



VERİ GÜDÜMLÜ KONTROLDE VERİ KALİTESİNİN KRİTİK ROLÜ: BİR DA MOTOR UYGULAMASI

Güray SONUGÜR^{1*}

¹ Afyon Kocatepe Üniversitesi, Teknoloji Fakültesi, Mekatronik Mühendisliği Bölümü, Afyonkarahisar, Türkiye

Anahtar Kelimeler	Öz
DA Motor Kontrolü, Veri Güdümlü Kontrol, Yapay Sinir Ağları, PID, Sentetik Veri.	Bu çalışmada, veri güdümlü kontrol (VGK) kapsamında doğru akım (DA) motorlarının hız denetiminde giriş verisi türlerinin etkisi incelenmiştir. Bu amaçla, klasik PID ve öğrenme tabanlı olarak çalışan Yapay Sinir Ağları (YSA) denetleyicileri karşılaştırılmıştır. VGK, bir sistemin matematiksel modeline ihtiyaç duymadan giriş-çıkış verilerine dayalı olarak denetim parametrelerinin hesaplanabilmesini sağlayan bir yaklaşımdır. Bu kapsamda, basamak, sinüs, testere dişi, rastgele ve karışık olmak üzere beş farklı türde sentetik veri seti üretilmiş, normalize edilerek DA motorlara giriş voltajı olarak uygulanmış ve motor milinin çıkış hızları ölçülmüştür. Toplanan veriler ile tasarlanan veri güdümlü PID ve YSA denetleyiciler en uygun veri seti/ denetleyici çiftini tespit etmek için gerçek zamanlı deneylere tabi tutulmuştur. Gerçek zamanlı deneylerden elde edilen sonuçlar, ortalama karesel hata, yükselme süresi, oturma süresi ve en yüksek yüzde aşma gibi performans ölçütleri ile değerlendirilmiştir. Ayrıca, DA motorun kontrol yanıtlarını optimize etmek amacıyla bulanık mantık tabanlı bir ölçekleme çarpanı tahmin sistemi geliştirilmiştir. DeneySEL bulgular, öğrenme tabanlı stratejilerle eğitilen YSA denetleyicilerinin, özellikle yüksek çeşitlilik içeren veri setleri ile daha başarılı performans sergilediğini göstermiştir.

THE CRITICAL ROLE OF DATA QUALITY IN DATA-DRIVEN CONTROL: A DC MOTOR CASE STUDY

Keywords	Abstract
DC Motor Control, Data-Driven Control, Artificial Neural Network, PID, Synthetic Data.	This study looked into the effect of different forms of input data on the speed control of direct current (DC) motors under data-driven control (DDC). For this purpose, traditional PID and learning-based Artificial Neural Network (ANN) controllers were evaluated. DDC is a method for calculating control parameters based on input-output data without the requirement for a mathematical model of the system. In this context, five distinct types of synthetic data sets, namely step, sine, sawtooth, random, and mixed, were produced, normalized, and applied as input voltage to DC motors, with the output shaft speeds monitored. Real-time experiments were performed on the data-driven PID and ANN controllers developed with the obtained data to determine the best dataset/controller combination. The results of the real-time experiments were evaluated using performance criteria such as mean squared error, rising time, settling time, and maximum percentage overshoot. In addition, a fuzzy logic-based scaling factor prediction system was built to optimize the DC motor's control responses. The experimental results show that ANN controllers trained with learning-based strategies perform better, especially with high-diversity data sets.

Alıntı / Cite

Sonugür, G., (2025). Veri Güdümlü Kontrolde Veri Kalitesinin Kritik Rolü: Bir DA Motor Uygulaması, Mühendislik Bilimleri ve Tasarım Dergisi, 13(2), 397-411.

Yazar Kimliği / Author ID (ORCID Number)	Makale Süreci / Article Process								
G. Sonugür, 0000-0003-1521-7010	<table><tr><td>Başvuru Tarihi / Submission Date</td><td>30.10.2024</td></tr><tr><td>Revizyon Tarihi / Revision Date</td><td>17.03.2025</td></tr><tr><td>Kabul Tarihi / Accepted Date</td><td>17.03.2025</td></tr><tr><td>Yayın Tarihi / Published Date</td><td>27.06.2025</td></tr></table>	Başvuru Tarihi / Submission Date	30.10.2024	Revizyon Tarihi / Revision Date	17.03.2025	Kabul Tarihi / Accepted Date	17.03.2025	Yayın Tarihi / Published Date	27.06.2025
Başvuru Tarihi / Submission Date	30.10.2024								
Revizyon Tarihi / Revision Date	17.03.2025								
Kabul Tarihi / Accepted Date	17.03.2025								
Yayın Tarihi / Published Date	27.06.2025								

* İlgili yazar / Corresponding author: gsonugur@aku.edu.tr, +90-272-218-2529

THE CRITICAL ROLE OF DATA QUALITY IN DATA-DRIVEN CONTROL: A DC MOTOR CASE STUDY


Güray SONUGÜR^{1†}

¹Afyon Kocatepe University, Faculty of Technology, Department of Mechatronic Engineering, Afyonkarahisar, Türkiye

Highlights

- The sensitivity of Data-Driven Control (DDC) to Input Data Forms was revealed.
- The importance of input data type and controller selection on controlling performance is emphasized.
- Real-time experiments were used to compare ANN and PID controllers.
- A fuzzy logic based scaling factor estimation system was developed.

Graphical Abstract



Purpose and Scope

The aim of this research is to examine the impact of dataset characteristics on the performance of data-driven control methods, with a focus on understanding how these characteristics influence control performance in DC motor speed control.

Design/methodology/approach

In this study, a DC motor's speed was controlled using data-driven PID and ANN techniques, and the outcomes were compared. The control algorithms were tested in real time on a DC motor using data sets of various characteristics in order to simulate the motor's realistic behavior. Specifically, the features of the dataset that influence the control algorithms' performance were examined.

Findings

ANN controllers trained with high uniqueness data sets outperform PID controllers, according to tests.

Originality

This work is unique in that it uses experimental analysis on real DC motors to investigate how dataset properties impact the efficiency of data-driven control approaches. The study conducts an in-depth examination of various dataset properties that affect data-driven control algorithm performance and proves their effect on motor control using real-time experiments.

[†] ilgili yazar / Corresponding author: gsonugur@aku.edu.tr, +90-272-218-2529

1. Giriş (Introduction)

Doğru akım (DA) motoru, elektrik enerjisini mekanik enerjiye dönüştüren bir tür elektrikli makinedir. Robotik, elektrikli araçlar, endüstriyel otomasyon ve yenilenebilir enerji sistemleri gibi çeşitli uygulamalarda yaygın olarak kullanılmaktadır. Diğer motorlara göre avantajları; daha iyi tork ve hız özellikleri, dinamik değişikliklere daha iyi tepki, yüksek güç/ağırlık oranı, akım uyarımına ihtiyaç duymaması, az gürültülü çalışması ve düşük maliyetidir (Kamal vd., 2014; Moussavi vd., 2012; Purnama vd., 2019). Bununla birlikte, bir DA motordan optimum performans ve verim elde etmek için direnç, endüktans, tork sabiti ve zıt elektro motor kuvvet (emk) sabiti gibi parametrelerini bilmek önemlidir. Bu parametreler yaşlanma, aşınma, yıpranma, çevresel koşullar, yük değişiklikleri ve zamana bağlı faktörler nedeniyle değişebilir. Bu nedenle motor parametrelerini doğru ve uyarlanabilir bir şekilde tanımlamak gerekir.

On yıllar boyunca kontrol teknikleri, Model Tabanlı Kontrolün (MTK, Model-based Control-MBC) çeşitli tiplerinden Veri Güdümlü Kontrole (VGK, Data Driven Control – DDC) doğru evrilmiştir (Khan vd., 2017). VGK, matematiksel bir modele dayanmadan, sistemden toplanan verilere dayalı denetleyiciler tasarlamayı amaçlayan bir kontrol teorisi dalıdır. Bunun tersi olarak MTK’de motor parametrelerinin fiziksel ilkeler ve matematiksel eşitlikler doğrultusunda hesaplanması ve/veya motor parametrelerinin üretici kataloglarından belirlenmesi veya deneysel olarak ölçülmesi gerekir. Örneğin armatür direncinin, armatür indüktansının veya eylemsizlik momentinin ölçülmesi vb. Bu şekilde sistemin transfer fonksiyonları veya durum uzay modelleri oluşturulabilir. VGK, robotik, havacılık ve akıllı şebekeler gibi karmaşık ve belirsiz sistemlere uygulanabilirliği nedeniyle son yıllarda büyük ilgi görmüştür (Hou vd., 2017). Bununla birlikte, VGK yöntemlerinin performansı büyük ölçüde giriş verilerinin kalitesine, etkinliğine ve miktarına bağlıdır. Rastgele, periyodik veya optimal sinyaller gibi farklı türdeki giriş verileri, VGK yöntemlerinin doğruluğu ve sağlamlığı üzerinde farklı etkilere sahip olabilir. Bu nedenle, VGK çalışmalarında giriş verisi türlerinin denetleyici performansını nasıl etkilediğinin araştırılması önemlidir.

Bir DA motorun veriye dayalı tanımlanması, motorun hiçbir fiziksel parametresine ihtiyaç duymadan ölçülen giriş-çıkış verilerinden parametrelerini tahmin etme sürecidir. Bu yaklaşım, belirsizliklere ve doğrusal olmayan durumlara karşı daha dayanıklı olması, daha az hesapsal maliyet gerektirmesi ve her tür DA motora uygulanabilir olması gibi geleneksel MTK yöntemlerine göre çeşitli avantajlara sahiptir. Veri toplama esnasında DA motorların normal çalışmaları sırasında karşılaşılmaları muhtemel senaryoların büyük bir kısmının motorlara uygulanması gerekir. Aksi takdirde özellikle öğrenme tabanlı denetleyiciler geliştiremedikleri senaryolara karşı doğru tepkileri üretemezler. Motor parametrelerinin tanımlanmasının ardından ikinci adım uygun bir denetleyici tasarlamaktır.

Bu makalede DA motorların hız kontrol performansını değerlendirmek için gerçek zamanlı veri kullanımının önemi vurgulanmaktadır. VGK kapsamında giriş veri seti türlerinin kontrol performansı üzerindeki etkisine ilişkin kapsamlı bir inceleme sunulmuştur. Basamak, rampa, sinüs, rastgele gibi farklı formattaki sentetik veri setlerinin denetleme performansını kararlılık ve sağlamlık açısından nasıl etkilediği analiz edilmiştir. Böylece VGK kontrol yöntemlerinin performansında veri seti formlarının oynadığı rol tespit edilmeye çalışılmıştır. Yapılan analizlerde simülasyonlar kullanılmamış, gerçek motorlarla gerçek zamanlı 42 farklı tipte deney gerçekleştirilmiş ve dört farklı performans verisi ölçülmüştür. Çoğunlukla kontrol performansını belirlemek amacıyla simülasyonlar kullanılırken, bu çalışma ile gerçek motorlar üzerinde deneyler yapılarak elde edilen sonuçların güvenilirliği yükseltmeye çalışılmıştır. Böylece sonuçların endüstriyel uygulamalarda daha doğru ve etkili kontrol stratejilerinin geliştirilmesi için kullanılabileceği düşünülmektedir. Ayrıca, VGK algoritmalarının DA motorlarının hız kontrolü için etkili bir yöntem olduğu ve farklı veri modellerinin hız kontrolü performansına farklı etkileri olduğu ortaya konmuştur. Ayrıca bu etkiler otomatik kontrol literatüründe başlıca iki yaklaşımı temsil eden PID (geleneksel) ve YSA (öğrenme tabanlı) yöntemleri kullanılarak analiz edilmiş ve sonuçlar karşılaştırılmıştır.

VGK yönteminde toplanan veriler ile farklı tipte kontrol stratejileri uygulanabilmektedir. Örneğin giriş-çıkış verileri arasında bir ilişki kurulup matematiksel modele dayalı bir transfer fonksiyonu elde edilebilir ve ardından bir PID (Jeng ve Ge, 2016; Özbaltan ve Çaşka, 2024; Baciü ve Lazar, 2023), LQR (Lineer Quadratic Regulator/ Doğrusal Karesel Düzenleyici) (Suleimenov ve Do, 2019) veya Geri adımlama (Back stepping Control) (Weng ve Wang, 2020) gibi geleneksel denetleyiciler geliştirilebilir. Bunun yanı sıra bu veriler ile öğrenme tabanlı denetleyiciler de tasarlanabilir. Örneğin (Hamoodi vd., 2019)’da iki YSA ve PID temelli iki teknik ile DA motorlarının parametreleri tanınmaya çalışılmıştır. Sonuçta YSA tabanlı tekniğin daha başarılı sonuçlar ürettiği yazarlar tarafından vurgulanmıştır. (Chaudhary vd., 2017)’da Uyarlanabilir Sinirsel-Bulanık Çıkarım Sistemi (Adaptive Neuro-Fuzzy Inference System-ANFIS) kullanılarak modellenen bir DA motor kontrol çalışması yapılmıştır. Bu çalışmada elde edilen sonuçlar, PID ve Bulanık Mantık kullanılarak elde edilen sonuçlar ile karşılaştırılmış ve en başarılı sonuçların ANFIS yönteminde elde edildiği belirtilmiştir. Öğrenme tabanlı yöntemler içinde zaman serilerini dikkate alarak giriş-çıkış ilişkisi oluşturan sinir ağları da vardır. Bunlar, hafızalı öğrenme yöntemleri olarak da bilinmektedirler. Bu yöntemlerde belirli bir döngü içinde çıkışlar ve girişler belirli bir zaman

gecikmesi ile giriş veri setlerine dahil olurlar (Munagala ve Jatoth, 2022). En çok kullanılanları Dışsal Girdili Doğrusal Olmayan Otokorelasyon (Nonlinear AutoRegressive with eXogenous inputs - NARX) yöntemi (Mishra, 2009) ve Tekrarlayan sinir ağı (Recurrent Neural Network- RNN) (Ismeal vd., 2014) yöntemleridir.

VGK sürecindeki en önemli adımlardan birisi DA motorların giriş ve çıkış verilerinin toplanmasıdır. Eğer bu noktada hatalı veya gürültülü veriler toplanırsa tanınan parametreler hatalı ve dolayısıyla da denetleyici başarısız olacaktır. (Salah ve Abdelati, 2010) tarafından yapılan çalışmada bir fırçalı DA motorunun giriş voltajı, çıkış devir hızı armatür akımı verileri bir DAQ cihazı vasıtasıyla toplanmıştır. (Carlet vd., 2020)'de ise bir DA senkron motorun hız denetimi için rastgele belirlenen voltaj girdilerine karşılık elde edilen akım verileri ile bir model oluşturulmuştur.

Bu çalışmada, giriş veri setlerine göre denetleyici performanslarının değişimini tespit etmek amacıyla bir adet öğrenme tabanlı bir adet de klasik denetleyici seçilmiştir. Öğrenme tabanlı olarak YSA denetleyici, geleneksel denetleme yöntemi olarak PID kullanılmış ve performansları karşılaştırılmıştır.

2. Materyal ve Yöntem (Material and Method)

VGK, sistem dinamiklerinin matematiksel modellerine dayanmadan karmaşık sistemler için denetleyiciler tasarlamayı amaçlayan bir denetleme stratejisidir. Bu tip denetleyiciler sistemi nasıl kontrol edeceklerini öğrenmek için denetlenecek sistemden elde edilen giriş-çıkış verilerini kullanır.

2.1. Veri Güdümlü Kontrol (Data-Driven Control)


Bu çalışmada, iki farklı stratejideki iki farklı yöntem kullanılmıştır. Öğrenme tabanlı VGK (ÖT-VGK) denetleyiciler ve Model tabanlı VGK (MT-VGK) denetleyiciler. ÖT-VGK denetleyiciler, sistem dinamiklerini açıkça modellemeyen doğrudan verilerden bir kontrol stratejisi öğrenir. Bu stratejiye kara kutu modelleme ismi de verilmektedir. MT-VGK denetleyicilerde ise verilerden sistemin giriş-çıkış ilişkisi transfer fonksiyonu veya durum uzay modeli vb. olarak çıkartılarak sistem parametreleri hesaplanır. Bu tür stratejilere de gri kutu modelleme ismi verilmektedir. Her iki denetleyici türü de kullanılan giriş verilerinin niteliğine ve niceliğine bağlıdır.

Öğrenme tabanlı denetleyiciler iki kategoride sınıflandırılabilir: takviyeli öğrenme (Reinforcement Learning) ve eğitici öğrenme (Supervised Learning). Takviyeli öğrenmeyi kullanan denetleyiciler sistemle etkileşime girerek ve eylemlerine bağlı olarak ödülleri veya cezaları alarak bir kontrol politikası öğrenir. Eğitici öğrenmeyi kullanan denetleyiciler ise bir dizi girdi ve doğru çıktı etiketleri kullanarak bir modelin öğrenmesi işlemidir. Her iki öğrenme tipini kullanan denetleyicilerden yüksek performans elde etmek için büyük miktarda girdi verisi gerekir. Bu verilerin, kullanılan sistemin farklı durumlarını ve eylemlerini kapsamaları ve arka plandaki dinamiklerini ortaya çıkarmaları için çeşitli ve bilgilendirici olması gerekir. Giriş verileri eksik, gürültülü, dengesiz dağılımlı, tekrarlı veya bozuka, öğrenme tabanlı denetleyici ilk defa karşılaştığı durumlar için genelleme yapamayabilir ve optimal veya güvenli olmayan yanıtlar oluşturabilir.

VGK stratejisini kullanmayan model tabanlı denetleyicilerde sistem parametreleri üretici kataloglarından veya sistem üzerinden ayrıntılı ölçümlerin yapılmasıyla elde edilir. DA motorlar özelinde motorun armatür direnci, armatür indüktansı veya eylemsizlik momentleri ölçüm cihazlarıyla ölçülebilir. Ardından fiziksel ilkelere göre matematiksel eşitliklerin oluşturulup gerekli hesaplamaların yapılması gerekir. Ancak, bu tip modellemede sistemi oldukça basitleştirecek bir kısım varsayımların yapılarak sistem karmaşıklığının azaltılması gereklidir. Bu durumda hesaplanan modeller sistemi tam olarak yansıtmayacaktır. MT-VGK denetleyiciler tipik olarak öğrenme tabanlı denetleyicilerden daha az girdi verisi gerektirir, çünkü sistem yapısı veya özellikleri hakkında önceki bilgi veya varsayımlardan faydalanılabilir. Ya da sadece üretici kataloglarından veya ölçme yoluyla elde edilemeyen parametreler için kestirimlerde bulunulabilir. Ancak yine de giriş verilerinin doğru olması ve sistem dinamiklerini yüksek oranda temsil etmesi gerekir. Giriş verileri çok gürültülü, tutarsız veya eksikse, model tabanlı denetleyici, performansını veya kararlılığını düşüren model hatalarından veya belirsizliklerden kötü yönde etkilenebilir. Sonuç olarak, girdi verileri veri güdümlü denetleyicilerin performansında çok önemli bir rol oynamaktadır (Chi vd., 2018; Umlauf ve Hirche, 2020; Yu vd., 2021). Öğrenme tabanlı denetleyiciler ve model tabanlı denetleyicilerin giriş verilerine ilişkin farklı gereksinimleri ve zorlukları vardır. ÖT-VGK denetleyiciler yüksek doğrulukta bir kontrol politikası öğrenerek giriş-çıkış arasındaki ilişkiyi genelleştirebilmeleri için büyük miktarda, çeşitli ve bilgilendirici giriş verisine ihtiyaç duyar. MT-VGK denetleyiciler ise sistem parametrelerinin gerçeğe yakın bir modelini çıkartmak için gerçek sistem ile model arasında yüksek eşleşme oranını sağlayacak verilere ihtiyaç duyar. Bu nedenle, uygun giriş verilerinin seçilmesi, etkili ve sağlam VGK denetleyicilerin tasarlanması için çok önemlidir.

2.2. Giriş Veri setleri (Input Datasets)


Bu çalışmada, MT-VGK yöntemi olarak PID, ÖT-VGK yöntemi olarak YSA seçilmiştir. MT-VGK tasarımında öncelikle, denetlenecek sistemin s-alanındaki transfer fonksiyonu elde edilmiştir. Bunun için Matlab R2020 yazılımının “System Identification (SI)” araç kutusu kullanılmıştır. Sonrasında P, I ve D katsayılarının ince ayarı için yine aynı yazılımın “PID Tuning” araç kutusu kullanılmıştır. Öğrenme tabanlı denetlemede YSA mimarisini geliştirmek için yine Matlab R2020 yazılımı kullanılmıştır. Her iki denetleme yönteminde de ortak olarak kullanılan girdi veri setleri Şekil 1’de verilmiştir. Her iki tip denetleme stratejisinde de girdi verileri DA motorların besleme gerilimlerinde kullanılan darbe genişlik modülasyonu (DGM - PWM) görev-orandır (duty cycle). Görev oranları genelde yüzde oran olarak verilir ve 0-1 aralığındaki sayılarla ifade edilir. Girdi veri setlerinde kullanılan sinyal tipleri basamak, sinüs, testere dişi, rastgele ve karışık olarak seçilmiştir. Girdi veri setinin boyutları tüm veri setlerinde eşit olarak belirlenmiştir. Ortalama 0.18s örnekleme periyodunda her bir veri seti tipi için gerçek zamanlı olarak 1000’er adet veri girdi-çıkı çifti toplanmıştır.



Şekil 1. Giriş olarak kullanılan veri seti karakteristikleri (Data set characteristics used as input)

2.3. PID Denetleyiciler (PID Controllers)

PID denetleyicileri, basit yapıları sayesinde pek çok farklı tipte sistemin denetleme süreçlerinde pratik çözümler sunabilir. Ayrıca geçici durum yanıtını hızlandırarak sistemin istenen değere daha çabuk ulaşmasını sağlar ve kararlı durum hatasını azaltarak sistemin ayar noktasından sapmasını önler. PID denetleyicilerinin bu avantajlarından tam olarak faydalanabilmek için, kontrolör parametrelerinin sisteme uygun bir şekilde seçilmesi gerekmektedir (Vural ve Bayindir, 2010). Çalışmada kullanılan PID denetleyicinin blok şeması Şekil 2’de verilmiştir.



Şekil 2. Çalışmada kullanılan PID denetleyici yapısı (PID controller structure used in the study)

Burada, i : iterasyon numarası, R_i : Önceden belirlenmiş olan referans değer, C_i : sistem çıkışı, E_i : hata, dU_i : denetleyici çıkışı, U_i : sistem girişi, $\ddot{O}\ddot{C}$: ölçekleme çarpanı ve Z^{-1} : birim gecikme olmak üzere, R_i ve C_i arasındaki fark olan E_i 'nin olabildiğince azaltılması için oransal (K_p), integral (K_{int}) ve türev (K_d) katsayıları düzenlenir. PID denetleyicilerde çıkış değeri Eşitlik 1-2’de verildiği şekilde hesaplanmaktadır.


$$dU_i = K_p E_i + K_{int} \int E_i dt + K_d \frac{dE_i}{dt} \quad (1)$$

$$U_i = \ddot{O}Ç * dU_i + U_{i-1} \quad (2)$$

PID denetleyici için basamak, sinüs eğrisi, testere dişi, rastgele ve karışık olarak adlandırılan ve örnekleri Şekil 1'de verilen altı farklı tipte elde edilen model giriş/çıkış verileri kullanılarak altı farklı transfer fonksiyonu ve altı $[K_p, K_{int}, K_d]$ katsayı üçlülere hesaplanmıştır. Transfer fonksiyonlarının hesaplanabilmesi için giriş değerleri ve bu değerlerin sistem yanıtları kullanılarak bir sistem tanımlama (System Identification-SI) işlemi gerçekleştirilmiştir. Bu işlem için Matlab R2020 SI araç kutusu kullanılmıştır. Bu araç kutusu, sistem tanımlama yöntemlerini kullanarak matematiksel modeller oluşturmaya ve sistemlerin davranışını analiz etmeye yarayan bir araç kutusudur. Bu işlem ile deneysel olarak elde edilen sistem giriş-çıkış verilerinin analiz edilmesi sonucu giriş ile çıkış arasındaki ilişki tanınmaya çalışılır. Yani sistemlerin matematiksel modellerinin çıkarılmasına olanak tanır. Matlab R2020'de PID tasarımı için başka araçlar ve fonksiyonlar da mevcuttur, örneğin "pidtune" ve "pidtool". Bu araçlar, otomatik PID katsayı optimizasyonu için kullanışlı grafik ara yüzleri sağlar. Matlab araç kutuları; P, PI, PD ve PID katsayılarını çeşitli yöntemler kullanarak ayarlar:

1. Ziegler-Nichols Ayar Metodu: Bu yöntem, sistemin tepkisini analiz ederek PID katsayılarını belirler. İlk olarak, P katsayısı sıfır alınır ve D katsayısı kapatılır. Sisteme bir adım girişi uygulanır ve çıkış tepkisi gözlenir. Tepkideki salınım periyodu ve salınım dönemi ölçülür. Ziegler-Nichols formüllerini kullanarak P, I ve D katsayıları hesaplanır.
2. Frekans Tepki Yöntemi: Bu yöntemde, sistem frekans tepkisi kullanılarak PID katsayıları belirlenir. İlk olarak, sistem frekans tepkisi alınır ve belirli bir frekans aralığında analiz edilir. Elde edilen frekans tepkisi kullanılarak PID katsayıları tahmin edilir veya optimize edilir.
3. Optimizasyon tabanlı ayarlama: Bu yöntem, istenen bir performans ölçütünü optimize eden PID katsayılarını bulmak için optimizasyon tekniklerini kullanır. Optimizasyon tabanlı ayarlama çok yüksek performans elde etmek için kullanılabilir, ancak hesapsal maliyeti yüksek olabilir.

Bu yöntemler Matlab yazılımında PID türevi yöntemlerin katsayılarını belirlemek için kullanılan yaygın yöntemlerdir (Mohamed vd., 2010). Çalışmada PID katsayılarının elde edilmesi için gerçekleştirilen işlem adımları Şekil 3'te verilmiştir.



Şekil 3. Matlab R2020 araç kutularının kullanımı (Using Matlab R2020 toolboxes)


Burada, $[Girdi, Çıktı]_j$ model verisetine göre DA motordan elde edilen görev-oranı ile dönüş hızı verilerini, $[TF_j]$ modele göre SI araç kutusu tarafından elde edilen transfer fonksiyonlarını ve $[K_p, K_{int}, K_d]_j$ üçlülere de PID katsayılarını temsil etmektedir.

2.4. YSA Denetleyiciler (ANN Controllers)

YSA, insan sinir sistemini basit bir şekilde matematiksel olarak temsil eden bir modeldir. Bir sinir ağı, eğitim verilerini öğrenme ve genelleme yeteneğine sahip bir bilgi işleme sistemidir. Birbirine bağlı çok sayıda işlem elemanlarından (nöron) oluşan katmanlardan kurulu bir mimariye sahiptir (Keles vd., 2023). Bu kapsamda pek çok sinir ağı mimarisi geliştirilmiştir. YSA tabanlı denetleyiciler otomatik kontrol süreçlerinde yaygın olarak kullanılan öğrenme tabanlı denetleyicilerdir. Genellikle doğrusal olmayan sistemlerin kontrolü için kullanılırlar. Bu denetleyiciler, geri besleme döngüsü kullanarak bir hedef referans değere ulaşmak amacıyla gerekli olan çıkışları üretmek için önceden eğitilirler. YSA mimarisinde nöronların eşik değerleri ve nöronlar arası bağlantıların sayısal ağırlık değerleri vardır. YSA'nın eğitim süreci, söz konusu ağırlık ve eşik değerlerinin optimize edilmesi yoluyla gerçekleştirilir. Bir YSA'nın eğitilmesi için giriş ve bu girişlere karşılık oluşan çıkış verilerinin mevcut olması gerekir. YSA'lar giriş ve çıkış verileri arasında doğrusal olmayan bir haritalama yapmak suretiyle daha önceden hiç karşılaşmadıkları girişlere karşı doğruya en yakın çıkışı üretmeyi amaçlarlar. Doğruya en yakın

sonuçların alınması için eğitimde kullanılan giriş ve çıkış değerlerinin yeterli nicelik ve nitelikte olması gerekir. Yapay sinir ağı temelli denetleyicilerin avantajı, hedefi belirleyen ve hedefe ulaşmak için gerekli olan çıkışları üreten öğrenme yeteneğidir (Timurkutluk vd., 2023). Bu yetenek sayesinde YSA denetleyiciler bozucu etkiler ile değişen dış koşullara ve değişen referans değerlere uyum sağlayabilirler. Bu çalışmada çevrim dışı eğitilmiş bir YSA kullanılmıştır. Bu yöntemde, motora uygulanan voltaj değerlerine karşılık gelen motor dönüş hızlarını eşleştiren bir dizi giriş/çıkış verisi kullanarak bir sinir ağı çevrimdışı olarak eğitilir.


Eğitim giriş verisi olarak basamak, sinüs eğrisi, testere dişi, rastgele ve karışık olarak adlandırılan ve örnekleri Şekil 1’de verilen altı farklı tipte sentetik veri kullanılmıştır. Eğitim sürecinden sonra elde edilen sinir ağı yapısı motorun hızını düzenlemek için kapalı döngü bir kontrol sisteminde kullanılmıştır. Tasarlanan sinir ağı 20’şer nörondan oluşan 2 gizli katman ile giriş ve çıkış katmanlarından oluşmaktadır. YSA modelinin mimarisi ve süreçleri Şekil 4’te blok şema olarak açıklanmıştır.



Şekil 4. (a) YSA mimarisi, (b) YSA modelinin yapısı ((a) ANN architecture, (b) ANN model structure)

Şekilde; V_i , DA motorlara uygulanan görev-oranını, n_i , devir/dakika cinsinden açısal hız çıkışını, $\hat{V}_i$, Tahmin edilen görev-oranı çıkışını ve V_{hata} , YSA modelinde geriye yayılan gerçek çıkışla tahmin edilen çıkış arasındaki farkı temsil etmektedir.

Kontrol sistemi, giriş kontrol sinyallerine dayalı olarak motor hızını tahmin etmek için sinir ağını kullanır ve istenen motor performansını elde etmek için kontrol sinyallerini buna göre ayarlar. Bu şekilde DA motorlarda tanımlanması zor olabilen belirsizliklerin olumsuz etkileri azaltılarak YSA’nın motorun tepkilerini doğrudan verilerden öğrenmesi sağlanmıştır. Yapay sinir ağı tasarımı, problemin bağlamına, verisetinin özelliklerine ve performans hedeflerine bağlı olarak değişir. Tasarımda kullanılacak en uygun parametrelerin belirlenmesi için deneme yanılma süreçleri gerçekleştirilmiş ve modellerin performansı izlenmiştir. Bir DA motorunda görev-oranı ve dönüş hızı arasındaki ilişkinin öğrenilmesi zor bir süreçtir. Çünkü DA motorların zamana bağlı olarak değişen iç dinamikleri vardır. Bu nedenle, tek gizli katmanlı tasarımlar yerine iki gizli katmanlı bir tasarım seçilmiştir. Gizli katman sayısının artırılması ise hesapsal maliyetin artması ve ezberleme (aşırı öğrenme) gibi sonuçlar ortaya çıkarabilmektedir. Gizli katmanda 20’şer nöron kullanarak DA motorlardaki görev-oranı ile dönüş hızı ilişkisi arasındaki zamana bağlı örüntülerin daha yüksek doğrulukta ortaya çıkarılması amaçlanmıştır. Daha düşük nöron sayılarıyla yapılan denemelerde test verilerindeki ortalama karesel hata performansının yeterli olmadığı gözlenmiştir. Her bir model için oluşturulan 1000’er verilik verisetlerinden 900’ü eğitim ve doğrulama süreçlerinde 100’ü de bağımsız test işlemlerinde kullanılmıştır. Yani ayrılan 100 adet veri, eğitim sürecine katılmamıştır. Bu şekilde eğitilmiş ağ, ilk defa karşılaştığı veriler ile test edilebilmiştir. Bu testler sayesinde YSA’nın genelleme yeteneği ölçülmüş ve aşırı öğrenme gibi istenmeyen durumların önüne geçilmiştir. Bu süreç ile ilgili ayrıntılı açıklamalar bölüm 3.2’de verilmiştir. Tasarlanan denetleyici mimarisi Şekil 5’te verilmiştir.



Şekil 5. Denetleyici mimarisi (Controller architecture)


Burada; R_i : Önceden belirlenmiş olan referans değerler, C_i : Sistem Çıkışı, dU_i : Denetleyici Çıkışıdır. Diğer bileşenler Eşitlik 3-4’te verilmiştir.

$$E_i = R_i - C_i \quad (3)$$

$$U_i = \ddot{O}\ddot{C} * dU_i + U_{i-1} \quad (4)$$


2.5. Ölçekleme Çarpanları (Scaling Factors)

Ölçekleme çarpanları (ÖÇ) zamana bağlı performans ölçütlerinin iyileştirilmesi için kullanılmıştır. Tasarlanan denetleyicilerin yazılımlarında her çevrimde elde edilen sistem çıkışları belirlenen ÖÇ değerleri ile ölçeklenerek referans değerlere daha hızlı yaklaşması amaçlanmıştır. ÖÇ kullanımı, giriş ve çıkış verilerinin büyüklük ve birimlerindeki farklılıkların denetleyici sistemlerin performansı üzerindeki olumsuz etkisini azaltmaya yardımcı olmaktadır. Kullanılan denetleyici tasarımında girdiler görev-orandır. Denetleyici çıkışları ise motorun dönüş hızıdır. Özellikle daha hassas kontrol süreçlerinde denetleyici çıkışlarının söz konusu seviyelere kısa sürelerde erişimi için bir ölçekleme yapılması çoğu zaman kaçınılmazdır. Yapılan çalışmada, kullanılan yöntem ve veri modeli bazında farklı ÖÇ değerleri elde edilmiştir. ÖÇ hesaplamasında bulanık mantık sistemi (BMS) (Uysal vd., 2019) tabanlı bir yöntem kullanılarak sonuca en hızlı ulaşmayı sağlayacak bir optimizasyon yazılımı geliştirilmiştir. Kullanılan BMS iki giriş ve bir çıkışlı olup Şekil 6'da gösterildiği gibi tasarlanmıştır.



Şekil 6. BMS tabanlı ÖÇ hesaplama sisteminin yapısı (Structure of the BMS based ÖÇ calculation system)

Burada E_i i anındaki Hata ve cE_i hatanın değişimidir. Girişler $(-1,1)$ aralığında çıkış ise $(0,2)$ aralığında değişmektedir. Giriş değişkenleri için 5'er bulanık küme ve üçgen üyelik fonksiyonları, çıkış için ise 3 bulanık küme ve üçgen üyelik fonksiyonu seçilmiştir. Grafiklerde yatay eksenler evrensel kümeleri yani değer aralıklarını temsil etmektedir. Seçilen bulanık kümeler ve üyelik fonksiyonları Şekil 7'de verilmiştir.




Şekil 7. BMS 'de kullanılan (a) hatanın değişimi, (b) hata ve (c) ölçekleme çarpanı üyelik fonksiyonları ((a) Change in error, (b) error, and (c) scaling factor membership functions used in BMS)

Bulanık küme etiketleri olarak VL: Çok Düşük, L: Düşük, Z: Sıfır, H:Yüksek, VH: Çok Yüksek ve M: Orta ifadeleri kullanılmıştır. Böylece, ÖÇ kullanımı ile sistem çıkışlarının yakınsama oranını iyileştirilmeye, aşırı şekilde büyük ve küçük çıkışlar engellenmeye çalışılmıştır.

2.6. Deney Platformu Kurulumu (Experiment Platform Setup)

Gerçek zamanlı deneysel çalışmaları gerçekleştirmek üzere, biri 100 d/dk'lık, diğeri 500 d/dk'lık iki adet DA motor içeren, 500 d/dk'lık motorun yük motoru olarak kullanıldığı, bir Arduino mega ve bir DA motor sürücü devresi ile oluşturulan bir deney platformu tasarımı yapılmıştır. Hız kontrolü uygulanan DA motoru, mil vasıtasıyla yük motoruna mekanik olarak bağlanmıştır. Kurulan deneysel donanımın şematik gösterimi Şekil 8'de verilmiştir.



Şekil 8. Kurulan deney platformunun (a) şematik, (b) gerçek gösterimi ((a) Schematic, (b) actual representation of the experimental platform)

Deney platformu DA motorların hız ve yön kontrolünü sağlamak için Arduino mega mikro denetleyicisi ile L298N motor sürücü modülünü kullanmaktadır. L298N motor sürücü modülü iki adet DA motorun hızını DGM sinyali ile kontrol etmek ve yönünü değiştirmek için kullanılan bir entegredir. Deney platformunda, 100 d/dk'lık motor, kontrol motoru olarak kullanılmıştır. Bu motorun hızı, çeşitli dalga şekillerinde (basamak, rampa ve sinüs) referans hızlar kullanılarak denetlenmiştir. Arduino mega, Matlab yazılımı ile hazırlanan program tarafından gönderilen yanıt değerlerine göre DGM sinyali üretmiş ve bu sinyali L298N modülüne göndermiştir. 500 d/dk'lık motora ise herhangi bir şekilde DGM uygulanmamış, sadece kontrol motoruna sabit torka sahip bir yük oluşturacak şekilde kullanılmıştır. Yük motoru herhangi bir şekilde tahrik edilmediği için sadece kendi eylemsizliği, sürtünme kuvveti, sönümleme katsayısı, ters elektromotor kuvveti ve shaft hızsızlığı gibi parametreleri ile bir yük oluşturmuştur. Arduino mega, kontrol motorunun hızını optik enkoder (48 CPR) ile ölçerek bu değeri yazılıma geri besleme olarak göndermektedir.

3. Bulgular ve Tartışma (Results and Discussion)

Model tabanlı ve öğrenme tabanlı VGK denetleyicilerde beş farklı modelde girdi veriseti kullanıldığı belirtilmişti. Bu girdiler kullanılarak tasarlanan denetleyicilerin performanslarını gerçek zamanlı olarak ölçebilmek amacıyla üç farklı tipte referans sinyal oluşturulmuştur. Bu sinyaller basamak, rampa ve sinüs sinyalleri şeklinde ve tamamen aynı boyutlarda üretilmiştir. Ölçme işlemlerinde kullanılan performans ölçütleri; ortalama karesel hata (E_{rms}): her çevrimde tepki ile referans arasındaki fark değerlerinin rms değeri, yükselme zamanı (t_r): tepkinin referans değerin %90'ına ulaşması için geçen süre, oturma zamanı (t_s): tepki eğrisinin anlık değerinin referansın $\pm 5\%$ 'i ile belirtilen aralığa ulaşması ve bu aralıkta kalması için geçen süre ve en yüksek yüzde aşma (M_p): tepki eğrisinin en yüksek tepe değerinin mevcut referans noktasına oranıdır. Bulgular bölümünde yüzde oran (%) olarak verilebilmesi için sonuçlar $\times 100$ şeklinde verilmiştir. Denetleyicilerin referansı takip performanslarını daha iyi ölçebilmek amacıyla her üç farklı tipte referans sinyallerin sabit kalmayıp farklı karakterlerde değişimi sağlanmıştır. Basamak tipi referans süreç boyunca iki farklı değer alırken, rampa tipi referans üç farklı eğimde ve sinüs tipi referans ise iki farklı frekanstan oluşmaktadır. t_s hesaplaması sırasında bir kısım varsayımlar yapılmıştır. Tepki sinyali analizinde 5% 'lik hata dilimi içerisinde kalan ilk ardışık 10 değer yakalandığı anda t_s olduğu varsayılmıştır. t_s oluşuktan sonra 5% 'lik hata diliminde meydana gelen değişiklikler dikkate alınmamıştır.

3.1. Veri Güdümlü PID Denetleyici (Data-Driven PID Controllers)

Bu stratejide, kullanılan farklı model girdi verilerine karşılık elde edilen çıktı değerleri arasında Matlab R2020 SI araç kutusu kullanılarak her bir model için s-alanında birer transfer fonksiyonu oluşturulmuştur. Bu transfer fonksiyonları geri beslemeli ve seri kompanzasyonlu denetim mimarisi içinde DA motorunun (plant) temsil etmektedir. Genel olarak gerçek çıkışlar ile tahmin edilen transfer fonksiyonu tepkileri arasındaki en yüksek uyumlar ikinci dereceden transfer fonksiyonlarında elde edilmiştir. Daha yüksek dereceden transfer fonksiyonlarında sonuçları etkileyecek değerde eşleşme çıkmadığı için transfer fonksiyonlarının tamamı ikinci dereceden tercih edilmiştir. DA motorun hız denetimini sağlamak üzere tasarlanan PID denetleyicinin

katsayılarını hesaplamak amacıyla Matlab PID optimizasyonu araçları kullanılmıştır. Bu şekilde, en hızlı yanıt süresine sahip ve en sağlam denetimi gerçekleştiren $[K_p, K_{int}, K_d]$ katsayıları hesaplanmıştır. Bazı veriseti modellerinde K_d katsayıları oluşmamıştır. Ayrıca yanıt süresini kısaltmak ve DA motorlara gönderilen kontrol sinyallerini ölçeklemek amacıyla denetleyici çıkışları BMS'den elde edilen ÖÇ katsayılarıyla çarpılmıştır. ÖÇ katsayıları her işlem adımında E_i ve cE_i değerlerine göre optimize edildiği için sabit bir değer değildir. Bu süreçte her model veriseti için kullanılan parametreler Tablo 1'de verilmiştir.

Tablo 1. PID yöntemi için hesaplanan transfer fonksiyonları ve katsayılar
(Transfer functions and coefficients calculated for PID method)

MODEL VERİSETİ	TRANSFER FONKSİYONU	K_p	K_{int}	K_d
Basamak	$\frac{120,2}{s^2 + 10,58s + 131,1}$	2,35	15,62	0,085
Sinüs	$\frac{0,039}{s^2 + 4,22e - 13s + 0,046}$	13,85	1,24	38,55
Testere	$\frac{1143}{s^2 + 1257s + 12270}$	1,76	22,1	0
Rastgele	$\frac{115,5}{s^2 + 10,17s + 131,1}$	2,3	15,08	0,085
Karışık	$\frac{874,9}{s^2 + 609,8s + 946,5}$	1,89	3,21	0

Doğrusal ve zamanla değişmeyen sistemlerin tek bir transfer fonksiyonlarının bulunması gerekir. Bu çalışmada aynı DA motoru için ikinci dereceden birden fazla transfer fonksiyonu elde edilmiştir. Bunun nedeni, DA motorların tam anlamıyla doğrusal ve zamanda değişmeyen bir sistem olmamasıdır. Her bir girdi türü motorun elektriksel ve mekanik özellikleriyle farklı şekilde etkileşime girerek farklı transfer fonksiyonlarına yol açabilir. DA motorlarının ısınma ve manyetik alan doygunluğu gibi sebeplerden yanıtlarının farklılaşabilmesi ya da farklı frekanstaki girdilere karşı frekans yanıtlarının farklı olabilmesi gibi nedenlerden dolayı farklı transfer fonksiyonlarının olduğu değerlendirilmiştir. Bu farklılaşma, çeşitli çalışma koşulları altında motor performansının anlaşılmasına ve optimize edilmesine yardımcı olabilecek bilgiler içermektedir.


3.2. Veri Güdümlü YSA Denetleyici (Data-Driven ANN Controller)

Her bir model veri seti için 1000'er adet girdi-çıkış örneğinin toplandığı Bölüm 2.2'de belirtilmişti. Bu verilerden 900'ü eğitim ve doğrulama süreçlerinde 100'ü bağımsız test işlemlerinde kullanılmıştır. Yani ayrılan 100 adet veri eğitime sürecine katılmamıştır. Bu şekilde eğitilmiş ağ, ilk defa karşılaştığı veriler ile test edilebilmiştir. Hazırlanan bir program ile her bir model 50 defa eğitim sürecinden geçirilerek 100 adet test verisi ile test edilmiş ve en düşük ortalama karesel hataya sahip eğitilmiş ağ seçilmiştir. Eğitim fonksiyonu olarak Bayesian Regularization, eğitim oranı 0.01, giriş ve gizli katmanların transfer fonksiyonu olarak hiperbolik tanjant, çıkış katmanı transfer fonksiyonu olarak doğrusal fonksiyon ve kayıp fonksiyonu olarak da ortalama karesel hata fonksiyonu kullanılmıştır. PID ve YSA için belirlenen parametreler ile özellikleri belirtilen DA motoru kullanılarak yapılan deneysel çalışmalarda elde edilen performans sonuçları Tablo 2'de verilmiştir.


Tablo 2. Gerçek zamanlı deneylerden elde edilen performans sonuçları (Performance results from real-time experiments)

MODEL VERİSETİ	REFERANS TİPİ	E_{rms}		$t_r(s)$		$t_s(s)$		$M_p(\%)$	
		PID	YSA	PID	YSA	PID	YSA	PID	YSA
Basamak	Basamak	6,38	8,65	2,22	1,4	2,15	1,95	7,2	3,5
Sinüs	Basamak	7,12	7,25	0,4	0,68	1,62	4,98	42,8	17,2
Testere	Basamak	6,83	6,1	3,67	0,45	4,4	1,13	5,9	19,1
Rastgele	Basamak	7,75	4,25	3,32	0,56	3,96	1,35	6,8	13,3
Karışık	Basamak	7,52	4	0,89	0,8	2,44	1,82	6,6	6,2
Basamak	Sinüs	8,4	16,8	2,02	1,01	2,83	1,4	8,9	17,1
Sinüs	Sinüs	8,55	15,7	0,81	1,5	2,85	Yok	25,5	20,5
Testere	Sinüs	8,85	7,1	4,05	1,3	6,1	2,61	23,8	11,4
Rastgele	Sinüs	11,25	6,75	2,03	0,57	3,46	1,69	5,6	9,5
Karışık	Sinüs	11	6,4	1,22	0,8	1,22	1,48	20,2	5,3
Basamak	Rampa	7,85	9,6	2,53	0,45	1,9	1,57	5,4	15,5
Sinüs	Rampa	8,05	6,9	0,4	0,45	1,2	7,2	32,6	12,5
Testere	Rampa	8,25	5,4	3,1	0,68	4,1	0,68	3,9	10,9
Rastgele	Rampa	9,4	4,75	1,8	0,45	2,2	1,78	6,8	11,1
Karışık	Rampa	9,1	4,35	0,4	0,68	1,63	1,22	10,7	11,4

Verilen performans sonuçlarının grafik olarak gösterimleri ise Şekil 9-10'da verilmiştir. Grafiklerde DA motor hızları d/dk cinsinden verilmiş ve dikey eksenle "rpm" etiketi ile temsil edilmiştir. Yatay eksen ise saniye (s) cinsinden verilmiş ve "t" etiketi ile temsil edilmiştir.



Şekil 9. PID denetleyici yanıtları (a) basamak referans, (b) rampa referans (c) sinüs referans (PID controller responses (a) step reference, (b) ramp reference (c) sine reference)



Şekil 10. YSA denetleyici yanıtları (a) basamak referans, (b) rampa referans (c) sinüs referans (ANN controller responses (a) step reference, (b) ramp reference (c) sine reference)

3.3. t-Testleri Sonuçları (t-Scores)

t-Testleri, iki grup veri arasında anlamlı farkların olup olmadığını ortaya çıkaran istatistikleridir. Teknik olarak iki grup veri arasındaki ortalama farkın standart hataya oranı olarak tanımlanabilirler. Eşitlik 5-6'da verildiği şekilde hesaplanmaktadır.

$$\frac{\overline{PID} - \overline{YSA}}{\sqrt{\text{var}_b^2 \left(\frac{1}{n_{PID}} + \frac{1}{n_{YSA}} \right)}} \quad (5)$$

$$\text{var}_b^2 = \frac{(n_{PID} - 1)\text{var}_{PID}^2 + (n_{YSA} - 1)\text{var}_{YSA}^2}{n_{PID} + n_{YSA} - 2} \quad (6)$$

Eşitliklerde, $\overline{PID}, \overline{YSA}$: birinci ve ikinci grup verilerin ortalamalarını, var_b^2 : birleştirilmiş varyansı, n_{PID}, n_{YSA} : sırasıyla birinci ve ikinci gruptaki veri sayılarını, $\text{var}_{PID}^2, \text{var}_{YSA}^2$: sırasıyla birinci ve ikinci grup verilerin varyanslarını temsil etmektedir. Bu yöntemde, grup veriler arasında farkı analiz ederken p-değeri adı verilen başka bir istatistiksel büyüklük hesaplanır. p-değeri, t-Testlerinin tesadüfen oluşma olasılığını hesaplamaktadır. Dolayısıyla küçük olmaları beklenmektedir. Genel olarak p-değeri < 0.05, gruplar arasındaki farkın istatistiksel olarak anlamlı olduğunu göstermektedir.

Bu çalışmada, denetleyici sistemlerin performansları açısından en önemli analizin model verisetleri temelinde E_{rms} değerleri olacağı değerlendirilmiştir. Bu nedenle t-değeri istatistikleri bu kapsamda hesaplanmıştır. Elde edilen sonuçlar Tablo-3'de verilmiştir.

Tablo 3. Model veri setleri temelinde değeri için t-Testi Sonuçları (t-Test Results for based on model data sets)

MODEL VERİSETİ	p-DEĞERİ	SONUÇ
Basamak	0.192	Anlamlı fark yok
Sinüs	0.511	Anlamlı fark yok
Testere	0.101	Anlamlı fark yok
Rastgele	0.007	Anlamlı fark var (p < 0.05)
Karışık	0.008	Anlamlı fark var (p < 0.05)

4. Sonuç (Conlusion)

Bu çalışmada DA motorların giriş-çıkış verilerine göre tasarlanan model tabanlı ve öğrenme tabanlı denetleyicilerin farklı giriş verisi tiplerine göre performansları test edilmiştir. Model tabanlı denetleyiciler için sistemin transfer fonksiyonları elde edilmiş, öğrenme tabanlı denetleyiciler için giriş ve çıkış verileri arasında bir sinir ağı tasarlanmıştır. Model tabanlı denetleyici olarak PID, öğrenme tabanlı denetleyici olarak YSA kullanılmıştır. Sistem çıkışlarına filtre uygulandığı takdirde sinyaldeki dalgalanma ve gürültüler belirli ölçülerde bastırılabilir. Ancak, deneysel çalışmalarda sonuçları etkilememesi için sistem çıkışlarına herhangi bir filtre uygulanmamıştır. Sonuçların değerlendirilmesinde rms hata (E_{rms}) ölçütü temel olarak alınmıştır. Çünkü bu ölçüt diğer tüm performans ölçütlerini de doğrudan etkilemektedir. Sonuçlar, model veri seti tipine göre ve referans sinyal tipine göre ayrı ayrı değerlendirilmiştir. Veri seti tipine göre E_{rms} değerlendirildiğinde en iyi sonuçlar basamak referansında rastgele ve karışık model veri setleriyle eğitilen YSA denetleyiciden elde edilmiştir. Bu sonucu destekleyecek şekilde, gerçekleştirilen t-testi çalışmaları neticesinde model veri setleri temelinde PID ve YSA yöntemleri arasındaki en anlamlı farkların rastgele ve karışık veri setlerinde ortaya çıktığı gözlenmiştir. Bu durum, öğrenme tabanlı kontrol stratejilerinde veri setlerinin rastgele ve karışık modellerde seçilebileceğini işaret etmektedir. YSA denetleyiciler basamak veri seti tipi dışındaki diğer tüm veri setlerinde PID'den daha iyi performans göstermiştir. DA motorun zamanla değişen karakteristikleri (örneğin aşınma, sıcaklık değişiklikleri) PID denetleyicinin başlangıçta ayarlanan parametreleriyle uyumsuz hale gelebileceği için başarısız sonuçların alındığı kanaatine varılmıştır. Rastgele ve karışık girdi veri setlerinde girdi uzayının her bölümünden verilerin olması ve verilerin hızlı değişimleri veri çeşitliliği olarak bir avantaja dönüşmüş ve giriş-çıkış ilişkisinin daha başarılı öğrenilmesine olanak tanımıştır. Ayrıca DA motorların doğrusal olmayan dinamiklerinin YSA'nın uyarlanabilirlik ve hata toleransı gibi özellikleri ile çözülmesi bu sonucun ortaya çıkmasını kolaylaştırmıştır. Bu şekilde öğrenme tabanlı denetleme stratejilerde girdi verilerinin benzersizliğinin önemi ortaya çıkmıştır. Kendini tekrar eden periyodik yapıdaki girdilerden elde edilen eğitim veri setlerinin ise karmaşık ve zamana bağlı iç dinamikleri olan DA motorların giriş-çıkış ilişkisini yeterince çözemedikleri kanaatine varılmıştır. Öğrenme tabanlı denetleme stratejisinde en başarısız sonuçlar sinüs referansında basamak veri setlerinde ortaya çıkmıştır. Sinyal değişiminin oldukça az olduğu sabit değerlerden oluşan basamak veri setlerinde öğrenmenin tam olarak gerçekleşmemesi sonucu DA motorun çalışma karakteristiği tam olarak genelleştirilemediği için sinüs gibi değişken bir referansa uyum sağlayamamıştır. Bu sonuç, öğrenme tabanlı kontrol sistemlerinde eğitim veri setinin kalitesinin önemini vurgulamaktadır.

PID yönteminde en başarılı performanslar basamak referansında basamak ve testere model veri setlerinden alınmıştır. Bu yöntemde rastgele ve karışık model veri setlerinde ise en başarısız sonuçlar elde edilmiştir. Başarısızlığın nedeni olarak, sistem tanımlama adımında transfer fonksiyonları elde ederken yaşanan fonksiyon uydurma sorunları olduğu değerlendirilmiştir. Çünkü basamak, testere ve sinüs gibi dinamik değişimlerin

olmadığı ya da değişimlerin de periyodik olduğu süreçlerde fonksiyon uydurma aşamasındaki eşleşme daha yüksek oranlarda gerçekleşmekte ve transfer fonksiyonları gerçeğe daha yakın olmaktadır. Rastgele ve karışık model veri setlerinde veriler arası hızlı değişim bulunmaktadır. Özellikle transfer fonksiyonlarına dayalı model tabanlı denetleyicilerde giriş sinyallerin değişim hızları önemlidir. Örneğin PID tip denetleyicilerde türevsel bileşen (Derivative -D) değişime duyarlı olan ve denetleyicinin hızlı ayar noktası değişikliklerine uyum sağlamasını sağlayan bileşendir. Ancak, yapılan ölçümlerde, PID denetleyicinin basamak, sinüs ve testere veri setlerindeki ortalama rms hatası 7,8 iken rastgele ve karışık veri setlerindeki ortalama rms hatası 9,4 olarak gerçekleşmiştir. Bu sonuçlar, PID kontrol stratejisinin hızlı değişkenlik gösteren veri setlerinde etkisiz kaldığını, buna karşın durağan veya periyodik değişim gösteren veri setlerinde nispeten daha yüksek bir performans sergilediğini ortaya koymaktadır.

En yüksek yüzde aşmalar (M_p), denetim sürecinde yön değişimleri ve başlangıç anları için hesaplanmıştır. Genel olarak E_{rms} 'in yüksek olduğu deneylerde yüksek aşma değerleri tespit edilmiştir. En yüksek aşmaların sinüs modelinde olması dikkat çekicidir. Deneysel çalışmalarda, YSA denetleyicilerde ortalama %11,73, PID denetleyicilerde ise ortalama %14,78 aşma değeri elde edilmiştir.

Model veri setlerinde sinüs ve testere gibi benzersizliği az ve kendini tekrar eden sinyallerde farklı frekanslara sahip bileşenler kullanılarak benzersizliğin artırılmasıyla daha başarılı YSA performansları elde edileceği değerlendirilmiştir. Ayrıca, daha fazla girdi-çıkı verisi kullanıldığında öğrenme tabanlı denetleyicilerde performansın artacağı düşünülmektedir.

Çıkar Çatışması (Conflict of Interest)

Yazar tarafından herhangi bir çıkar çatışması beyan edilmemiştir. No conflict of interest was declared by the author.

Kaynaklar (References)

- Baciu, A., Lazar, C., 2023. Iterative feedback tuning of model-free intelligent PID controllers. *Actuators*, 12(2), 56. <https://doi.org/10.3390/act12020056>
- Carlet, P.G., Favato, A., Bolognani, S., Dorfler, F., 2020. Data-driven predictive current control for synchronous motor drives. *IEEE Energy Conversion Congress and Exposition (ECCE)*, 5148-5154. <https://doi.org/10.1109/ECCE44975.2020.9235958>
- Chaudhary, H., Khatoun, S., Singh, R., 2017. ANFIS based speed control of DC motor. *IEEE International Conference on Innovative Applications of Computational Intelligence on Power, Energy and Controls with Their Impact on Humanity (CIPECH)*, 63-67. <https://doi.org/10.1109/CIPECH.2016.7918738>
- Chi, R., Hou, Z., Jin, S., Huang, B., 2018. Computationally efficient data-driven higher order optimal iterative learning control. *IEEE Transactions on Neural Networks and Learning Systems*, 29(12), 5971-5980. <https://doi.org/10.1109/TNNLS.2018.2814628>
- Hamoodi, S.A., Sheet, I.I., Mohammed, R.A., 2019. A comparison between PID controller and ANN controller for speed control of DC motor. *International Conference on Electrical, Communication, Computer, Power and Control Engineering (ICECCPCE)*, 221-224. <https://doi.org/10.1109/ICECCPCE46549.2019.203777>
- Hou, Z., Chi, R., Gao, H., 2017. An overview of dynamic-linearization-based data-driven control and applications. *IEEE Transactions on Industrial Electronics*, 64(5), 4076-4090. <https://doi.org/10.1109/TIE.2016.2636126>
- Ismeal, G.A., Kyslan, K., Fedák, V., 2014. DC motor identification based on recurrent neural networks. *16th International Conference on Mechatronics (Mechatronika)*, 701-705. <https://doi.org/10.1109/MECHATRONIKA.2014.7018347>
- Jeng, J.C., Ge, G.P., 2016. Disturbance-rejection-based tuning of proportional-integral-derivative controllers by exploiting closed-loop plant data. *ISA Transactions*, 62, 312-324. <https://doi.org/10.1016/j.isatra.2016.02.011>
- Kamal, M.M., Mathew, L., Chatterji, S., 2014. Speed control of brushless DC motor using intelligent controllers. *IEEE Conference on Engineering and Systems for Global Sustainability (SCES)*, 1-5. <https://doi.org/10.1109/SCES.2014.6880121>
- Keles, Z., Sonugur, G., Alcin, M., 2023. The modeling of the Rucklidge chaotic system with artificial neural networks. *Chaos Theory and Applications*, 5(2), 59-64. <https://doi.org/10.51537/CHAOS.1213070>
- Khan, S., Paul, A., Sil, T., Basu, A., Tiwari, R., Mukherjee, S., Mondal, U., Sengupta, A., 2017. Position control of a DC motor system for tracking periodic reference inputs in a data driven paradigm. *International Conference on Intelligent Control, Power and Instrumentation (ICICPI)*, 17-21. <https://doi.org/10.1109/ICICPI.2016.7859665>
- Mishra, M., 2009. Speed control of DC motor using novel neural network configuration. *National Institute of Technology Rourkela, Odisha, India*. <http://ethesis.nitrkl.ac.in/245/1/10502014.pdf>
- Mohamed, T.L.T., Mohamed, R.H.A., Mohamed, Z., 2010. Development of auto tuning PID controller using graphical user interface (GUI). *2nd International Conference on Computer Engineering and Applications (ICCEA)*, 491-495. <https://doi.org/10.1109/ICCEA.2010.101>
- Moussavi, S.Z., Alasvandi, M., Javadi, S., 2012. Speed control of permanent magnet DC motor by using combination of adaptive controller and fuzzy controller. *International Journal of Computer Applications*, 52(20), 11-15. <https://doi.org/10.5120/8316-1774>
- Munagala, V.K., Jatoth, R.K., 2022. A novel approach for controlling DC motor speed using NARXnet based FOPID controller.

- Evolving Systems, 14, 101-116. <https://doi.org/10.1007/s12530-022-09437-1>
- Özbaltan, M., Çaşka, S., 2024. Altitude control of quadcopter with symbolic limited optimal discrete control. *International Journal of Dynamics and Control*, 12(5), 1533-1540. <https://doi.org/10.1007/s40435-023-01278-3>
- Purnama, H.S., Sutikno, T., Alavandar, S., Subrata, A.C., 2019. Intelligent control strategies for tuning PID of speed control of DC motor - A review. *IEEE Conference on Energy Conversion*, 24-30. <https://doi.org/10.1109/CENCON47160.2019.8974782>
- Salah, M., Abdelati, M., 2010. Parameters identification of a permanent magnet DC motor. *IASTED International Conference on Modelling, Identification and Control*, 177-182. <https://doi.org/10.2316/P.2010.675-085>
- Suleimenov, K., Do, T.D., 2019. Data-driven LQR for permanent magnet synchronous machines. *IEEE Vehicle Power and Propulsion Conference (VPPC)*, 1-5. <https://doi.org/10.1109/VPPC46532.2019.8952466>
- Timurkutluk, B., Ciflik, Y., Sonugur, G., Altan, T., Genc, O., Colak, A.B., 2023. Microstructural design of solid oxide fuel cell electrodes by micro-modeling coupled with artificial neural network. *Powder Technology*, 425, 118551. <https://doi.org/10.1016/J.POWTEC.2023.118551>
- Umlauf, J., Hirche, S., 2020. Feedback linearization based on Gaussian processes with event-triggered online learning. *IEEE Transactions on Automatic Control*, 65(10), 4154-4169. <https://doi.org/10.1109/TAC.2019.2958840>
- Uysal, A., Gokay, S., Soylu, E., Soylu, T., Çaşka, S., 2019. Fuzzy proportional-integral speed control of switched reluctance motor with MATLAB/Simulink and programmable logic controller communication. *Measurement and Control*, 52(7-8), 1137-1144. <https://doi.org/10.1177/0020294019858188>
- Vural, A.M., Bayindir, K.C., 2010. Optimization of parameter set for STATCOM control system. *IEEE PES Transmission and Distribution Conference and Exposition: Smart Solutions for a Changing World*. <https://doi.org/10.1109/TDC.2010.5484230>
- Weng, Y., Wang, N., 2020. Data-driven robust backstepping control of unmanned surface vehicles. *International Journal of Robust and Nonlinear Control*, 30(9), 3624-3638. <https://doi.org/10.1002/RNC.4956>
- Yu, X., Hou, Z., Polycarpou, M.M., Duan, L., 2021. Data-driven iterative learning control for nonlinear discrete-time MIMO systems. *IEEE Transactions on Neural Networks and Learning Systems*, 32(3), 1136-1148. <https://doi.org/10.1109/TNNLS.2020.2980588>