



T.C.
EGE ÜNİVERSİTESİ
Fen Bilimleri Enstitüsü



HAVALANDIRMA SİSTEMLERİ İÇİN PEKİŞTİRMELİ ÖĞRENME TABANLI DENETLEYİCİ TASARIMI

Yüksek Lisans Tezi

Enes BİGA

Elektrik-Elektronik Mühendisliği Anabilim Dalı

İzmir
2025

T.C.
EGE ÜNİVERSİTESİ
Fen Bilimleri Enstitüsü

**HAVALANDIRMA SİSTEMLERİ İÇİN
PEKİŞTİRMELİ ÖĞRENME TABANLI
DENETLEYİCİ TASARIMI**

Enes BİGA

Danışman: Prof. Dr. Musa ALCI

Elektrik-Elektronik Mühendisliği Anabilim Dalı
Elektrik Mühendisliği Yüksek Lisans Programı

İzmir
2025

Enes BİGA tarafından yüksek lisans tezi olarak sunulan “Havalandırma Sistemleri İçin Pekiştirmeli Öğrenme Tabanlı Denetleyici Tasarımı” başlıklı bu çalışma EÜ Lisansüstü Eğitim ve Öğretim Yönetmeliği ile EÜ Fen Bilimleri Enstitüsü Eğitim ve Öğretim Yönergesi'nin ilgili hükümleri uyarınca tarafımızdan değerlendirilerek savunmaya değer bulunmuş ve 05.02.2025 tarihinde yapılan tez savunma sınavında aday oybirliği/oyçokluğu ile başarılı bulunmuştur.

Jüri Üyeleri:

İmza

Jüri Başkanı	: Prof. Dr. Musa ALCI
Raportör Üye	: Prof. Dr. Aydoğan SAVRAN
Üye	: Prof. Dr. Sezai TAŞKIN

EGE ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ

ETİK KURALLARA UYGUNLUK BEYANI

EÜ Lisansüstü Eğitim ve Öğretim Yönetmeliğinin ilgili hükümleri uyarınca Yüksek Lisans Tezi olarak sunduğum “Havalandırma Sistemleri İçin Pekiştirmeli Öğrenme Tabanlı Denetleyici Tasarımı” başlıklı bu tezin kendi çalışmam olduğunu, sunduğum tüm sonuç, doküman, bilgi ve belgeleri bizzat ve bu tez çalışması kapsamında elde ettiğimi, bu tez çalışmasıyla elde edilmeyen bütün bilgi ve yorumlara atıf yaptığımı ve bunları kaynaklar listesinde usulüne uygun olarak verdiğimi, tez çalışması ve yazımı sırasında patent ve telif haklarını ihlal edici bir davranışım olmadığını, bu tezin herhangi bir bölümünü bu üniversite veya diğer bir üniversitede başka bir tez çalışması içinde sunmadığımı, bu tezin planlanmasından yazımına kadar bütün safhalarda bilimsel etik kurallarına uygun olarak davrandığımı ve aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul edeceğimi beyan ederim.

05 / 01 / 2025

Enes BİGA

ÖZET**HAVALANDIRMA SİSTEMLERİ İÇİN PEKİŞTİRMELİ
ÖĞRENME TABANLI DENETLEYİCİ TASARIMI**

BİGA, Enes

Yüksek Lisans Tezi, Elektrik-Elektronik Mühendisliği Anabilim Dalı

Tez Danışmanı: Prof. Dr. Musa ALCI

Ocak 2025, 57 sayfa

Bu tez çalışması kapsamında, günümüz havalandırma sistemlerinde kullanılan fan motorlarının kontrol algoritmalarında yaygın olarak kullanılan klasik Oransal-Integral-Türev (PID) denetleme yöntemine alternatif olarak, değişken sistem dinamiklerine uyum sağlayabilen ve yapay zeka alt dallarından biri olan pekiştirmeli öğrenme tabanlı uyarlamalı bir denetleyici kullanılması amaçlanmaktadır. Bu yöntem ile sistemin kararlı ve sürekli rejime daha hızlı ulaşması ve enerji verimliliğinin artırılması hedeflenmektedir.

Çalışma gerçekleştirilirken, havalandırma sistemlerinde kullanılan bir fanın debi-basınç eğrilerinden elde edilmiş veriler MATLAB ortamına aktarılmış ve benzetim çalışmaları gerçekleştirilmiştir. Benzetim çalışmaları, kurulmuş deneysel bir düzenek ile desteklenmiştir. Yapılan benzetim çalışmaları ve deneysel çalışmada tasarlanan kontrolcünün kazanç parametrelerinin, farklı statik basınç değerleri karşısında dinamik olarak değiştiği, sistemi istenilen hedef debi değerine hızlı bir şekilde ulaştırdığı ve sistemin sürekli bir rejimde çalışmasını sağladığı gözlemlenmiştir. Bu tez çalışma doğrultusunda elde edilen bulgulara göre tasarlanan pekiştirmeli öğrenme tabanlı denetleyicinin havalandırma sistemlerinde bulunan fan motorlarının kontrolünde kullanımının benzetim çalışmalarında ortalama 6 saniye, deneysel çalışmada ise ortalama 10 saniye daha kısa sürede sistemi istenilen rejime ulaştırdığı, kazanç parametreleri sabit klasik PI kontrolcü ile denetimine kıyasla %6'ya kadar enerji tasarrufu sağlandığı sonucuna varılmıştır.

Anahtar sözcükler: Yapay Zeka, Uyarlamalı Denetleyici, Pekiştirmeli Öğrenme, Enerji Verimliliği.



ABSTRACT**REINFORCEMENT LEARNING BASED CONTROLLER DESIGN
FOR VENTILATION SYSTEMS**

BİGA, Enes

MSc in Electrical Eng.

Supervisor: Prof. Dr. Musa ALCI

January 2025, 57 pages

Within the scope of this thesis, as an alternative to the classical Proportional-Integral-Derivative (PID) control method, which is widely used in the control algorithms of fan motors used in today's ventilation systems, it is aimed to use an adaptive controller based on reinforcement learning, one of the sub-branches of artificial intelligence, which can adapt to variable system dynamics. With this method, it is aimed to reach the stable and continuous regime of the system faster and to increase energy efficiency.

During the study, the data obtained from the flow-pressure curves of a fan used in ventilation systems were transferred to MATLAB environment and simulation studies were carried out. The simulation studies were supported by an experimental setup. In the simulation and experimental studies, it was observed that the gain parameters of the designed controller changed dynamically against different static pressure values, quickly reaching the desired target flow rate value and ensuring the system to operate in a continuous regime. According to the findings obtained in this thesis, it is concluded that the use of the designed reinforcement learning based controller in the control of fan motors in ventilation systems brings the system to the desired regime in an average of 6 seconds in simulation studies and 10 seconds less in the experimental study, and energy savings up to 6% compared to the control with a classical PI controller with constant gain parameters.

Keywords: Artificial Intelligence, Adaptive Controller, Reinforcement Learning, Energy Efficiency.

ÖNSÖZ

Bu tez çalışması ile iklimlendirme ve havalandırma sistemlerinin kontrol ve otomasyonunun temel yapı taşı olan elektronik kontrolcülerde yaygın olarak kullanılan ve artık klasikleşmiş bir yöntem olan PID kontrol yerine değişken sistem dinamiklerine ayak uydurabilen yapay zeka tabanlı bir kontrol algoritması kullanımının katkılarının ne olacağı bilimsel yazına kazandırılmak istenmiştir.

Bu tez çalışmasının başından sonuna kadar olan süreçte bu hedef doğrultusunda aynı heyecan ile ilerlenmiş ve elde edilen bulguların iklimlendirme ve havalandırma sektörüne katkı sağlaması amaçlanmıştır.

İZMİR

05/01/2025

Enes BİGA



İÇİNDEKİLER

	<u>Sayfa</u>
İÇ KAPAK.....	ii
KABUL VE ONAY SAYFASI	iii
ETİK KURALLARA UYGUNLUK BEYANI	v
ÖZET	vii
ABSTRACT	ix
ÖNSÖZ	xi
İÇİNDEKİLER	xiii
ŞEKİLLER DİZİNİ	xv
TABLOLAR DİZİNİ	xix
SİMGELER VE KISALTMALAR DİZİNİ	xxi
1.GİRİŞ.....	1
2.BİLİMSEL YAZIN İNCELEMESİ VE GENEL BİLGİLER.....	4
3.GEREÇ VE YÖNTEM.....	7
3.1 Endüstriyel Kontrol Sistemleri	7
3.1.1 Sensörler	7
3.1.2 Kontrolcü	8
3.1.3 Eyleyiciler.....	9
3.1.4 HMI ve SCADA	10
3.2 PID Kontrol	12
3.2.1 Oransal Kontrol	13
3.2.2 İntegral Kontrol	13
3.2.3 Türev Kontrol	14
3.2.4 PID Denetleyici Kazanç Parametrelerinin Belirlenmesi	14
3.2.5 Yapay Zeka Yöntemleri ile PID Kazanç Parametrelerini Belirlemek ..	19
3.3 Kontrol Sistemlerinin Havalandırma Cihazlarına Uygulamaları	19
3.4 Pekiştirmeli Öğrenme	21
3.4.1 Markov Karar Süreci	22
3.4.2 DDPG Algoritması	23

İÇİNDEKİLER (devam)

	<u>Sayfa</u>
3.5 Pekiştirmeli Öğrenme Tabanlı Uyarlamalı Denetleyici Tasarımı.....	24
4.BENZETİM ÇALIŞMALARI	26
4.1 Karşı Basınç Eğrilerinin Tanımlanması	26
4.2 Sürtünme Faktörü ve Karşı Basınç Hesabı	28
4.3 Benzetim Çalışmaları	29
4.3.1 Klasik PI Denetleyici Bulguları	30
4.3.2 Pekiştirmeli Öğrenme Tabanlı Denetleyici Bulguları.....	33
4.4 Enerji Verimliliği İrdelemesi ve Bulguları	36
5.DENEYSEL ÇALIŞMA	37
5.1 Deneysel Çalışma Bulguları.....	42
5.1.1 Klasik PI Denetleyici Bulguları	42
5.1.2 Pekiştirmeli Öğrenme Tabanlı Denetleyici Bulguları.....	45
6.TARTIŞMA VE YORUM.....	49
7.SONUÇ	50
8.ÖNERİLER.....	51
KAYNAKLAR DİZİNİ	52
TEŞEKKÜR.....	56
ÖZGEÇMİŞ	57

ŞEKİLLER DİZİNİ

<u>Şekil</u>	<u>Sayfa</u>
3.1 Bir havalandırma sisteminde kullanılan (a) kanal tipi nem sensörü (b) oransal fark basınç sensörü	8
3.2 Havalandırma sistemlerinde kullanılan elektronik kontrol cihazı	9
3.3 Havalandırma sistemlerinde kullanılan EC motorlu fan	10
3.4 Endüstriyel kontrol sistemlerinde kullanılan HMI cihazı.....	11
3.5 Endüstriyel kontrol sistemi temel çalışma prensibi	11
3.6 PID denetleyicinin kapalı çevrim kontrol sisteminde kullanımı	12
3.7 Sistem birim basamak cevabının zamana göre eğrisi	15
3.8 Havalandırma cihazı ve kontrolünü gösteren blok diyagramı	20
3.9 Pekiştirmeli Öğrenme Temel Çalışma Diyagramı.....	21
3.10 DDPG algoritması temel akış diyagramı	24
3.11 Tasarlanan pekiştirmeli öğrenme tabanlı denetleme algoritması akış diyagramı	25
4.1 EC motorlu geriye yatık kanatlı bir fana ait debi karakteristik eğrisi.....	26
4.2 EC motorlu fan kontrol voltajına karşılık gelen debi-basınç eğrileri	28
4.3 Klasik PI denetleyici ile kontrolü gerçekleştirilmiş sistemin debi-zaman grafiği	30
4.4 Klasik PI denetleyici ile kontrolü gerçekleşmiş sistemin 0. ve 50. saniye arasındaki hata grafiği.....	31

ŞEKİLLER DİZİNİ (devam)

<u>Şekil</u>	<u>Sayfa</u>
4.5 Klasik PI denetleyici ile kontrolü gerçekleştirilmiş sistemin zamana bağlı kontrol işareti	32
4.6 Pekiştirmeli öğrenme tabanlı denetleyici ile kontrolü gerçekleştirilmiş sistemin debi-zaman grafiği	33
4.7 Pekiştirmeli öğrenme tabanlı denetleyici ile kontrolü gerçekleştirilmiş sistemin zamana bağlı kontrol işareti.....	34
4.8 Pekiştirmeli öğrenme tabanlı denetleyici kazanç parametreleri zaman bağlı değişimi.....	35
5.1 Deney düzeneği tasarımı ve boyutları, (a) önden görünüşü, (b) arkadan görünüşü	37
5.2 Deney düzeneği (a) yandan görünüm, (b) önden görünüm, (c) izometrik görünüm, (d) damper görünümü	38
5.3 Deney düzeneği: (a) PLC ile bilgisayar bağlantısı, (b) PLC ekranı.....	39
5.4 Düzeneğe takılmış fark basınç sensörü ve montaj şekli	40
5.5 Klasik PI denetleyici ile kontrolü gerçekleştirilmiş deneysel sistemin debi-zaman grafiği.....	42
5.6 Klasik PI denetleyici ile kontrolü gerçekleşmiş deneysel sistemin 0. ve 50. saniye arasındaki hata grafiği.....	43
5.7 Klasik PI denetleyici ile kontrolü gerçekleştirilmiş deneysel sistemin zamana bağlı kontrol işareti	44

ŞEKİLLER DİZİNİ (devam)ŞekilSayfa

- 5.8 Pekiştirmeli öğrenme tabanlı denetleyici ile kontrolü gerçekleştirilmiş deneysel sistemin debi-zaman grafiği.....45
- 5.9 Pekiştirmeli öğrenme tabanlı denetleyici ile kontrolü gerçekleşmiş deneysel sistemin 0. ve 50. saniye arasındaki hata grafiği46
- 5.10 Pekiştirmeli öğrenme tabanlı denetleyici ile kontrolü gerçekleştirilmiş deneysel sistemin zamana bağlı kontrol işareti47
- 5.11 Deneysel çalışmada pekiştirmeli öğrenme tabanlı denetleyici kazanç parametreleri zaman bağlı değişimi48



TABLolar DİZİNİ

<u>Tablo</u>	<u>Sayfa</u>
3.1 Cohen-Coon metodu eşitlikleri.....	15
3.2 Ziegler-Nichols reaksiyon eğrisi metodu eşitlikleri	16
3.3 Ziegler-Nichols osilasyon metodu eşitlikleri.....	17
3.4 Chien-Hrones-Reswick metodu parametre ayarlama eşitlikleri	17
3.5 Chien-Hrones-Reswick metodu bozucu etki bastırma eşitlikleri	18
3.6 Wang-Juang-Chan metodu eşitlikleri	18
3.7 Pekiştirmeli öğrenme yöntemi, modele bağımlı ve modelden bağımsız algoritmalar.....	21
4.1 Değişken kontrol voltajı için karşı basınç polinomsal ifadeleri	27
5.1 Deney düzeneğinde kullanılmış elektronik ekipmanlar	40



SİMGELER VE KISALTMALAR DİZİNİ

<u>Simgeler</u>	<u>Açıklama</u>
K_p	Oransal kontrol kazanç katsayısı
K_i	İntegral kontrol kazanç katsayısı
K_d	Türev kontrol kazanç katsayısı
$u(t)$	PID kontrolcü: zamana bağlı kontrol işareti
$e(t)$	PID kontrolcü: zamana bağlı hata sinyali
t	Zaman (Saniye)
$Q^\mu(S_t, a_t)$	DDPG algoritması: durum-değer fonksiyonu
S_t	DDPG algoritması: durum (state)
a_t	DDPG algoritması: eylem (action)
E	DDPG algoritması: beklenen değer
R_t	DDPG algoritması: ödül (reward)
γ	DDPG algoritması: indirim faktörü (discount factor)
$\mu(S_{t+1})$	DDPG algoritması: politika
f	Sürtünme faktörü
ϵ	Kanal malzemesi yüzey pürüzlülük katsayısı
D_h	Kanal içi akış hidrolik çap
Re	Reynold Sayısı

SİMGELER VE KISALTMALAR DİZİNİ (devam)

Simgeler

Açıklama

ρ	20 ° c' deki hava yoğunluğu
v	Kanal içi ortalama hava hızı
\dot{V}	Kanal içi hava hacimsel debisi
η_{fan}	Fan verimi
W_{fan}	Fan güç tüketimi
m	Metre
mm	Milimetre
a_n	Polinom Katsayısı
n	Toplam Veri Sayısı

Kısaltmalar

PI	Proportional-Integral
PD	Proportional-Derivative
PID	Proportional-Integral-Derivative
PLC	Programmable Logic Controller
TD3	Twin-Delayed Deep Deterministic Policy Gradient
DDPG	Deep Deterministic Policy Gradient
DQN	Deep Q-Network

SİMGELER VE KISALTMALAR DİZİNİ (devam)Kısaltmalar

IOT	Internet of Things
HMI	Human-Machine Interface
SCADA	Supervisory Control and Data Acquisition
DCS	Distributed Control Systems
CO ₂	Carbon Dioxide
VOC	Volatile Organic Compounds
EC	Electronically Commutated
GA	Genetic Algorithm
PSO	Particle Swarm Optimization
DE	Differential Evolution Algoritihm



1.GİRİŞ

Günümüz endüstriyel kontrol sistemlerinde farklı stratejiler izlenmektedir. Bu stratejiler arasında yaygın olarak tercih edilen Oransal-İntegral-Türev (PID) kontrol yöntemi (Müftü, 2023; Kocakaya, 2023; Yavuzsoy vd., 2023); havalandırma sektörü başta olma üzere elektronik kontrol cihazları, mekanik sistemler, hidrolik-pnömotik sistemler gibi kontrol-otomasyon sistemlerinde kullanılan bir denetleme mekanizmasıdır. Kontrol sisteminin düzgün ve kararlı çalışabilmesi için PID denetleyici performansını etkileyen temel parametrelerin en uygun biçimde belirlenmesi önem taşımaktadır. Bu parametrelerin belirlenmesinde sık kullanılan klasik yöntemler mevcuttur. Fakat, gelişen teknolojinin de etkisiyle günümüz kontrol algoritmalarının bu sistemleri istenilen rejim ve sürede kontrol etmesi karmaşık bir hale gelmiştir. Bu durum, PID parametrelerinin klasik yöntemler ile belirlenmesini zorlaştırmış ve farklı dış etmenler altında bu parametrelerin optimize edilmesi ihtiyacını doğurmuştur. Bir diğer yandan farklı denetleyicilerin de ele alınması ihtiyacını gündeme getirmiştir. Bu tez kapsamında, bu ihtiyaçlar ele alınarak daha çok iklimlendirme sektöründe kullanılan cihazların bileşenlerinin kontrolü ele alınmıştır.

Mevcut teknolojinin imkanları dahilinde üretilen iklimlendirme cihazlarında kullanılan kompresörler, fan motorları, vana motorları, genişleme vanası motorları, elektrikli ısıtıcılar ve ısıtıcı brülörlerin kontrolleri dahil olmak üzere daha hassas bir regülasyon yapmak amacıyla invertörlü uygulamalar tercih edilmektedir (He et al., 2023). Bu invertörlerin kontrol sinyalleri sistemde bulunan PLC (Programlanabilir Mantıksal Denetleyici) tarafından genellikle PID algoritmaları kullanılarak üretilmekte ve sisteme uygulanmaktadır. PID denetleyici temel olarak bir hata azaltma mekanizmasıdır. Kullanıldığı kontrol sisteminde istenilen referans değeri ile girişten aldığı sinyal verisini karşılaştırarak hata değerini hesaplamaktadır. Karşılaştırma işlemi sonucu bulunan hata değeri denetleyici tarafından bir oran, integral ve türev kazanç katsayısı ile çarpılarak kontrolcü çıkışına gönderilmektedir ve kontrol işareti olarak sisteme gönderilmektedir. İşlem sonucunda, çıkış sinyali ile giriş sinyali arasındaki fark tekrar alınarak hata değeri tekrar hesaplanmaktadır. Bütün bu döngü, hata oranı en düşük değere ulaşana kadar süreç boyunca devam ettirilmektedir.

Bunun yanı sıra bu PID algoritmalarının kazanç parametrelerine herhangi bir optimizasyon stratejisi (farklı koşullar için) uygulanmamaktadır. Üretilen iklimlendirme cihazının en hızlı ve doğru şekilde regülasyona ulaşması,

kararlılığının korunması ve ortamın taze hava ihtiyacını sağlayabilmesi için PID kazanç parametreleri günümüzde test veya üretim mühendisleri tarafından belirlenmektedir (Sugarman, 2020). Ancak bu parametreler, iklimlendirme cihazının kısa bir periyotta bulunduğu ortam koşulları altında belirlenmektedir. Dolayısı ile testi gerçekleştirilen iklimlendirme cihazında olası tüm diğer dış iklimatik durumlar ihmal edilmektedir. Öte yandan testi gerçekleştiren personel bu katsayıların belirlenmesinde fazla zaman harcamaktadır. Benzer problemler iklimlendirme cihazlarında olduğu kadar, havalandırma amacı güden sistemlerde de mevcuttur ve yine benzer yöntemlerle testi gerçekleştirilmektedir. Bu yönüde alternatif olarak PLC algoritmalarında kullanılmak üzere tasarlanacak pekiştirmeli öğrenme tabanlı denetleyici, parametre belirleyecek bir personel gerektirmeksizin havalandırma cihazını daha hızlı sürede kararlı rejime getirebilir. Böylece klasik PID denetleyici ile kontrol işleminde parametre belirlenmesinde oluşacak insan kaynaklı hata faktörleri de en aza indirgenmiş olacaktır.

Küresel anlamda tüm endüstriyel cihazlarda olduğu gibi iklimlendirme ve havalandırma sistemlerinde de üretilen cihazların düşük enerji tüketimli ve yüksek verimli olması son yıllarda üzerinde çalışılan bir diğer konudur. İklimlendirme ve havalandırma cihazlarında kullanılan invertörlü uygulamalar hassas regülasyonun yanı sıra enerji verimliliğinin artırılmasında da önemli bir rol oynamaktadır. İklimlendirme ve havalandırma cihazlarının, istenilen kapasiteye ulaşmasıyla birlikte cihazlarda bulunan kompresör ve motorların tamamen kapatılıp kapasitenin azalmasıyla birlikte tekrar çalıştırılması yerine cihazın kısmi ve istenilen kapasitelerde sabit olarak çalışacak şekilde içerisinde barındırdığı motorların invertörler yardımıyla farklı devirlerde sürekli devrede kalması enerji tüketiminin azalmasına katkı sağlamaktadır (Khuntia et al., 2022). Ayrıca günümüz trendlerinde Avrupa Birliği regülasyonları ile getirilen verimlilik kısıtlamaları, iklimlendirme cihazlarının geliştirilmesinde bazı standartları ve test prosedürlerini oluşturmuştur. Bu prosedürler ve tasarım koşulları EN 14825 ve EN 14511 standartları uyarınca belirlenmiştir (Standart, EN 14825, EN 14511). Bilhassa EN 14825 standardı bir iklimlendirme cihazının performansının belirlenmesinin sezonsal olarak olması gerekliliğini önerip, sezonsal verimlilik kavramını ortaya koymuştur. Rekabet edebilir ve düşük enerji tüketimli iklimlendirme cihazlarının tasarlanması esnasında ele alınan sezonsal verimlilik parametrelerinde, sistemde ikincil akışkanın dolaşımını sağlayan fan ve pompaların güç tüketimi önemli bir pay sahibidir. Gelişen değişken devirli motor teknolojileri bu güç tüketimi değerlerinin iyileştirmesine olanak sağlamaktadır. Ancak bu motorların verimli bir şekilde kullanılabilmesi için kontrol stratejilerinin de ele alınması gerekmektedir.

Bu invertörlerin kontrol sinyallerini oluşturan PLC'lerde, belirli bir koşul altında parametreleri belirlenmiş klasik kontrol algoritmaları yerine değişken koşullar karşısında parametreleri dinamik olarak değişecek uyarlamalı bir kontrol algoritması kullanılması enerji tüketiminin azalmasına ek katkı sağlayacaktır. Böylece benzer bir mantıkla havalandırma amacı güden cihazlarda bulunan fan motorlarının uyarlamalı denetleyici ile devir kontrolünün gerçekleştirilmesi, havalandırma cihazının enerji verimliliğini artırması beklenmektedir.

Bu tez çalışmasında, bilimsel yazındaki eksik ve giriş bölümünde ele alınan sektörel kaygılar ele alınarak iklimlendirme sektöründe yaygın olarak kullanılan EC (Electronically Commutated) motorlu (Fırçasız DC motor) bir fanın kontrol strateji üzerine detaylıca çalışılmıştır. Çalışmanın ilk aşamasında farklı karşı basınçlarda fanın güç tüketimi davranışının MATLAB ortamında benzetim çalışması gerçekleştirilerek, farklı karşı basınç girdilerine cevap verecek bir kontrol algoritması çalışılmıştır. Kontrol algoritması ilk etapta klasik PID kontrolcüsü olarak ele alınmıştır ve ikinci etapta makine öğrenmesinin bir alt dalı olan ve pekiştirmeli öğrenme algoritması olan DDPG (Derin Deterministik Politika Gradyanı) algoritması ile fanın kontrolü benzetim ortamında gerçekleştirilmiştir. Benzetim çalışmalarının tamamlanması ardından tasarlanan kontrol algoritması bir havalandırma kanalı, bir fan ve bir damper ile kurulan deney düzeneği kontrol eden bir PLC üzerinde deneysel bir çalışma ile sonuçlandırılmıştır. Elde edilen bulgularda DDPG'nin klasik PID algoritmalarına kıyasla, fanın sürekli rejime ulaşmasında benzetim çalışmalarında ortalama 6 saniye, deneysel çalışmada ise ortalama 10 saniye daha az zaman harcadığını ve sürekli rejime ulaşma süresi esnasında %6 kadar daha az güç tüketimi ortaya koyduğunu göstermiştir. Bilimsel yazın incelendiğinde bu çalışmanın olmadığı görülmüş ve sektörel anlamda bu kazancın iklimlendirme sektörü için oldukça anlamlı olacağı gözlemlenmiştir. Bu sebeple benzetim çalışması gerçekleştirilen fan kontrolcüsünün bir fan ve kanal sisteminde deneysel çalışmaları gerçekleştirilmiştir. Elde edilen bulgular neticesinde deneysel sonuçlar ile benzetim çalışması sonuçlarının uyum içerisinde olduğu ve üzerinde çalışılan sistemin birbirlerine yakın sürelerde sürekli rejime geldiği gözlemlenmiştir.

2.BİLİMSEL YAZIN İNCELEMESİ VE GENEL BİLGİLER

Tez çalışması kapsamında kurgulanan yenilikçi makine öğrenmesi algoritmaları destekli kontrol sistemi stratejisinin mevcut bilimsel yazındaki durumunu değerlendirmek ve bilimsel yazına katkı sunacak çalışmalar gerçekleştirmek amacıyla yapılan tarama üç ana başlıkta gerçekleştirilmiştir, (i) iklimlendirme sistemlerinde kullanılan fanların mevcut kontrol stratejilerinin değerlendirilmesi (ii) Pekiştirmeli öğrenme algoritmalarının motor sürücülerinde kontrol stratejisi amacıyla kullanımının değerlendirilmesi ve (iii) bir EC motorlu fanın deney prosedürlerinin araştırılması ve mevcut bilimsel yazındaki deneysel sonuçların incelenmesi.

Bu tez çalışması kapsamında bilimsel yazın incelemesi yapıldığında; Tüfekçi vd. (2016), yaptıkları çalışmada havalandırma işlemi için kullanılan bir fanın Kayan Kipli Gözlemleyici ve Genişletilmiş Luenberger Gözlemleyici yöntemi olmak üzere iki farklı metotla sensörsüz kontrolünü gerçekleştirmiş ve fan motorunun 6 Nm ve 12 Nm yük altında ayrı ayrı performans sonuçlarını kıyaslamışlardır. Elde ettikleri bulguya göre, Kayan Kipli Gözlemleyici' nin sürekli hal hız hatasının Genişletilmiş Luenberger Gözlemleyici 'ye kıyasla daha yüksek olduğu, düşük hız bölgesinde Genişletilmiş Luenberger Gözlemleyici' nin daha iyi sonuçlar verdiğini sonucuna varmıştır. Elde ettikleri bir diğer bulguda ise, bunun aksine Kayan Kipli Gözlemleyici' nin faz akım formlarının daha sinüzoidal olduğunu ve işlem süresinin 0,3 µs daha az olduğu tespit etmişlerdir. Solmaz ve Alkan (2017), merkezi bir ısı santralinde enerji tasarrufu sağlayabilmek adına sistem otomasyonunu bir PLC yardımıyla gerçekleştirmişlerdir. Sistemde bulunan pompa motorlarını sürücü yardımıyla PID denetleyici algoritmaları kullanarak devir kontrolünü gerçekleştirmişler ve PID kazanç parametrelerini Ziegler-Nichols yöntemi ile ayarlamışlardır. Elde ettikleri bulgulara göre, üzerinde çalıştıkları merkezi ısıtma sistemini manuel kontrol yerine PLC yardımıyla ve PID algoritmalarıyla otomasyon ile kontrolünü gerçekleştirdiğinde %15 civarında enerji tasarrufu elde ettiğini belirtmiştir. Savaş (2020), yaptığı çalışmada kapalı devre buhar türbini sistem tasarımını gerçekleştirmiş ve bu sistemin soğutulması için kullanılan pompa, fan ve kompresör devir kontrollerini sistemde bulunan sıcaklık ve basınç sensör verileri aracılığıyla bir mikroişlemci vasıtasıyla PID kontrol yöntemi kullanarak gerçekleştirmiştir. Kullandığı kontrol algoritması ile buhar türbinini soğutulmasında kullanılan soğutma sisteminde bulunan kondenser sıcaklığının -20°C'ye kadar düştüğünü ve ortamın dış hava sıcaklığını bağlı olarak 10°C soğutulduğu ifade edilmiştir. Elde ettiği bulguya göre, tasarladığı sistemin

soğutulması için harcanılan enerjinin %2,08'ini sisteme geri kazandırdığını belirtmiştir.

Budak vd. (2022), yaptıkları çalışmada MATLAB ortamında bir sıvı tankı modellemiş ve sıvı seviye kontrolü için pekiştirmeli öğrenme yöntemini önermişlerdir. Yaptıkları benzetimde pekiştirmeli öğrenme algoritmalarından TD3 (ikiz-gecikmeli derin deterministik politika gradyanı) ve DDPG algoritmalarını kullanarak tanktaki sıvı seviyesini kontrol etmişlerdir. Önerdikleri sistemin performansını kıyaslamak için aynı zamanda bir PID denetleyici ile de sıvı seviye kontrolünün benzetimini gerçekleştirmişlerdir. Elde ettikleri bulgular sonucunda önerdikleri yöntemin sistemin geçici durum ile kalıcı durum performansını iyileştirebileceğini ve klasik PID ile karşılaştırıldığında TD3 ve DDPG algoritmalarının kontrol performanslarının daha düzgün ve verimli olduğunu gözlemlemişlerdir. Aydın (2022), yaptığı çalışmada DC motor hız kontrolünü gerçekleştirmek için pekiştirmeli öğrenme tabanlı uyarlamalı PID denetleyici tasarlamış ve bunu gerçek zamanlı bir sisteme uyarlamıştır, tasarımını yaparken pekiştirmeli öğrenme algoritmalarından biri olan Q-Öğrenme algoritmasını kullanmıştır. Elde ettiği sonuçlar doğrultusunda tasarlamış olduğu denetleyici model tabanlı bir klasik PID denetleyiciye yakın sonuçlar verdiğini gözlemlemiş ve karmaşık sistemlerde bu metodun uygulanabileceğini belirtmiştir. Kılıç (2022), yaptığı çalışmada vektör kontrollü asenkron motor sürücülerinde PI hız denetleyicinin parametrelerini pekiştirmeli öğrenme yöntemi algoritmalarından olan TD3 algoritmasını kullanarak optimize etmiştir. Sistemi farklı referans hızlarda ve yük koşulları altında test etmiştir. Elde ettiği sonuçlar arasında TD3 algoritması kullanılarak optimize edilmiş PI denetleyicinin vektör kontrollü asenkron motor sürücülerinde benzetim ortamında yükselme zamanı, yerleşme zamanı, aşım ve sifıra yakın kararlı hal hatası ile yük bozucu etkisi karşısında da iyi bir performans gösterdiğini tespit etmiştir. Coşkun ve İtik (2023), yaptıkları çalışmada oransal valf ile sürülen asimetric bir pistonun konum kontrolü için pekiştirmeli öğrenme tabanlı bir denetleyici tasarlamış ve benzetimini gerçekleştirmişlerdir. Denetleyici tasarımı yapılırken pekiştirmeli öğrenme algoritmalarından DDPG algoritmasını kullanmışlardır. Yaptıkları çalışmada aynı zamanda sistem modeli oluşturarak kazanç parametrelerini Ziegler-Nichols metodu ile belirledikleri bir PID denetleyici ile de kontrolünü benzetim ortamında gerçekleştirmişlerdir. Yaptıkları benzetim çalışmaları doğrultusunda sistem modeline ihtiyaç duymadan tasarladıkları denetleyici ile konum kontrolünde, sistem modeli oluşturarak tasarladıkları klasik PID denetleyiciye kıyasla %25,51 daha başarılı sonuç elde ettiklerini gözlemlemişlerdir.

Yoon et al. (2022), yaptıkları çalışmada kurulu bir temiz oda klimasının performans tahminleri için yapay sinir ağı kullanmayı önermişlerdir. EC motorlu bir fan barındıran bir iklimlendirme ünitesi üzerinde deneysel bir çalışma yapmışlar ve deney düzeneğinden elde ettikleri 2816 adet verinin %80 ile yapay sinir ağı modelini eğiterek sistemin performansını tahmin etmeye çalışmışlardır. Yaptıkları çalışma ile EC motorlu bir fan bulunan iklimlendirme ünitelerinin deney prosedürlerini açıklamışlar ve eğittikleri yapay sinir ağı modeli ile sensör kalibrasyon işleminin de gerçekleştirilebileceğini belirtmişlerdir.

Bu tez çalışması kapsamında bilimsel yazın incelemesi sonucu elde edilen bulgular ve sonuçlar doğrultusunda önerilen alternatif pekiştirmeli öğrenme tabanlı denetleyici ile sistemin farklı dış etmenlere uyum sağlaması, sistemin kararlı ve sürekli rejime daha hızlı ulaşmasını sağlamak ve bütün bunlara ek olarak bu kontrol yöntemi ile havalandırma sisteminin enerji verimliliğinin artırılması amaçlanmaktadır.

3.GEREÇ VE YÖNTEM

Bu bölümde tez çalışması kapsamında incelenen kontrol sisteminin benzetim çalışmalarının detayları, tez çalışması kapsamında ele alınan pekiştirmeli öğrenme algoritmalarından olan DDPG algoritmasının matematiksel alt yapısı ve tez çalışması kapsamında gerçekleştirilen deneysel çalışmaların metodolojisi açıklanmıştır.

3.1 Endüstriyel Kontrol Sistemleri

Endüstriyel kontrol sistemleri, büyük veya orta ölçekli üretim ve hizmet sektörlerinde kullanılan kontrol ve otomasyon cihazlarının bütünü olarak tanımlanmaktadır. Bu sistemler; bir süreci yürütmek, üretim süreçlerindeki hataları azaltmak, enerji verimliliğini artırmak gibi çeşitli amaçlara hizmet etmektedir.


Endüstriyel kontrol sistemleri; otomotiv sektörü, kimya endüstrisi, enerji üretimi, gıda ve hizmet sektörü, havalandırma ve iklimlendirme sektörü başta olmak üzere çeşitli sektörlerde yaygın olarak kullanımına rastlanmaktadır. Endüstriyel kontrol sistemleri teknolojinin gelişmesiyle birlikte yapay zeka ve IOT (Nesnelerin İnterneti) sistemleri ile harmanlanarak daha karmaşık süreçleri yönetebilir ve kontrol edebilir hale gelmiştir.

En temel anlamda bir endüstriyel kontrol sisteminin temel bileşenleri; (i) sensörler, (ii) kontrolcü, (iii) eyleyiciler, (iv) HMI (İnsan Makine Arayüzü) ve SCADA (Gözetleyici Kontrol ve Veri Toplama Sistemi) 'dan oluşmaktadır. Bu bileşenler bu bölümde açıklanmıştır.

3.1.1 Sensörler

Sensörler, bir kontrol sisteminin temel algılayıcı cihazlarıdır. Süreç boyunca sistemden veri toplamakta ve bir haberleşme protokolü aracılığıyla sistemin ana kontrolcüsüne bu verileri iletmektedirler. Bu veriler içerisinde barındırılan kontrol sisteminin kullanım alanına ve sürece göre; sıcaklık, nem, basınç, akış hızı, uçucu organik bileşik miktarları (CO₂ veya VOC) gibi süreç boyunca ölçülmesi ve gözetim altında tutulması istenen parametrelerdir.

Endüstriyel kontrol sistemlerinde kullanılan (a) kanal tipi nem sensörü ve (b) oransal fark basınç sensörü şekil 3.1’de gösterilmiştir (Belimo, 2024).



Şekil 3.1: Bir havalandırma sisteminde kullanılan (a) kanal tipi nem sensörü (b) oransal fark basınç sensörü

3.1.2 Kontrolcü

Bir endüstriyel kontrol sisteminde bulunan PLC veya DCS (Dağıtılmış Kontrol Sistemleri) elektronik kontrol cihazları, içerisinde barındırılan sistemin temel elemanı ve sürecin yöneticisidir. Bu cihazlar, kontrolü gerçekleştirilen süreç boyunca aynı sistemde bulunan sensörler aracılığıyla elde ettikleri verileri işleyerek yine aynı sistemde bulunan eyleyicilere komut sinyalleri oluştururlar. Bu işlem bir kapalı döngü altında süreç boyunca devam etmektedir.

Elektronik kontrolcüler, sistemin ve sürecin karmaşıklığına göre programlayıcısı tarafından yazılmış algoritmalar ile süreci işletmektedirler. Bu algoritmalar arasında PID kontrol yöntemi sık tercih edilen bir yöntemdir.

Bu tez kapsamında ele alınacak endüstriyel sistem olan havalandırma cihazlarında yaygın olarak kullanılan kontrolcü (PLC) Şekil 3.2' de gösterilmiştir (Siemens, 2017).



Şekil 3.2: Havalandırma sistemlerinde kullanılan elektronik kontrol cihazı

3.1.3 Eyleyiciler

Eyleyiciler, kontrolcüden gelen komut sinyallerini fiziksel harekete çeviren kontrol sistemi elemanlarıdır. Sistemde bulunan motorlar ve kompresörler bu elemanlara örnektirler. Sistem, süreç boyunca kapalı döngü altında kontrolcünün oluşturduğu komut sinyalleri aracılığıyla aktüatörleri harekete geçirecek ve aktüatörlerin hareketleri sonucunda sistemde yer alan sensörler yeni değerler algılayacaktır. Sistemde bulunan kontrolcü, yeni sensör verileri ile aktüatörlere yeni komut sinyalleri gönderecek ve kapalı döngü süreç boyunca anlatılan şekilde işlemeye devam edecektir.

Tez kapsamında deney düzeneğinde kullanılacak olan bir eyleyici örneđi, EC motorlu fan görseli Şekil 3.3 'te gösterilmiştir (Ebmpapst, 2018).



Şekil 3.3: Havalandırma sistemlerinde kullanılan EC motorlu fan

3.1.4 HMI ve SCADA


HMI ve SCADA cihazları, bir endüstriyel kontrol sisteminde sürecin operatörler tarafından izlenmesine yarayan ve gerekli durumlarda sisteme operatörler tarafından müdahale edilmesi için kullanılan görsel grafik ekranlarıdır. Bu ekranlar aracılığıyla operatör anlık olarak sistemde bulunan sensör verilerini, aktüatör çalışma ve konum bilgilerini, sistemin toplam çalışma zamanı gibi parametreleri gözetleyebilmekte, bu verileri kayıt altına alabilmekte ve sistemin çalışma zamanını yönetebilmektedir.

Endüstriyel kontrol sistemlerinde sık olarak karşımıza çıkan ve sistemin gözetlenmesini sağlayan HMI cihazına ait görsel, Şekil 3.4'te gösterilmiştir (Siemens, 2020)



Şekil 3.4: Endüstriyel kontrol sistemlerinde kullanılan HMI cihazı


Bir endüstriyel kontrol sistemi temel çalışma prensibini anlatan kapalı çevrim blok diyagramı Şekil 3.5' te gösterilmiştir.



Şekil 3.5: Endüstriyel kontrol sistemi temel çalışma prensibi

3.2 PID Kontrol

PID kontrol yöntemi, başta endüstriyel kontrol ve otomasyon sistemlerinin vazgeçilmez kontrolcüsü olan PLC ve diğer mekanik kontrol sistemlerinde karşımıza yaygın bir şekilde çıkmaktadır. Bir geri besleme denetleyicisi olan PID denetleyici temel yapısı Şekil 3.6'da gösterilmiştir.



Şekil 3.6: PID denetleyicinin kapalı çevrim kontrol sisteminde kullanımı

PID denetleyici, kullanılacak kontrol sisteminde istenilen değer ile girişten aldığı sinyal verisini karşılaştırarak hata değerini hesaplamaktadır. Elde edilen bu hata değeri denetleyici tarafından bir oran, integral ve türev kazanç katsayısı ile çarpılarak tekrar çıkışa gönderilir. İşlem sonucunda, çıkış sinyali ile giriş sinyali arasındaki fark tekrar alınır ve hata tekrar hesaplanır. Bütün bu işlemler hata oranı en düşük değere ulaşana kadar devam ettirilmektedir. Bilimsel yazında sık karşımıza çıkan PID denetleyici sürekli zaman matematiksel gösterimi Denklem (1)'de verilmiştir (Aström and Hagglund, 1995; Ogata, 2010).

$$u(t) = k_p e(t) + k_i \int_0^t e(t) d(t) + k_d \frac{d}{dt} e(t) \quad (1)$$

Denklem (1)'de belirtilen $u(t)$ kontrol işaretinin zaman bağlı ifadesi, K_p , K_i ve K_d katsayıları sırasıyla oran, integral ve türev kazanç parametrelidir, $e(t)$ ise hata sinyalinin zamana bağlı ifadesidir. Bu parametreler bir kontrol sisteminde hepsi birlikte kullanılacağı gibi ayrı ayrı olarak da karşımıza çıkabilmektedir. Bir kontrol sisteminde sadece PI (Oransal-İntegral) denetleyici olabileceği gibi yalnızca PD (Oransal-Türev) denetleyicide kullanılabilir. PID (Oransal-

İntegral-Türev) denetleyici parametrelerinin her birinin kontrol sistemine olan etkisi birbirinden farklıdır.

Denklem (1) üzerinde Laplace dönüşümü ve Euler yöntemlerini uygulayarak PID denetleyici ayrık zaman matematiksel gösterimini elde edebiliriz. Bu işlemler sonucu elde edilen gösterim Denklem (2)'de verilmiştir.

$$C(z) = k_p + \frac{k_i T_s z}{z - 1} + \frac{K_d(z - 1)}{T_s z} \quad (2)$$

Bu deklemden T_s örnekleme zamanını ifade etmektedir.

Bu tez kapsamında üzerinde çalışılmış olan havalandırma cihazlarında kullanılan fanların motor kontrolünde elektronik kontrolcülerin fan hız kontrolü esnasında fazla salınım yapması nedeniyle PID kontrol yerine PI kontrol tercih edilmektedir.

3.2.1 Oransal Kontrol

Oransal kontrol, hedeflenen değer ile giriş verisini karşılaştırıp bulduğu hata değerini bir “ K_p ” kazanç katsayısı ile çarparak hızlı bir şekilde hatayı küçültür. Genellikle, salınım yapma olasılığı fazla olmasından dolayı endüstriyel kontrol sistemlerinde tek başına kullanımı tercih edilmemektedir. Bu kontrol yöntemi ile elde edilen kontrol işaretinin matematiksel gösterimi denklem (3)'de gösterilmiştir.

$$u(t) = k_p e(t) \quad (3)$$

3.2.2 İntegral Kontrol

İntegral kontrol, temelde geçmiş hataların toplamı olarak düşünülebilir. Giriş sinyali ile elde edilen hata sinyali eğrileri arasında kalan alan integral işlemi kullanılarak hesaplanır. Hesaplanan bu değer, hata azaltılana kadar bir “ K_i ” kazanç katsayısı ile çarpılarak toplanır. Bu kontrol yöntemi ile elde edilen kontrol işaretinin matematiksel gösterimi denklem (4)'te gösterilmiştir.

$$u(t) = k_i \int_0^t e(t) d(t) \quad (4)$$

3.2.3 Türev Kontrol

Türev kontrol, gelecekteki meydana gelebilecek hataları tahmin etmek amacıyla kullanılmaktadır. Hata sinyalinin geçmişteki değişim değerleri göz önüne alınır ve bir “ K_d ” kazanç katsayısı ile çarpılarak hata oranını azaltmak için sistem sınırlandırılır. Bu kontrol yöntemi ile elde edilen kontrol işaretinin matematiksel gösterimi denklem (5)’te gösterilmiştir.

$$u(t) = k_d \frac{d}{dt} e(t) \quad (5)$$

3.2.4 PID Denetleyici Kazanç Parametrelerinin Belirlenmesi

PID denetleyici kullanılan bir otomatik kontrol işleminin kararlı, düzgün ve istenilen şekilde en az salınım ile çalışması için “ K_p , K_i ve K_d ” kazanç parametrelerinin en uygun biçimde seçilmesi büyük önem taşımaktadır. PID tasarımı yapılırken bu parametrelerinin belirlenmesinde bilimsel yazında bahsi geçen çeşitli metotlar mevcuttur. Ancak, gelişen teknoloji ve endüstriyel sistemlerin daha karmaşık süreçleri işler hale gelmesi bilimsel yazında bahsi geçen klasik yöntemler ile bu parametrelerin belirlenmesi zorlaştırmıştır. Klasik yöntemler ile belirlenen parametreler belirli bir koşul altında etkili sonuç verse bile değişken sistem dinamikleri karşısında yeniden belirlenme ihtiyacı doğurmaktadır.

Bu metotlar; (i) deneme yanılma metodu, (ii) Cohen-Coon metodu, (iii) Ziegler-Nichols metodu, (iv) Chien-Hrones-Reswick (CHR) metodu ve (v) Wang-Juang-Chan metodu olarak sıralanabilir (Gidemen ve Fırat, 2015). Ancak bu yöntemlerin mutlak ve en iyi ayarlamayı yapamadığı, ayar için iyi sayılabilecek bir başlangıç parametre seti verdiği unutulmamalıdır.

Deneme Yanılma Metodu

Deneme yanılma yöntemi bilimsel yazında adı geçen ve hala önemli bir yere sahip olan bir metottur. Bu yöntem ile uygun parametrelerin seçimi birkaç tekrar sonrası belirlenebilir. Belirlenen bu parametrelerin deneyin yapıldığı zamana ve sistem dinamiklerine bağlı olarak etkisi değişmektedir.

Çizelge 3.1’de belirtilen L ifadesi, Şekil 3.7’de çizilen sistemin çıkışının birim basamak cevabının eğrisine çizilen teğeti kestiği nokta ile $x=0$ noktası arasındaki ölü zamanı ifade ederken, T ifadesi ise aynı nokta ise teğetin kesiştiği noktadan x eksenine indirilen dikme arasındaki mesafedir ve zaman sabiti olarak ifade edilir, a ifadesi ise kL/T eşitliği kullanılarak hesaplanmakta ve eğriye çizilen teğet ile $y=0$ noktasına olan mesafedir.

Ziegler-Nichols Metodu

Günümüzde de geçerliliğini koruyan bu metot, Cohen-Coon metodu kadar eski bir metottur. Bu yöntem iki farklı şekilde parametre elde edilmesine olanak sağlamaktadır. Ziegler-Nichols reaksiyon eğrisi metodu ile işlem yapılırken Cohen-Coon metodu ile aynı adımlar takip edilerek Şekil 3.3’te gösterilen eğri elde edilir ve Çizelge 3.2’deki eşitlikler yardımıyla PID denetleyici parametreleri bulunur.

Çizelge 3.2: Ziegler-Nichols reaksiyon eğrisi metodu eşitlikleri

$$a = \frac{kL}{T}$$

	K_p	T_i	T_d
P	$\frac{1}{a}$	-	-
PI	$\frac{0.9}{a}$	$3L$	-
PID	$\frac{1.2}{a}$	$2L$	$0.5L$

Çizelge 3.2’te belirtilen L ifadesi ölü zamanı, T ifadesi ise zaman sabitini ifade etmektedir, a değeri ise Çizelge 3.1’de verilen formül ile elde edilmiş parametredir.

Ziegler-Nichols osilasyon metodunda ise sistemin frekans cevabından yararlanılır ve Çizelge 3.3’teki eşitlikler yardımıyla PID kontrolcü parametreleri tespit edilebilmektedir.

Çizelge 3.3: Ziegler-Nichols osilasyon metodu eşitlikleri

$$T_c = \frac{2\pi}{\omega_c}$$

	K_p	T_i	T_d
P	$0.5K_c$	-	-
PI	$0.4K_c$	$0.8T_c$	-
PID	$0.6K_c$	$0.5T_c$	$0.12T_c$

Şekil 3.3'te bulunan K_c ifadesi sürekli salınım kazancı olarak, T_c ise salınım periyodunun saniye cinsinden ifadesidir.

Chien-Hrones-Reswick (CHR) Metodu

Bu yöntem ile üzerinde çalışılan kontrol sisteminin açık çevrim birim basamak cevabı kullanılarak Çizelge 3.4'teki eşitlikler yardımıyla PID denetleyici parametreleri elde edilmektedir. Çizelge 3.5'teki eşitlikler ise kontrol sisteminin bozucu etkilerini engellemek için kullanılmaktadır.

Çizelge 3.4: Chien-Hrones-Reswick metodu parametre ayarlama eşitlikleri

	%0 Aşım			%20 Aşım		
	K_p	T_i	T_d	K_p	T_i	T_d
P	$\frac{0.3}{a}$	-	-	$\frac{0.7}{a}$	-	-
PI	$\frac{0.35}{a}$	$1.2T$	-	$\frac{0.6}{a}$	T	-
PID	$\frac{0.6}{a}$	T	$0.5L$	$\frac{0.95}{a}$	$1.4T$	$0.47L$

Çizelge 3.4'te belirtilen L ifadesi ölü zamanı, T ifadesi ise zaman sabiti olarak ifade edilmektedir, a değeri ise Çizelge 3.1'de verilen formül ile elde edilmiş parametredir.

Çizelge 3.5: Chien-Hrones-Reswick metodu bozucu etki bastırma eşitlikleri

	%0 Aşım			%20 Aşım		
	K_p	T_i	T_D	K_p	T_i	T_D
P	$\frac{0.3}{a}$	-	-	$\frac{0.7}{a}$	-	-
PI	$\frac{0.35}{a}$	$4L$	-	$\frac{0.7}{a}$	$2.3L$	-
PID	$\frac{0.6}{a}$	$2.4L$	$0.42L$	$\frac{1.2}{a}$	$2L$	$0.42L$

Çizelge 3.5'te belirtilen L ifadesi ölü zaman, T ifadesi ise zaman sabiti olarak ifade edilmektedir, a değeri ise Çizelge 3.1'de verilen formül ile elde edilmiş parametredir.

Wang-Juang-Chan Metodu

Bu metot ile sistemin birim basamak cevabından elde edilen K , T ve L değişkenleri kullanılarak Çizelge 3.6'daki eşitlikler yardımıyla PID kontrolcü parametreleri elde edilebilmektedir.

Çizelge 3.6: Wang-Juang-Chan metodu eşitlikleri

	K_p	T_i	T_D
PID	$\frac{(0.7303 + \frac{0.5307T}{L})(0.5L + T)}{K(L + T)}$	$0.5L + T$	$\frac{0.5LT}{0.5L + T}$

Çizelge 3.6'da belirtilen L ifadesi ölü zaman, T ifadesi ise zaman sabiti olarak ifade edilmektedir.

3.2.5 Yapay Zeka Yöntemleri ile PID Kazanç Parametrelerini Belirlemek

Bilimsel yazında adı geçen ve alışlagelmiş yöntemler ile PID denetleyici parametreleri en uygun parametre setini garanti etmeyecek şekilde belirlenebilmektedir. Fakat, gelişen teknoloji ile daha karmaşık bir hal alan kontrol sistemleri için bu parametreleri belirlemek zor bir hal almaktadır. Ayrıca bu parametrelerin belirlenmesi uygulamada kullanılan makinelerde (iklimlendirme – havalandırma sektöründe kullanılan makineler dahil) anlık ve mevcut test koşulları altında belirlenmektedir. Makinenin çalışma koşulları değiştiğinde bir seferlik belirlenen bu parametreler, yeni koşullara uygun olmayabilmektedir (Sugarman., 2020). Bu sebeple bu parametrelerin değişen şartlara uyum sağlaması gerekmektedir. Bu duruma karşı günümüzde üzerinde çalışmaya devam edilen genetik algoritmalar (GA), parçacık sürü optimizasyonu (PSO), farksal evrim algoritması (DE) gibi yapay zeka optimizasyon algoritmaları bu parametrelerin belirlenmesinde kullanılabilir (Akay, 2006; Şavaşçıhabeş, 2008). Bunlara ek olarak bir diğer metot olan derin öğrenme (Deep Learning) ve makine öğrenmesi yöntemleri PID denetleyici parametrelerini belirlemede avantaj sağlayabilmektedir (Aki ve Dirik, 2020).


Bu tez çalışması kapsamında incelenen bilimsel yazın, pekiştirmeli öğrenme algoritmaları ile PID parametre ayarının mümkün olduğunu göstermektedir. Bu motivasyon ışığında bu algoritma oluşturulurken bu parametrelerin değişken şartlar altında pekiştirmeli öğrenme tabanlı denetleyici algoritması ile değişimi gerek MATLAB ortamında benzetim çalışmaları gerekse deneysel olarak gözlenip, gözlemin bulguları sonuçlar bölümünde sunulmuştur.

3.3 Kontrol Sistemlerinin Havalandırma Cihazlarına Uygulamaları

Günümüz havalandırma ve iklimlendirme sektöründe kullanılan sistemlerin ana kontrolcüsü, otomasyon sistemlerinin vazgeçilmezi olan PLC' lerdir (Sugarman, 2020). Bu cihazlar programlayıcısı tarafından oluşturulan senaryo ve algoritmalar doğrultusunda sistemi kontrol edecek sinyaller üretmektedir. Mevcut durumda bu PLC' ler de kullanılan PID algoritmalarına ait parametreler klasik yöntemlerle belirlenmektedir (Gidemen ve Fırat, 2015). Bunun yanı sıra deneme yanılma metodu iklimlendirme ve havalandırma sektöründe en sık kullanılan metottur. Deneyin yapıldığı zamandaki şartlara bağlı olarak uygun bir çıktı verebilir. Ancak bu yöntemin kullanımı tecrübeye dayalıdır, doğruluğunun bilimsel bir alt yapısı bulunmamaktadır. Sistemin tüm dinamiklerini dikkate alan uygun parametreler yakalanmamış olabilir. Diğer metotlarda ise parametre hesaplamaları

tablolar ile verilmektedir ancak kesin sonuçlar vermemektedir. Hesaplanan parametre değerleri ancak sistemin başlangıç değerleri olarak kullanılabilir (Akay, 2006; Doğan, 2006). Bunun yanı sıra doğru parametre hesabı için sistem modeline ihtiyaç duyarlar. Ayrıca deneme yanılma metodunda da olduğu gibi, herhangi bir sistemin değişen koşullar altında dinamik olarak PID parametre optimizasyonunu gerçekleştiremezler.

Bir havalandırma cihazı; temelde (i) fan, (ii) hava kanalı, (iii) debi sensörü olmak üzere üç ana bileşenden oluşmaktadır. Çalışma kapsamında tasarlanan pekiştirmeli öğrenme tabanlı uyarlamalı denetleyici algoritması ile sistemin kanal çıkışında bulunan bir fark basınç sensörü verisiyle istenilen debi kıyaslanarak fanın devir ve debi kontrolü yapılacaktır. Bu algoritma ile kanaldaki farklı dış statik basınç değerine bağlı olarak fanın kontrolü gerçekleştirilecektir. Sistemin çalışmasını gösteren blok diyagramı Şekil 3.8’de gösterilmiştir.



Şekil 3.8: Havalandırma cihazı ve kontrolünü gösteren blok diyagramı

Bu tez kapsamında PLC ile kontrol edilen havalandırma cihazlarında kullanılmak üzere yenilikçi yaklaşım olan yapay zekâ algoritmalarından yararlanılarak kazanç parametrelerini uyarlamalı olarak ayar eden bir denetleyici tasarımı yapılmış ve tasarlanan bu denetleyici hem MATLAB ortamında benzetim çalışmaları ile desteklenmiş hem de deneysel düzenek üzerinde uygulanmıştır. Bu denetleyici tasarlanırken makine öğrenmesi alt dallarından pekiştirmeli öğrenme yöntemi ele alınmıştır.


3.4 Pekiştirmeli Öğrenme

Bu tez kapsamında ele alınan metodun avantajı klasik kontrol yöntemlerine kıyasla bir sistem modeline ihtiyaç duyulmamasıdır. Makine öğrenmesi alt dallarından olan pekiştirmeli öğrenme yöntemi modelden bağımsız çalışabilen algoritmalar barındırmaktadır. Pekiştirmeli öğrenme metodu, bir ajanın kendi eylem ve deneyimleri ışığında edindiği geri bildirimleri kullanarak maksimum ödüle ulaşmayı amaçlamaktadır. Pekiştirmeli öğrenme algoritmaları çevrim bitince veya çevrim boyunca her durum geçişi için değer fonksiyonunu güncellemektedir. Güncellenen değer fonksiyonları ışığında hatanın mutlak değerinde azalma gözleniyorsa ajan pozitif ödüllendirilirken, tersi durumda ise negatif ödüllendirilmektedir (Jang et al., 1997; Sutton and Barto, 2011). Pekiştirmeli öğrenme algoritmaları Çizelge 3.7’de gösterilmiştir.

Çizelge 3.7: Pekiştirmeli öğrenme yöntemi, modele bağımlı ve modelden bağımsız algoritmalar

Pekiştirmeli Öğrenme				
Modelden Bağımsız Algoritmalar			Model Tabanlı Algoritmalar	
Politika Optimizasyonu	Q-Öğrenme	Politika Optimizasyonu-Q-Öğrenme Birleşimi	Öğrenilmiş Model	Verilmiş Model
Politika Gradyanı	DQN	DDPG	World Models	AlphaZero
A2C/A3C	C51	TD3	I2A	
PPO	QR-DQN	SAC	MBMF	
TRPO	HER		MBVE	

Pekiştirmeli öğrenme temel çalışması gösteren diyagram Şekil 3.9’da gösterilmiştir.



Şekil 3.9: Pekiştirmeli Öğrenme Temel Çalışma Diyagramı

3.4.1 Markov Karar Süreci

Pekiştirmeli öğrenme metodunda ajan, aksiyona geçireceği eylemi (a_t) ortamdaki durum parametrelerinin (S_t) bir fonksiyonuna belirlemektedir. Bu durum parametresi sistemin tamamı hakkında bilgi verirken aynı zamanda sadece algoritmanın kullanım amacına yönelik olarak belirli bir noktadaki durumu da ifade edebilmektedir. Markov özelliği sağlayan bir sistemde durum sinyalleri, anlık ölçümleri yanı sıra sistemin geçmiş durumundan da bilgiler içermektedir (Aydın, 2022).

Markov karar süreci S , A , P , R ve γ olmak üzere beş farklı parametre ile temsil edilir. S ifadesi S_1, S_2, \dots, S_n 'e kadar olan durumların kümesini, A ifadesi a_1, a_2, \dots, a_n 'e kadar olan eylem kümesini, P durum geçiş matrisini, R ödülü ve γ ise indirim faktörünü ifade etmektedir. Bu süreçte ajan, ortamda s başlangıç durumundadır ve bir a eylemini gerçekleştirmektedir. Ardından ortam bir sonraki s' durumunu ve ajana r ödülünü vermektedir. Ajan çevreyle sürekli etkileşim halindedir (Li et al., 2023).

R_t ise t zaman adımından sonraki kümülatif ödüllerin toplamıdır ve Denklem (6) ile ifade edilebilir.

$$R_t = r_{t+1} + \gamma r_{t+2} + \gamma^2 r_{t+3} + \dots = \sum_{k=0}^{\infty} \gamma^k r_{t+k+1} \quad (6)$$

π politikası, s durumunda bir a eyleminin seçilme olasılığıdır. Denklem (7)'deki eşitlik ile hesaplanabilir;

$$\pi(a|s) = P[a_t = a | s_t = s] \quad (7)$$

Durum-değer fonksiyonu $V^\pi(s)$, başlangıç durumunda π politikasını uygularken beklenen toplam ödül miktarını ifade etmektedir. Denklem (8) ile ifade edilebilir.

$$V^\pi(s) = E_\pi[R_t | s_t = s] = E_\pi\left[\sum_{k=0}^{\infty} \gamma^k r_{t+k+1} | s_t = s\right] \quad (8)$$

Eylem-değer fonksiyonu $Q^\pi(s, a)$, a eylemi gerçekleştirildiğinde elde edilen beklenen toplam ödüldür, s durumunda gerçekleştirilir ve sonraki eylemler için π politikasını izlemektedir. Denklem (9) ile ifade edilebilir.

$$Q^\pi(s, a) = E_\pi[R_t | s_t = s, a_t = a] = E_\pi\left[\sum_{k=0}^{\infty} \gamma^k r_{t+k+1} | s_t = s, a_t = a\right] \quad (9)$$

Pekiştirmeli öğrenmenin amacı, ödülü maksimize etmek için Markov karar sürecinin optimal politika fonksiyonunu π^* çözmektir. $V^*(s)$ optimal durum-değer fonksiyonu Denklem (11) ve $Q^*(s, a)$ optimal eylem-değer fonksiyonu Denklem (12) ile ifade edilebilir. Optimal politika fonksiyonunu π^* Denklem (10) ile gösterilmiştir.

$$\max_{\pi} E\left[\sum_{k=0}^{\infty} \gamma^k r_{t+k+1}\right] \quad (10)$$

$$V^*(s) = \max_{\pi} V^\pi(s) \quad (11)$$

$$Q^*(s, a) = \max_{\pi} Q^\pi(s, a) \quad (12)$$

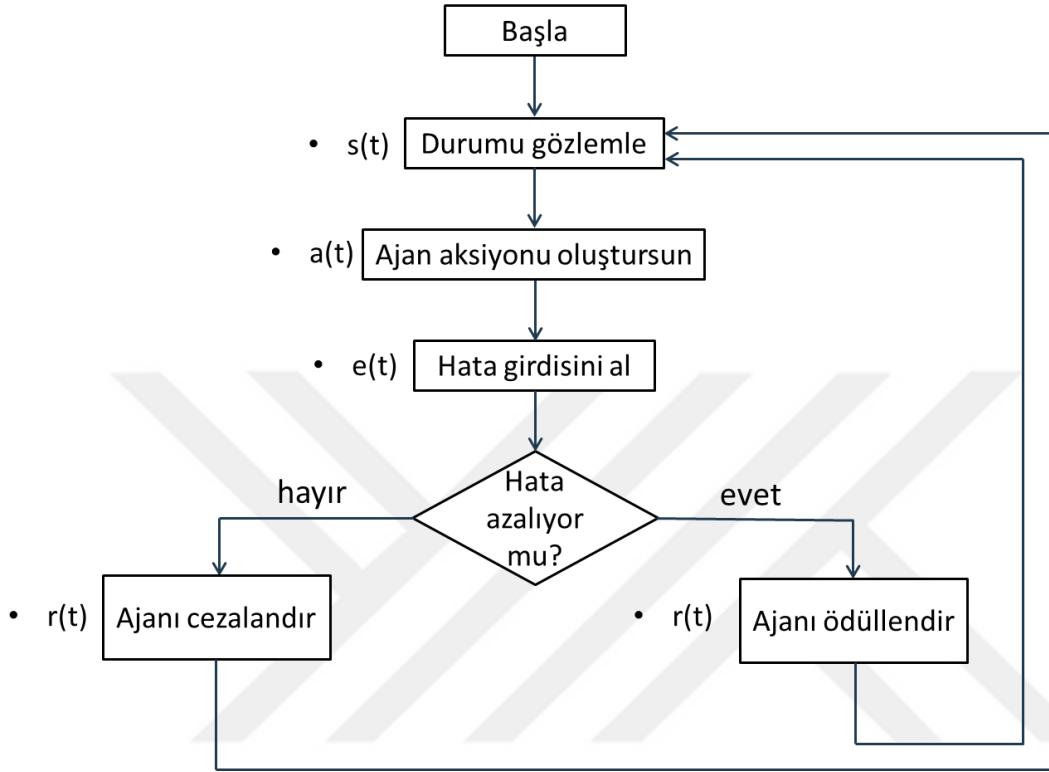
3.4.2 DDPG Algoritması

Tez kapsamında denetleyici tasarımı yapılırken pekiştirmeli öğrenme yöntemlerinden sistem modelinden bağımsız olduğu için Zamansal-fark yaklaşımının bir alt kırımını olan Q-Öğrenme ve Politika Optimizasyonu algoritmalarından, Derin Q Network (DQN) ve Politika Gradyanı algoritmasının birleşiminden oluşan ve bilimsel yazın taramasında da belirtildiği gibi sürekli uzayda hassasiyetinden dolayı DDPG algoritması kullanılmıştır. DDPG algoritmasının öğrenme yöntemi Bellman denkleminde dayanır (Lillicrap et al., 2015; Li et al., 2023). Bu denklem, Denklem (13)'de gösterilmiştir.

$$Q^\mu(S_t, a_t) = E[(R_t + \gamma Q^\mu(S_{t+1}, \mu(S_{t+1})))] \quad (13)$$

Denklem (5)'te ifade edilen $Q^\mu(S_t, a_t)$ DDPG algoritması durum-değer fonksiyonunu, S_t bu algortmadaki durum parametresini, a_t algoritmanın gerçekleştirdiği eylemi, E beklenen değeri, R_t anlık ödül parametresini, γ indirim faktörünü yani gelecekteki ödüllerin mevcut duruma olan etkisini, $\mu(S_{t+1})$ ise şu anki durumdaki en iyi eylemi belirleyen stratejiyi ifade etmektedir.

Bu tez kapsamında kullanılacak DDPG algoritması akış diyagramı Şekil 3.10'da verilmiştir.

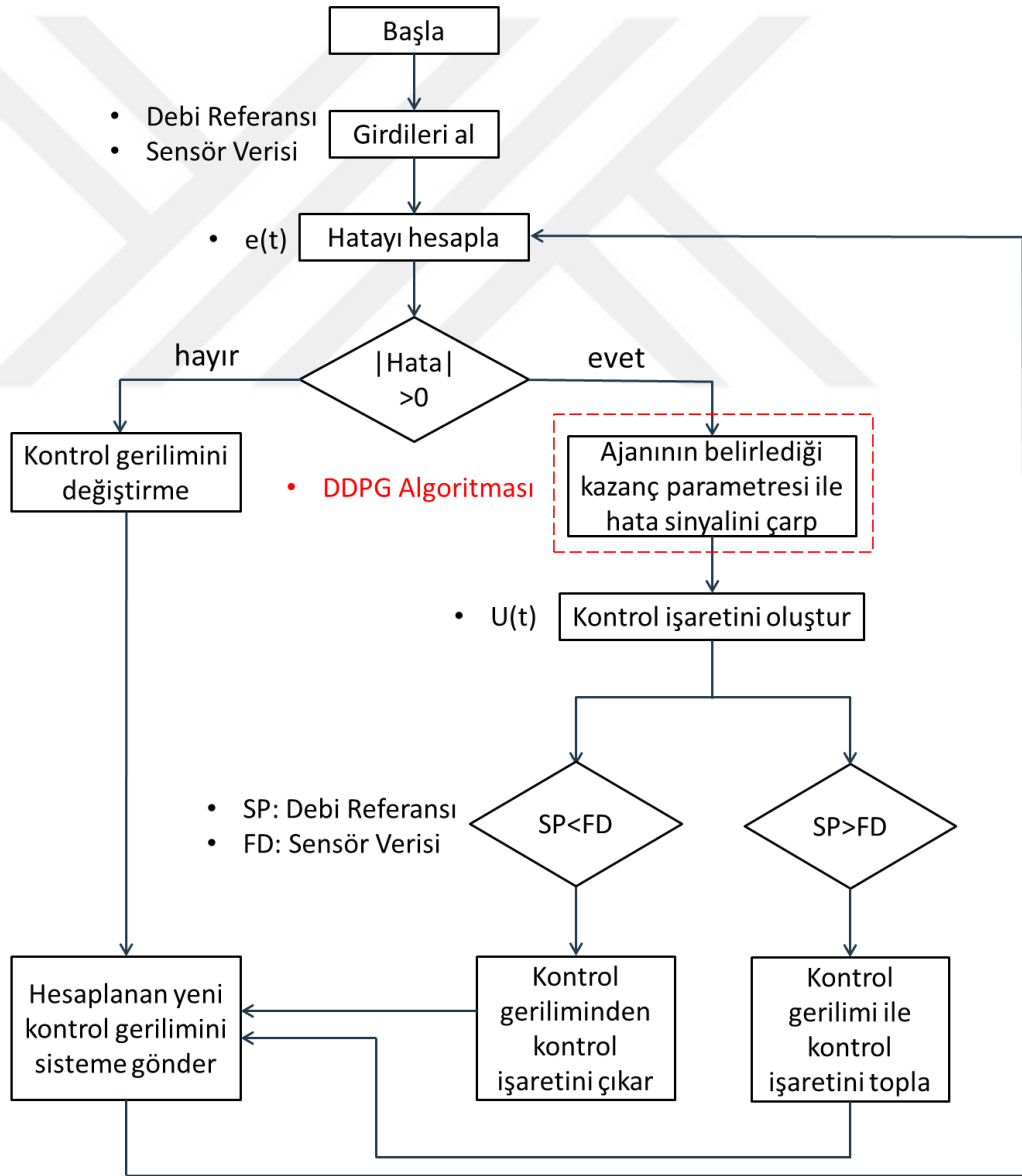


Şekil 3.10: DDPG algoritması temel akış diyagramı

3.5 Pekiştirmeli Öğrenme Tabanlı Uyarlamalı Denetleyici Tasarımı

Bu tez kapsamında tasarlanacak pekiştirmeli öğrenme tabanlı denetleyici için MATLAB üzerinden bir kontrol algoritması oluşturulmuştur. Bu algoritma sisteme girilen hedef debi referans değeri ile sensörden aldığı veriyi kıyaslayarak bir hata değeri ($e(t)$) hesaplamaktadır. Hesaplanan hatanın mutlak değeri DDPG algoritması ile belirlenen bir kazanç parametresiyle çarpılarak bir kontrol işareti oluşturmaktadır. ($u(t)$). Sensör verisi ve hedef debi değeri arasındaki fark pozitif ise fanın devir ayarı için sürücüye sinyal olarak iletilecek kontrol voltajından hesaplanan kontrol işareti çıkarılarak yeni bir kontrol voltajı oluşturulur ve sürücüye iletilir. Eğer, sensör verisi ve hedef debi değeri arasındaki fark negatif ise mevcut kontrol voltajına kontrol işareti eklenerek yeni bir kontrol voltajı oluşturulur ve sürücüye iletilir. Sisteme tanımlanan hedef debi değeri ile sensör

verisi arasındaki fark sıfır olduğunda yani hata değeri sıfırlanana kadar algoritma kapalı döngü içerisinde belirtilen şekilde çalışmaya devam etmektedir. Sisteme tanımlanan hedef debi değeri ile sensör verisi arasındaki fark sıfır olduğunda yani hata değeri sıfırlandığında ise en son hesaplanan kontrol voltajı sürücüye gönderilerek fanın aynı devirde döndürülmesi sağlanmaktadır. Tasarlanan kontrol algoritması, sistemde değişen ani debi referans değeri ve karşıt basınca karşın sistem aynı mantık ile tekrar kontrol voltajını hesaplayarak fanın istenilen devirde döndürülmesi sağlanmaktadır. Bu algoritmanın akış diyagramı Şekil 3.11’de gösterilmiştir. Şekil 3.11’de görülen DDPG algoritmasının kullanımının detayı Şekil 3.10’da verilmiştir.



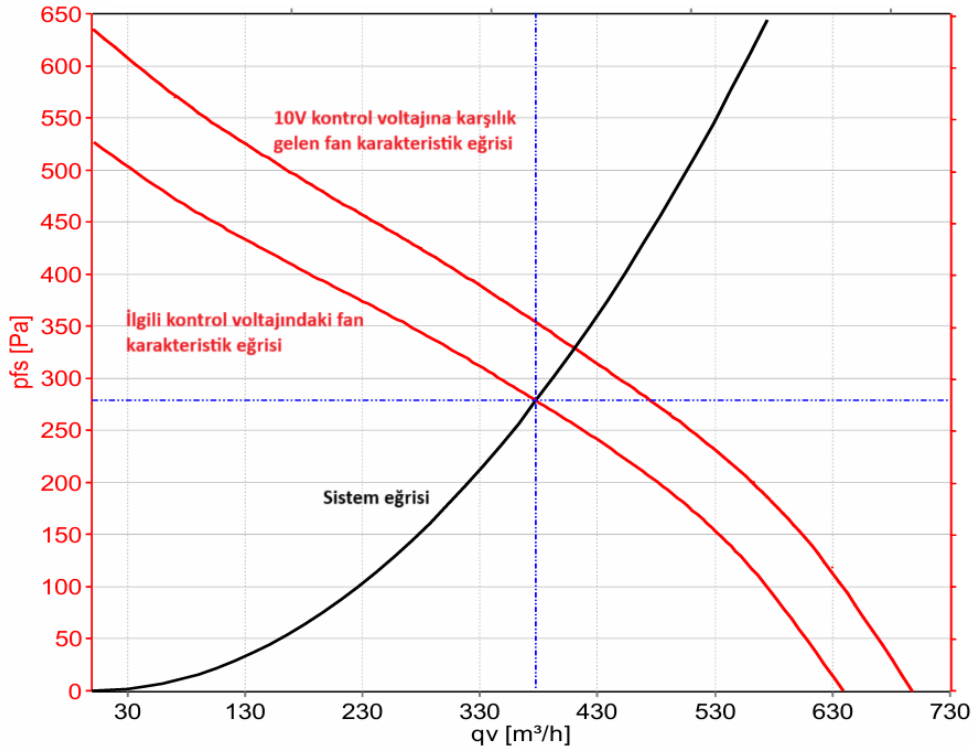
Şekil 3.11: Tasarlanan pekiştirmeli öğrenme tabanlı denetleme algoritması akış diyagramı

4.BENZETİM ÇALIŞMALARI

Bu tez çalışması kapsamında benzetim çalışması yapılabilmesi için havalandırma sistemlerinde kullanılan EC Plug bir fanın debi-basınç eğrilerinden elde edilmiş veriler MATLAB ortamına aktarılmış ve bu ortamda oluşturulmuş oransal bir kontrol algoritmasının kazanç parametreleri bu fan verilerini kullanarak pekiştirmeli öğrenme yöntemi ile DDPG algoritması kullanılarak eğitilmiştir. Yapılan benzetim çalışmaları sonucunda elde edilen bulgular kaydedilmiştir.

4.1 Karşı Basınç Eğrilerinin Tanımlanması

Tez çalışması kapsamında sektörel olarak kullanılan EC motorlu geriye yatık kanatlı bir fanın debi karakteristik fan eğrisi kullanılmıştır. Fanın herhangi bir kontrol voltajındaki karakteristik eğrisi Şekil 4.1 ile verilmiştir (Ebmpapst,2018). Şekil 4.1’ de belirtilen sistem eğrisi fanın kullanıldığı sistemin debiye bağlı basınç kaybını temsil etmektedir ve debi ile doğru orantılıdır. Burada sistem eğrisi ile fan karakteristik eğrisinin kesiştiği nokta, fanın çalışma noktasını vermektedir.



Şekil 4.1: EC motorlu geriye yatık kanatlı bir fana ait debi karakteristik eğrisi

İlgili fanın farklı kontrol voltajlarındaki karakteristik eğrilerini oluşturan debi-basınç verileri kullanılarak polinomsal regresyon yöntemi ile ikinci dereceden bir polinom elde edilmiştir. Polinoma ait genel ifade Denklem (14) ile gösterilmiştir. Katsayıların elde edilebilmesi için regresyon işlemi sonrası elde edilen denklem takımı Denklem (15), Denklem (16) ve Denklem (17) ile ifade edilmiştir. (Gilat and Subramaniam, 2008).

$$y = a_2 x_i^2 + a_1 x_i + a_0 \quad (14)$$

$$n a_0 + \left(\sum_{i=1}^n x_i \right) a_1 + \left(\sum_{i=1}^n x_i^2 \right) a_2 = \sum_{i=1}^n y_i \quad (15)$$

$$\left(\sum_{i=1}^n x_i \right) a_0 + \left(\sum_{i=1}^n x_i^2 \right) a_1 + \left(\sum_{i=1}^n x_i^3 \right) a_2 = \sum_{i=1}^n x_i y_i \quad (16)$$

$$\left(\sum_{i=1}^n x_i^2 \right) a_0 + \left(\sum_{i=1}^n x_i^3 \right) a_1 + \left(\sum_{i=1}^n x_i^4 \right) a_2 = \sum_{i=1}^n x_i^2 y_i \quad (17)$$

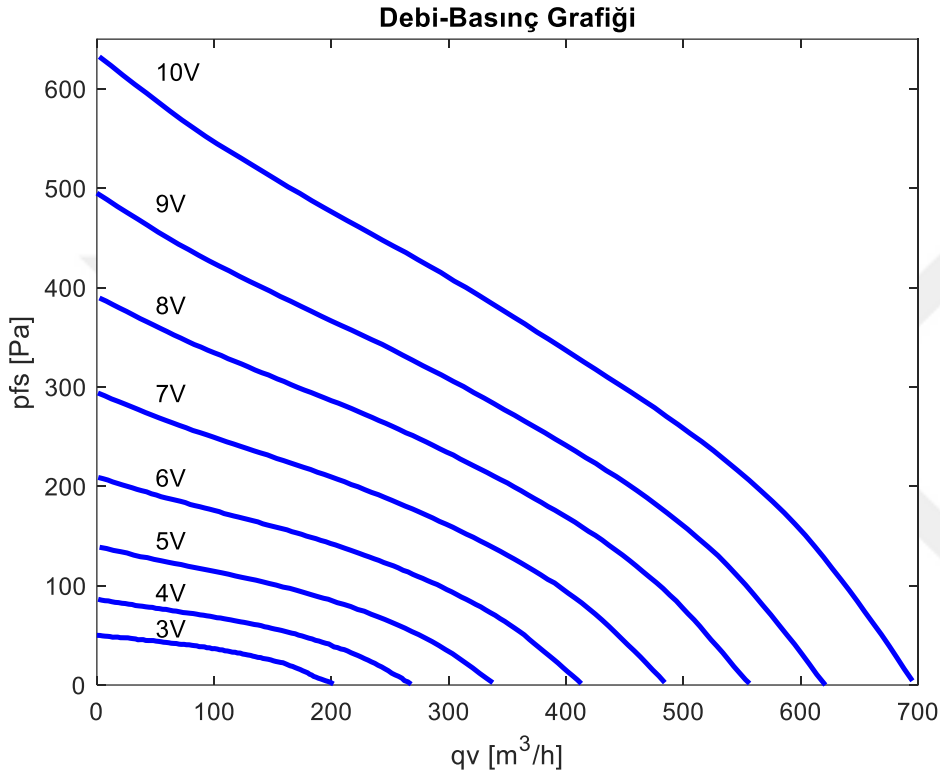
Burada x bağımsız değişkeni (hacimsel debi), a polinom katsayısını, n toplam veri sayısını ve y bağımlı değişkeni (basınç farkı) ifade etmektedir.

Bu denklem takımının çözümlenmesinde Gauss eliminasyon yöntemi kullanılmıştır. Her bir kontrol voltajı için hesaplanan katsayılar kullanılarak elde edilen polinomlar Çizelge 4.1’de ifade edilmiştir.

Çizelge 4.1: Değişken kontrol voltajı için karşı basınç polinomsal ifadeleri

Kontrol Voltajı [V]	Karşı Toplam Statik Basınç Karakteristik Denklemi [Pa]
3	$\Delta P = -0.0839\dot{V}^2 + 0.4931\dot{V} + 190.66$
4	$\Delta P = -0.001\dot{V}^2 - 0.0275\dot{V} + 82.404$
5	$\Delta P = -0.0154\dot{V}^2 - 0.2426\dot{V} + 329.58$
6	$\Delta P = -0.0075\dot{V}^2 - 0.3999\dot{V} + 406.46$
7	$\Delta P = -0.0004\dot{V}^2 - 0.5152\dot{V} + 483.24$
8	$\Delta P = -0.0023\dot{V}^2 - 0.5696\dot{V} + 558.45$
9	$\Delta P = -0.0014\dot{V}^2 - 0.6334\dot{V} + 629.21$
10	$\Delta P = -0.0008\dot{V}^2 - 0.6546\dot{V} + 712.99$

Çizelge 4.1 yardımıyla elde edilmiş, benzetim çalışmasında ve deneysel düzende kullanılacak EC motorlu geriye yatık kanatlı fanın PLC ‘den aldığı kontrol voltaj verisine karşılık gelen Debi-Basınç eğrileri Şekil 4.2’de gösterilmiştir.



Şekil 4.2: EC motorlu fan kontrol voltajına karşılık gelen debi-basınç eğrileri

4.2 Sürtünme Faktörü ve Karşı Basınç Hesabı

Tez çalışması kapsamında ele alınan havalandırma kanalı içerisinde sürtünme faktörü Haaland Denklemi ile hesaplanmıştır. Bu denklem, Denklem (18)’de gösterilmiştir (Çengel, 2010).

$$\frac{1}{\sqrt{f}} = -1.8 \log_{10} \left[\left(\frac{\epsilon}{D_h(3.7)} \right)^{1.11} + \frac{6.9}{Re} \right] \quad (18)$$

Burada f sürtünme faktörüdür, ϵ kanal malzemesinin yüzey pürüzlülük katsayısı, D_h kanal içi akışta hidrolik çap olup Denklem 19 ile ifade edilmiştir, Re ise kanal içi hava hızına göre hesaplanan boyutsuz Reynolds sayısıdır. Denklem (18) ile verilen sürtünme faktörünün hesaplanmasıyla kanal içerisinde toplam karşı basınç Denklem (20) ile hesaplanabilir.

$$D_h = \frac{4A_c}{p} \quad (19)$$

$$\Delta P = \left(f \frac{L}{D_h} \right) \left(\frac{\rho v^2}{2} \right) \quad (20)$$

Denklem (19) da verilen A_c kanalın kesit alanını, p ise kanal kesitinin çevre uzunluğunu temsil etmektedir. Denklem (20)'de verilen ρ havanın 20 °C'de standart yoğunluğu, v kanal içi ortalama hava hızıdır. Sürtünme faktörüne bir başlangıç değeri verilerek, kanal içerisindeki toplam karşı statik basınç değerleri, değişen hava hacimsel debileri için iteratif olarak MATLAB ortamında hesaplanmış, elde edilen değerler ile Çizelge 4.1'de verilen polinomsal ifadeler altında anlık olarak fanın çalışma gerilimi belirlenmiştir.

4.3 Benzetim Çalışmaları

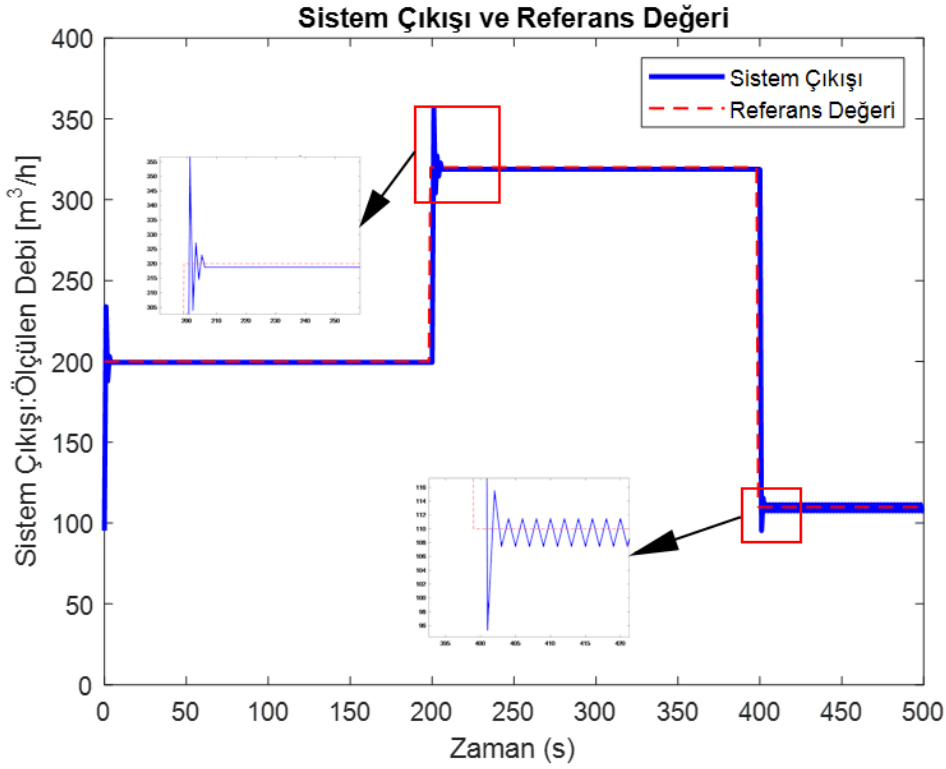
Bu tez çalışması gerçekleştirilirken, havalandırma sistemlerinde kullanılan EC Plug fan verileri bölüm 4.1 ve bölüm 4.2'de anlatılan yöntem ile MATLAB ortamına aktarılmış ve farklı kontrol voltajı karşısında çıkış debilerine göre belirlenmiş kanal ölçülerine karşın basınç değerleri dinamik olarak değişen bir algoritma ile benzetim çalışması kurgulanmıştır.

Benzetim çalışması gerçekleştirilirken ilk etapta kazanç parametreleri Ziegler-Nichols osilasyon metodu ile belirlenmiş klasik PI denetleyici kullanılarak MATLAB ortamına aktarılmış fan verileri ile benzetim çalışması gerçekleştirilmiştir. İkinci aşamada ise aynı fan debi-basınç verileri kullanılarak bölüm 3.5'te anlatılan yöntem ile tasarlanmış pekiştirmeli öğrenme tabanlı fan kontrol algoritması ile benzetim çalışmaları tekrarlanmıştır.

Tez çalışması kapsamında gerçekleştirilmiş olan benzetim çalışmaları (i) klasik PI denetleyici bulguları ve (ii) pekiştirmeli öğrenme tabanlı denetleyici bulguları olmak üzere iki ana başlık altında incelenmiştir.

4.3.1 Klasik PI Denetleyici Bulguları

Tez çalışması kapsamında yapılan benzetim çalışmalarının ilk aşamasında, bölüm 4.2 'de anlatılan yöntem ile MATLAB ortamına aktarılmış fan verileri ile kazanç parametreleri Ziegler-Nichols osilasyon metodu kullanılarak oransal kazanç parametresi olan K_p değeri 0.5, integral kazanç parametresi olan K_i değeri ise 0.04 olarak belirlenmiş klasik PI algoritması kullanılarak sistem benzetim çalışması yapılmış, benzetim çalışması 500 saniye boyunca devam ettirilmiş, bu süre zarfında hedef debi değerleri belli aralıklarla değiştirilerek sistem dinamikleri değiştirilmiştir. Benzetim çalışması sonucu elde edilen debi- zaman grafiği Şekil 4.3' te gösterilmiştir.

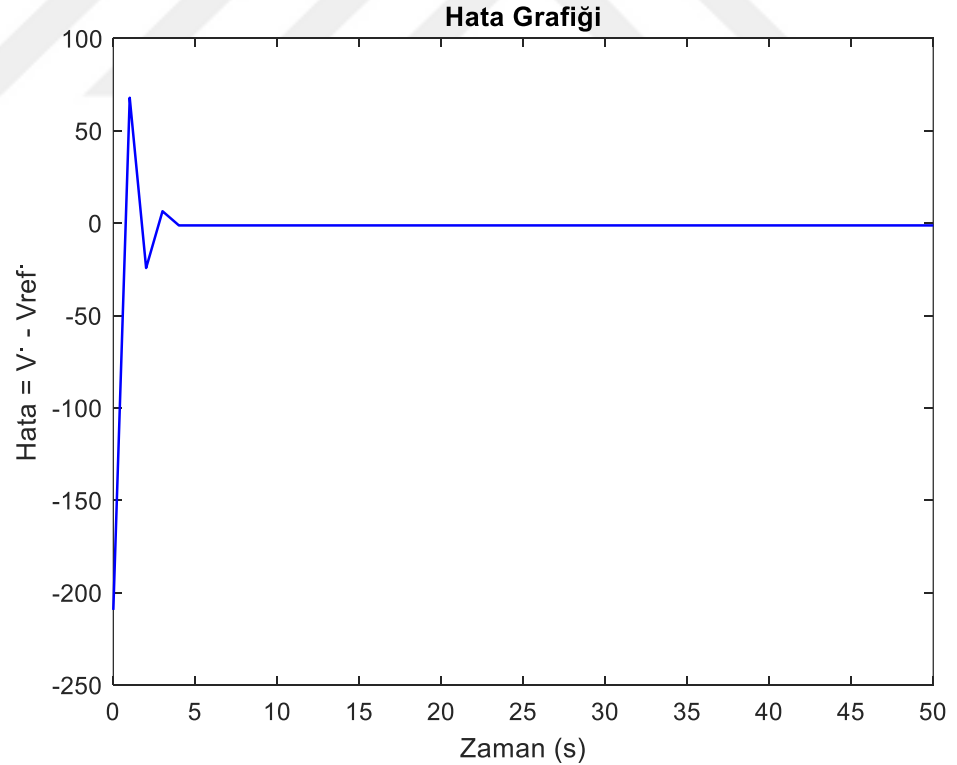


Şekil 4.3: Klasik PI denetleyici ile kontrolü gerçekleştirilmiş sistemin debi-zaman grafiği

Şekil 4.3'te elde edilen grafik incelendiğinde; kazanç parametreleri Ziegler-Nichols osilasyon metodu elde edilmiş klasik PI denetleyici ile yapılan kontrol işleminde fan hedef debi değerine ulaşırken ilk sınır 200 m³/h debi değerini geçtiği sürede salınım yaptığı, belli süre sonunda hedef debiye ulaştığı ve bir sonraki hedef

debi değerine kadar sabit bir devirde çalışmasına devam ettiği, benzer şekilde benzetim çalışmasının 200. saniyesinde sisteme tanımlanmış olan yeni hedef değeri olan $320 \text{ m}^3/\text{h}$ debi değerine ulaşmak için ilk etapta salınım yaptığı, daha sonra referans değere oturduğu ve bir sonraki hedef debi değerine kadar sabit devirde çalışmaya devam ettiği gözlemlenmiştir. Benzetim çalışmasının 400.saniyesinde sisteme tanımlanan yeni hedef değeri olan $110 \text{ m}^3/\text{h}$ debi değerinde ise benzetim çalışması sonuçlanana kadar salınıma devam etmiştir. Bu salınımın ek enerji tüketimine sebebiyet vereceği ve sistemin hedef debiye ulaşmasını geciktireceği bu grafik sonuçlarına bakılarak söylenebilmektedir. Ek olarak, bu tez kapsamının argümanı olan farklı dış ortam şartları için sabit kazanç parametrelerinin sistem dinamiklerine tam uyum sağlayamadığını ve uyarlamalı olarak güncellenmesi gerektiğini kanıtlar niteliktedir.

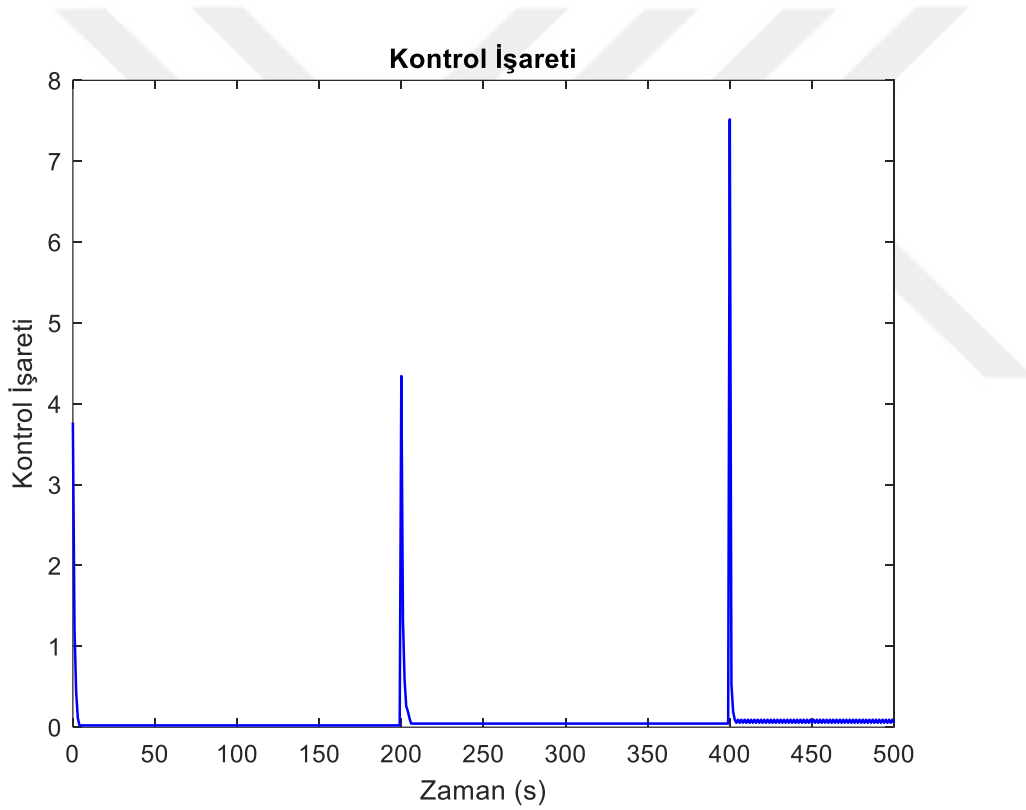
Benzetim çalışması sırasındaki 0. saniye ve 50. saniye arasındaki hata grafiği Şekil 4.4 ile gösterilmiştir.



Şekil 4.4: Klasik PI denetleyici ile kontrolü gerçekleştirilmiş sistemin 0. ve 50. saniye arasındaki hata grafiği

Şekil 4.4 ile verilmiş grafik incelendiğinde, benzetim çalışması sırasında değiştirilmiş ilk debi değerine ulaşması sırasında 6 saniye boyunca salınım yaptığı 6 saniye sonunda hedef değere ulaştığı bulgusu elde edilmiştir. Benzetim çalışması boyunca fanın ilk debi değeri olan $200 \text{ m}^3/\text{h}$ ulaşması sırasında da benzer bir sürelerde salınım yaptığı, üçüncü hedef değer olan $110 \text{ m}^3/\text{h}$ debi miktarına ulaşması sırasında ise benzetim çalışması tamamlanıncaya kadar salınıma devam ettiği Şekil 4.3'te görülmektedir.

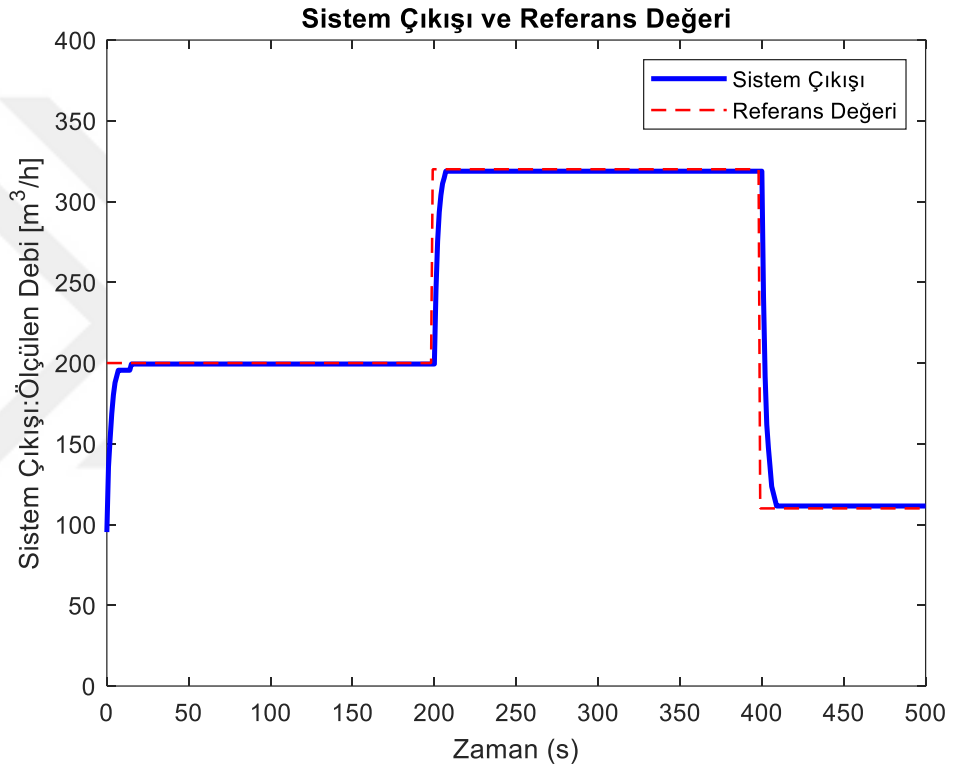
Klasik PI denetleyici ile benzetim çalışması yapılması sonucu elde edilmiş kontrol işareti zamana bağlı değişim grafiği Şekil 4.5'te gösterilmiştir.



Şekil 4.5: Klasik PI denetleyici ile kontrolü gerçekleştirilmiş sistemin zamana bağlı kontrol işareti

4.3.2 Pekiştirmeli Öğrenme Tabanlı Denetleyici Bulguları

Benzetim çalışmasının bir sonraki etabında, aynı fan verileri ile tez kapsamında üzerinde çalışması yapılan bölüm 3.5'te anlatılan yöntem ile tasarımı yapılmış pekiştirmeli öğrenme tabanlı denetleyici ile benzetim çalışması yapılmış, 500 saniye boyunca devam ettirilmiş, bu süre zarfında hedef debi değerleri belli aralıklarla değiştirilerek sistem dinamikleri değiştirilmiştir. Benzetim çalışması sonucu elde edilen debi- zaman grafiği Şekil 4.6' da gösterilmiştir.




Şekil 4.6: Pekiştirmeli öğrenme tabanlı denetleyici ile kontrolü gerçekleştirilmiş sistemin debi- zaman grafiği

Şekil 4.6' da elde edilen grafik incelendiğinde; kazanç parametreleri DDPG algoritması tarafından sistem değişken dinamikleri gözlemlenerek elde edilen pekiştirmeli öğrenme tabanlı uyarlamalı denetleyici kullanılarak sistem kontrollü gerçekleştirildiğinde, klasik PI kontrolcüye kıyasla istenilen hedef debi değerine salınım yapmadan ulaştığı, benzetim çalışması boyunca belli aralıkta hedef debi değiştirilmesine ve sistem dinamiklerinin değişmesine karşın kontrolcünün kazanç

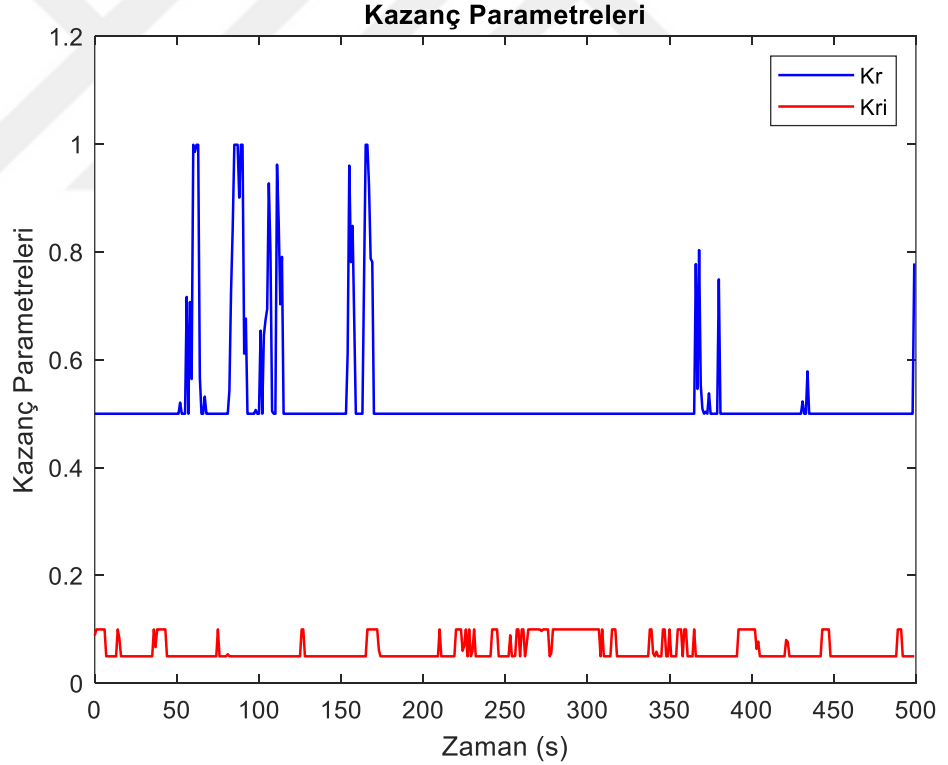
parametrelerini dinamik olarak deęiřtirerek deęiřken sistem dinamiklerine uyum saęladığı gözlemlenmiştir.

Ancak, benzetim ortamında neredeyse kusursuz bir řekilde hedef debi deęere ulaşan fan sisteminin geręek bir sistemde bu derece kusursuz bir řekilde hedef deęere ulaşamayacağı, az da olsa belli bir miktar salınım yapacağı öngörülmektedir. Çalışmanın bir sonraki aşaması olan deneysel düzenek üzerinde geręekleştirilen kontrol işleminde bu öngörü doğrulanmıştır. Pekiřtirmeli öğrenme tabanlı denetleyici ile benzetim çalışması yapılması sonucu elde edilmiş kontrol işareti zamana baęlı deęişim grafięi Şekil 4.7’de gösterilmiştir.



Şekil 4.7: Pekiřtirmeli öğrenme tabanlı denetleyici ile kontrolü geręekleştirilmiş sistemin zamana baęlı kontrol işareti

Yapılan benzetim çalışması sonucunda tez kapsamında tasarımı yapılan denetleyici sistemin kazanç parametrelerini, pekiştirmeli öğrenme alt algoritmalarından olan DDPG algoritması ile sistem şartlarını gözlemleyerek dinamik olarak değiştirmiştir. Pekiştirmeli öğrenme tabanlı denetleyici kullanılarak kontrolü gerçekleştirilmiş sisteme ait oransal kazanç parametresi “ K_r ” ve integral kazanç parametresi “ K_{ri} ” olmak üzere kazanç parametrelerinin zamana bağlı değişim grafiği Şekil 4.8’de gösterilmiştir. Şekil 4.8’de görüldüğü gibi kazanç parametreleri, sistemin farklı koşullar altındaki davranışına uyum sağlayabilmek adına sürekli olarak algoritma tarafından güncellenmektedir. Benzetim çalışmasının ilk aşaması olan klasik PI algoritması ile yapılmış kontrol işleminde Ziegler-Nichols osilasyon metodu ile belirlenmiş olan kazanç parametreleri başlangıç değeri olarak kullanılmış ve kazanç parametreleri değişim aralığı sistem kararlılığını bozmamak adına sınırlandırılmıştır.



Şekil 4.8: Pekiştirmeli öğrenme tabanlı denetleyici kazanç parametreleri zaman bağlı değişimi

4.4 Enerji Verimliliği İrdelemesi ve Bulguları

Tez çalışması kapsamında PID ve DDPG algoritması ile gerçekleştirilen kontrol stratejileri için fanın çalışma süresi boyunca güç tüketimi Denklem (21) ile hesaplanmıştır.


$$W_{fan} = \Delta P * \frac{\dot{V}}{\eta_{fan}} \quad (21)$$

Burada $\dot{V} = dV/dt$ kanal içerisindeki havanın hacimsel debisini η_{fan} ise fanın toplam verimini temsil etmektedir. Denklem (21) aracılığı ile W_{fan} fan güç tüketimi hesaplanabilir. Tez çalışması kapsamında ele alınan fanın motor verimi üretici firmanın da (Ebmpapst,2018) beyanıyla ortalama olarak %80 alınmıştır.

Yapılan benzetim çalışmaları ve elde edilen grafiklerden çıkarılmış bulgular doğrultusunda tez çalışması kapsamında çalışması yapılan kontrol algoritmasının kullanımıyla düşük salınım ile istenilen debi değerine ulaştığı ve Denklem (21) ile yapılan güç tüketim hesapları doğrultusunda enerji tüketimini azalttığı sonucuna varılmıştır. Yapılan her iki benzetim çalışmasından elde edilmiş güç tüketimleri kıyaslandığında, tez kapsamında üzerinde çalışılmış olan pekiştirmeli öğrenme tabanlı denetleyici ile kontrol işleminde klasik PI denetleyici ile kontrol işlemine kıyasla yaklaşık %6 enerji tasarrufu sağlanmıştır.

5.DENEYSEL ÇALIŞMA

Tez çalışması kapsamında ele alınan deney düzeneği Şekil 5.1 ile verilmiştir. Şekil 5.1 (a)'da düzeneğin yandan görünüşü, Şekil 5.1 (b)'da ise düzeneğin arkadan görünüşü verilmektedir.



Şekil 5.1: Deney düzeneği tasarımı ve boyutları, (a) önden görünüşü, (b) arkadan görünüşü

Şekil 5.1 ile tasarımı yapılmış deney düzeneği bir iklimlendirme firması bünyesinde kurulumu gerçekleştirilmiştir. Düzenek bir fan, bir havalandırma kanalı ve karşıt basınç yaratacak bir damperden oluşmaktadır. Düzeneğe MATLAB üzerinden veri alacak ve sensör verisini okuyacak bir PLC, bu PLC'ye debi bilgisi iletecek bir fark basınç sensörü takılmıştır.


İklimlendirme firması bünyesinde kurulan deney düzeneği Şekil 5.2'de gösterilmiştir. Düzenek 3 m uzunluğunda havalandırma kanalına sahip ve damper kesit ölçüleri 500 mm x 500 mm 'dir. Şekil 5.2 (a) ile düzeneğin yandan görünümü, Şekil 5.2 (b) ile düzeneğin önden görünümü, Şekil 5.2 (c) ile düzeneğin izometrik görüntüsü ve Şekil 5.2 (d) ile düzeneğe takılan damper gösterilmiştir.



(a)



(b)



(c)




(d)

Şekil 5.2: Deneý düzeneđi (a) yandan görünüm, (b) önden görünüm, (c) izometrik görünüm, (d) damper görünümü

Deneyel çalışmaya başlamadan önce düzeneğe takılmış olan PLC ile tez çalışmasında tasarımı yapılan MATLAB algoritmasını çalıştıracak olan bir bilgisayar Modbus TCP/IP protokolü ile haberleştirilmesi sağlanmıştır. Bu sayede düzeneğe takılan sensör verisi PLC tarafından algılanacak ve bir dijital sayıya dönüştürülüp MATLAB yazılımının çalıştırılacağı bilgisayara aktarılacaktır. MATLAB algoritması PLC' den aldığı sensör verisini işleyip programlanmış algoritma ile bir kontrol voltajı oluşturup PLC' ye aktaracaktır. PLC tarafından okunan kontrol voltaj verisi EC motorlu fana bütünleşik olan sürücüye iletilecek ve fanın değişken devirlerde kontrolü sağlanacaktır.

Deney düzeneği çalıştırılması Şekil 5.3'te gösterilmiştir. Şekil 5.3 (a) ile PLC ve bilgisayar arasındaki bağlantı, Şekil 5.3 (b) ile çalışma sırasında PLC ekranı üzerinde gösterilen değerler verilmiştir.




(a)



(b)

Şekil 5.3: Deney düzeneği: (a) PLC ile bilgisayar bağlantısı, (b) PLC ekranı

Düzenek üzerinde yerleştirilen fark basınç sensörü tasarımda olduğu şekilde “-“ ucu fan emiş ağzından itibaren 1 metre uzağa takılırken, “+” ucu ise boşta bırakılıp dış ortam ile kanal içindeki basınç farkı ölçülerek debi kontrolü gerçekleştirilmiştir. Düzeneğe takılan sensör ve montaj şekli, Şekil 5.4’te gösterilmiştir.



Şekil 5.4: Düzeneğe takılmış fark basınç sensörü ve montaj şekli

Düzenekte kullanılan ekipman ve sensör listesi Çizelge 5.1 ile verilmiştir. Çizelge 5.1’de düzenekte kullanılan sensörlerin ölçüm aralığı ve hassasiyeti verilmektedir.

Çizelge 5.1: Deney düzeneğinde kullanılmış elektronik ekipmanlar

Kullanılan Malzeme	Çalışma Voltajı	Ölçüm Aralığı	Ölçüm Hassasiyeti	Tepki Süresi
PLC	24V ~	0-10 V DC	< 50 mV @10 V	< 1 s
Fark Basınç Sensörü	24V ~	0-3000 Pa	±%3	1 s
EC Motorlu Fan	230V~	-	-	-

Tez kapsamında yapılan deneysel çalışma gerekleřtirilirken aynı benzetim alıřmalarında olduėu gibi 500 saniye boyunca deney srdrlmřtr.

Deneysel alıřmanın ilk etabında benzetim alıřmalarında da olduėu gibi kazanç parametreleri Ziegler-Nichols osilasyon metodu ile belirlenmiř klasik PI kontrol algoritması ile deney dzeneėindeki fanın hız kontrol iřlemi gerekleřtirilmiřtir. Deney dzeneėine baėlı bir PLC sensrden aldıėı verileri Modbus TCP/IP haberleřme protokol zerinde MATLAB yazılımına aktarmıř ve MATLAB yazılımı elde edilen verileri kullanarak klasik PI algoritmasını alıřtırmıřtır. MATLAB algoritması bir kontrol voltaj bilgisi reterek PLC' ye aktarmıřtır. PLC aldıėı kontrol voltaj bilgisini dzenekte bulunan EC motorlu fan srcsne iletmıř ve sistemi istenilen debi referans deėerinde tutmak iin fan devir kontroln gerekleřtirmiřtir. Bu iřlem 500 saniye boyunca kapalı dng ierisinde devam ettirilmiřtir. Elde edilen sonu ve bulgular kaydedilmiřtir.

Deneysel alıřmanın ikinci etabında ise yine aynı benzetim alıřmaların da tekrarlandıėı gibi tez kapsamında zerinde alıřılan pekiřtirmeli ėrenme tabanlı uyarlamalı denetleyici ile deney dzeneėinde bulunan fanın hız kontrol iřlemi gerekleřtirilmiřtir. Bir nceki ařamada kurulan haberleřme aėı yapısı korunmuř ve dzenekte yer alan PLC sensrden aldıėı bilgiyi MATLAB algoritmasına iletmıřtir. MATLAB algoritması sensr verisi ve hedef debi deėeri karřılařtırması yaparak hesapladıėı hata deėerini azaltmak zere kontrolcnn dinamik olarak kazanç parametrelerini gncellemiřtir. Algoritma bu veriler ıřıėında yeni oluřturduėu kontrol voltaj bilgisini PLC' ye aktarmıřtır. PLC aldıėı kontrol voltaj bilgisini EC motorlu fan srcsne ileterek sistemi istenilen debi referans deėerinde tutmak iin fan hız kontroln gerekleřtirmiřtir. Bu iřlem bir nceki adımda da olduėu gibi toplamda 500 saniye boyunca kapalı dng ierisinde devam ettirilmiřtir.

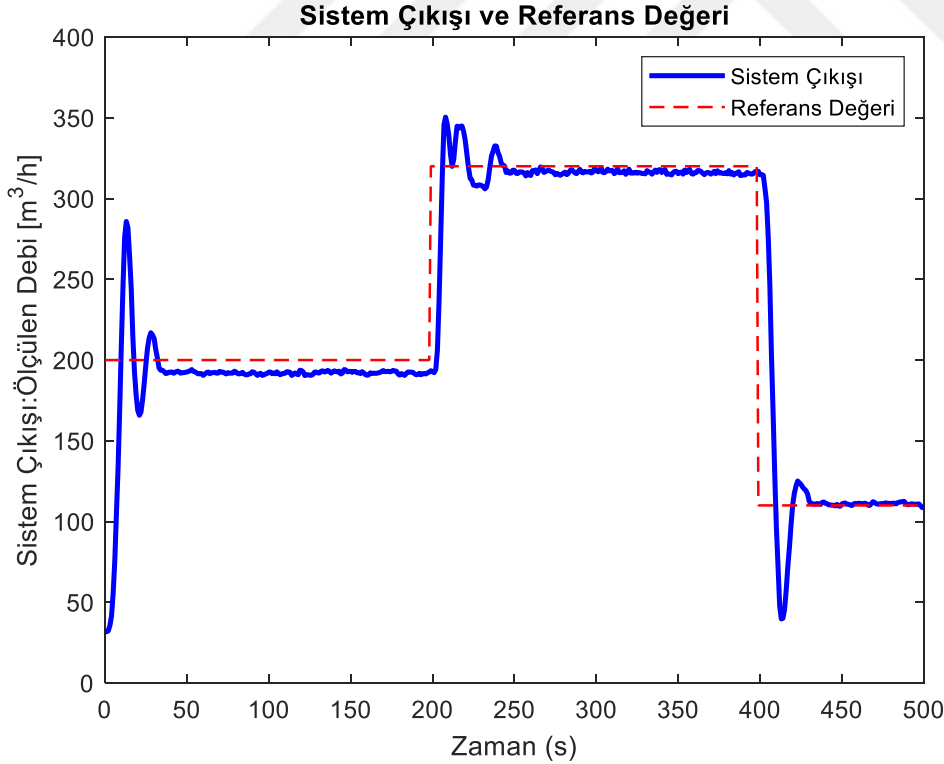
Deneysel alıřmalar gerekleřtirilirken sensr verisi ve MATLAB iřlem hızının senkron bir řekilde alıřmadıėı gzlemlenmiř daha saėlıklı bir kontrol voltajı retmek ve salınımı azaltmak adına algoritma boyunca her bir dngde kontrol voltajı oluřturulurken 0,5 saniye gecikme verilmiřtir.

5.1 Deneysel Çalışma Bulguları

Tez kapsamında gerçekleştirilmiş olan deneysel çalışmaları benzer şekilde benzetim çalışmaları ile aynı yöntem doğrultusunda gerçekleştirilmiş, (i) klasik PI denetleyici bulguları ve (ii) pekiştirmeli öğrenme tabanlı denetleyici bulguları olmak üzere iki ana başlık altında incelenmiştir.

5.1.1 Klasik PI Denetleyici Bulguları

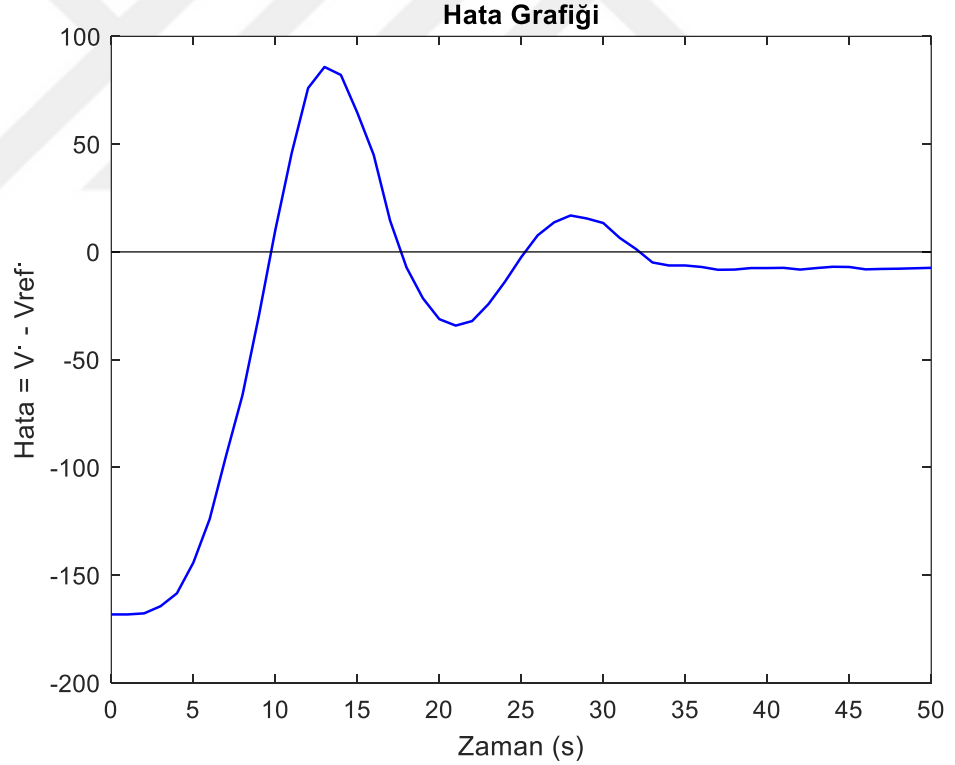
Tez çalışması kapsamında yapılan deneysel çalışmaların ilk aşamasında, kazanç parametreleri Ziegler-Nichols osilasyon metodu ile belirlenmiş klasik PI algoritması kullanılarak sistem kontrolü gerçekleştirilmiştir. Deneysel çalışma aynı benzetim çalışmasında olduğu gibi 500 saniye boyunca devam ettirilmiş, bu süre zarfında hedef debi değerleri belli aralıklarla değiştirilerek sistem dinamikleri değiştirilmiştir. Benzetim çalışması sonucu elde edilen debi- zaman grafiği Şekil 5.5' te gösterilmiştir.



Şekil 5.5: Klasik PI denetleyici ile kontrolü gerçekleştirilmiş deneysel sistemin debi-zaman grafiği

Şekil 5.5' te elde edilen grafik incelendiğinde; kazanç parametreleri Ziegler-Nichols osilasyon metodu elde edilmiş klasik PI denetleyici ile yapılan kontrol işleminde fan hedef debi değerine ulaşırken ilk sınır $200 \text{ m}^3/\text{h}$ debi değerini geçtiği sürede salınım yaptığı, belli süre sonunda hedef debiye yakın bir konuma ulaştığı ve bir sonraki hedef debi değerine kadar sabit bir devirde çalışmasına devam ettiği ancak bir sonraki hedef debi değerine kadar istenilen debi değerine tam olarak ulaşmadığı, benzer şekilde benzetim çalışmasının 200. saniyesinde sisteme tanımlanmış olan yeni hedef değeri olan $320 \text{ m}^3/\text{h}$ debi değerine ulaşmak için ilk etapta salınım yaptığı, daha sonra referans değere oturduğu ve bir sonraki hedef debi değerine kadar sabit devirde çalışmaya devam ettiği bulgusuna varılmıştır.

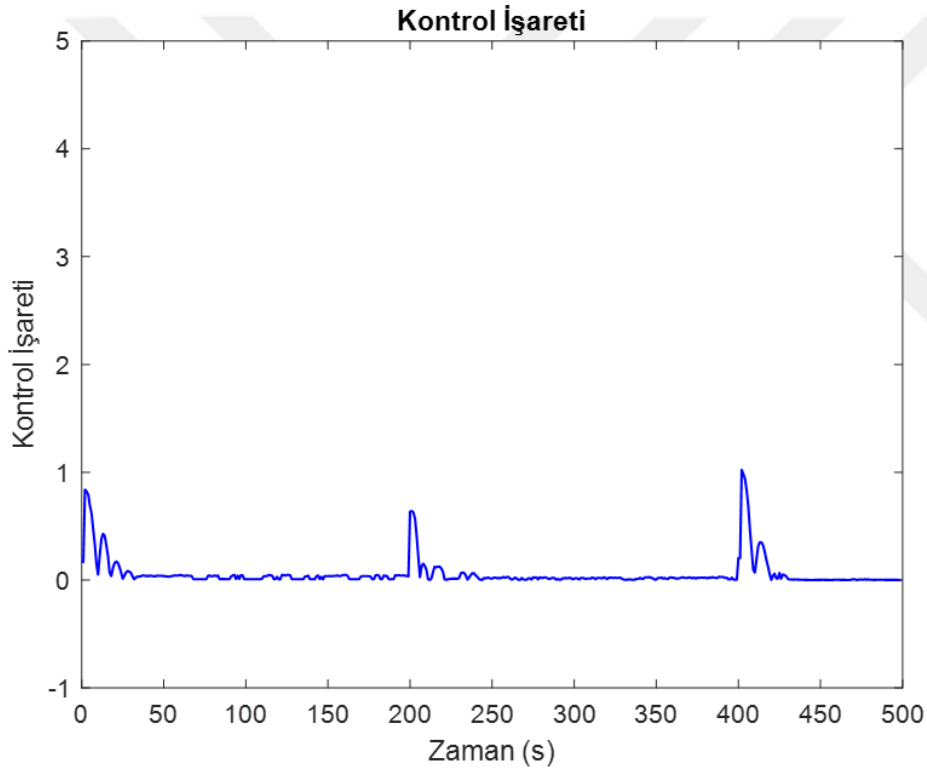
Klasik PI denetleyici ile yapılan deneysel çalışması sırasındaki 0. saniye ve 50. saniye arasındaki hata grafiği Şekil 5.6 ile gösterilmiştir.



Şekil 5.6: Klasik PI denetleyici ile kontrolü gerçekleştirilmiş deneysel sistemin 0. ve 50. saniye arasındaki hata grafiği

Şekil 5.6 ile verilmiş grafik incelendiğinde, fanın deneysel çalışması sırasında değiştirilmiş ilk debi değerine ulaşması sırasında yaklaşık 32 saniye boyunca salınım yaptığı 32 saniye sonunda hedef değere yaklaştığı bulgusuna varılmıştır. Deneysel çalışma boyunca fanın ilk debi değeri olan 200 m³/h ve üçüncü hedef değer olan 110 m³/h debi miktarına ulaşması sırasında da benzer bir sürelerde salınım yaptığı Şekil 5.5’ te görülmektedir.


Klasik PI denetleyici ile yapılan deneysel çalışma sonucu elde edilmiş kontrol işareti zamana bağlı değişim grafiği Şekil 5.7’ de gösterilmiştir.



Şekil 5.7: Klasik PI denetleyici ile kontrolü gerçekleştirilmiş deneysel sistemin zamana bağlı kontrol işareti

5.1.2 Pekiştirmeli Öğrenme Tabanlı Denetleyici Bulguları

Yapılan deneysel çalışmanın bir sonraki etabında, tez kapsamında tasarlanmış pekiştirmeli öğrenme tabanlı denetleyici algoritması kullanılarak sistem kontrolü gerçekleştirilmiş, deneysel çalışma 500 saniye boyunca devam ettirilmiş, bu süre zarfında hedef debi değerleri belli aralıklarla değiştirilerek sistem dinamikleri değiştirilmiştir. Benzetim çalışması sonucu elde edilen debi- zaman grafiği Şekil 5.8’ de gösterilmiştir.

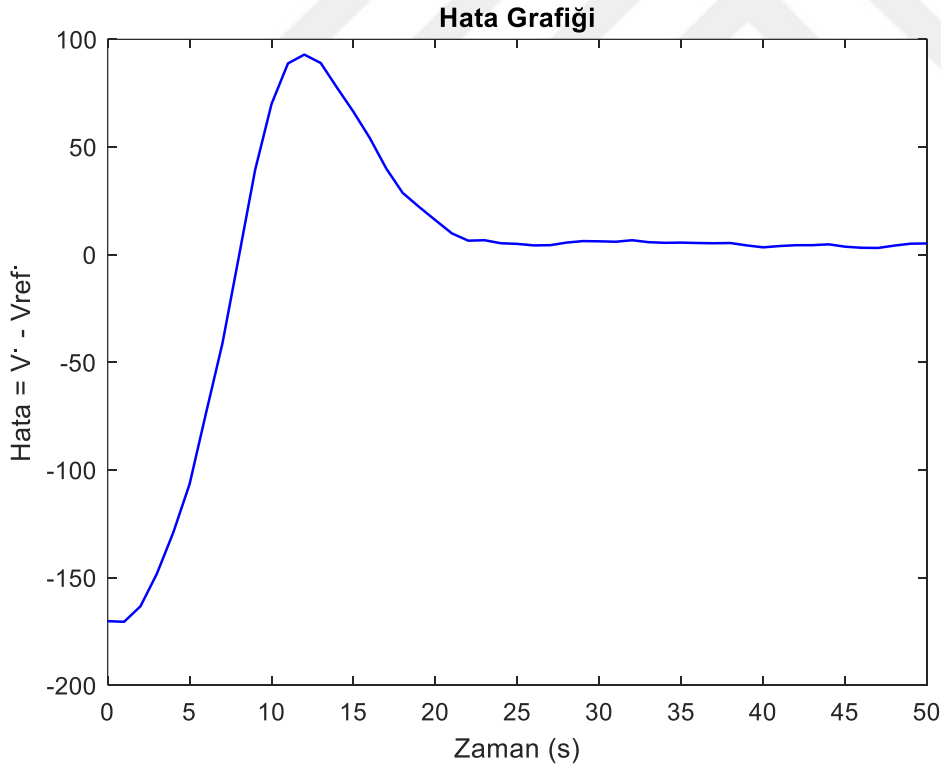


Şekil 5.8: Pekiştirmeli öğrenme tabanlı denetleyici ile kontrolü gerçekleştirilmiş deneysel sistemin debi-zaman grafiği

Şekil 5.8’ de elde edilen grafik incelendiğinde; kazanç parametreleri DDPG algoritması tarafından sistem değişken dinamikleri gözlemlenerek elde edilen uyarlamalı denetleyici kullanılarak deneysel çalışma gerçekleştirildiğinde, klasik PI kontrolcüye kıyasla istenilen hedef debi değerine daha az salınım yaparak ulaştığı, deneysel çalışma boyunca belli aralıkta hedef debi değiştirilmesine ve sistem dinamiklerinin değişmesine karşın kontrolcünün kazanç parametrelerini dinamik

olarak deęiřtirerek deęiřken sistem dinamiklerine uyum saęladığı gözlemlenmiştir. Deneysel çalışma sırasında pekiřtirmeli öğrenme tabanlı denetleyici ile yapılan kontrol işleminde fan hedef debi deęerine ulaşırken ilk sınır $200 \text{ m}^3/\text{h}$ debi deęerini geçtiği sürede salınım yaptığı ancak bu salınımın klasik PI denetleyici ile kontrole kıyasla gözle görülür şekilde daha az olduđu, belli süre sonunda hedef debiye ulařtığı ve bir sonraki hedef debi deęerine kadar sabit bir devirde çalışmasına devam ettiđi, benzer şekilde benzetim çalışmasının 200. saniyesinde sisteme tanımlanmış olan yeni hedef deęeri olan $320 \text{ m}^3/\text{h}$ debi deęerine ulaşmak için ilk etapta bir miktar salınım yaptığı, daha sonra referans deęere oturduđu ve bir sonraki hedef debi deęerine kadar sabit devirde çalışmaya devam ettiđi bulgusuna varılmıştır.

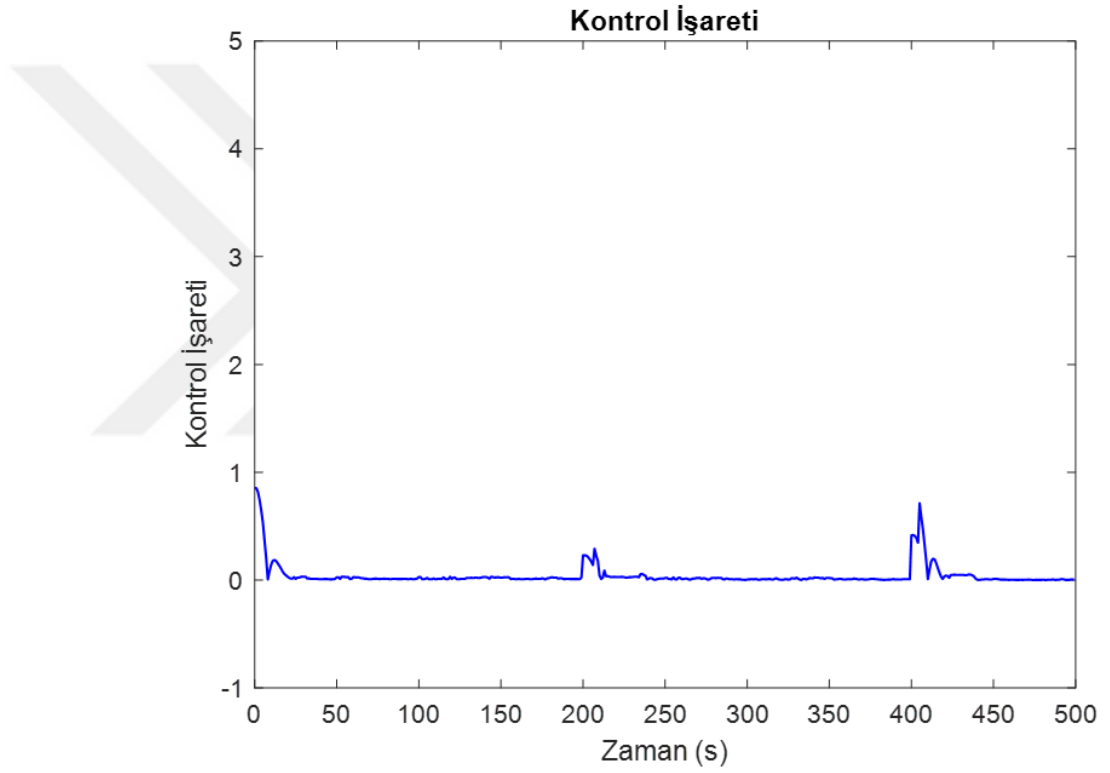
Pekiřtirmeli öğrenme tabanlı denetleyici ile yapılan deneysel çalışması sırasındaki 0. saniye ve 50. saniye arasındaki hata grafiđi Şekil 5.9 ile gösterilmiştir.



Şekil 5.9: Pekiřtirmeli öğrenme tabanlı denetleyici ile kontrolü gerçekleştirilmiş deneysel sistemin 0. ve 50. saniye arasındaki hata grafiđi

Şekil 5.9 ile verilmiş grafik incelendiğinde, fanın deneysel çalışması sırasında değiştirilmiş ilk debi değerine ulaşması sırasında yaklaşık 22 saniye boyunca salınım yaptığı 22 saniye sonunda hedef değere ulaştığı ve bu değerın klasik PI kontrolcüye kıyasla 10 saniye daha az olduğu bulgusuna varılmıştır.


Pekiştirmeli öğrenme tabanlı denetleyici ile yapılan deneysel çalışma sonucu elde edilmiş kontrol işareti zamana bağlı değişim grafiği Şekil 5.10' da gösterilmiştir.



Şekil 5.10: Pekiştirmeli öğrenme tabanlı denetleyici ile kontrolü gerçekleştirilmiş deneysel sistemin zamana bağlı kontrol işareti

Yapılan deneysel çalışma sonucunda tez kapsamında tasarımı yapılan uyarlamalı denetleyici aynı benzetim çalışmalarında olduğu gibi sistemin kazanç parametrelerini, pekiştirmeli öğrenme alt algoritmalarından olan DDPG algoritması ile sistem şartlarını gözlemleyerek dinamik olarak değiştirmiştir.

Pekiştirmeli öğrenme tabanlı denetleyici kullanılarak kontrolü gerçekleştirilmiş sisteme ait oransal kazanç parametresi “ K_r ” ve integral kazanç parametresi “ K_{ri} ” olmak üzere kazanç parametrelerinin zamana bağlı değişim grafiği Şekil 5.11’de gösterilmiştir. Benzetim çalışmalarında da olduğu gibi kazanç parametreleri, sistemin farklı koşullar altındaki davranışına uyum sağlayabilmek adına sürekli olarak algoritma tarafından güncellenmektedir. Fanın çalışma koşulu değişmediğinde kazanç parametrelerinin sabit kaldığı ancak değişken karşıt basınç altında ya da sistem hedef debi referans değeri değiştirildiğinde kazanç parametrelerinin algoritma tarafından değiştirildiği Şekil 5.11 ile görülebilir. Benzetim çalışmalarında da olduğu gibi kazanç parametreleri değişim aralığı sistem kararlılığını bozmamak adına sınırlandırılmıştır.



Şekil 5.11: Deneysel çalışmada pekiştirmeli öğrenme tabanlı denetleyici kazanç parametreleri zaman bağlı değişimi

6.TARTIŞMA VE YORUM

Bu tez çalışmasından elde edilmiş bulgularla belirtilen problemler göz önünde bulundurularak, havalandırma cihazlarında kullanılmak üzere pekiştirmeli öğrenme tabanlı uyarlamalı bir denetleyici tasarlanması ve sektöre uygulanması; havalandırma cihazlarının farklı dış statik basınç değerleri için fan debi kontrolünün otonom olarak optimizasyonunu gerçekleştirecek, insan faktöründen kaynaklı hataları azaltacak, üretilen havalandırma cihazlarının enerji verimliliğini artıracak ve cihazların ortamı daha hızlı bir şekilde adapte olmasına katkıda bulunacaktır. Öte yandan bilimsel yazında da gözlendiği gibi, endüstriyel kontrol işleminde kullanılan yenilikçi yapay zeka algoritmalarının bir kıyaslaması bu tez kapsamında da ele alınmış, elde edilen bulgular iklimlendirme sektöründe kullanım oranı olarak önemli bir paya sahip olan havalandırma cihazları özelinde bilimsel yazına kazandırılmıştır. Bu çıktılar ülkemiz ve dünya bilimsel gelişmesine katkıda bulunacaktır.

Bu tez kapsamında üzerinde çalışılmış olan bir diğer konu ise havalandırma ve iklimlendirme cihazlarının elektronik kontrolcüsü olan PLC' lerin gelişmiş matematiksel işlemleri yapabilen bir yazılım olan MATLAB programı ile haberleştirilme işleminin sektörel anlamda uygulanış yöntemlerini ve katkılarını bilimsel yazına katmış olmasıdır. Bu tez kapsamında yapılan deneysel çalışma ile özellikle iklimlendirme ve havalandırma cihazlarında kullanımı yaygın olan elektronik kontrolcülerin karmaşık matematik işlemlerini yapacak kütüphaneye sahip olmaması ve işlem gücünün yetersiz kalması sorununa bir çözüm önerisi sunulmuş, sistem verilerinin PLC hafızasında depolanması yerine haberleşme ağı üzerinden yerel sunucularda depolanmasına olanak tanımıştır.

7.SONUÇ

Bu tez kapsamında, iklimlendirme ve havalandırma sektöründe kullanılan elektronik kontrolcülerin sistem kontrolü için kullandıkları kontrol algoritmalarına yenilikçi yaklaşım olan makine öğrenmesi alt dallarından pekiştirmeli öğrenme tabanlı sistem değişken dinamiklerine uyum sağlayabilen uyarlamalı bir denetleyici algoritması üzerine çalışılmıştır. Bu tez kapsamında yapılan benzetim çalışmaları ve deneysel çalışmalarda bir havalandırma cihazı debi kontrolü ele alınmıştır. Yapılan hem benzetim çalışmalarında hem de deneysel çalışma da üzerinde çalışılan havalandırma sisteminin öncelikli olarak kazanç parametreleri Ziegler-Nichols osilasyon metodu kullanılarak elde edilmiş klasik PI denetleyici ile kontrolü gerçekleştirilmiş, ikinci etapta ise tez kapsamında tasarımı yapılan pekiştirmeli öğrenme tabanlı kontrol algoritması ile kontrol işlemi gerçekleştirilmiştir. Çalışma sonunda elde edilen sonuç ve bulgular ayrı başlıklar altında açıklanmıştır.

Yapılan benzetim çalışmaları ve deneysel çalışmalar sonucunda elde edilen bulgular gösteriyor ki tez çalışması kapsamında tasarlanan pekiştirmeli öğrenme tabanlı denetleyici algoritmasının klasik PI algoritmasına kıyasla hem benzetim çalışmalarında hem de deneysel çalışmada sistem hata değişimleri incelendiğinde istenilen hedef debi değerine daha az salınım yaparak ulaştırdığı, salınım miktarının az olması sebebi ile %6 oranında enerji tasarrufu sağladığı, fan çalışma süresi boyunca hedef debi referans değerlerinin değişmesine ve farklı dış basınç statik basınç değerlerine karşın sistemi uyarladığı, bu esnada kontrolcü kazanç parametrelerinin sisteme uyum sağlayacak şekilde sürekli olarak değiştirdiği sonucuna varılmıştır.

Tez çalışması kapsamında yapılan deneysel çalışmada sektörel anlamda endüstriyel kontrol sistemlerinde kullanılan PLC ile akademik alanda sık olarak kullanılan MATLAB yazılımı başarılı bir şekilde haberleştirilmiş, anlık olarak PLC verileri MATLAB yazılımına aktarılıp işlenerek çıktılar tekrar PLC' ye gönderilmiştir.

Günümüzde popüler olan yapay zeka algoritmaların bir diğer kullanım örneği bu çalışma ile iklimlendirme ve havalandırma cihazları özelinde bilimsel yazına kazandırılmış, üstünlükleri ve eksik yönleri ortaya konulmuştur.

8.ÖNERİLER

Bu tez çalışması sonucu elde edilen bulgular ışığında çalışmanın devamı niteliğinde aşağıdaki belirtilen konular özelinde çalışma sürdürülebilir;

- (i) Bu tez çalışması kapsamında tasarlanan pekiştirmeli öğrenme tabanlı denetleyici iklimlendirme ve havalandırma sistemleri özelinde sadece fan kontrolünde değil, sistem bütünü ele alındığında kompresör, kondenser fanları, damper motorları, vana motorları, genleşme vanası kontrolü ve ısıtıcı kontrollerinde kullanıldığı bir çalışma yapılabilir, deneysel bir düzenek ile sınırlı kalınmayıp gerçek bir iklimlendirme cihazı üzerinde test edilebilir.
- (ii) Bu tez çalışması kapsamında gerçekleştirilmiş olan MATLAB ile PLC haberleştirilme yöntemine alternatif olarak pekiştirmeli öğrenme algoritması doğrudan PLC cihazına programlanarak denetleme işlemi gerçekleştirilebilir ve bu tez kapsamında gerçekleştirilmiş deney düzeneğinde de gözlemlenen sensör kaynaklı dalgalanmaların önüne geçmek üzere bir çözüm üretilerek algoritmaya dahil edilebilir.
- (iii) Bu tez çalışması kapsamında değinilmiş olan yapay zeka yöntemlerinden makine öğrenmesinin alt dalı olan pekiştirmeli öğrenmenin bir algoritması olan DDPG algoritması yerine modelden bağımsız ve modele bağımlı diğer algoritmalar ile bir denetleyici tasarlanıp benzer fan kontrol işlemi gerçekleştirilerek elde edilen sonuçlar bu çalışmanın bulguları ile kıyaslanabilir.

KAYNAKLAR DİZİNİ

- Akay, R.**, 2006, Memetik Algoritma Kullanarak PID Denetleyici Tasarımı, Yüksek Lisans Tezi, Erciyes Üniversitesi, 123s (Yayınlanmamış).
- Aki, K., Dirik, A. E.**, 2020, Derin Öğrenme Tabanlı ve PID Kontrol Tabanlı Sürücüsüz Araç Sistemleri, Mühendislik Bilimleri ve Tasarım Dergisi, 8(5):306-316s.
- Aström, K. J., Hagglund, T.**, 1995, PID Cntrollers: Theory, Design, and Tuning, Instrument Society of America, USA, 343p.
- Aydın, B. M.**, 2022, Pekiştirmeli Öğrenme Yöntemi ile Optimal DC Motor Hız Kontrolcüsünün Tasarlanması, Yüksek Lisans Tezi, Sakarya Üniversitesi, 59s (yayınlanmamış).
- Belimo**, 2024, Catalog of Belimo Sensors , 20p.
- Budak, S., Sungur, C. ve Durdu, A.**, 2022, Pekiştirmeli Öğrenme ile Endüstriyel Proses Kontrolü, Fırat Üniversitesi Uzay ve Savunma Teknolojileri Dergisi, 1(1):370-374s.
- Control Tutorials for MATLAB and Simulink (CTMS)**,
<https://ctms.engin.umich.edu/CTMS/index.php?example=Introduction§ion=ControlPID> (Erişim tarihi: Mayıs 2023).
- Control Water Level in a Tank Using a DDPG Agent**,
<https://www.mathworks.com/help/reinforcement-learning/ug/control-water-level-usingddpg-agent.html> (Erişim tarihi: Mayıs 2024).
- Coşkun, M. Y. ve İtik, M.**, 2023, Elektrohidrolik bir sistemin pekiştirmeli öğrenme tabanlı denetleyici ile konum denetiminin gerçekleştirilmesi, Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi, 12(1):280-288s.
- Çengel, Y. A. and Cimbala, J. M.**, 2010, Fluid Mechanics: Fundamental and Applications (SI Units), Tata MCGraw Hill Education Private Limited, 1000p.
- Deep Deterministic Policy Gradient (DDPG) Agent**,
<https://www.mathworks.com/help/reinforcement-learning/ug/ddpg-agents.html> (Erişim tarihi: Mayıs 2024).

KAYNAKLAR DİZİNİ (devam)

- Doğan, M.**, 2006, Öz Ayarlamalı PID Kontrolör (PLC Uygulaması), Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi, 46s (Yayımlanmamış).
- Ebmpapbst**, 2018, EC Plug Fans in AHU Applications, 48p.
- Gidemen, G. ve Furat, M.**, 2015, PID Parametrelerinin Ayarlama Yöntemleri: 2. Derece Sistem Modeline Uygulanması ve Karşılaştırmalı Olarak Değerlendirilmesi, Çukurova Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi, 30(2):355-362s.
- Gilat, A., and Subramaniam, V.**, 2008, Numerical Methods for Engineers and Scientists – An Introduction with Applications Using MATLAB, John Wiley & Sons, USA, 459p.
- He, L., Li, P., Zhang, Y., Jing, H. and Gu, Z.**, 2023, Control strategy analysis of multistage speed compressor for vehicle air conditioning based on particle swarm optimization, Case Studies in Thermal Engineering, 47,103033, 17p.
- Jang, J. S. R., Sun, C. T. and Mizutani, E.**, 1997, Neuro-Fuzzy and Soft Computing, A Computational Approach to Learning and Machine Intelligence, Prentice Hall, New Jersey, 640p.
- Khuntia, S., Hanif, A., Singh, S. P. and Ahmed, Q.**, 2022, Control Oriented Model of Cabin HVAC System in a Long-Haul Trucks for Energy Management Applications, WCX SAE World Congress Experience, United States, 12p.
- Kılıç, E.**, 2022, Asenkron Motor Sürücülerinde Pekiştirmeli Öğrenme Tabanlı PI Hız Denetleyici Optimizasyonu, International Symposium on Advanced Engineering Technologies (ISADET), Kahramanmaraş, 7s.
- Kocakaya, T.**, 2023, Farklı CPU'lu PLC'lerin Hidrolik Oransal Valf Sisteminde PID Kontrol Performanslarının Karşılaştırılması, Yüksek Lisans Tezi, Karabük Üniversitesi, 100s (Yayımlanmamış).
- Li, S. E.**, 2023, Reinforcement Learning for Sequential Decision and Optimal Control, Springer, Beijing, 484p.

KAYNAKLAR DİZİNİ (devam)

- Müftü, S.**, 2023, İki Uzunlu Bir Robot Kolunun Pozisyon Kontrolü İçin Optimize Edilmiş PID Kontrolcü Tasarımı, Yüksek Lisans Tezi, Necmettin Erbakan Üniversitesi, 81s (Yayımlanmamış).
- Ogata, K.**, 2010, Modern Control Engineering Fifth Edition, Prentice Hall, Boston, 894p.
- Savaş, Y.**, 2020, Soğutma Sistemi ile Desteklenen Kapalı Devre Buhar Türbini Sisteminin Tasarımı ve Deneysel Araştırılması, Yüksek Lisans Tezi, Gazi Üniversitesi, 94s. (Yayımlanmamış)
- Siemens**, 2017, Catalog of Climatix Controller, 21p.
- Siemens**, 2020, Human Machine Interface Systems/ PC-based Automation, 806p.
- Solmaz, R., ve Alkan, A.**, 2017, Merkezi Isıtma Sistemlerinde Verimi Artırmak İçin Dinamik Kontrol ve Otomasyon Uygulaması, KSU Mühendislik Bilimleri Dergisi, 20(1):48-57s.
- Standart, EN 14511**, 2018, Air conditioners, liquid chilling packages and heat pumps, with electrically driven compressors, for space heating and cooling, European Committee for Standardization, CEN.
- Standart, EN 14825**, 2016, Air conditioners, liquid chilling packages and heat pumps, with electrically driven compressors, for space heating and cooling – Testing and rating at part load conditions and calculation of seasonal performance, European Committee for Standardization, CEN.
- Sugarman, S. C.**, 2020, HVAC Fundamentals, River Publishers, Gistrup, 508p.
- Sutton, R. S. and Barto, A. G.**, 2011, An introduction to reinforcement learning, The MIT Press, Cambridge, 551p.
- Şavaşçihabeş, A.**, 2008, Yapay Zeka Yöntemleri Kullanılarak PID Denetleyici Parametrelerinin Belirlenmesi, Yüksek Lisans Tezi, Erciyes Üniversitesi, 83s (Yayımlanmamış).
- T.P. Lillicrap, J.J. Hunt, A. Pritzel, N. Heess, T. Erez, Y. Tassa, D. Silver and D. Wierstra**, 2015, Continuous control with deep reinforcement learning, ICLR 2016, London, 14p.

KAYNAKLAR DİZİNİ (devam)**Train DDPG Agent for Path-Following Control,**

<https://www.mathworks.com/help/reinforcement-learning/ug/train-ddpg-agent-for-path-followingcontrol.html> (Erişim tarihi: Mayıs 2024).

Tüfekçi, A., Şimşek, R., Ö., Çalık, R., ve Kıvanç, Ö., C., 2023, Endüstriyel Fan Uygulamaları İçin Sürekli Miknatıslı Senkron Motorların Sensörsüz Kontrol Performanslarının Karşılaştırılması, TOK 2023, İstanbul, 6s.

Yavuzsoy, A., Sargın, H., Yaren, T. ve Kızır, S., 2023, Model Referans Uyarlamalı PID Denetleyici Tasarımı ve Denetleyici Parametrelerinin Sistem Davranışına Etki Analizi: DC Motor Konum Kontrolü, Konya Mühendislik Bilimleri Dergisi, 11(3):730-747s.

Yoon, M., Yi, D., Seo, M., and Ryu, S., 2022, Performance Prediction and Calibration of a Clean-Room Air Conditioner Using an Embedded Artificial Neural Network, International Air Conditioning Conference, Purdue University, 11p.

TEŐEKKÜR

Bu alıŐma sÜresince desteklerini esirgemeyen kıymetli danıŐman hocam Prof. Dr. Musa Alcı'ya, deneysel verilerin elde edilmesinde ve gerekli alt yapının hazırlanmasına katkıda bulunan DoĐu İklİmlendirme San. Ve Tic. A.Ő.'ye, tezin biçimlenmesinde deĐerli katkılarını aldığım Müh. Özdem Özel, Yük. Müh. Kadir OĐuzhan ÜnüŐtü, Müh. Eralp Erim ve Öğr. Gör. Tunahan AkıŐ'a teŐekkürü bir bor bilirim.

05 / 01 / 2025

Enes BİGA

ÖZGEÇMİŞ**KİŞİSEL BİLGİLER:**

Adı- Soyadı: Enes BİGA

EĞİTİM BİLGİLERİ:

Yükseklisans Ege Üniversitesi, Fen Bilimleri Enstitüsü, Elektrik Mühendisliği, 2025

Lisans Manisa Celal Bayar Üniversitesi, Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği, 2020

Lise Konak Selma Yiğit Alp Anadolu Lisesi, 2015

TEZDEN ÜRETİLMİŞ YAYINLAR:

Kongre Kitabı Havalandırma Sistemlerinde Elektronik Kontrolcüler İçin Uyarlamalı Denetleyici Tasarımı, 10th International Aegean Congress on Innovation Technologies & Engineering, İzmir, 2024, 195-204 pp.