parametrik değişimlerde uyarlanabilirliği sınırlandırmaktadır. Ayrıca, son dönemde gerçekleştirilen regresyon tabanlı ve sinir ağı destekli LQR kazanç tahmin çalışmaları, değişken hız koşulları altında çalışan jiroskopik savaş robotları için umut verici sonuçlar göstermiştir (Oğuz vd.,2026; Çetin vd.,2026). Ayrıca, klasik kontrol yaklaşımları arasında, Doğrusal Kuadratik Regülatör (LQR), sistematik optimal kazanç tasarımı, güçlü kararlılık özellikleri ve hesaplama açısından basitliği nedeniyle robotik ve kontrol mühendisliğinde en yaygın kullanılan yöntemlerden biri olmaya devam etmektedir (Shafiei, 2022; Vu vd., 2017). LQR, durum uzay çerçevesinde durum düzenleme ile kontrol çabasını dengeleyerek kuadratik bir performans indeksini minimize eder ve nominal çalışma noktası yakınında mükemmel kapalı çevrim performansı sağlar.

Ancak klasik LQR'nin temel sınırlaması, tek bir denge noktası etrafında yapılan doğrusallaştırmadan türetilen sabit kazanç yapısıdır. Sistem bu nominal noktadan önemli ölçüde uzaklaştığında, ki bu durum değişken disk hızları, dönüş oranları ve geri tepme bozucuları altında çalışan CMG tabanlı sistemlerde sıklıkla görülür, denetleyici dayanıklılığını kaybeder ve performans düşüşü, hatta tam kararsızlık ortaya çıkabilir (Nghi vd., 2021; Gautam, 2016; Vu vd., 2017).

Bu doğrultuda mevcut çalışma, değişken Kontrol Moment Jiroskopu (CMG) disk hızları için önceden optimize edilmiş LQR kazanç matrislerinden sentezlenen derin öğrenme algoritmalarının entegrasyonu aracılığıyla, iki tekerlekli jiroskopik bir platformun dinamik kararlılığını ve dayanıklılığını artırmaya yönelik özgün bir yaklaşımı incelemektedir. İki tekerlekli jiroskopik sistemlerin dinamik modeli, CMG disk hızına karşı yüksek derecede hassasiyet göstermektedir; bu durum, geleneksel sabit kazançlı LQR kontrolcülerinin değişken operasyonel hızlar ve öngörülemeyen dış koşullar altında dayanıklılık (robustness) performansını korumasını güçleştirmektedir.

Literatürdeki önceki araştırmalar, doğrusal olmayan durumların ve dış bozucu etkilerin yönetilmesinde LQR tabanlı sistemleri geliştirmek amacıyla sinir ağlarını yardımcı bir araç olarak kullanmaya odaklanmış olsa da (Nghi vd., 2021), bu çalışma, deterministik kontrolün kesinliğini uyarlanabilir öğrenme stratejileriyle birleştiren hibrit bir çerçeve oluşturmaktadır. Bu çerçeve kapsamında, yapay sinir ağı doğrudan önceden hesaplanmış optimal LQR katsayıları ile eğitilerek, sistemin farklı operasyonel rejimler arasında gerçek zamanlı ve kesintisiz bir geçiş yapmasına olanak tanınmaktadır.


Doğrusal Kuadratik Regülatör (LQR) kontrolünü desteklemek amacıyla geliştirilen ve genellikle çevrimiçi (online) öğrenme veya uyarlanabilir sinir ağlarına dayanan mevcut yaklaşımların aksine, bu yöntem, geniş bir yelpazedeki Kontrol Moment Jiroskopu (CMG) disk hızları için optimize edilmiş, önceden hesaplanmış LQR kazanç matrisleri kullanılarak çevrimdışı (offline) eğitilmiş bir yapay sinir ağı mimarisini esas almaktadır.

Bu hibrit strateji sayesinde önerilen çerçeve, LQR'nin yapısal kısıtlarını aşmakta ve öngörülemeyen çevresel koşullarda dahi, değişken disk hızları ve yük parametreleri altında robotun dinamik kararlılığını gerçek zamanlı olarak muhafaza etme kabiliyetini geliştirmektedir. Bu araştırma, yapay sinir ağlarının eğitim sürecinde doğrudan LQR'nin deterministik hassasiyetinden faydalanarak, yüksek derecede dinamik sistemler için dayanıklı (robust) ve kararlı bir denetim mekanizması sunmakta; böylece hibrit kontrol literatüründeki gelişmeleri bir adım ileriye taşımaktadır.

2. SİSTEM TANIMLAMA

Şekil 1’de sunulduğu üzere, bir silah sistemiyle entegre edilmiş jiroskopik iki tekerlekli robotik platform, silahın geri tepme (recoil) kuvvetleri ve dış bozucu etkiler altında dahi yüksek dinamik kararlılık ve hassasiyet sağlayacak şekilde tasarlanmıştır. Robot, bozucu etkileri sönmölemek ve iki tekerlek üzerinde dengesini dinamik olarak muhafaza etmek amacıyla kontrol moment jiroskoplarından (CMG) yararlanmaktadır. Bu yapı, platformun karmaşık operasyonel ortamlarda yüksek manevra kabiliyeti ve enerji verimliliği ile görev icra etmesine olanak tanır.


Silah sisteminin entegrasyonu, sistem üzerinde önemli impulsif (ani) geri tepme kuvvetleri oluşturmakta; robot ise bu zorlayıcı etkileri, gelişmiş jiroskopik stabilizasyon mekanizmaları ve hassas kontrol algoritmaları aracılığıyla minimize etmektedir. Tablo 1’de detaylandırıldığı üzere, volanlar (flywheels), mafsal çemberleri (gimbals), tekerlekler ve gövde yapısını kapsayan hassas atalet ve kütle dağılım parametreleri, sistemin genel dinamik performansını doğrudan optimize etmektedir. Ayrıca sistem, Şekil 2 ve Şekil 3’te gösterildiği gibi, operasyonel doğruluk ve hedef hattı stabilitesini korumak için kontrol edilebilir gimbal torku ve değişken disk hızı parametrelerini aktif olarak kullanmaktadır.




Şekil 1. Dönüş hızına (ϵ) sahip iki tekerlekli bir robotun fiziksel modeli

Tablo 1. Silahlı jiroskopik robotun fiziksel özellikleri (Çetin, 2024)

Sembol	Sayısal değerler	Açıklama
g	9.80665 m/s^2	Yerçekimi ivmesi
r	125 mm	Her bir tekerleğin yarıçapı
R_b	0.1822 m	Gövdenin kütle merkezinin uzunluğu
R_c	0.4000 m	Silah taretini kütle merkezinin uzunluğu
R_g	0.120 mm	Her bir jiroskobun viraj alma yarıçapı
R_w	302.5 mm	Her bir tekerleğin viraj alma yarıçapı
m_b	18.6839780819629 kg	Gövde kütlesi
m_c	32.9259498913541 kg	Top kütlesi
m_d	8.04305131897262 kg	Her bir volanın kütlesi
m_g	1.51609201864529 kg	Her bir iç mafsaldın (gimbal) kütlesi
m_f	2.98299999999993 kg	Her bir dış mafsaldın (gimbal) kütlesi
m_w	17.7033576411532 kg	Her bir tekerleğin kütlesi
I_p	$0.02333499618287 \text{ kg.m}^2$	Her bir volanın dönüş eylemsizliği
I_o	$0.01401769203259 \text{ kg.m}^2$	Her bir volanın kütle eylemsizlik momenti
I_{gx}	$0.00732123414677 \text{ kg.m}^2$	İç mafsaldın x-yönü boyunca asal eylemsizlik momenti
I_{gy}	$0.00644373266792 \text{ kg.m}^2$	İç mafsaldın y-yönü boyunca asal eylemsizlik momenti
I_{gz}	$0.00158758607978 \text{ kg.m}^2$	İç mafsaldın z-yönü boyunca asal eylemsizlik momenti
I_{fx}	0.01793055200	Dış mafsaldın x-yönü boyunca asal eylemsizlik momenti
I_{fy}	0.03564985674158	Dış mafsaldın y-yönü boyunca asal eylemsizlik momenti
I_{fz}	0.01896222140532	Dış mafsaldın z-yönü boyunca asal eylemsizlik momenti
I_{bx}	$0.264998284262085 \text{ kg.m}^2$	Gövdenin x-yönü boyunca asal eylemsizlik momentleri
I_{by}	$0.545455494328967 \text{ kg.m}^2$	Gövdenin y-yönü boyunca asal eylemsizlik momentleri
I_{bz}	$0.748189395896411 \text{ kg.m}^2$	Gövdenin z-yönü boyunca asal eylemsizlik momentleri
I_{cx}	$0.181247054149038 \text{ kg.m}^2$	Topun x-yönü boyunca asal eylemsizlik momentleri
I_{cy}	$0.258310357854772 \text{ kg.m}^2$	Topun y-yönü boyunca asal eylemsizlik momentleri
I_{cz}	$0.120890993681732 \text{ kg.m}^2$	Topun z-yönü boyunca asal eylemsizlik momentleri
I_{wx}	$0.169125843507142 \text{ kg.m}^2$	Tekerleğin x-yönü boyunca asal eylemsizlik momentleri
I_{wy}	$0.0908587843781125 \text{ kg.m}^2$	Tekerleğin y-yönü boyunca asal eylemsizlik momentleri
ε	2 rad/s	Robotun dönüş hızı
Ω	1000-4000 rad/s	Volanın dönüş hızı
F	0 - 3000 N	Silah taretine uygulanan geri tepme yükü (ani kuvvet)
α	$0.25(1 - \cos 2.5t) \text{ rad}$	Silahın yunuslama (kafa) açısı



Şekil 2. Kontrol torku (τ_{gimbal}) etkisi altındaki jiroskopik iki tekerlekli robot



Şekil 3. Bir silah sistemiyle entegre edilmiş jiroskopik iki tekerlekli robotun yandan görünümü

2.1 Jiroskopik İki Tekerlekli Robot İçin Hareket Denklemleri

Sistemin dinamik davranışını tanımlayan hareket denklemlerini türetmek amacıyla, volanlar, mafsal çemberleri (gimbals), gövde, mühimmat/silah sistemi ve tekerlek birimlerinin kinetik enerjilerinin ayrı ayrı tanımlanması hesaplama kolaylığı sağlamaktadır. Bu doğrultuda, basitleştirilmiş modeli Şekil 1-3'te sunulan çift jiroskoplu ve iki tekerlekli robotik platformun toplam kinetik enerjisini oluşturan bileşenler aşağıda formüle edilmiştir:

$$T_{vola} = \frac{1}{2} m_d \varepsilon^2 R_g^2 + \frac{1}{2} I_o \left[(\dot{\theta} + \varepsilon \sin \varphi)^2 + (\dot{\varphi} \cos \theta + \varepsilon \sin \theta)^2 \right] + \frac{1}{2} I_p (\Omega + \dot{\varphi} \sin \theta - \varepsilon \cos \theta \cos \varphi)^2 \quad (\text{Eşitlik 1})$$

$$T_{volan} = \frac{1}{2}m_d \varepsilon^2 R_g^2 + \frac{1}{2}I_p(-\Omega - \varepsilon)^2 \quad (\text{Eşitlik 2})$$

$$T_{iç\ gimba} = \frac{1}{2}m_g \varepsilon^2 R_g^2 + \frac{1}{2}I_{gx}(\dot{\varphi} \cos \theta + \varepsilon \sin \theta)^2 + \frac{1}{2}I_{gy}(\dot{\varphi} \sin \theta - \varepsilon \cos \theta \cos \varphi)^2 + \frac{1}{2}I_{gz}(\dot{\theta} + \varepsilon \sin \varphi)^2 \quad (\text{Eşitlik 3})$$

$$T_{iç\ gimba} = \frac{1}{2}m_g \varepsilon^2 R_g^2 + \frac{1}{2}I_{gy}(-\varepsilon)^2 \quad (\text{Eşitlik 4})$$

$$T_{dış\ gimba} = \frac{1}{2}m_f \varepsilon^2 R_f^2 + \frac{1}{2}I_{fx}\dot{\varphi}^2 + \frac{1}{2}I_{fy}(-\varepsilon \cos \varphi)^2 + \frac{1}{2}I_{fz}(\varepsilon \sin \varphi)^2 \quad (\text{Eşitlik 5})$$

$$T_{dış\ gimbal2} = \frac{1}{2}m_f \varepsilon^2 R_f^2 + \frac{1}{2}I_{fy}(-\varepsilon)^2 \quad (\text{Eşitlik 6})$$

$$T_{gövde} = \frac{1}{2}m_b(R_b \varepsilon \sin \varphi)^2 + \frac{1}{2}m_b[(-R_b \dot{\varphi} \sin \varphi)^2 + (R_b \dot{\varphi} \cos \varphi)^2] + \frac{1}{2}I_{bx}\dot{\varphi}^2 + \frac{1}{2}I_{by}\varepsilon^2 \cos^2 \varphi + \frac{1}{2}I_{bz}\varepsilon^2 \sin^2 \varphi \quad (\text{Eşitlik 7})$$

$$T_{silah} = \frac{1}{2}m_c(R_c \varepsilon \sin \varphi)^2 + \frac{1}{2}m_c[(-R_c \dot{\varphi} \sin \varphi)^2 + (R_c \dot{\varphi} \cos \varphi)^2] + \frac{1}{2}I_{cy}\varepsilon^2 \cos^2 \alpha + \frac{1}{2}I_{cz}\varepsilon^2 \sin^2 \alpha \quad (\text{Eşitlik 8})$$

$$T_{teker} = \frac{1}{2}m_w \varepsilon^2 R_w^2 + \frac{1}{2}I_{wx} \left(\varepsilon \frac{R_w}{r} \right)^2 + \frac{1}{2}I_{wy}\varepsilon^2 \quad (\text{Eşitlik 9})$$

Bu doğrultuda, sistemin toplam kinetik enerjisi (T_{toplam}), yukarıda tanımlanan her bir alt bileşenin enerjilerinin süperpozisyonu ile elde edilmektedir. Robotik platformun toplam kinetik enerjisi, aşağıdaki genel formülasyon ile hesaplanmaktadır:

$$T_{toplam} = T_{volan1} + T_{vol} + T_{iç\ gimbal1} + T_{iç\ gimbal2} + T_{dış\ gimbal1} + T_{dış\ gimbal2} + T_{gövde} + T_{silah} + 2T_{teker} \quad (\text{Eşitlik 10})$$

Matematiksel modelin sadeleştirilmesi amacıyla, mafsal çemberlerinin (gimbals) ve volanların potansiyel enerjileri ihmal edilmiştir. Bu basitleştirmeyi fiziksel olarak mümkün kılmak için jiroskopların kütle merkezi, yaylı kütle ile aks birleşim noktasından geçen dönme eksenini üzerinde konumlandırılmıştır. Bu kabuller neticesinde, sistemin toplam potansiyel enerjisi (V_{toplam}) yalnızca ana gövde parametrelerine bağlı olarak aşağıdaki forma indirgenmektedir:

$$V_{toplam} = (m_b R_b + m_c R_c) g \cos \varphi \quad (\text{Eşitlik 11})$$

Yukarıda türetilen toplam kinetik ve potansiyel enerji ifadelerinin iki serbestlik dereceli sistemler için tanımlanan Lagrange denklemlerinin yerine konulmasıyla, platformun dinamik davranışını betimleyen hareket denklemleri elde edilmektedir. Bu bağlamda, her bir genelleştirilmiş koordinat (Θ ve φ) için Lagrange formülasyonu aşağıdaki şekilde uygulanmaktadır:

$$\frac{d}{dt} \left(\frac{\partial T_{toplam}}{\partial \dot{\theta}} \right) - \frac{\partial T_{toplam}}{\partial \theta} + \frac{\partial V_{toplam}}{\partial \theta} = 0 \quad (\text{Eşitlik 12})$$

$$\frac{d}{dt} \left(\frac{\partial T_{toplam}}{\partial \dot{\varphi}} \right) - \frac{\partial T_{toplam}}{\partial \varphi} + \frac{\partial V_{toplam}}{\partial \varphi} = -F(t) R_c (\cos \alpha \cos \varphi - \sin \alpha \sin \varphi) \quad (\text{Eşitlik 13})$$

Yukarıda sunulan doğrusal olmayan Lagrange formülasyonundan hareketle, sistemin dinamiklerini betimleyen iki serbestlik dereceli hareket denklemleri aşağıdaki biçimde türetilmektedir:

$$G_1 \ddot{\theta} + G_1 \varepsilon \dot{\varphi} \cos \varphi + G_2 (\dot{\varphi} \cos \theta + \varepsilon \sin \theta) (\dot{\varphi} \sin \theta - \varepsilon \cos \theta) - G_3 (\dot{\varphi} \cos \theta + \varepsilon \sin \theta \cos \varphi) (\dot{\varphi} \sin \theta - \varepsilon \cos \theta \cos \varphi) - I_p \Omega (\dot{\varphi} \cos \theta + \varepsilon \sin \theta \cos \varphi) = 0 \quad (\text{Eşitlik 14})$$

$$(G_2 \cos^2 \theta + G_3 \sin^2 \theta + G_4) \ddot{\varphi} - G_2 \dot{\varphi}^2 \sin \theta \cos \theta + (G_2 - G_3 \cos \varphi) (\varepsilon \dot{\theta} \cos^2 \theta - \varepsilon \dot{\theta} \sin^2 \theta) - G_5 \dot{\varphi} \dot{\theta} \sin \theta \cos \theta - G_1 \dot{\theta} \varepsilon \cos \varphi - (G_6 + G_3 \cos^2 \theta) \varepsilon^2 \sin \varphi \cos \varphi - (m_b R_b + m_c R_c) g \sin \varphi + I_p \Omega (\dot{\theta} - \varepsilon \sin \varphi) \cos \theta = -F(t) R_c (\cos \alpha \cos \varphi - \sin \alpha \sin \varphi) \quad (\text{Eşitlik 15})$$


Burada,

$$\begin{aligned} G_1 &= I_o + I_{gz} \\ G_2 &= I_o + I_{gx} \\ G_3 &= I_p + I_{gy} \\ G_4 &= m_b R_b^2 + m_c R_c^2 + I_{bx} + I_{fx} \\ G_5 &= G_2 - 2G_3 = I_o + I_{gx} - 2(I_p + I_{gy}) \\ G_6 &= m_b R_b^2 + m_c R_c^2 - I_{by} - I_{fy} + I_{bz} + I_{fz} + G_1 \end{aligned} \quad (\text{Eşitlik 16})$$


Bu çalışmada, platformun dinamik davranışını analiz etmek amacıyla Tablo 1'de sunulan fiziksel parametreler esas alınarak hareket denklemleri MATLAB ortamında

çözömlenmiştir. Sistemin dinamik yanıtlarını doğrulamak ve kapsamlı bir analiz gerçekleştirmek üzere, eşzamanlı olarak RecurDyn ve MATLAB/Simulink yazılımları kullanarak simölasyon çalışmaları yürütölmüştür.

Tüm simölasyon senaryoları sıfır başlangıç koşulları altında 60 saniyelik toplam süre boyunca koşturulmuş ve sayısal çözümlerde 0.001 saniyelik sabit zaman adımı (fixed-step size) kullanılmıştır. Elde edilen sonuçların hızlı bir şekilde kararlılığa ulaşması nedeniyle, grafiksel gösterimlerde netliği artırmak amacıyla yalnızca ilk 10 saniyelik zaman yanıtlarına yer verilmiştir.



Şekil 4. $F=120$ N sabit geri tepmeye maruz kalan $\alpha=0$ rad silah açısı ile $\varepsilon = 2$ rad/s and $\Omega = 2000$ rad/s için RecurDyn ve teorik simölasyonların karşılaştırılması ($\tau_{\text{gimbal}} = 0$ N)



Şekil 5. $F=120$ N sabit geri tepmeye maruz kalan $\alpha=0$ rad silah açısı ile $\varepsilon = 2$ rad/s ve $\Omega=4000$ rad/s için RecurDyn ve teorik simülasyonların karşılaştırılması ($\tau_{\text{gimbal}} = 0$ N)

3. LQR-KONTROLCÜ TASARIMI

Sistemin denge noktasındaki davranışı incelendiğinde, sıfır mafsalsal (gimbal) açısı için mafsalsal hızı da sıfır değerini almaktadır. Mafsalsal titreşimlerinin ve presesyon (devinme) hareketinin küçük genlikli olduğu varsayımı altında, hız bileşenlerini içeren yüksek dereceli terimlerin robotun denge konumu üzerindeki etkisi ihmal edilebilir düzeydedir. Bu doğrusallaştırma kabulleri neticesinde, Denklem (14) ve (15) ile verilen dinamik ifadeler aşağıdaki basitleştirilmiş forma indirgenmektedir:

$$G_1\ddot{\theta} + G_1\varepsilon\dot{\varphi} + G_2(\dot{\varphi} + \varepsilon\dot{\theta})(-\varepsilon) - G_3(\dot{\varphi} + \varepsilon\dot{\theta})(-\varepsilon) - I_p\Omega(\dot{\varphi} + \varepsilon\dot{\theta}) = 0 \quad (\text{Eşitlik 17})$$

$$(G_2 + G_4)\ddot{\varphi} + (G_2 - G_1 - G_3)(\varepsilon\dot{\theta}) - (G_6 + G_3)\varepsilon^2\varphi - (m_b R_b + m_c R_c)g\varphi + I_p\Omega(\dot{\theta} - \varepsilon\dot{\varphi}) = -F(t)R_c(\cos\alpha\cos\varphi - \sin\alpha\sin\varphi) \quad (\text{Eşitlik 18})$$

Sistemin dinamik durumunu temsil eden durum vektörü (x), dört boyutlu bir yapıdadır ve $x = [\varphi, \dot{\varphi}, \theta, \dot{\theta}]^T$ şeklinde tanımlanmaktadır. Burada θ gövde açısını, φ ise mafsalsal (gimbal) açısını temsil ederken; $\dot{\theta}$ ve $\dot{\varphi}$ bu değişkenlerin zamana göre türevlerini (açısal hızlarını) ifade etmektedir. Kontrol girdisinin ($u = [0, 0, \tau_{gimbal}, 0]^T$) Denklem (17)'ye dahil edilmesiyle, sistem dinamiklerini tanımlayan Denklem (17) ve (18), doğrusal olmayan kontrol teorisinde yaygın olarak kullanılan afin formda (affine form) ifade edilebilir. Kararlılık analizi ve kontrolcü tasarımı süreçlerinde, sistemin denge noktası civarındaki davranışı esas alınarak aşağıdaki kabul yapılmaktadır:

$$\dot{x} = Ax + Bu + d \quad (\text{Eşitlik 19})$$

Sistemin dinamik modelini temsil eden durum matrisi ($A \in \mathcal{R}^{4 \times 4}$), girdi matrisi ($B \in \mathcal{R}^{4 \times 1}$) ve afin terimi ($d \in \mathcal{R}^4$) aşağıdaki formülasyonlarla tanımlanmaktadır:

Burada θ , robot gövdesinin dikey eksenle yaptığı eğilme açısını; φ ise Kontrol Moment Jiroskopu (CMG) mafsalsal (gimbal) açısını temsil etmektedir. Kontrol girdisi (u), CMG ünitesi tarafından gövdeye uygulanan kontrol torkunu ifade eder. Bu matris yapısı, sistemin doğrusal olmayan dinamiklerinin denge noktası civarındaki davranışını ve kontrol girdisinin sistem üzerindeki etkisini matematiksel olarak özetlemektedir.

$$A = \begin{bmatrix} 0 & 1 & 0 & 0 \\ a_{21} & 0 & 0 & a_{24} \\ 0 & 0 & 0 & 1 \\ 0 & a_{42} & a_{43} & 0 \end{bmatrix}$$

$$B = \begin{bmatrix} 0 \\ 0 \\ 0 \\ \frac{1}{G_1} \end{bmatrix} \quad B_d = \begin{bmatrix} 0 \\ \frac{-F(t)R_c(\cos \alpha \cos \varphi - \sin \alpha)}{G_2 + G_4} \\ 0 \\ 0 \end{bmatrix} \quad (\text{Eşitlik 20})$$

Burada,

$$a_{21} = -\frac{-(m_b R_b + m_c R_c)g - (G_6 + G_3)\varepsilon^2 - I_p \Omega \varepsilon}{G_2 + G_4}$$

$$a_{24} = -\frac{\varepsilon(G_2 - G_1 - G_3) + I_p \Omega}{G_2 + G_4}$$

$$a_{42} = -\frac{\varepsilon(G_1 - G_2 + G_3) - I_p \Omega}{G_1}$$

$$a_{43} = -\frac{\varepsilon^2(G_3 - G_2) - \varepsilon I_p \Omega}{G_1}$$

Tablo 1’de sunulan fiziksel parametreler ile belirlenen operasyonel çalışma noktası ($\Omega = 4000$ rad/s ve $\varepsilon = 2$ rad/s) değerleri kullanılarak; sistemin denge noktası civarındaki durum-uzay (state-space) matrisleri sayısal olarak aşağıdaki şekilde elde edilmiştir:

$$A = \begin{bmatrix} 0 & 1 & 0 & 0 \\ 60 & 0 & 0 & -15 \\ 0 & 0 & 0 & 1 \\ 0 & 5978 & 11960 & 0 \end{bmatrix}$$

$$B = \begin{bmatrix} 0 \\ 0 \\ 0 \\ 64.08 \end{bmatrix} \quad B_d = \begin{bmatrix} 0 \\ -7.7520 \\ 0 \\ 0 \end{bmatrix}$$

Afin model (Denklem 19) için denge noktası (x^*, u^*) , sistem dinamiklerinin zamana göre değişiminin sıfır olduğu durum olarak tanımlanır. Bu bağlamda denge noktası, aşağıdaki cebirsel denklemin çözümü ile elde edilmektedir:

$$0 = Ax + Bu + d \quad (\text{Eşitlik 21})$$

Gerçekleştirilen analizler neticesinde, sistemin denge durumunu muhafaza etmesi için gereken denge girdi değeri ($u^* = 0$) ve buna karşılık gelen denge durum vektörü ($x^* = [\varphi^*, 0, 0, 0]^T$) elde edilmiştir. Sistemin statik dengesini tanımlayan gövde eğim açısı (φ^*), analitik olarak $\varphi^* = \frac{-F(t)R_c(\cos \alpha \cos \varphi - \sin \alpha \sin \varphi)}{-(m_b R_b + m_c R_c)g - (G_6 + G_3)\varepsilon^2 - I_p \Omega \varepsilon}$ formülasyonla ifade edilebilir.

Yapılan sayısal hesaplamalar sonucunda, gövde eğim denge açısı $\varphi^* = 0.1284 \text{ rad}$ olarak belirlenmiştir. Bu teorik sonuç, simülasyon çalışmaları neticesinde elde edilen nihai gövde eğim değeri ile yüksek derecede tutarlılık sergilemektedir. Bu durum, türetilen matematiksel modelin ve uygulanan doğrusallaştırma yaklaşımlarının doğruluğunu ampirik olarak kanıtlamaktadır.

Denge noktası etrafında klasik bir LQR tasarlamak için sapma değişkenleri $\tilde{x} = x - x^*, \tilde{u} = u - u^*$ tanımlanır. Denge denklemi kullanıldığında, doğrusal zamanla değişmeyen modelin sapması aşağıdaki gibi elde edilir:

$$\dot{\tilde{x}} = A\tilde{x} + B\tilde{u} \quad (\text{Eşitlik 22})$$

Bu matematiksel çerçeve, önerilen kontrolcü tasarımının temel dayanağını oluşturmaktadır. Doğrusal Kuadratik Regülatör (LQR) tasarımında amaç; sistem performansını ve enerji tüketimini optimize eden, aşağıdaki kuadratik performans indeksini (J) minimize edecek optimal durum geri besleme kazanç matrisini (K) hesaplamaktır:

$$J = \int_{t=0}^{\infty} (\tilde{x}^T Q \tilde{x} + \tilde{u}^T R \tilde{u}) dt \quad (\text{Eşitlik 23})$$

Burada $Q \in \mathcal{R}^{4 \times 4}$, durum ağırlık (ceza) matrisini; $R \in \mathcal{R}^{1 \times 1}$ ise kontrol girdisi ceza katsayısını temsil etmektedir. Bu çalışmada, gövde eğim açısı ve CMG mafsalları (gimbal) açısını denge noktası civarında minimum hata payı ile stabilize etmek amacıyla, ilgili durum değişkenlerine karşılık gelen ağırlık değerleri yüksek seçilmiştir. Kontrol sinyali üzerindeki kısıtlamayı belirleyen R parametresi $R = 10^{-2}$ olarak

belirlenmiş; böylece klasik LQR çerçevesi dahilinde sistemin dinamik yanıt hızını artıran yüksek kazançlı (high-gain) bir durum geri besleme yapısı elde edilmiştir.

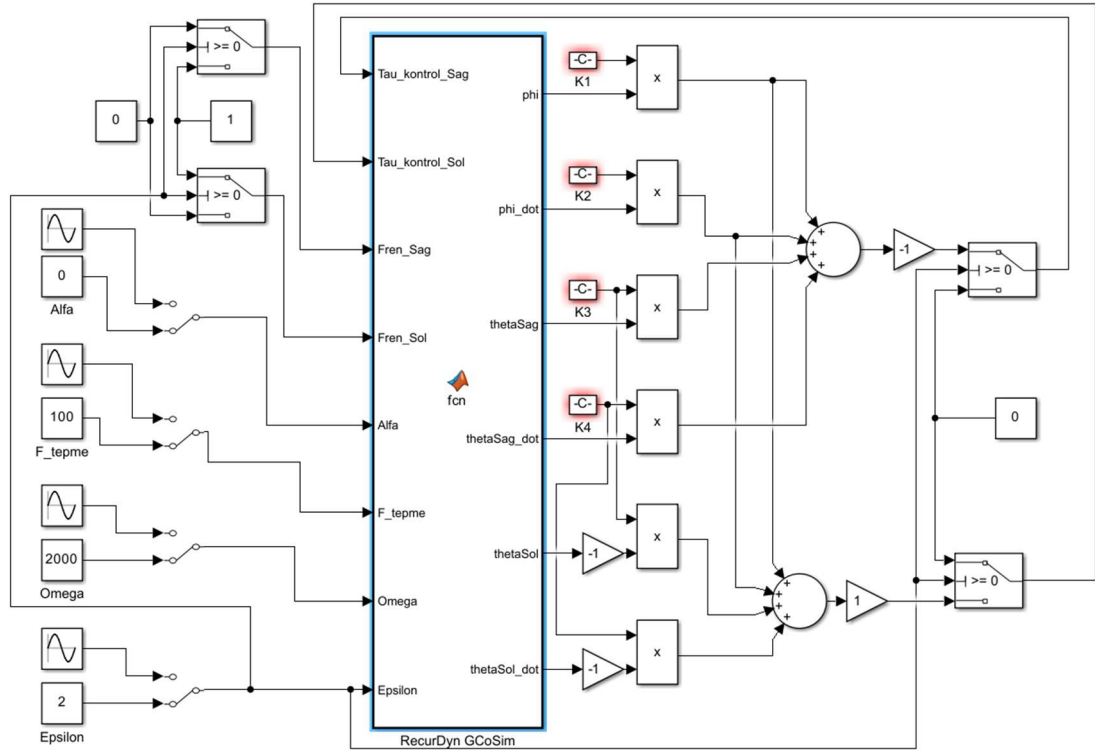

LQR optimizasyon probleminin çözümü için, Denklem (22)'de sunulan sistem modeline dayalı olarak tanımlanan Sürekli Zaman Cebirsel Riccati Denklemi (ARE) aşağıda verilmiştir:

$$A^T P + PA - PBR^{-1}B^T P + Q = 0 \quad (\text{Eşitlik 24})$$

Söz konusu Cebirsel Riccati Denklemi (ARE) sayısal yöntemlerle çözülerek, sistemin kararlılığını garanti eden pozitif tanımlı (positive-definite) P matrisi elde edilmektedir. Bu matris doğrultusunda, sistemi minimize edilmiş bir performans indeksiyle dengeye getiren optimal durum geri besleme kazanç matrisi (K), $K = R^{-1}B^T P$ bağıntısı ile hesaplanmaktadır.

Bu çalışma kapsamında gerçekleştirilen sayısal analizler ve belirlenen ağırlık matrisleri (Q ve R) neticesinde, kontrolcü için gerekli olan durum geri besleme kazancı $K = [-594.5574 \quad -18.4777 \quad -213.1497 \quad 2.1296]$ olarak elde edilmiştir.

Şekil 6'da detaylandırıldığı üzere, LQR kontrolcü tasarım süreci, sistem davranışını hassas bir şekilde modellemek ve denetlemek amacıyla türetilen Denklem (14) ve (15) dinamik ifadeleri temel alınarak önerilen robot platformuna uygulanmıştır. Ancak gerçek dünya uygulamalarında, robotun değişen yük koşulları ve operasyonel gereksinimleri doğrultusunda CMG disk hızının (Ω) değişkenlik göstermesi zorunludur.




Şekil 6. Simulink-RecurDyn GCoSim eş-simülasyonu ile çift CMG kontrol ve anahtarlama mimarisinin blok diyagramı

Şekil 7’de sunulan zaman yanıtları incelendiğinde, LQR kontrolcüsü uygulanan sistemde mafsal açısı (Θ), kontrolsüz durumdaki yüksek genlikli salınımların aksine, 1 rad değerinde hızla stabilize olmaktadır. Bu değer, kontrol edilmeyen sistemin serbest salınım hareketindeki maksimum genlik seviyesine karşılık gelen kararlı durum referansını temsil etmektedir.

Aynı grafik üzerinde gözlemlenen LQR kontrollü gövde açısı (φ) ise, yaklaşık 1 saniye gibi kısa bir sürede 0.13 radyan seviyesine yerleşerek (settling), kontrolsüz davranışta izlenen salınımların merkez noktasını (ortalama değerini) başarılı bir şekilde korumaktadır. Bu sonuçlar, tasarlanan LQR tabanlı denetim mekanizmasının sistemin

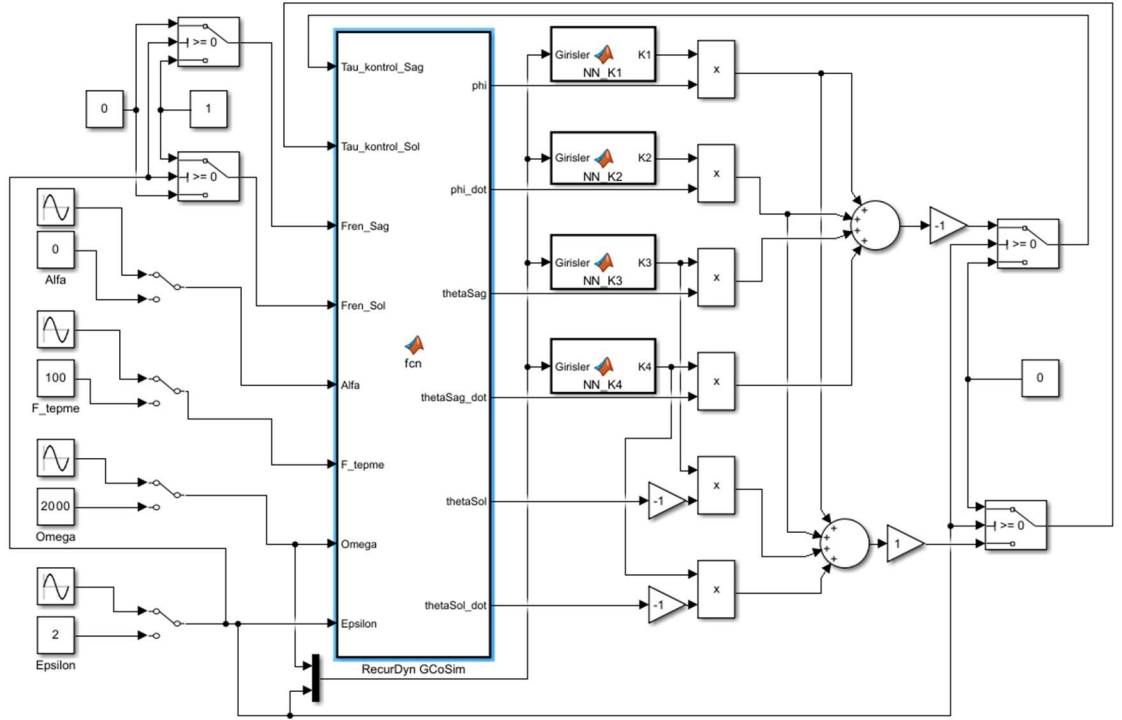
dinamik kararlılığını sağlamadaki etkinliğini ve geçici rejim (transient response) özelliklerini optimize etmedeki başarısını doğrulamaktadır.



Şekil 7. $F=120$ N sabit geri tepmeye maruz kalan $\alpha=0$ rad silah açısı ile $\varepsilon = 2$ rad/s ve $\Omega = 4000$ rad/s için kontrolsüz mafsals ($\tau_{\text{gimbal}} = 0$ N) ve LQR kontrollü ($\tau_{\text{gimbal}} = -Kx$) mafsals simülasyonlarının karşılaştırması.

4. SINIR AĞI TABANLI KONTROLCÜ TASARIMI

Şekil 8, disk hızını giriş verisi olarak kabul eden ve LQR katsayılarını anlık olarak güncelleyerek kontrol torkunu (u) yöneten Yapay Sinir Ağı (YSA) tabanlı kapalı çevrim sistem mimarisini göstermektedir. Üretilen bu tork, dinamik ve değişken çalışma koşullarında dengeyi muhafaza etmek amacıyla CMG diskini dikey eksen doğrultusunda hizalayarak robotun kararlılığını sağlamaktadır.



Şekil 8. NNLQR kapalı çevrim kontrol diyagramı

Ω parametresindeki bu değişimler, sistemin karakteristik matrislerini doğrudan etkileyerek dinamik yapıyı başkalaştırmaktadır. Bu durum, yalnızca belirli nominal parametreler için optimize edilmiş sabit kazançlı bir LQR kontrolcüsünün parametrik değişimler karşısında sistem kararlılığını yitirmesine veya performans kaybına uğramasına neden olabilmektedir (Oğuz vd.,2026; Çetin vd., 2026). Bu doğrultuda, sistemin geniş bir çalışma aralığında stabilizasyonunu korumak için disk hızındaki değişimlere adaptif olarak yanıt verebilen bir kontrol stratejisine ihtiyaç duyulmaktadır.

Söz konusu zorlukların üstesinden gelmek ve sistemin tüm çalışma aralığında kararlılığını sağlamak amacıyla, Ω değerleri 2000 rad/s ile 5000 rad/s arasında 100

rad/s'lik adımlarla, ε değerleri ise 0 rad/s ile 3 rad/s arasında 0.001 rad/s'lik hassas artışlarla sistematik olarak taranmıştır. Bu geniş parametre uzayı boyunca robotu stabilize edecek optimal LQR kazanç katsayıları (K), her bir çalışma noktası için ayrı ayrı hesaplanarak kapsamlı bir veri kümesi oluşturulmuştur.

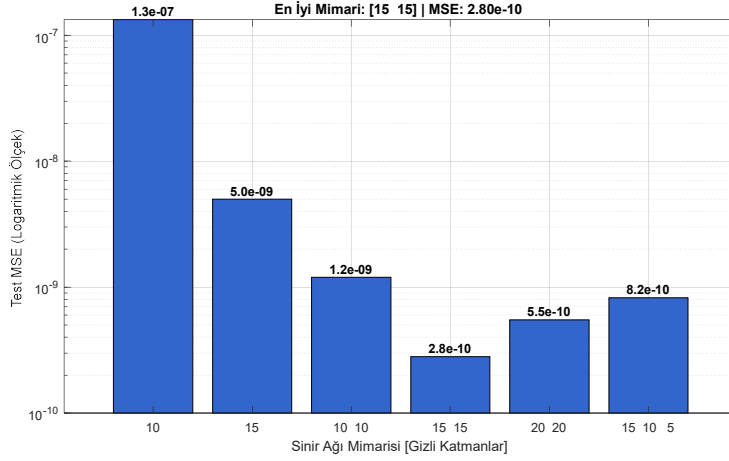
Çalışmanın temel amacı, değişken disk hızına (Ω) ve dönüş hızına (ε) bağlı olarak bu LQR katsayılarını anlık olarak tahmin edebilen (prediction) bir Yapay Sinir Ağı (YSA) mimarisi tasarlamaktır. Bu yaklaşım, sistemin dinamik yapısındaki değişimlere karşı kontrolcünün kazanç değerlerini (gain scheduling) otomatik olarak güncellemesine olanak tanımaktadır.

Hedeflenen kestirim performansı için en uygun yapay sinir ağı (YSA) mimarisini belirlemek amacıyla, farklı gizli katman konfigürasyonlarını kapsayan kapsamlı bir karşılaştırmalı analiz gerçekleştirilmiştir. Şekil 9, incelenen altı farklı ağ mimarisinin Test Ortalama Kare Hatası (MSE) değerlerini karşılaştırmalı analizi kolaylaştırmak adına logaritmik ölçekte sunmaktadır.

Değerlendirilen mimariler, düşük hesaplama maliyetli tek katmanlı tasarımlardan sistemin doğrusal olmayan dinamiklerini daha hassas modelleyebilen karmaşık çok katmanlı yapılara kadar geniş bir yelpazede çeşitlendirilmiştir. Hata analizleri sonucunda, hem eğitim hızı hem de genelleme yeteneği (generalization) açısından optimum performansı sergileyen katman yapısı, nihai kontrolcü tasarımı için seçilmiştir.

Sütun grafiğinde sunulan veriler doğrultusunda, her biri 15 nörondan oluşan iki gizli katmanlı [15 15] konfigürasyonu, 2.80×10^{-10} değeriyle en düşük Test Ortalama Kare Hatasını (MSE) vererek optimum mimari olarak belirlenmiştir. Elde edilen sonuçlar, ağ derinliğinin tek katmanlı yapılardan (örneğin [10] veya [15]) çift katmanlı bir yapıya çıkarılmasının, MSE değerindeki keskin düşüşten de anlaşılacağı üzere, kestirim doğruluğunu (predictive accuracy) mertebesel olarak artırdığını kanıtlamaktadır.

Öte yandan, model karmaşıklığının [20 20] veya üç katmanlı [15 10 5] konfigürasyonlarına yükseltilmesi, test hatasında sırasıyla 5.5×10^{-10} ve 8.2×10^{-10} seviyelerine varan hafif artışlara yol açmıştır. Bu durum, [15 15] modelinin hem yetersiz öğrenme (underfitting) hem de aşırı öğrenme (overfitting) tuzaklarından etkili bir şekilde kaçınarak, öğrenme kapasitesi ile genelleme (generalization) yeteneği arasında ideal bir denge kurduğunu doğrulamaktadır.



Şekil 9. Izgara araması (Grid Search) ile belirlenen optimize edilmiş sinir ağı yapısı

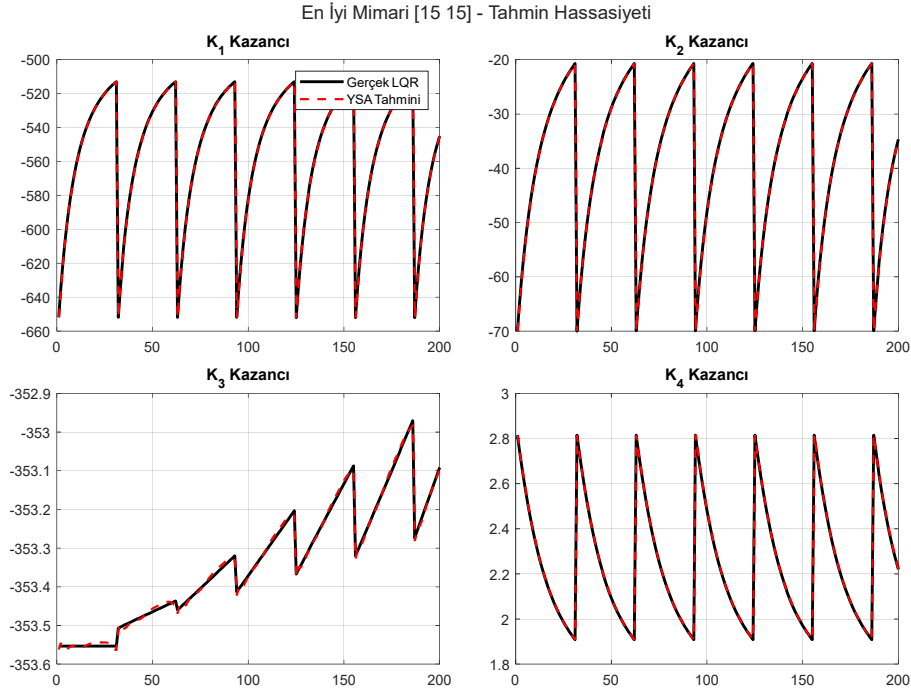
Optimize edilmiş [15 15] sinir ağı mimarisinin nihai doğrulaması; ağ tarafından kestirilen çıktıların analitik olarak hesaplanan gerçek Doğrusal Kuadratik Regülatör (LQR) kazanç matrisi bileşenleri (K_1 , K_2 , K_3 ve K_4) ile karşılaştırıldığı Şekil 10'da sunulmaktadır. Modelin izleme (tracking) performansını ve genelleme yeteneğini değerlendirmek amacıyla, YSA tarafından tahmin edilen değerler (kesikli kırmızı çizgiler) test veri kümesindeki temel doğru (ground truth) verileri (düz siyah çizgiler) ile eşzamanlı olarak grafik edilmiştir.

Görsel sonuçlar incelendiğinde, kestirimlerin gerçek değerler ile neredeyse tam bir örtüşme sergilediği görülmektedir. Bu yüksek korelasyon, ağın sistem dinamiklerindeki değişimleri başarıyla öğrendiğini ve değişken çalışma koşulları altında ihtiyaç duyulan optimal kontrol kazançlarını son derece düşük hata paylarıyla üretebildiğini teyit etmektedir.

Elde edilen sonuçlar, dört kontrol parametresinin tamamı için Yapay Sinir Ağı (YSA) kestirimleri ile analitik LQR kazançları arasında neredeyse kusursuz bir örtüşme olduğunu ortaya koymaktadır. Kazanç yörüngelerinin (gain trajectories) doğrusal olmayan ve periyodik karakteristiğine rağmen, ağ her bir tepe noktasını ve geçici değişimi (transient variation) herhangi bir faz gecikmesi veya genlik sapması olmaksızın yüksek bir hassasiyetle takip etmektedir.

Bu yüksek sadakatli (high-fidelity) izleme performansı, YSA'nın sistem durumları ile optimal kontrol kazançları arasındaki karmaşık ve doğrusal olmayan eşlemeyi (mapping) başarıyla öğrendiğini kanıtlamaktadır. Tüm kanallarda gözlemlenen minimal artık (residual) hata değerleri, önerilen [15 15] mimarisinin gürültüye karşı dayanıklı (robust) olduğunu ve dinamik kontrol sistemlerinde gerçek zamanlı kazanç

zamanlaması (real-time gain scheduling) için geleneksel, yoğun hesaplama gerektiren yöntemlere güçlü bir alternatif teşkil ettiğini doğrulamaktadır.



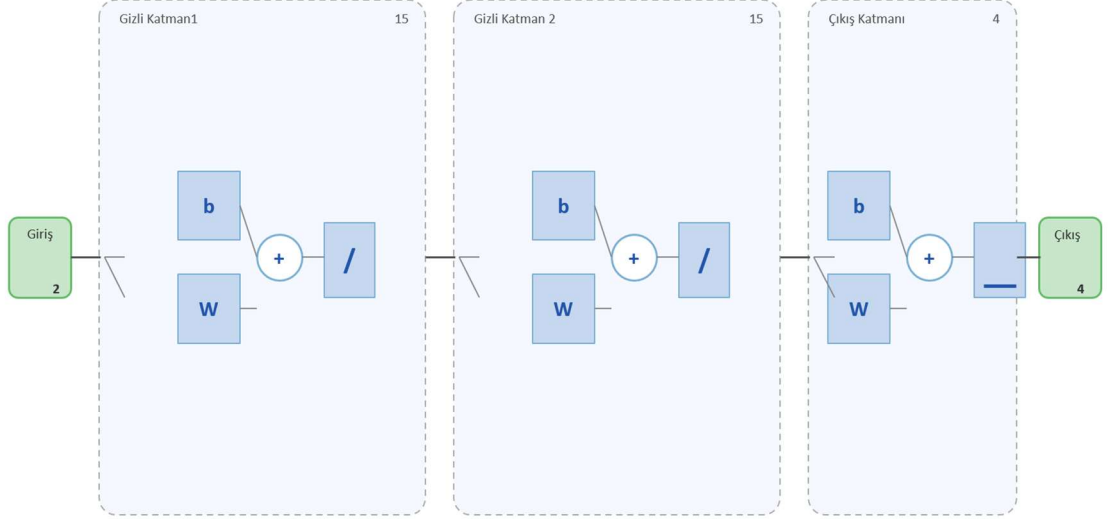
Şekil 10. Tahmin hassasiyeti

Önerilen Yapay Sinir Ağının (YSA) yapısal konfigürasyonu Şekil 11'de şematik olarak tasvir edilmiştir. Model, sistem durumları ile optimal kontrol kazançları arasındaki doğrusal olmayan eşlemeyi gerçekleştirmek amacıyla özel olarak optimize edilmiş, ileri beslemeli (feed-forward) çok katmanlı bir algılayıcı (MLP - Multi-Layer Perceptron) yapısında tasarlanmıştır.

Söz konusu mimari, dinamik sistemin bağımsız değişkenlerini (girdi parametrelerini) temsil eden 2 nöronlu bir girdi katmanı ve sistemin karmaşık dinamiklerini öğrenmek üzere yapılandırılmış, her biri 15 nöron içeren iki gizli katmandan oluşmaktadır. Bu katmanlı yapı, kontrol katsayılarının kestiriminde yüksek doğruluk sağlarken, gerçek zamanlı uygulamalar için gereken düşük hesaplama maliyetini de muhafaza etmektedir.

Şematik gösterimde detaylandırıldığı üzere, gizli katmanlar sistemin karmaşık ve doğrusal olmayan davranışlarını modellemek amacıyla hiperbolik tanjant sigmoid (tansig) aktivasyon fonksiyonunu kullanmaktadır. Çıktı katmanı ise, geniş bir aralıkta sürekli değerler üretebilmek için doğrusal bir transfer fonksiyonu (purelin) ile yapılandırılmış ve kestirilen LQR kazançlarını (K₁, K₂, K₃, K₄) temsil eden 4 nörondan oluşmaktadır.

Ağın her bir katmanı, eğitim aşamasında Levenberg-Marquardt (LM) geri yayılım algoritması aracılığıyla iteratif olarak optimize edilen ağırlık (W) ve sapma (b - bias) matrislerini barındırmaktadır. Belirlenen bu spesifik [2-15-15-4] konfigürasyonu, gerçekleştirilen kapsamlı bir ızgara araması (grid search) neticesinde, düşük hesaplama maliyeti ile yüksek kestirim doğruluğunu ideal bir noktada dengeleyen optimum mimari olarak seçilmiştir.



Şekil 11. NN (Sinir Ağı) yapısı

Yapay sinir ağının eğitim süreci, belirlenen maksimum 3000 epok (epoch) sınırına ulaşmadan önce, hedeflenen performans kriterlerinin karşılanmasıyla birlikte 133. epokta erken durdurma (early stopping) prensibiyle tamamlanmıştır. Tablo 2’de detaylandırılan bu sonuçlar, ağın sistem dinamikleri ile kontrol kazançları arasındaki karmaşık eşlemeyi nispeten az sayıda iterasyonla, yüksek bir verimlilikle öğrenebildiğini kanıtlamaktadır.

Toplam eğitim süresinin 2 dakika 47 saniye gibi kısa bir sürede tamamlanması, önerilen [2-15-15-4] mimarisinin düşük hesaplama maliyetli ve hızlı yakınsama (convergence) kabiliyetine sahip olduğunu göstermektedir. Bu operasyonel verimlilik, modelin gerçek zamanlı kontrol sistemlerine entegrasyonu ve değişken parametreler altında yeniden eğitilmesi süreçlerinde önemli bir avantaj teşkil etmektedir.

Eğitim süreci sonunda elde edilen nihai Ortalama Kare Hata (MSE) değeri 9.66×10^{-9} olarak gerçekleşmiş; böylece 1×10^{-8} olarak belirlenen hedef performans kriteri başarıyla aşılmıştır. Bu sonuç, eğitim aşamasının hedeflenen hassasiyetle

tamamlandığını ve modelin eğitim verileri üzerinde yüksek bir regresyon doğruluğuna ulaştığını kanıtlamaktadır.

Optimizasyon sürecine dair kritik bir gösterge olan nihai gradyan değeri ise 8.73×10^{-6} olarak kaydedilmiştir. Bu düşük gradyan seviyesi, eğitim algoritmasının hata yüzeyindeki (error surface) yerel minimumlar yerine kararlı bir bölgeye etkin bir şekilde yakınsadığını (convergence) ve ağırlık güncellemelerinin optimum değerler civarında stabilize olduğunu doğrulamaktadır.

Ayrıca, Levenberg-Marquardt optimizasyon algoritmasındaki sönümlenme (damping) parametresi μ , 1×10^{-8} seviyesine kadar gerilemiştir. Bu durum, algoritmanın çözümün optimum noktasına yaklaştıkça gradyan inişinden (gradient descent) ziyade Gauss-Newton davranışına evrildiğini ve karesel yakınsama hızına ulaştığını teknik olarak kanıtlamaktadır.

Eğitim süresince doğrulama (validation) kontrol sayısının sıfırda kalması, sürecin doğrulama hatasındaki bir artış (overfitting belirtisi) nedeniyle kesilmediğini, aksine hedeflenen performans seviyesine (MSE) ulaşıldığı için başarıyla sonlandığını doğrulamaktadır. Bu bulgular, ağırlık eğitim verileriyle mükemmel bir uyum yakalarken genelleme yeteneğini de koruduğunu ve kararlı bir çözüm kümesine ulaştığını göstermektedir.

Eğitim sürecinde veri seti, modelin genelleme yeteneğini (generalization) artırmak amacıyla rastgele alt kümelere ayrılmıştır. Yapay sinir ağının eğitimi, orta ölçekli ağ yapılarında sergilediği hızlı yakınsama (convergence) kabiliyeti ve ikinci derece türev bilgilerini kullanma yeteneği ile literatürde yaygın kabul gören Levenberg-Marquardt (trainlm) algoritması aracılığıyla gerçekleştirilmiştir.

Eğitim aşamasında performans metriği olarak Ortalama Kare Hata (MSE) esas alınmış; hesaplama maliyetini minimize etmek ve işlem hızını optimize etmek amacıyla tüm matematiksel operasyonlar MATLAB Yürütülebilir (MEX) fonksiyonları kullanılarak donanım seviyesinde hızlandırılmıştır. Bu yaklaşım, karmaşık kontrol kazançlarının yüksek çözünürlüklü veri setleri üzerinden hızlı ve verimli bir şekilde öğrenilmesine olanak tanımıştır.

Genel bir değerlendirme yapıldığında, eğitim sonuçları önerilen yapay sinir ağının yalnızca 133 epok içerisinde 10^{-9} mertebesinde kritik bir hata seviyesine ulaşarak başarılı bir şekilde yakınsadığını (convergence) kanıtlamaktadır. Bu yüksek hassasiyetli yakınsama performansı, modelin eğitim verileri arasındaki karmaşık ilişkileri ve sistem dinamiklerini yüksek sadakatle temsil ettiğini doğrulamaktadır.

Elde edilen bu düşük hata payı, ağın sadece verileri ezberlemekle kalmayıp kontrol kazançlarının Ω ve ε parametrelerine olan bağımlılığını istatistiksel olarak anlamlı bir doğrulukla modelleyebildiğini göstermektedir. Bu durum, tasarlanan kontrolcünün gerçek zamanlı operasyonlarda teorik LQR performansına son derece yakın sonuçlar üretebileceğinin en güçlü göstergesidir.

Tablo 2. Sinir ağı eğitim sonuçları yorumu

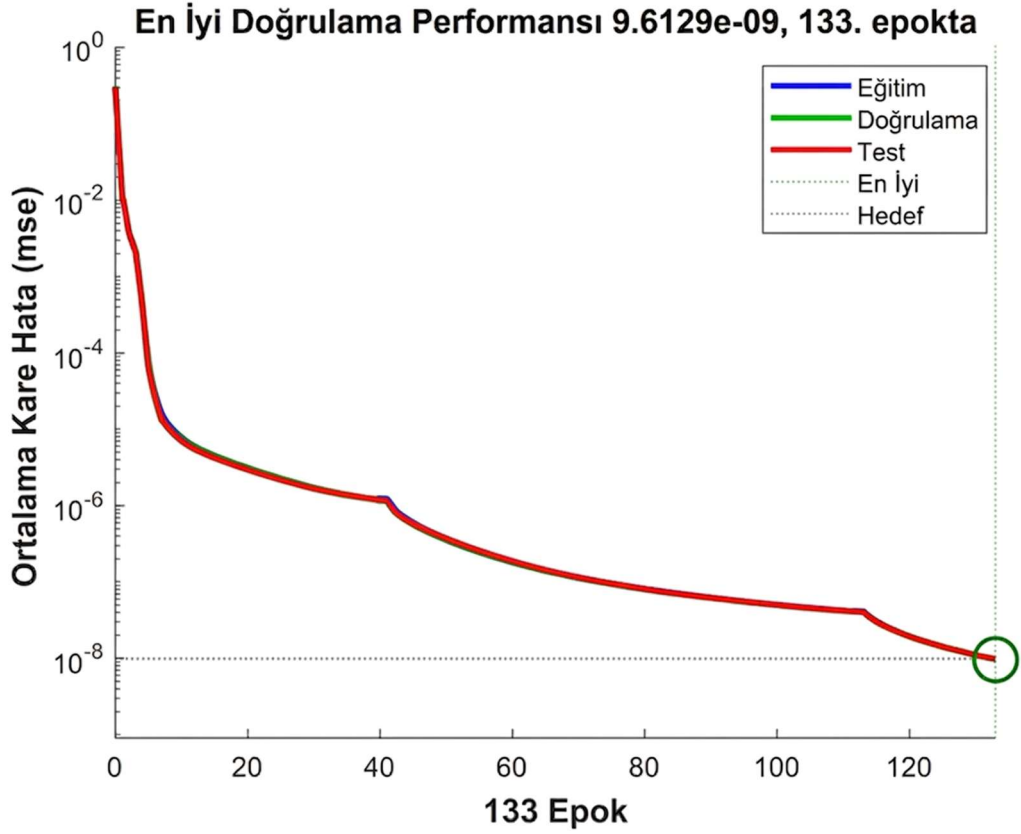
Birim	Başlangıç Değeri	Durdurulan Değer	Hedef Değer
Epok	0	133	3000
Geçen Süre	-	00:02:47	-
Performans	0.31	9.66×10^{-9}	1×10^{-8}
Gradyan	0.695	8.73×10^{-6}	1×10^{-7}
μ	0.001	1×10^{-8}	1×10^{10}
Doğrulama Konrolleri	0	0	20

Yapay sinir ağının eğitim ilerlemesi, 133 epok boyunca Ortalama Kare Hatadaki (MSE) değişimi yansıtan Şekil 12'de sunulmaktadır. Model, optimum performans noktasına 133. epokta ulaşarak 9.61×10^{-9} gibi son derece düşük bir doğrulama hatası değerine erişmiştir.

Grafikten elde edilen temel bulgu: eğitim, doğrulama (validation) ve test eğrileri arasındaki yüksek dereceli yakınsama ve uyumdur. Bu üç yörüngenin tüm eğitim süreci boyunca birbirine paralel ve bitişik seyretmesi, modelin aşırı öğrenme (overfitting) emaresi göstermediğini ve eğitim setinde yer almayan verilere karşı son derece güçlü bir genelleme yeteneği (generalization) sergilediğini kanıtlamaktadır. Bu kararlı hata düşüşü, seçilen [15 15] mimarisinin ve Levenberg-Marquardt algoritmasının sistemin karmaşık giriş-çıkış ilişkisini modellemedeki başarısını doğrulamaktadır.

Dahası, doğrulama (validation) eğrisinde herhangi bir sapma veya yukarı yönlü bir bükülme (divergence) olmaksızın Ortalama Kare Hatanın (MSE) sürekli bir azalma eğilimi sergilemesi, ağın aşırı öğrenme (overfitting) fenomeninden etkilenmediğini açıkça ortaya koymaktadır. Elde edilen nihai hata değerinin önceden tanımlanmış performans hedefini başarıyla karşılaması, seçilen ağ mimarisinin ve hiperparametre konfigürasyonunun kullanılan veri seti için yüksek bir uyumluluk sergilediğini kanıtlamaktadır.

Eğitim sürecinin başlangıcındaki keskin düşüşü takip eden istikrarlı ince ayar (fine-tuning) dönemi, kararlı bir öğrenme oranını (learning rate) ve verimli bir optimizasyon sürecini yansıtmaktadır. Bu karakteristik, algoritmanın hata yüzeyinde savrulmadan ilerlediğini ve yerel minimumlara takılmadan küresel optimum noktasına yüksek bir hassasiyetle yaklaştığını doğrulamaktadır.

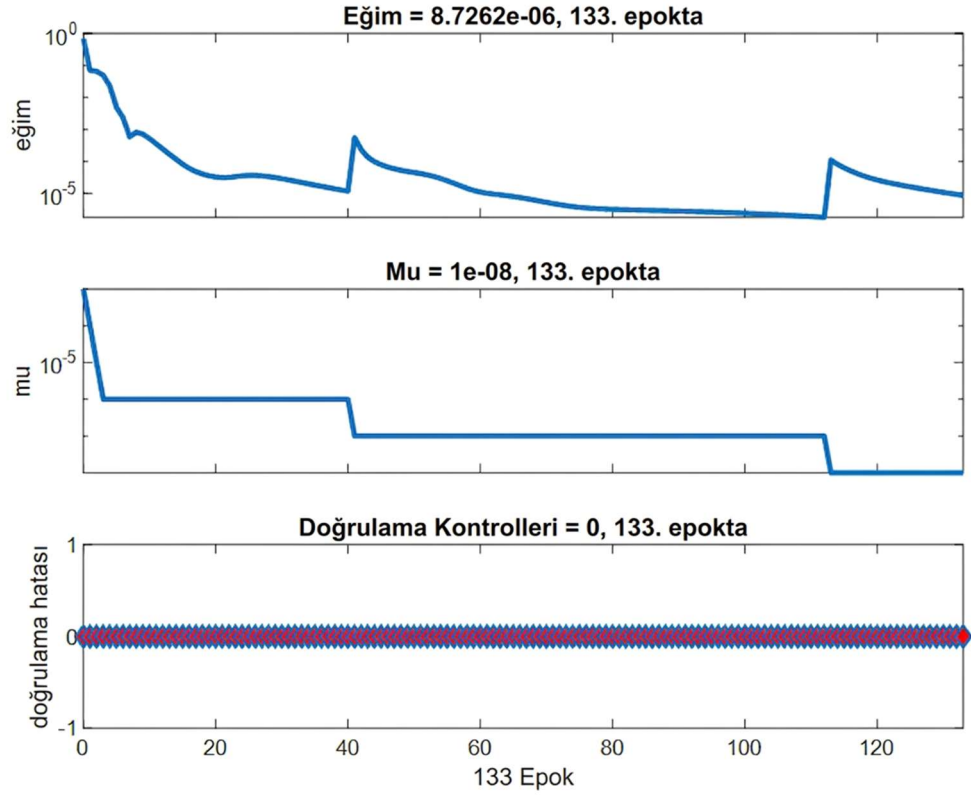


Şekil 12. NN'nin eğitim performansı

Eğitim durumu parametrelerinin derinlemesine analizi, uygulanan optimizasyon sürecinin yüksek kararlılığını doğrulamaktadır. Şekil 13'te sunulan veriler doğrultusunda, gradyan büyüklüğü süregelen bir azalma eğilimi sergileyerek eğitim sonunda 8.73×10^{-6} gibi oldukça düşük bir nihai değere ulaşmıştır. Sıfıra yaklaşan bu gradyan seviyesi, algoritmanın hata yüzeyindeki kararlı bir minimum noktasına başarıyla yakınsadığını (convergence) kanıtlamaktadır.

Dahası, sönümlenme faktörünün (μ) 1×10^{-8} seviyesine gerilemiş olması, modelin çözüm kümesine yaklaştıkça daha hassas ve karesel yakınsama hızı sunan Gauss-Newton tipi optimizasyon adımlarına geçiş yaptığını yansıtmaktadır. Dikkat çekici bir diğer bulgu ise doğrulama (validation) kontrollerinin tüm 133 epok boyunca sıfırda kalmasıdır. Bu durum, eğitimin erken durdurma (early stopping) kriterleri nedeniyle kesintiye uğramadığını ve doğrulama hatasının süreç boyunca sürekli olarak iyileştiğini doğrulamaktadır.

Birlikte ele alındığında, bu sonuçlar seçilen ağ mimarisinin ve hiperparametre konfigürasyonunun yüksek sayısal hassasiyet ve dayanıklı (robust) bir kestirim performansı sunarak sistem gereksinimlerini en üst düzeyde karşıladığını göstermektedir.



Şekil 13. NN'nin öğrenim aşaması

Yapay sinir ağının kestirimsel doğruluğu, Şekil 14'te sunulan kapsamlı regresyon analizi ile istatistiksel olarak mühürlenmiştir. Regresyon grafikleri, eğitim, doğrulama (validation) ve test aşamaları boyunca ağ çıktıları ile hedeflenen (target) değerler arasındaki korelasyonu detaylandırmaktadır.

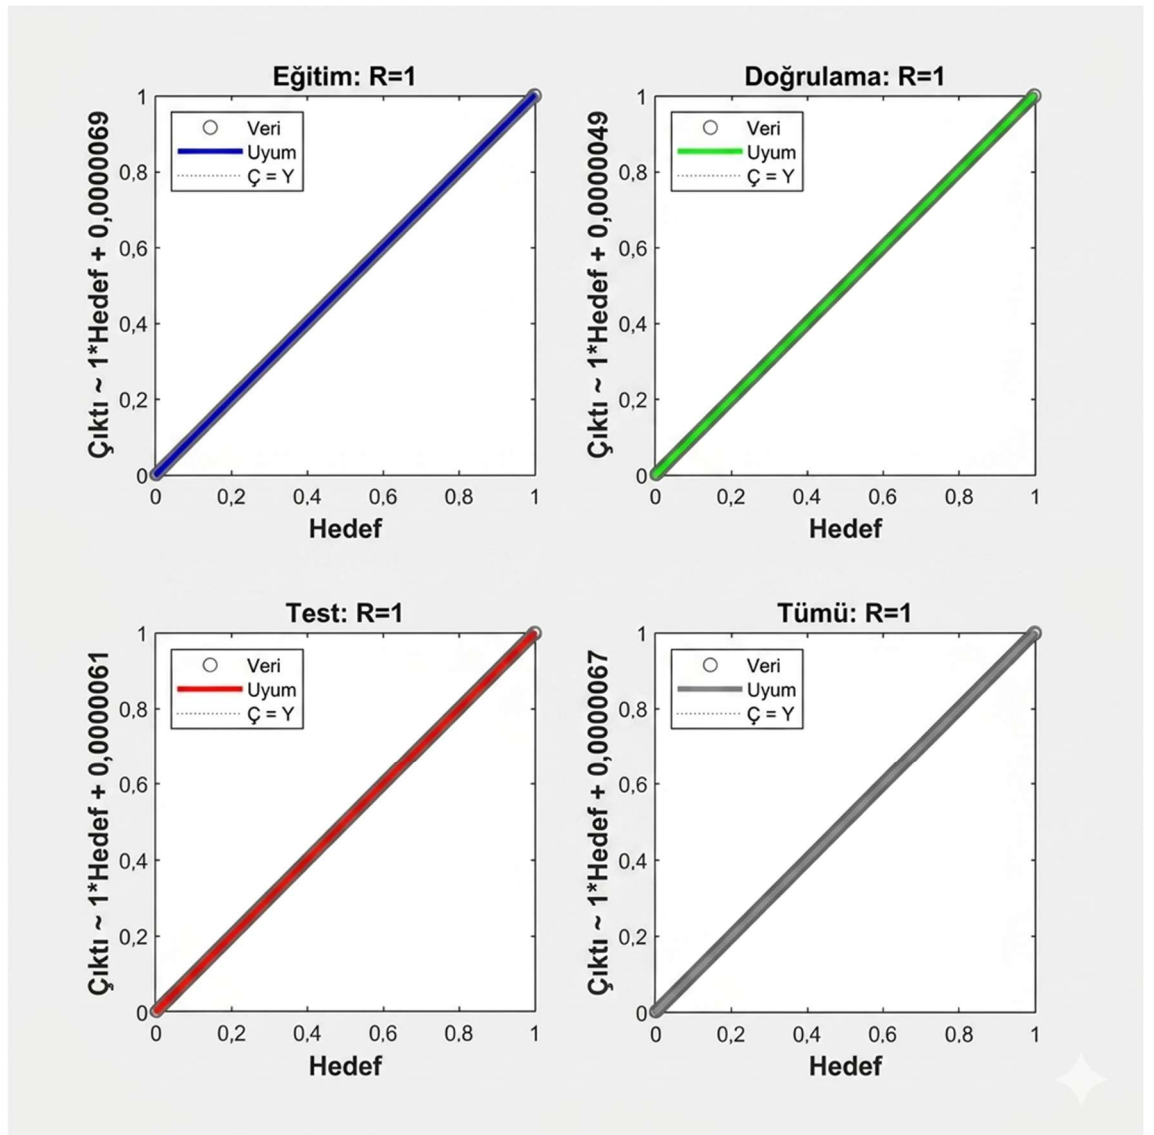
Elde edilen sonuçlara göre ağ tüm veri alt kümelerinde $R = 1$ korelasyon katsayısına ulaşmıştır. Bu istatistiksel değer, YSA tarafından tahmin edilen katsayılar ile analitik olarak hesaplanan gerçek hedefler arasında kusursuz bir doğrusal ilişki olduğunu ve modelin varyansı tam bir hassasiyetle açıkladığını kanıtlamaktadır.

Dört farklı grafik panelinde de verilerin regresyon doğrusu üzerinde sapmasız bir şekilde dizilmesi, modelin sadece eğitim verilerini öğrenmekle kalmayıp aynı zamanda test aşamasındaki dışsal verilere de aynı doğrulukla uyum sağladığını göstermektedir. Bu düzeyde bir korelasyon ($R=1$), önerilen kontrol stratejisinin dinamik disk hızı değişimleri altında teorik LQR performansından ödün vermeden çalışabileceğinin nihai kanıtıdır.

Regresyon çizgileri, ideal 45 derecelik yörüngeyi ($Y = T$) hassasiyetle takip etmekte ve veri noktaları uyum çizgisi (fit line) etrafında ihmal edilebilir bir sapma ile kümelenmektedir. Bu yüksek korelasyon, modelin sistem dinamikleri ile kontrol

kazançları arasındaki karmaşık eşlemeyi (mapping) tespit edilebilir bir sistematik hata barındırmaksızın başarıyla yakaladığını teyit etmektedir.

Daha önce sunulan düşük MSE değerleri ve kararlı eğitim durumu parametreleriyle birlikte değerlendirildiğinde, bu regresyon sonuçları, modelin dayanımı (robustness), yüksek sayısal hassasiyeti ve olağanüstü genelleme yeteneğine dair kesin bilimsel kanıtlar sunmaktadır. Elde edilen bu istatistiksel doğruluk, tasarlanan yapay sinir ağının (YSA) değişken çalışma koşulları altında robotun stabilizasyonunu sağlamak için gereken optimal LQR katsayılarını gerçek zamanlı olarak üretme kabiliyetini doğrulamaktadır.



Şekil 14. Regresyon

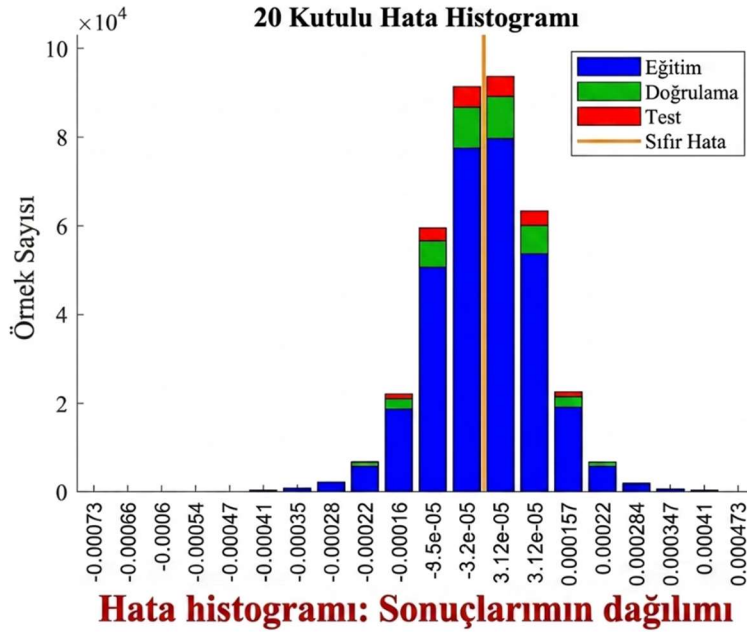
Yapay sinir ağının kestirim kalitesini derinlemesine değerlendirmek amacıyla, Şekil 15'te sunulan 20 bölmeli (bins) hata histogramı oluşturulmuştur. Bu grafik, eğitim,

doğrulama (validation) ve test veri setleri genelindeki artıkların (residuals) istatistiksel dağılımını detaylandırmaktadır.

Histogram verileri, hataların çok büyük bir kısmının Sıfır Hata (Zero Error) eksenini etrafında dar bir bantta yoğunlaştığını açıkça ortaya koymaktadır. Bu merkezi yoğunlaşma, modelin yanlılık (bias) barındırmadığını ve yüksek bir doğruluk seviyesine ulaştığını kanıtlamaktadır. Hataların sıfır noktası civarındaki bu simetrik ve dar dağılımı, önerilen [2-15-15-4] mimarisinin sistem dinamiklerini modellemede sergilediği yüksek hassasiyetin ve tahmin tutarlılığının sayısal bir göstergesidir.

Hata dağılımı, en sık rastlanan örneklerin -3.2×10^{-5} ile 3.12×10^{-5} dar aralığına kümelenmesiyle, ideale yakın bir normal (Gauss) dağılım sergilemektedir. Dağılımın sıfır eksenini etrafındaki simetrisi, modelin tahminlerinde herhangi bir sistematik yanlılık (bias) barındırmadığını ve hataların rastsal karakterde olduğunu kanıtlamaktadır.

Ayrıca, histogramın kuyruk bölgelerini temsil eden aykırı değer (outlier) bölmelerinde çok az sayıda örneğin bulunması, ağıın tüm veri seti genelindeki kestirim tutarlılığını doğrulamaktadır. Artıkların (residuals) sıfır noktası etrafındaki bu sıkı yoğunlaşması, daha önce sunulan regresyon ve MSE analizlerinden elde edilen bulguları destekleyerek, yapay sinir ağının hedef sistem dinamikleri için son derece güvenilir ve yüksek hassasiyetli bir modelleme sunduğunu kanıtlamaktadır.



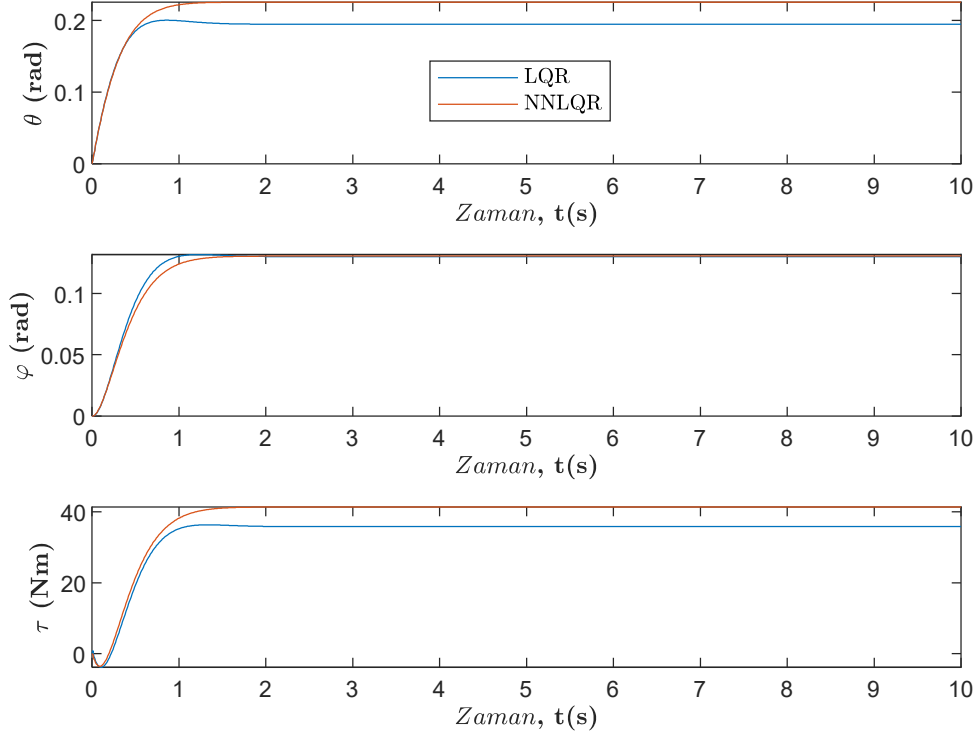
Şekil 15. Eğitim, doğrulama ve test veri setleri için hata histogramı

5. LQR KATSAYILARINDAN EĞİTİLMİŞ SINIR AĞINA DAYALI SONUÇLAR

5.1 LQR ve Sinir Ağı Kontrol Algoritmaları için Karşılaştırmalar

Gerçekleştirilen simülasyonlarda, geleneksel LQR ve önerilen Yapay Sinir Ağı tabanlı LQR (NNLQR) kontrollü sistemlerin zaman düzlemi yanıtları, $\Omega = 4000$ rad/s disk hızı, $\alpha = 0$ rad eğim açısı ve $F = 120$ N sabit bozucu kuvvet etkisi altında analiz edilmiştir. Şekil 16, teorik LQR matematiksel modeli ile RecurDyn ortamında koşturulan sinir ağı simülasyon sonuçları arasında yüksek dereceli bir uyum olduğunu ortaya koymaktadır. Kararlılık performansı ve sistemin genel dinamik eğilimleri birbiriyle hassasiyetle örtüşmekte olup, her iki kontrol stratejisi de değişken koşullar altında tutarlı bir davranış sergilemektedir.

Şekil 16'dan elde edilen bulgular, hem LQR hem de NN tabanlı kontrolcülerin geçici rejim (transient) yanıtlarının ardından başarıyla kararlı duruma (steady-state) ulaştığını ve yörünge takibi noktasında birbirini desteklediğini kanıtlamaktadır. Bu durum, eğitilmiş sinir ağının sadece teorik verileri öğrenmekle kalmadığını, aynı zamanda RecurDyn gibi yüksek güvenilir (high-fidelity) sistemin simülasyonunda da beklenen kontrol performansını başarıyla sergilediğini doğrulamaktadır.



Şekil 16. $F=120$ N sabit geri tepmeye ve $\varepsilon = 2$ rad/s dönüş hızına maruz kalan, silah açısı $\alpha=0$ rad ile $\Omega = 4000$ rad/s'de LQR kontrollü ve Sinir Ağı (NNLQR) simülasyonlarının karşılaştırması. ($K_{LQR} = [-594.6 \quad -18.5 \quad -213.1 \quad 2.1]$ and $K_{NNLQR} = [-676.4 \quad -17.11 \quad -208.2 \quad 0.9]$)

5.2. Robotun Değişen CMG Disk Hızlarıyla Sabit Kuvvet Altındaki Yanıt Analizi

Şekil 17, RecurDyn simülasyonlarından elde edilen zaman düzlemi yer değiştirme yanıtlarının karşılaştırmalı analizini sunmaktadır. Bu senaryoda sistem dinamikleri, disk hızının $\Omega = 2000 + 1000\sin(2.5t)$ rad/s ve dönüş hızının $\varepsilon = 2\cos(2.5t)$ rad/s fonksiyonlarına bağlı olarak sürekli değiştiği, oldukça kararsız bir çalışma rejimi altında test edilmiştir. Silah eğim açısı (α) ise 0 rad değerinde sabit tutulmuştur.

Kontrol stratejilerinin performansını değerlendirmek amacıyla, geleneksel LQR kontrolcüsüne ait kazanç matrisi, $\Omega = 2000$ rad/s ve $\varepsilon = 2$ rad/s nominal çalışma koşulları için hesaplanan $K_{LQR} = [-769.3 \quad -65.1 \quad -272.4 \quad 3.0]$ değerine sabitlenmiştir. Buna karşılık, önerilen Yapay Sinir Ağı tabanlı kontrolcü (K_{NNLQR}), test süreci boyunca değişen anlık sistem dinamiklerine göre kazanç katsayılarını dinamik ve uyarlanabilir (adaptive) bir şekilde güncellemektedir.


Bu karşılaştırma, sabit kazançlı bir yapının değişen çalışma frekansları altındaki performans sınırlarını ortaya koyarken, eğitilen sinir ağının sistemin zamanla değişen

parametrelerine (time-varying parameters) gerçek zamanlı olarak nasıl uyum sağladığını ve kontrol kalitesini nasıl optimize ettiğini kanıtlamaktadır.

Simülasyon sonuçları,>NNLQR kontrolcüsünün yüksek frekanslı ve değişken dinamik koşullar altında üstün bir dayanım (robustness) sergilediğini ve kararlı durum yanıtını başarıyla koruduğunu ortaya koymaktadır. Analizler, sabit kazançlı LQR kontrolcüsünün değişken parametreler altında 1.5 saniye içerisinde sistem kararlılığını kaybederek ıraksadığını, buna karşın>NNLQR kontrolcüsünün simülasyonun tamamında sistemi denge sınırları içerisinde tuttuğunu açıkça göstermektedir.

Geleneksel LQR yapısında gözlemlenen bu kararsızlık, kontrolcünün yalnızca $\Omega = 2000$ rad/s sabit disk hızı ve nominal çalışma noktası için tasarlanmış statik bir K kazancı ile çalışmasından kaynaklanmaktadır. Bu statik yapı, sistem dinamiklerini ve ağırlık merkezinin konumunu doğrudan etkileyen ε (dönüş hızı) değişimlerine karşı uyum sağlayamamaktadır. Öte yandan>NNLQR, sistem durumlarındaki anlık varyasyonları takip ederek kazanç matrisini sürekli güncellediği için parametre değişimlerinden kaynaklanan bozucu etkileri sönmüleyebilmekte ve kontrol çevriminin sürekliliğini teminat altına almaktadır.>NNLQR kontrolcüsü, disk hızındaki gerçek zamanlı varyasyonları anlık olarak işleyerek LQR katsayılarını dinamik bir biçimde optimize etmekte ve mafsal (gimbal) kontrol torkunu etkili bir şekilde yöneterek zorlu dinamik koşullar altında sistem dengesini muhafaza etmektedir.

Elde edilen bulgular, sabit bir LQR katsayısı kullanımının, Kontrol Moment Jiroskopu (CMG) içeren ve disk hızlarının sürekli değiştiği gerçek zamanlı uygulamalarda sistem kararlılığını korumak adına yetersiz kaldığını açıkça vurgulamaktadır (Şekil 17). Yapay sinir ağının sunduğu bu adaptif mekanizma, statik kontrolcülerin aksine, sistemin doğrusal olmayan dinamiklerine ve parametre belirsizliklerine karşı yüksek dereceli bir bağımsızlık sağlayarak operasyonel güvenilirliği artırmaktadır.




Şekil 17. $F=120$ N sabit geri tepmeye ve $\varepsilon = 2 \cos 2.5t$ rad/s dönüş hızına maruz kalan, silah açısı $\alpha=0$ rad ile $\Omega = 2000+1000\sin 2.5t$ rad/s'de LQR kontrollü ve Sinir Ağı (NNLQR) simülasyonlarının karşılaştırması. ($\Omega = 2000$ rad/s ve $\varepsilon = 2$ rad/s ile LQR kontrolcüsü için $K_{LQR} = [-769.3 \ -65.1 \ -272.4 \ 3.0]$ seçilmiş ve sabitlenmiştir, bu arada K_{NNLQR} test sırasında sisteme uyum sağlamak için değişmektedir.)

5.3 Robotun Değişen CMG Disk Hızlarıyla Ateşleme Yükü Darbeleri Altındaki Yanıt Analizi

Şekil 18, bir saniyelik zaman zarfındaki sürekli ateşleme yükü darbelerini ve dakikada 600 mermi (600 RPM) atış frekansına sahip bir silahtan kaynaklanan geri tepme kuvvetinin (recoil force) ürettiği impulsif dalga formunun tekil bir tepe noktasını detaylandırmaktadır (Oğuz vd., 2026 ; Figurski ve Rybak, 2007).

Bu grafiksel gösterim, mermi çıkış anında oluşan yüksek genlikli ve kısa süreli kuvvet etkilerini karakterize etmektedir. Sistem kararlılığı açısından kritik öneme sahip olan bu ani kuvvetler, iki tekerlekli gyroskopik robotun denge kontrol mekanizması üzerinde ani bozucu etkiler (disturbances) yaratmaktadır. Dalga formunun spektral analizi ve tepe değerleri, kontrolcünün (NNLQR) bu tür geçici ancak şiddetli dinamik yükler altında robotun dikey konumunu ne derece hassasiyetle koruyabildiğini test etmek amacıyla giriş verisi olarak kullanılmıştır.



(a) Bir saniye içinde meydana gelen rastgele darbeler (b) Bir tepe atışının süresi

Şekil 18. Geri tepme kuvvetinin sürekli ateşleme hızı (Oğuz vd., 2026).

Şekil 19, sistemin hem zamana bağlı parametre değişimlerine hem de dışsal ani kuvvetlere maruz kaldığı en kapsamlı senaryoya ait zaman düzlemi yer değiştirme yanıtlarını sunmaktadır. Bu simülasyonda, değişken disk hızı ($\Omega = 2000 + 1000\sin(2.5t)$ rad/s), değişken dönüş hızı ($\varepsilon = 2\cos(2.5t)$ rad/s) ve dinamik silah eğim açısı ($\alpha = 0.25(1 - \cos(2.5t))$ rad) eşzamanlı olarak uygulanmıştır.

Bu karmaşık dinamik yapıya ek olarak, sisteme Şekil 18'de karakterize edilen silah geri tepme kuvveti (F_{recoil}) bir bozucu giriş olarak dahil edilmiştir. RecurDyn simülasyonlarından elde edilen karşılaştırmalı sonuçlar, önerilen kontrol stratejisinin hem yüksek frekanslı parametre varyasyonları hem de şiddetli geri tepme şokları altında robotun dikey kararlılığını koruma kapasitesini doğrulamaktadır. Grafiklerde gözlemlenen tepkiler, kontrolcünün ani moment değişimlerini sönmüleyerek gövde salınımlarını kabul edilebilir sınırlar içerisinde tuttuğunu kanıtlamaktadır.

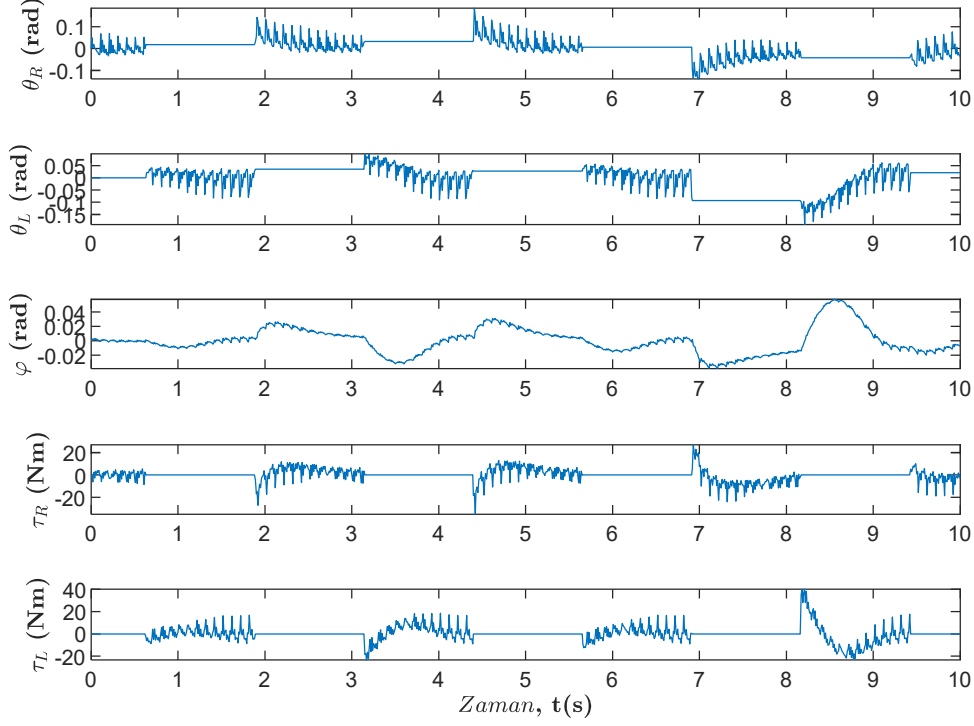
NNLQR kontrollü CMG sistemi, Şekil 19'da sunulan sonuçlardan da anlaşılacağı üzere, dışsal bozucu kuvvetler ve değişken parametreler altında üstün bir dayanım sergilemektedir. Yapay sinir ağı (NN), disk hızındaki anlık değişimlere ve dinamik silah eğim açlarına bağlı olarak LQR katsayılarını gerçek zamanlı olarak güncellemekte, böylece robotun dikey kararlılığını dinamik bir operasyon aralığında muhafaza etmektedir.

Şekil 17 ile yapılan karşılaştırmalı analizde geleneksel LQR kontrolcüsünün $\Omega = 2000$ rad/s ve $\varepsilon = 2$ rad/s nominal koşulları için hesaplanmış statik bir K kazancı ile

çalışması nedeniyle, bozucu etkiler altında 1 saniye içerisinde kararlılığını yitirerek ıraksadığı gözlemlenmiştir. Bu durum, sabit kazançlı yapıların geniş bir çalışma spektrumuna sahip doğrusal olmayan sistemlerde (nonlinear systems) yetersizliğini; önerilen NNLQR yapısının ise bu belirsizlikleri kompanse etme yeteneğini açıkça kanıtlamaktadır.

NNLQR kontrolcüsü Şekil 18'de detaylandırılan şiddetli silah geri tepme kuvvetleri altında dahi sistem dengesini muhafaza etmektedir. LQR kontrolcüsünün değişen disk hızlarına (Ω) uyum sağlayamaması, sistemin kararlılık marjını önemli ölçüde sınırlandırmakta ve ani geri tepme yüklerinin neden olduğu yer değiştirme dalgalanmaları kontrolcünün enerji sönümleme performansını kritik seviyeye düşürmektedir.

Öte yandan NNLQR kontrolcüsü, anlık değişen disk hızlarına yanıt olarak K kazanç matrisini dinamik olarak ayarlamak suretiyle dengeyi etkili bir şekilde korumaktadır. Bu adaptif yapı, sistemin geri tepme enerjisini absorbe etme kabiliyetini optimize ederek, en zorlu ve dinamik operasyon koşulları altında dahi yüksek bir dayanım (robustness) sergilemektedir. Elde edilen sonuçlar, önerilen yöntemin sadece parametre değişimlerine değil, aynı zamanda ani dış bozucu etkilere karşı da sistem bütünlüğünü koruduğunu doğrulamaktadır.



Şekil 19. $F = F_{\text{recoil}}$ geri tepmesine ve $\varepsilon = 2 \cos 2.5t$ rad/s dönüş hızına maruz kalan, silah açısı $\alpha = 0.25(1 - \cos 2.5t)$ rad ile $\Omega = 2000 + 1000 \sin 2.5t$ rad/s'de Sinir Ağı (NNLQR) simülasyonları. (K_{NNLQR} test sırasında sisteme uyum sağlamak için değişirken.)

Yapay Sinir Ağı'nın (YSA) kontrol döngüsüne entegre edilmesiyle oluşturulan hibrit kontrol yapısı, sistemin belirli çalışma senaryolarının ötesine geçerek yüksek bir genelleme kabiliyeti kazanmasını sağlamaktadır. Bu entegrasyon, robotun dışsal bozucu etkilere ve CMG disk hızındaki beklenmedik varyasyonlara karşı dinamik olarak uyum sağlamasına olanak tanır (Çetin vd., 2026). YSA, disk hızı ile kontrol gereksinimleri (optimal kazanç katsayıları) arasındaki doğrusal olmayan karmaşık ilişkileri modelleme yeteneğinden yararlanarak, robotun operasyonel kararlılığını ve manevra esnekliğini artıran gerçek zamanlı uyarlanabilir (adaptive) yanıtlar üretmektedir.

Bu yaklaşım, deterministik kontrol teorisinin (LQR) sağladığı kararlılık ve güvenilirlik avantajlarını muhafaza ederken, bu yapısal faydaları derin öğrenmenin sunduğu esneklik ve kestirim gücüyle desteklemektedir. Sonuç olarak önerilen metodoloji, geleneksel kontrolcülerin yetersiz kaldığı değişken dinamikli ortamlarda, sistemin performansını optimize eden dayanıklı (robust) bir mimari sunmaktadır.

5.4 Klasik ve Gelişmiş Kontrol Stratejileri ile Karşılaştırmalı Analiz

Klasik PID denetleyiciler, yüksek derecede bağlaşıklık doğrusal olmayan sistemlere uygulandığında bazı temel sınırlamalar sergiler; bunlar arasında önemli parametre değişimlerine karşı zayıf dayanıklılık ve rotor hızına bağlı olarak doğrusal olmayan şekilde ölçeklenen jiroskopik bağlaşıklık terimlerini telafi edemeyen yapısal bir yetersizlik bulunmaktadır (Shafiei, 2022 ; Åström ve Murray, 2010). Optimal LQR kontrolü, durum-uzay modellerine dayalı kazanç tasarımı için sistematik bir çerçeve sunar (Anderson ve Moore, 1990 ; Vu vd., 2017) ve sabit çalışma koşulları altında üstün performans sağlar; ancak tek bir doğrusallaştırma noktasına dayanması, parametrik değişimler altındaki etkinliğini sınırlar.

Uyarlamalı kontrol (Ioannou ve Sun, 2012), kayan kipli kontrol (Huang vd., 2010 ; Utkin, 1992) ve dayanıklı H_∞ kontrolü (Doyle, 1996 ; Zhou vd., 1996) gibi gelişmiş yöntemler, model belirsizliklerine karşı daha yüksek dayanıklılık sunar. Bununla birlikte, bu yaklaşımlar çoğu zaman muhafazakâr ayar gereksinimleri doğurur, yüksek frekanslı titreşim (özellikle kayan kipli kontrol varyantlarında) üretir veya gerçek zamanlı gömülü uygulamalar için kısıtlayıcı olabilecek önemli hesaplama yükleri getirir.

Önerilen NNLQR yöntemi, mevcut öğrenme tabanlı yaklaşımlardan (Oğuz vd., 2026; Çetin vd., 2026; Recht, 2019; Sutton ve Barto, 2018) farklı olarak kontrol politikasını bir “kara kutu” şeklinde öğrenmek yerine, doğrudan optimal LQR kazanç manifoldunu yaklaşıklar. Bu strateji, LQR'nin biçimsel yorumlanabilirliğini ve doğal kararlılık özelliklerini korurken, eşzamanlı olarak kesintisiz gerçek zamanlı uyarlanabilirlik sağlar. Kontrol teorisi açısından bakıldığında, NNLQR, CARE çözüm manifoldunun sürekli bir yaklaşımı olarak işlev görür ve hesaplama açısından yoğun bir matris optimizasyon problemini deterministik ve gerçek zamanlı olarak değerlendirilebilir bir fonksiyona dönüştürür. Bu düzgün fonksiyonel yaklaşım, süreksiz kontrol eylemlerini önleyerek robotik platformun genel yapısal dayanıklılığını artırır.

6. SONUÇ

Bu çalışmanın temel katkısı, derin öğrenme algoritmalarını LQR kontrolü ile entegre eden hibrit bir mimarinin geleneksel statik kontrol yöntemlerine kıyasla çok daha üstün bir kararlılık ve dayanım (robustness) sergileyebildiğini deneysel olarak kanıtlamasıdır. Çalışma, yapay sinir ağının LQR katsayılarını optimize edecek şekilde tasarlanması ve eğitilmesinden elde edilen adaptif yanıtların kontrol döngüsüne kesintisiz entegrasyonuna kadar önerilen hibrit mimarinin derinlemesine bir analizini sunmaktadır.

Farklı operasyonel senaryolar altında gerçekleştirilen kapsamlı simülasyon ve deneyler, sistemin şiddetli dinamik bozucu etkiler ve değişken CMG disk hızları altında dahi robotun dikey dengesini korumadaki yüksek etkinliğini doğrulamaktadır. Elde edilen bulgular, önerilen bu akıllı kontrol stratejisinin karmaşık dinamiklere sahip otonom sistemler için güvenilir ve ölçeklenebilir bir çözüm sunduğunu ortaya koymaktadır.

Bu çalışma, uyarlanabilir (adaptive)>NNLQR kontrolcüsü ile teçhiz edilmiş bir Kontrol Moment Jirokobu (CMG) kullanarak, silah geri tepme kuvvetleri etkisindeki iki tekerlekli bir robotun stabilizasyonunu araştırmaktadır. Simülasyon sonuçları,>NNLQR kontrolcüsünün dinamik ve zorlu operasyonel koşullar altında sistem kararlılığını koruma noktasında geleneksel LQR kontrolcüsünden önemli ölçüde daha yüksek bir performans sergilediğini ortaya koymaktadır.

NNLQR kontrolcüsü, LQR kazanç katsayılarını değişken disk hızlarına (Ω) bağlı olarak dinamik bir şekilde güncelleyerek, sistem dinamiklerindeki anlık değişimlere başarıyla uyum sağlamaktadır. Bu süreçte CMG ünitesi, hassas mafsal (gimbal) tork kontrolü üreterek geri tepme kuvvetlerinin istikrarsızlaştırıcı etkilerini etkin bir şekilde sönmölemek ve robotun dikey dengesini muhafaza etmektedir.

Sabit katsayılı LQR kontrolcüsü, disk hızındaki varyasyonları ve buna bağlı olarak değişen sistem matrislerini kompanse edememekte; bu durum kontrol döngüsünde kısa sürede kararsızlığa (instability) ve sistemin iraksamasından kaynaklanan denge kaybına yol açmaktadır. Elde edilen bulgular, Kontrol Moment Jirokobu (CMG) tabanlı sistemlerde gerçek zamanlı kararlılık ve dayanım elde edebilmek için sinir ağı destekli LQR gibi uyarlanabilir (adaptive) kontrol stratejilerinin kritik rolünü açıkça vurgulamaktadır.

Bu çalışma, doğrusal olmayan ve zamanla değişen parametrelere sahip sistemlerde, statik kontrolcülerin sınırlamalarını aşmak adına yapay zeka tabanlı hibrit yaklaşımların gerekliliğini teknik verilerle ispatlamaktadır. Deterministik kontrol ile uyarlanabilir.(adaptive) yöntemler arasında köprü kuran hibrit stratejiler geliştirerek robotik literatürüne önemli bir katkı sunmaktadır. Çalışmanın odak noktası her ne kadar iki tekerlekli jiroskopik bir muharebe robotu olsa da, önerilen kontrol çerçevesi, denge, dinamik hassasiyet ve yüksek uyarlanabilirlik gerektiren diğer robotik platformlara da entegre edilebilecek genel bir mimari sunmaktadır.

Geliştirilen bu metodolojinin potansiyel uygulama alanları arasında öngörülemeyen arazi koşullarında kararlılık ve hızlı tepki süresi gerektiren arama-kurtarma robotları ile ekstrem çevresel faktörler altında görev yapan otonom gözetleme sistemleri yer almaktadır. Nihayetinde bu çalışma, geleneksel kontrol teorisinin güvenilirliğini makine öğreniminin esnekliğiyle birleştiren hibrit sistemlerin keşfi için sağlam bir zemin hazırlamakta; daha akıllı, dayanıklı (robust) ve otonom robotik platformların gelişimine yönelik stratejik bir adım teşkil etmektedir.

Gelecekteki çalışmalar, sistemin dayanımını (robustness) daha da ileriye taşımak amacıyla, engebeli arazi koşulları ve yüksek frekanslı geri tepme dinamikleri gibi ekstrem operasyonel senaryolar altında uyarlanabilirliği maksimize edecek çevrimiçi (online) öğrenme tabanlı ileri yapay zeka (AI) kontrolcülerini uygulamaya odaklanacaktır.

Bu kapsamda, kontrol katsayılarının sadece önceden eğitilmiş bir ağ üzerinden değil, robotun çalışma anında karşılaştığı öngörülemeyen çevresel etkilere göre kendini gerçek zamanlı olarak güncelleyen Pekiştirmeli Öğrenme (Reinforcement Learning) veya Adaptif Sinirsel Kontrol algoritmalarının entegrasyonu hedeflenmektedir. Bu tür ileri seviye yaklaşımlar, sistemin dinamik belirsizliklere karşı toleransını artırarak, hibrit kontrol mimarisinin çok daha karmaşık ve değişken muharebe ortamlarında operasyonel sürekliliğini teminat altına alacaktır.

KAYNAKÇA

- Anderson, B. D. O. ve Moore, J. B. (1990). *Optimal Control: Linear Quadratic Methods*, Prentice-Hall.
- Åström, K. J. ve Murray, R. M. (2010). *Feedback Systems: An Introduction for Scientists and Engineers*, Princeton University Press.
- Brunton, S. L. ve Kutz, J. N. (2019). *Data-Driven Science and Engineering: Machine Learning, Dynamical Systems, and Control*, Cambridge University Press.
- Çetin, G. ve Ünker, F. (2024). Control moment gyroscope recoil stabiliser including LQR controller for two-wheeled robot, *International Journal of Heavy Vehicle Systems*, 31(6), 787–797, <https://doi.org/10.1504/IJHVS.2023.10060383>
- Çetin, G. ve Ünker, F. (2024). Gyroscopic precession control for maneuvering two-wheeled robot recoil stabilization, *Journal of Field Robotics*, 41, 991–1005, <https://doi.org/10.1002/rob.22305>
- Çetin, G., Oğuz, Y. ve Ünker, F. (2026). Enhanced control of a two-wheeled gyroscopic combat robot with variable CMG disk speeds using LQR-Based neural network, *Gümüşhane Üniversitesi Fen Bilimleri Dergisi*, 16(1), 110–125, <https://doi.org/10.17714/gumusfenbil.1785098>
- Doyle, J. (1996). Robust and optimal control, Proc. 35th IEEE Conference on Decision and Control, 1595–1598, <https://doi.org/10.1109/CDC.1996.572756>
- Figurski, J. ve Rybak, P. (2007). Fighting Means Quality and Military Vehicle Load, *Journal of KONES Powertrain and Transport*, 14(2), 125–132.
- Gautam, P. (2016). Optimal control of Inverted Pendulum system using ADALINE artificial neural network with LQR, 2016 International Conference on Recent Advances and Innovations in Engineering (ICRAIE), 1-6, <https://doi.org/10.1109/ICRAIE.2016.7939523>
- Huang, J., Guan, Z.-H., Matsuno, T., Fukuda, T. ve Sekiyama, K. (2010). Sliding-mode velocity control of mobile-wheeled inverted-pendulum systems, *IEEE Transactions on Robotics*, 26(4), 750–758, <https://doi.org/10.1109/TRO.2010.2053732>
- Ioannou, P. A. ve Sun, J. (2012). *Robust Adaptive Control*, Dover Publications.
- Nakamura-Zimmerer, T., Gong, Q. ve Kang, W. (2021). QRnet: Optimal Regulator Design With LQR-Augmented Neural Networks, *IEEE Control Systems Letters*, 5(4), 1303–1308, <https://doi.org/10.1109/LCSYS.2020.3034415>

- Nghi, H. V. vd. (2021). A LQR Neural Network Control Approach for Fast Stabilizing Rotary Inverted Pendulums, *International Journal of Precision Engineering and Manufacturing*, 23, 45–56, <https://doi.org/10.1007/s12541-021-00606-x>
- Oğuz, Y., Çetin, G. ve Ünker, F. (2026). Regression-Based Controller Design Using LQR Data for a Two-Wheeled Gyroscopic Combat Robot, *International Journal of Acoustics and Vibration*, 31(1), 61–74, <https://doi.org/10.20855/ijav.2026.31.12195>
- Recht, B. (2019). A tour of reinforcement learning: The view from continuous control, *Annual Review of Control, Robotics, and Autonomous Systems*, 2, 253–279, <https://doi.org/10.1146/annurev-control-053018-023825>
- Shafiei, B. (2022). A review on PID control system simulation of the active suspension system of a quarter car model while hitting road bumps, *Journal of the Institution of Engineers (India): Series C*, 103, 1001–1011, <https://doi.org/10.1007/s40032-022-00821-z>
- Sutton, R. S. ve Barto, A. G. (2018). *Reinforcement Learning: An Introduction*, 2. baskı, MIT Press.
- Utkin, V. I. (1992). *Sliding Modes in Control and Optimization*, Springer.
- Ünker, F. (2020). Tuned gyro pendulum stabilizer for control of vibrations in structures, *International Journal of Acoustics and Vibration*, 25(3), 355–362, <https://doi.org/10.20855/ijav.2020.25.31632>
- Ünker, F. (2022). Oscillation Control of Two-Wheeled Robot using a Gyrostabilizer, *Gazi Üniversitesi Fen Bilimleri Dergisi Part C: Tasarım ve Teknoloji*, 10(3), 547–557, <https://doi.org/10.29109/gujsc.1062497>
- Ünker, F. (2022). Proportional control moment gyroscope for two-wheeled self-balancing robot, *Journal of Vibration and Control*, 28(17-18), 2310–2318, <https://doi.org/10.1177/10775463211009988>
- Ünker, F. (2022). Angular Momentum Control for Preventing Rollover of a Heavy Vehicle, *International Journal of Automotive Science and Technology*, 6(2), 135–140, <https://doi.org/10.30939/ijastech..1085111>
- Ünker, F. (2023). Gyroscopic suspension for a heavy vehicle, *International Journal of Heavy Vehicle Systems*, 30(2), 201–210, <https://doi.org/10.1504/IJHVS.2023.132315>
- Ünker, F. (2023). Recoil Stabilization of Two-Wheeled Robot Through Control Moment Gyroscope (CMG), 2023 5th International Congress on Human-

Computer Interaction, Optimization and Robotic Applications (HORA), 1-6,
<https://doi.org/10.1109/HORA58378.2023.10156663>

Vu, V. T., Sename, O., Dugard, L. ve Gaspar, P. (2017). Enhancing roll stability of heavy vehicle by LQR active anti-roll bar control using electronic servo-valve hydraulic actuators, *Vehicle System Dynamics*, 55(9), 1405–1429,
<https://doi.org/10.1080/00423114.2017.1317822>

Zhou, K., Doyle, J. C. ve Glover, K. (1996). *Robust and Optimal Control*, Prentice Hall.

EKLER

Ek 1. Matlab Kodları

```
%% 1. Sembolik Kurulum
syms x1 x2 x3 x4 uc f ddtAlfa eps_s omega_s

% Sabitler
g = 9.8066;
Rb = 0.20222685-0.020;
Rc = 0.400;
Rg = 0.120;
mb = 18.6839780819629 ;
mc = 32.9259498913541;

Ip = 2.33349961828701e-002 ;
Io = 1.40176920325945e-002 ;

Igx = 7.32123414676823e-003 ;
Igy = 6.44373266792268e-003;
Igz = 1.58758607977766e-003;

Ifx = 1.79305520029288e-002;
Ify = 3.56498567415821e-002;
Ifz = 1.896222140532e-002;

Ibx = 0.264998284262085 ;
Iby = 0.545455494328967;
Ibz = 0.748189395896411 ;
Icx = 0.181247054149038;

G1=(Io+Igz);G2=(Io+Igx);G3=Ip+Igy;G4=mb*Rb^2+mc*Rc^2+Ibx+Ifx;
G5=(Igx-2*Igy-2*Ip+Io);
G6=mb*Rb^2+mc*Rc^2-Iby-Ify+Ibz+Ifz+Io+Igz;

% Lineer olmayan denklemler
f1=x2;%phi
f2=(G2*(x2^2*sin(x3)*cos(x3))-(G2-G3*cos(x1))*(eps_s*x4*cos(x3)^2-
eps_s*x4*sin(x3)^2)+G5*x2*x4*sin(x3)*cos(x3)+...

G1*x4*eps_s*cos(x1)+(G6+G3*cos(x3)^2)*eps_s^2*sin(x1)*cos(x1)+(mb*Rb+
mc*Rc)*g*sin(x1)-Ip*omega_s*(x4-eps_s*sin(x1))*cos(x3)-Icx*ddtAlfa-
f*Rc*(cos(0)*cos(x1)-sin(0)*sin(x1)))/(G2*cos(x3)^2+G3*sin(x3)^2+G4);
f3=x4;%Theta
f4=(-G1*eps_s*x2*cos(x1)-G2*(x2*cos(x3)+eps_s*sin(x3))*(x2*sin(x3)-
eps_s*cos(x3))+G3*(x2*cos(x3)+eps_s*sin(x3)*cos(x1))*(x2*sin(x3)-
eps_s*cos(x3)*cos(x1))+Ip*omega_s
*(x2*cos(x3)+eps_s*sin(x3)*cos(x1))+uc)/G1;

% Jacobian ve Fonksiyon Dönüştürme
```

Ek 1. (Devamı)

```
jacA = jacobian([f1;f2;f3;f4], [x1, x2, x3, x4]);
jacB = jacobian([f1;f2;f3;f4], [uc, f, ddtAlfa]);

func_As = matlabFunction(subs(jacA, [x1,x2,x3,x4,uc,f,ddtAlfa], [0,0,0,0,0,0,0]),
    'Vars', [eps_s, omega_s]);
func_Bs = matlabFunction(subs(jacB, [x1,x2,x3,x4,uc,f,ddtAlfa], [0,0,0,0,0,0,0]),
    'Vars', [eps_s, omega_s]);

%% 2. Sayısal Döngü (Daha Geniş Aralık)
omega_vec = 2000:100:5000; % Adımı biraz büyüterek başlattım, hıza göre 10'a
    çekebilirsin
eps_vec = 0:0.001:3;
[E, O] = meshgrid(eps_vec, omega_vec);
Result = zeros(numel(E), 6); % [eps, omg, K1, K2, K3, K4]

% LQR Ağırlıkları (4x4)
Q = diag([50000, 1, 50000, 1]);
R = 0.4;

for k = 1:numel(E)
    cur_eps = E(k);
    cur_omg = O(k);

    As_n = func_As(cur_eps, cur_omg);
    Bs_n = func_Bs(cur_eps, cur_omg);
    Bx_n = Bs_n(:, 1);

    try
        % Sadece 4 durumlu standart LQR
        K = lqr(As_n, Bx_n, Q, R);
        Result(k, :) = [cur_eps, cur_omg, K];
    catch
        Result(k, :) = [cur_eps, cur_omg, NaN(1,4)];
    end
end

% Kayıt
header = {'epsilon','omega','K1','K2','K3','K4'};
writecell(header,'LQR_Kazanclar.xlsx','Sheet',1,'Range','A1');
writematrix(Result(~any(isnan(Result),2),
    :),'LQR_Kazanclar.xlsx','Sheet',1,'Range','A2');
disp('✔ Veri Üretimi (Sadece K_state) Tamamlandı.');
```

%%%%%%%%%

```
clear; clc; close all;

%% 1. Veriyi Yükle ve Hazırla
fprintf('Veri okunuyor...\n');
data = readmatrix('LQR_Kazanclar.xlsx');
```

Ek 1. (Devamı)

```
% NaN temizliği (Garantiye almak için)
data = data(~any(isnan(data),2), :);

% Girişler (X): epsilon, omega
% Çıkışlar (Y): K1, K2, K3, K4
X = data(:, 1:2)';
Y = data(:, 3:6)';

%% 2. Normalizasyon Parametreleri
% Eğitimde ve Simulink'te aynı normalizasyonu kullanmak zorunludur.
Xmin = min(X,[],2); Xmax = max(X,[],2);
Ymin = min(Y,[],2); Ymax = max(Y,[],2);

Xn = (X - Xmin) ./ (Xmax - Xmin);
Yn = (Y - Ymin) ./ (Ymax - Ymin);

%% 3. Sinir Ağı Mimarisi Tasarımı
% [15 15] yapısı 50 bin satır veri için daha esnek bir öğrenme sağlar.
hiddenLayerSizes = [15 15];
net = feedforwardnet(hiddenLayerSizes, 'trainlm');

% Eğitim Parametreleri Ayarı
net.trainParam.epochs = 3000;    % Maksimum tur
net.trainParam.goal = 1e-8;      % Hata hedefi (MSE)
net.trainParam.max_fail = 20;    % Overfitting engelleme (Validation check)
net.trainParam.showWindow = true; % Eğitim grafiğini gör
net.divideParam.trainRatio = 0.85; % %85 Eğitim
net.divideParam.valRatio = 0.10;  % %10 Doğrulama
net.divideParam.testRatio = 0.05; % %5 Test

%% 4. Eğitimi Başlat
fprintf('Sinir ağı eğitiliyor, bu işlem verinin boyutuna göre zaman alabilir...\n');
[net, tr] = train(net, Xn, Yn);

%% 5. Sonuçları Analiz Et
figure;
plotperform(tr); % Eğitim performans grafiği

%% 6. Simulink Ağırlıklarını Kaydet
% Katman ağırlıklarını ve bias değerlerini çekiyoruz
W1 = net.IW{1,1}; b1 = net.b{1};    % Giriş -> Gizli 1
W2 = net.LW{2,1}; b2 = net.b{2};    % Gizli 1 -> Gizli 2
W3 = net.LW{3,2}; b3 = net.b{3};    % Gizli 2 -> Çıkış

save('NN_LQR_WEIGHTS.mat', 'W1','b1','W2','b2','W3','b3', ...
    'Xmin','Xmax','Ymin','Ymax');

fprintf('✔ Eğitim tamamlandı.\n');
fprintf('✔ "NN_LQR_WEIGHTS.mat" dosyası Simulink için hazırlandı.\n');
```

Ek 1. (Devamı)

```
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%% === GRID SEARCH GÖRSELLEŞTİRME ===
figure('Name', 'Grid Search Mimari Analizi', 'Color', 'w', 'Position', [100 100 900 500]);

% Tablodaki verileri garantiye alalım
mse_vals = results.MSE;
arch_names = results.Architecture;
% Kategorik eksenin alfabetik sıralanmasını engellemek için 'Ordinal' yapıyoruz
cat_arch = categorical(arch_names);
cat_arch = reordercats(cat_arch, arch_names);

% Bar grafiği
b = bar(cat_arch, mse_vals, 'FaceColor', [0.2 0.4 0.8]);
set(gca, 'YScale', 'log'); % Hatalar çok küçük, log ölçek şart
grid on;

% En iyi mimariyi tespit et (Tabloya göre)
[minMSE, minIdx] = min(mse_vals);
b.CData(minIdx,:) = [0.1 0.7 0.1]; % En düşük MSE'yi yeşil yap

ylabel('Test MSE (Logaritmik Ölçek)');
xlabel('Sinir Ağı Mimarisi [Gizli Katmanlar]');
title(['En İyi Mimari: [' arch_names{minIdx} '] | MSE: ' num2str(minMSE, '%.2e')]);

% Barların üzerine sayısal değerleri yaz
for k = 1:length(mse_vals)
    text(k, mse_vals(k), sprintf('%1e', mse_vals(k)), ...
        'HorizontalAlignment', 'center', 'VerticalAlignment', 'bottom', 'FontWeight', 'bold');
end

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%% EN İYİ MODEL TAHMİN ANALİZİ
% En iyi ağın (bestNet) tahminlerini al
Y_pred_n = bestNet(Xn);
Y_pred = mapminmax('reverse', Y_pred_n, Yps); % Gerçek değerlere dön

figure('Name', 'LQR Kazanç Tahmin Doğruluğu', 'Color', 'w', 'Position', [150 150 1000
    700]);
t = tiledlayout(2,2, 'TileSpacing', 'Compact');

for i = 1:4
    nexttile;
    plot(Y(i, 1:200), 'k', 'LineWidth', 2); hold on; % İlk 200 örnek
    plot(Y_pred(i, 1:200), 'r--', 'LineWidth', 1.5);

    grid on;
    title(['K_' num2str(i) ' Kazancı']);
    if i == 1, legend('Gerçek LQR', 'YSA Tahmini'); end
end
title(t, ['En İyi Mimari [15 15] - Tahmin Hassasiyeti']);
```

Ek 1. (Devamı)

```
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%% 2. Grid Search Hazırlığı
architectures = {[10], [15], [10 10], [15 15], [20 20], [15 10 5]};
nArch = length(architectures);

% Tabloyu önceden tanımlayarak uyarıyı engelleyelim
results = table(cell(nArch,1), zeros(nArch,1), 'VariableNames', {'Architecture', 'MSE'});
bestMSE = inf;
fprintf('Grid Search Başlatıldı...\n');
fprintf('-----\n');

%% 3. Optimizasyon Döngüsü
for i = 1:nArch
    currentArch = architectures{i};
    archStr = num2str(currentArch);

    net = feedforwardnet(currentArch, 'trainlm');
    net.trainParam.showWindow = false;
    net.trainParam.epochs = 1000;

    [net, tr] = train(net, Xn, Yn);

    % Test hatası hesapla
    testOutput = net(Xn(:, tr.testInd));
    currentMSE = mse(Yn(:, tr.testInd) - testOutput);

    % Tabloya veriyi düzgünce yerleştir
    results.Architecture{i} = archStr;
    results.MSE(i) = currentMSE;

    fprintf('Yapı: [%s] | Test MSE: %.2e\n', archStr, currentMSE);

    if currentMSE < bestMSE
        bestMSE = currentMSE;
        bestArch = currentArch;
        bestNet = net;
    end
end

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
function K_state = NN_LQR_Block(eps, omega)
%#codegen
persistent W1 b1 W2 b2 W3 b3 Xmin Xmax Ymin Ymax

if isempty(W1)
    S = load('NN_LQR_WEIGHTS.mat');
    W1=S.W1; b1=S.b1; W2=S.W2; b2=S.b2; W3=S.W3; b3=S.b3;
    Xmin=S.Xmin; Xmax=S.Xmax; Ymin=S.Ymin; Ymax=S.Ymax;
end

% Giriş Sınırlandırma ve Normalizasyon
```

Ek 1. (Devamı)

```
eps_c = max(min(eps, Xmax(1)), Xmin(1));
omg_c = max(min(omega, Xmax(2)), Xmin(2));
Xn = ([eps_c; omg_c] - Xmin) ./ (Xmax - Xmin);

% İleri Besleme
z1 = tanh(W1*Xn + b1);
z2 = tanh(W2*z1 + b2);
Yn = W3*z2 + b3;

% Denormalizasyon
K_state = Yn .* (Ymax - Ymin) + Ymin; % 4x1 Vektör
end
```

ÖZGEÇMİŞ

İlk ve orta öğrenimini İstanbul'da tamamladı. 2018 yılında Karadeniz Teknik Üniversitesi Makine Mühendisliği Bölümünden mezun oldu. Özel sektörde makine mühendisi ve kalite kontrol mühendisi olarak çalıştı. 2021 yılında Trabzon Büyükşehir Belediyesi'nde Makine Mühendisi olarak çalışmaya başladı ve devam etmektedir. 2023 yılında Gümüşhane Üniversitesi Mühendislik ve Doğa Bilimleri Fakültesi Makine Mühendisliği Bölümü Makine Teorisi ve Dinamiği Anabilim Dalında yüksek lisans eğitimine başladı ve halen devam etmektedir.