

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

MAKİNE ÖĞRENMESİ TABANLI İÇ ORTAM SICAKLIK
KONTROLÜ İÇİN BİR SİMÜLATÖR YAZILIMI TASARIMI

YÜKSEK LİSANS TEZİ

Aydın BOSTANCI

Bilgisayar ve Bilişim Mühendisliği Anabilim Dalı

TEMMUZ 2024

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

MAKİNE ÖĞRENMESİ TABANLI İÇ ORTAM SICAKLIK
KONTROLÜ İÇİN BİR SİMÜLATÖR YAZILIMI TASARIMI

YÜKSEK LİSANS TEZİ

Aydın BOSTANCI

Bilgisayar ve Bilişim Mühendisliği Anabilim Dalı

Tez Danışmanı: Prof. Dr. Devrim AKGÜN

TEMMUZ 2024

Aydın BOSTANCI tarafından hazırlanan “Makine Öğrenmesi Tabanlı İç Ortam Sıcaklık Kontrolü için Bir Simülatör Yazılımı Tasarımı” adlı tez çalışması 29.07.2024 tarihinde aşağıdaki jüri tarafından oy birliği ile Sakarya Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar ve Bilişim Mühendisliği Anabilim Dalı’nda Yüksek Lisans tezi olarak kabul edilmiştir.

Tez Jürisi

Jüri Başkanı :	Doç. Dr. Süleyman UZUN Sakarya Uygulamalı Bilimler Üniversitesi	
Jüri Üyesi :	Prof. Dr. Devrim AKGÜN (Danışman) Sakarya Üniversitesi	
Jüri Üyesi :	Doç. Dr. Ünal ÇAVUŞOĞLU Sakarya Üniversitesi	



ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ

Sakarya Üniversitesi Fen Bilimleri Enstitüsü Lisansüstü Eğitim-Öğretim Yönetmeliğine ve Yükseköğretim Kurumları Bilimsel Araştırma ve Yayın Etiği Yönergesine uygun olarak hazırlamış olduğum “Makine Öğrenmesi Tabanlı İç Ortam Sıcaklık Kontrolü için Bir Simülatör Yazılımı Tasarımı” başlıklı tezin bana ait, özgün bir çalışma olduğunu; çalışmamın tüm aşamalarında yukarıda belirtilen yönetmelik ve yönergeye uygun davrandığımı, tezin içerdiği yenilik ve sonuçları başka bir yerden almadığımı, tezde kullandığım eserleri usulüne göre kaynak olarak gösterdiğimi, bu tezi başka bir bilim kuruluna akademik amaç ve unvan almak amacıyla vermediğimi ve 20.04.2016 tarihli Resmi Gazete’de yayımlanan Lisansüstü Eğitim ve Öğretim Yönetmeliğinin 9/2 ve 22/2 maddeleri gereğince Sakarya Üniversitesi’nin abonesi olduğu intihal yazılım programı kullanılarak Enstitü tarafından belirlenmiş ölçütlere uygun rapor alındığını, çalışmamla ilgili yaptığım bu beyana aykırı bir durumun ortaya çıkması halinde doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi beyan ederim.

(..../..../2024).

(imza)

Aydın BOSTANCI





Desteęini hiçbir zaman esirgemeyen Anneme, Babama ve Eşime ithaf ediyorum...



TEŞEKKÜR

Değerli danışmanım Prof. Dr. Devrim AKGÜN'e, bu tez çalışmasının her aşamasında bana yol gösteren, bilgi ve deneyimleriyle beni destekleyen, sabırla yanımda olan ve akademik gelişimime büyük katkı sağlayan değerli katkıları için en içten teşekkürlerimi sunarım.

Aydın BOSTANCI



İÇİNDEKİLER

Sayfa

ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ	v
TEŞEKKÜR	ix
İÇİNDEKİLER	xi
KISALTMALAR	xiii
SİMGELER	xv
TABLO LİSTESİ	xvii
ŞEKİL LİSTESİ	xix
ÖZET	xxi
SUMMARY	xxiii
1. GİRİŞ.....	1
1.1. Isıtma, Soğutma ve Havalandırma (HVAC) Sistemleri ve Enerji Verimliliği..	1
1.2. Makine Öğrenmesinin İç Ortam Sıcaklık Kontrolündeki Potansiyeli	1
1.3. Literatür Taraması	2
1.3.1 HVAC Sistemleri ve Enerji Verimliliği.....	2
1.3.2 Öğrenimi Tabanlı Kontrol Makine Algoritmaları.....	2
1.3.3 Geleneksel Kontrol Yöntemleri	3
1.3.4 Pekiştirmeli Öğrenme (Reinforcement Learning).....	3
1.3.5 Simülasyon Yazılımları.....	4
1.3.6 Kişiselleştirilmiş Termal Konfor	4
1.4. Tezin Amacı	5
1.5. Tezin Kapsamı.....	5
1.6. Hipotez	5
2. YÖNTEM.....	7
2.1. Veri Toplama ve Ön İşleme	7
2.2. Dış Ortam Sıcaklığı Verilerinin İnterpolasyonu	8
2.3. Özellik Mühendisliği	9
2.4. Kontrol Algoritmaları.....	9
2.4.1 Açık-Kapalı Kontrol	9
2.4.2 PID Kontrol.....	10
2.4.3. Q-Learning Algoritması	10
2.5. Simülatör Yazılımı	10
2.6. Performans Değerlendirme Metrikleri	12
2.7. Simülasyon Çıktıları.....	13
3. BULGULAR VE TARTIŞMA	15
3.1. Simülasyon Ortamı.....	15
3.2. Farklı Senaryolarda Simülasyon Sonuçları	15
3.3. Enerji Tüketimi, Konfor Düzeyi ve İç Ortam Hava Kalitesi Analizi.....	16
3.4. Karşılaştırmalı Analiz: Makine Öğrenmesi Tabanlı Kontrol ve Geleneksel Kontrol	17
3.5. Çalışmanın Sınırlamaları ve Gelecekteki Çalışmalara Yönelik Öneriler.....	26
4. SONUÇ VE ÖNERİLER.....	29

4.1. Tezin Özgün Katkıları	29
4.2. Gelecekteki Çalışmalar İçin Öneriler	29
KAYNAKLAR.....	31
EKLER.....	33
EK A. Termostat simülasyonu uygulaması yazılımı sözde kodu.....	34
ÖZGEÇMİŞ.....	37



KISALTMALAR

ANN	: Yapay Sinir Ağı
BMS	: Bina Yönetim Sistemleri
FLC	: Bulanık Mantık Kontrol
HVAC	: Isıtma, Soğutma ve Havalandırma
GA	: Genetik Algoritma
LSTM	: Uzun Kısa Dönem Bellek
PID	: Oransal İntegral Türev
RMSE	: Ortalama Karesel Hata
SVM	: Destek Vektör Makinesi
VAV	: Değişken Hava Hacmi
YSA	: Yapay Sinir Ağı



SİMGELER

C	: Termal Kapasitans [$J/^{\circ}C$]
dT/dt	: Sıcaklık Değişim Hızı [$^{\circ}C/s$]
Q_gain	: Isı Kazanımı [W]
Q_loss	: Isı Kaybı [W]
Kp	: Oransal Kazanç
Ki	: İntegral Kazanç
Kd	: Türev Kazanç
A	: Öğrenme Oranı
Γ	: İndirim Faktörü
E	: Keşif Oranı
$^{\circ}C$	: Derece Celsius



TABLO LİSTESİ

Sayfa

Tablo 3.1. Örnek senaryolar ve sonuçları.....	16
Tablo 3.2. Başlangıç Sıcaklığı 18°C Senaryosu parametreleri.	18
Tablo 3.3. Termostat Hassasiyeti 0,1°C Senaryosu parametreleri.	20
Tablo 3.4. Isı Kaybı 0,1°C/dakika Senaryosu parametreleri.	22
Tablo 3.5. 1440 Dakika Simülasyon Senaryosu parametreleri.	24





ŞEKİL LİSTESİ

Sayfa

Şekil 2.1. Veri ve parametre giriş ekranı.	8
Şekil 2.2. Dış ortam sıcaklığı grafiği.	9
Şekil 2.3. Tarayıcı üzerinden adres giriş ekranı.	11
Şekil 2.4. Uygulama ana ekranı ve çalışma süreci.	11
Şekil 3.1. Başlangıç Sıcaklığı 18°C Senaryosu oda sıcaklığı grafiği.	19
Şekil 3.2. Başlangıç Sıcaklığı 18°C Senaryosu konfor ve enerji tüketimi grafiği.	19
Şekil 3.3. Başlangıç Sıcaklığı 18°C Senaryosu toplam konfor grafiği.	20
Şekil 3.4. Termostat Hassasiyeti 0,1°C Senaryosu oda sıcaklığı grafiği.	21
Şekil 3.5. Termostat Hassasiyeti 0,1°C senaryosu konfor ve enerji tüketimi grafiği.	21
Şekil 3.6. Termostat Hassasiyeti 0,1°C Senaryosu toplam konfor grafiği.	22
Şekil 3.7. Isı Kaybı 0,1°C/dakika Senaryosu oda sıcaklığı grafiği.	23
Şekil 3.8. Isı Kaybı 0,1°C/dakika Senaryosu konfor ve enerji tüketimi grafiği.	23
Şekil 3.9. Isı Kaybı 0,1°C/dakika Senaryosu toplam konfor grafiği.	24
Şekil 3.10. 1440 Dakika Simülasyon Senaryosu oda sıcaklığı grafiği.	25
Şekil 3.11. 1440 Dakika Simülasyon Senaryosu konfor ve enerji tüketimi grafiği.	25
Şekil 3.12. 1440 Dakika Simülasyon Senaryosu toplam konfor grafiği.	26



MAKİNE ÖĞRENMESİ TABANLI İÇ ORTAM SICAKLIK KONTROLÜ İÇİN BİR SİMÜLATÖR YAZILIMI TASARIMI

ÖZET

Günümüzde binaların enerji tüketiminde önemli bir paya sahip olan Isıtma, Soğutma ve Havalandırma (HVAC) sistemlerinin optimizasyonu, enerji verimliliği ve kullanıcı konforunu artırmak için kritik öneme sahiptir. Bu çalışmada, iç ortam sıcaklık kontrolünün optimizasyonu amacıyla makine öğrenimi tabanlı bir kontrol algoritması olan Q-learning'in performansı, geleneksel Açık-Kapalı ve PID kontrol yöntemleriyle karşılaştırmalı olarak incelenmiştir.

Bu amaç doğrultusunda, dış hava sıcaklığı, güneş radyasyonu, iç ısı kazanımları ve bina yapısının termal özellikleri gibi çeşitli faktörleri dikkate alan bir simülatör yazılımı Python programlama dili kullanılarak geliştirilmiştir. Simülatörde, odanın termal dinamiği tek bölgeli bir model olarak kabul edilmiş ve 0.1 saniyelik zaman adımlarıyla 60 dakika ve 24 saatlik simülasyonlar gerçekleştirilmiştir. Farklı senaryolar altında, başlangıç oda sıcaklığı, termostat hassasiyeti, ısı kayıp oranı ve Q-learning eğitim bölümleri gibi parametreler değiştirilerek üç kontrol algoritmasının performansı değerlendirilmiştir. Performans karşılaştırmaları, enerji tüketimi (dolaylı olarak aşım ve alt geçiş süreleriyle değerlendirilmiştir), konfor seviyesi (aşım ve alt geçiş) ve iç ortam hava kalitesi gibi metrikler üzerinden gerçekleştirilmiştir.

Simülasyon sonuçları, Q-learning algoritmasının, özellikle uzun süreli simülasyonlarda (24 saat) ve değişken koşullar altında (ısı kaybı oranının yüksek olduğu durumlar), geleneksel yöntemlere göre daha iyi performans gösterdiğini ortaya koymuştur. Q-learning, daha düşük aşım ve alt geçiş değerlerine sahip olarak daha iyi bir konfor seviyesi ve daha düşük enerji tüketimi sağlamıştır. Bu bulgular, Q-learning'in iç ortam sıcaklık kontrol sistemlerinin optimizasyonunda kullanılmasının, enerji verimliliğini artırma ve kullanıcı konforunu iyileştirme potansiyelini doğrulamaktadır.

Tez çalışmasının özgün katkıları arasında, iç ortam sıcaklık kontrolü için Q-learning algoritmasının eğitimi ve optimizasyonu, farklı senaryolarda iç ortam sıcaklık kontrolünü simüle edebilen bir yazılımın geliştirilmesi, Q-learning, Açık-Kapalı ve PID kontrol yöntemlerinin performanslarının karşılaştırılması ve kullanılan Q-learning algoritmasının ve simülatör yazılımının açık kaynak kodlu olarak sunulması yer almaktadır.

Elde edilen sonuçlar, Q-learning gibi makine öğrenimi tabanlı kontrol algoritmalarının, HVAC sistemlerinin optimizasyonunda kullanılmasının, enerji verimliliğini artırma ve kullanıcı konforunu iyileştirme potansiyelini göstermiştir. Bu çalışma, gelecekteki akıllı bina kontrol sistemlerinin geliştirilmesine ve daha sürdürülebilir bir yapı stokunun oluşturulmasına katkı sağlayabilir.



DESIGN OF A SIMULATOR SOFTWARE FOR MACHINE LEARNING-BASED INDOOR TEMPERATURE CONTROL

SUMMARY

In the face of escalating global energy demands and the imperative for sustainable practices, the optimization of Heating, Ventilation, and Air Conditioning (HVAC) systems in buildings has emerged as a critical area of research. HVAC systems, while indispensable for maintaining suitable indoor environments, account for a substantial proportion of a building's energy consumption. The limitations of traditional control methods, often reliant on fixed setpoints and schedules, in adapting to dynamic environmental conditions and occupant preferences, have fueled the exploration of intelligent and adaptive control strategies. The integration of machine learning algorithms, particularly reinforcement learning, into HVAC control systems presents a promising avenue to address these challenges, paving the way for enhanced energy efficiency and personalized comfort experiences.

This thesis delves into the efficacy of Q-learning, a model-free reinforcement learning algorithm, in optimizing indoor temperature control systems. The central objective is to conduct a comparative analysis of Q-learning's performance against conventional control methods, namely On-off and Proportional-Integral-Derivative (PID) control. To facilitate this investigation, a simulator software has been meticulously developed in Python. This simulator incorporates a simplified room model that accounts for various factors influencing indoor temperatures, including external weather conditions, solar radiation, internal heat gains, and heat loss through the building envelope. The simulator's capabilities extend to simulating indoor temperature control under diverse scenarios, enabling a comprehensive evaluation of the impact of different control strategies on energy consumption, comfort levels (overshoot and undershoot), and indoor air quality. The simulator leverages the Streamlit library to provide a user-friendly interface, allowing for interactive visualization and exploration of simulation results. The simulator's design emphasizes flexibility, allowing users to manipulate various parameters such as initial room temperature, thermostat setpoint, heater power, heat loss rate, simulation duration, thermostat sensitivity, Q-learning training episodes, learning rate, discount factor, exploration rate, and PID parameters. This flexibility enables a thorough investigation of the control algorithms' performance under a wide range of operating conditions and scenarios.

The simulation results unequivocally demonstrate the superior performance of Q-learning, particularly in extended simulations and under dynamic conditions. Let's consider the scenario of a 1440-minute simulation with varying external temperatures and heat loss. In this scenario, Q-learning showcased its adaptive prowess by achieving a remarkably low total area of 13.41 °C-minutes, signifying minimal overshoot and undershoot, which directly translates to improved occupant comfort and reduced energy wastage. In stark contrast, the On-off control exhibited a total area of 368.00 °C-minutes, highlighting its susceptibility to temperature fluctuations and energy wastage due to its inherent binary control mechanism. The PID control, while

performing better than On-off, still lagged behind Q-learning with a total area of 12.68 °C-minutes, indicating its limitations in handling complex and dynamic environments. This compelling evidence underscores Q-learning's ability to learn and adapt to the environment, leading to superior temperature regulation, enhanced occupant comfort, and reduced energy consumption.

Furthermore, the Q-learning algorithm's performance was robust across different scenarios, showcasing its adaptability to varying initial room temperatures, thermostat sensitivities, and heat loss rates. The algorithm's ability to learn optimal control policies through trial and error, guided by a carefully designed reward function, enabled it to consistently outperform traditional methods. This adaptability is particularly crucial in real-world building environments where conditions are constantly changing due to factors such as occupancy, weather, and building usage patterns. The simulator software played a pivotal role in facilitating this comparative analysis, allowing for the systematic evaluation of the control algorithms under a wide range of conditions.

The contributions of this thesis are multifaceted. Firstly, it offers a comprehensive implementation and optimization of the Q-learning algorithm tailored for indoor temperature control, encompassing meticulous design and tuning of critical components such as state space, action space, reward function, and hyperparameters. Secondly, it presents a user-friendly simulator software, developed in Python and leveraging the Streamlit library, capable of simulating indoor temperature control under diverse scenarios. This simulator empowers researchers and engineers to evaluate the impact of different control strategies on energy consumption, comfort levels, and indoor air quality, facilitating the development and refinement of innovative control algorithms. The interactive nature of the simulator, enabled by Streamlit, promotes accessibility and encourages exploration of the complex dynamics of indoor temperature control systems. Thirdly, the thesis provides a rigorous comparative analysis of Q-learning, On-off, and PID control methods, elucidating the strengths and weaknesses of each approach under various scenarios, such as varying initial room temperatures, thermostat sensitivities, and heat loss rates. This analysis offers valuable insights into the performance trade-offs associated with different control strategies and guides the selection of the most suitable algorithm for specific building environments and operational requirements. Finally, the open-source nature of the Q-learning algorithm and simulator software fosters reproducibility and encourages further research and development in this field, promoting collaboration and knowledge sharing within the research community.

Literature Review

The literature review presented in this thesis provides a comprehensive overview of the current state-of-the-art in the field of indoor temperature control, energy efficiency, and machine learning. It highlights the growing interest in leveraging machine learning techniques to optimize HVAC systems and achieve a balance between energy efficiency and occupant comfort. The review explores the potential of various machine learning models, including deep reinforcement learning and artificial neural networks, in predicting indoor temperatures and optimizing HVAC control strategies. It also underscores the importance of simulation software in evaluating the performance of these models and control algorithms under different scenarios. Additionally, the literature review emphasizes the significance of personalized thermal comfort and its potential to further enhance energy efficiency and occupant satisfaction.

Findings of this Study

The findings of this study illuminate the potential of machine learning-based control algorithms, notably Q-learning, in revolutionizing HVAC systems for improved energy efficiency and occupant comfort. The developed simulator, with its user-friendly interface and ability to simulate diverse scenarios, serves as a valuable tool for researchers and engineers to explore and evaluate innovative control strategies. The comparative analysis provides compelling evidence of Q-learning's superiority over traditional methods, particularly in dynamic and long-duration scenarios.

Future Research Directions

Future research can further explore the potential of Q-learning and other advanced machine learning models in real-world building environments, paving the way for a new generation of intelligent and energy-efficient HVAC control systems. Further exploration of personalized thermal comfort models and the integration of Q-learning with other building control systems are also promising avenues for future research. The insights gained from this thesis can contribute to the development of more sustainable and comfortable buildings, aligning with the global goals of energy conservation and environmental protection.



1. GİRİŞ

1.1. Isıtma, Soğutma ve Havalandırma (HVAC) Sistemleri ve Enerji Verimliliği

İç ortam konforu, insanların binalarda sağlıklı, üretken ve keyifli bir şekilde yaşamaları ve çalışmalarını sürdürebilmeleri için kritik bir öneme sahiptir. Bu konforun sağlanmasında en önemli faktörlerden biri, iç ortam sıcaklığının uygun seviyelerde tutulmasıdır. Isıtma, Soğutma ve Havalandırma (HVAC) sistemleri, binalardaki iç ortam sıcaklığını, nemini ve hava kalitesini kontrol etmek için kullanılan karmaşık mekanizmalardır. Ancak, bu sistemler aynı zamanda binalardaki en büyük enerji tüketicilerinden biridir ve küresel enerji tüketiminin yaklaşık %40'ını oluşturmaktadır [1]. Bu nedenle, HVAC sistemlerinin optimizasyonu, enerji verimliliğini artırmak, işletme maliyetlerini düşürmek ve çevresel etkileri azaltmak için büyük önem taşımaktadır.

Enerji verimliliği, HVAC sistemlerinin tasarımından işletimine kadar her aşamada dikkate alınması gereken bir önceliktir. Geleneksel HVAC sistemleri, genellikle sabit ayar noktalarına ve zaman çizelgelerine dayalı olarak çalışır. Bu yaklaşım, iç ve dış ortam koşullarındaki değişimlere hızlı bir şekilde uyum sağlayamama, gereksiz enerji tüketimi ve kullanıcı konforunda azalma gibi sorunlara yol açabilir. Bu nedenle, HVAC sistemlerinin optimizasyonu için daha akıllı ve uyarlanabilir kontrol stratejilerine ihtiyaç duyulmaktadır.

1.2. Makine Öğrenmesinin İç Ortam Sıcaklık Kontrolündeki Potansiyeli

Son yıllarda, makine öğrenimi teknikleri, HVAC sistemlerinin kontrolünü optimize etmek için umut verici bir çözüm olarak ortaya çıkmıştır. Makine öğrenimi, bilgisayar sistemlerinin açıkça programlanmadan veri analizi yoluyla öğrenmelerini sağlayan bir yapay zekâ dalıdır. Bu teknikler, büyük miktarda veriyi analiz ederek iç ortam sıcaklıklarını etkileyen faktörler arasındaki karmaşık ilişkileri öğrenebilir ve gelecekteki sıcaklıkları tahmin edebilir. Bu tahminler, HVAC sistemlerinin kontrolünü optimize etmek, enerji tüketimini azaltmak ve kullanıcı konforunu artırmak için kullanılabilir.

Makine öğrenimi tabanlı kontrol algoritmaları, geleneksel yöntemlere göre bir dizi avantaja sahiptir. Öncelikle, bu algoritmalar, iç ve dış ortam koşullarındaki değişimlere hızlı bir şekilde uyum sağlayabilir ve HVAC sistemlerinin çalışma parametrelerini buna göre ayarlayabilir. Bu, enerji tasarrufu sağlar ve kullanıcı konforunu artırır. İkinci olarak, makine öğrenimi algoritmaları, bina sakinlerinin tercihlerini ve davranışlarını öğrenebilir ve iç ortam sıcaklık kontrolünü kişiselleştirebilir. Bu, kullanıcı memnuniyetini artırır ve enerji israfını önler. Son olarak, makine öğrenimi tabanlı kontrol algoritmaları, HVAC sistemlerinin arıza tespiti ve önleyici bakım gibi konularda da kullanılabilir. Bu, sistemlerin daha güvenilir ve verimli bir şekilde çalışmasını sağlar.

1.3. Literatür Taraması

İç ortam sıcaklık kontrolü, enerji verimliliği ve kullanıcı konforu arasındaki hassas dengeyi sağlamak, modern bina yönetim sistemlerinin (BMS) temel hedeflerinden biridir. Bu hedefe ulaşmak için geleneksel yöntemlerin yanı sıra, son yıllarda makine öğrenimi tabanlı kontrol algoritmaları da büyük ilgi görmektedir. Bu bölümde, iç ortam sıcaklık kontrolü, enerji verimliliği, makine öğrenimi ve pekiştirmeli öğrenme alanlarındaki literatür detaylı bir şekilde incelenecek ve bu çalışmaların tez kapsamındaki konuma katkıları değerlendirilecektir.

1.3.1 HVAC sistemleri ve enerji verimliliği

HVAC (Isıtma, Soğutma ve Havalandırma) sistemleri, binalardaki enerji tüketiminin önemli bir bölümünü oluşturur. Bu nedenle, enerji verimliliği, HVAC sistemlerinin tasarımından işletimine kadar her aşamada dikkate alınması gereken kritik bir faktördür. Geleneksel HVAC kontrol yöntemleri, genellikle bina sakinlerinin konforunu sağlamak için önceden belirlenmiş kurallar veya zamanlamalar kullanır. Ancak, bu yöntemler değişken dış hava koşullarına, bina doluluk oranlarına ve iç ısı kazanımlarına yeterince uyum sağlayamayabilir, bu da enerji israfına ve konforsuzluğa yol açabilir [3].

1.3.2 Öğrenimi tabanlı kontrol makine algoritmaları

Makine öğrenimi, bilgisayar sistemlerinin açıkça programlanmadan veri analizi yoluyla öğrenmelerini sağlayan bir yapay zekâ dalıdır. Bu teknikler, iç ortam sıcaklıklarını etkileyen faktörler arasındaki karmaşık ilişkileri modelleyebilir ve

gelecekteki sıcaklıkları tahmin etmek için kullanılabilir. Bu tahminler, HVAC sistemlerinin kontrolünü optimize etmek, enerji tüketimini azaltmak ve kullanıcı konforunu artırmak için kullanılabilir [1, 4].

Literatürde, makine öğrenimi tabanlı kontrol algoritmalarının HVAC sistemlerinin performansını artırma potansiyelini gösteren çeşitli çalışmalar bulunmaktadır. Örneğin, Wang ve diğerleri (2022), makine öğrenimi tabanlı tahmin modellerinin HVAC sistemlerinin kontrolünde kullanılmasının enerji tasarrufu ve konfor optimizasyonu açısından önemli faydalar sağlayabileceğini göstermiştir [1]. Benzer şekilde, Shin ve diğerleri (2024), hava durumu tahmin verilerini kullanan derin pekiştirmeli öğrenme algoritmalarının HVAC sistem kontrolünde enerji tasarrufu potansiyelini ortaya koymuştur [6].

1.3.3 Geleneksel Kontrol Yöntemleri

Geleneksel kontrol yöntemleri, HVAC sistemlerinin kontrolünde yaygın olarak kullanılan yaklaşımlardır. Bu yöntemler arasında Açık-Kapalı kontrol, Oransal İntegral Türev (PID) kontrol gibi basit geri besleme kontrol mekanizmaları bulunur. Açık-Kapalı kontrol, sıcaklık belirli bir eşik değerinin altına düştüğünde ısıtma sistemini açar ve belirli bir eşik değerinin üzerine çıktığında kapatır. PID kontrol ise, hata sinyalinin oransal, integral ve türev bileşenlerini kullanarak daha hassas bir kontrol sağlar [11].

Geleneksel kontrol yöntemleri, basitlikleri ve kolay uygulanabilirlikleri nedeniyle yaygın olarak kullanılmaktadır. Ancak, bu yöntemler değişken koşullara uyum sağlamakta zorlanabilir ve enerji verimliliği açısından optimal sonuçlar vermeyebilir.

1.3.4 Pekiştirmeli Öğrenme (Reinforcement Learning)

Pekiştirmeli öğrenme, bir ajanın bir ortamla etkileşim kurarak deneme yanılma yoluyla öğrenmesini sağlayan bir makine öğrenimi yöntemidir. Bu yöntemde, ajan, belirli bir durumda yaptığı eylemler sonucunda aldığı ödüller ve cezalar aracılığıyla öğrenir ve zamanla en yüksek ödülü elde etmek için en iyi eylem stratejisini (politika) geliştirmeye çalışır.

Pekiştirmeli öğrenme, HVAC sistemlerinin kontrolünde de kullanılmaktadır. Örneğin, Wang ve diğerleri (2024), derin pekiştirmeli öğrenme kullanarak çok bölgeli açık ofislerde HVAC kontrolünü optimize etmiş ve enerji tüketiminde %37'ye varan

tasarruf sağlamıştır [7]. Bu tür çalışmalar, pekiştirmeli öğrenmenin HVAC sistemlerinin performansını artırma potansiyelini göstermektedir.

1.3.5 Simülasyon Yazılımları

Simülasyon yazılımları, HVAC sistemlerinin davranışını modellemek ve farklı kontrol stratejilerinin etkilerini değerlendirmek için önemli araçlardır. Bu yazılımlar, gerçek dünya verileri üzerinde eğitim almadan önce makine öğrenimi modellerinin test edilmesine olanak tanır ve böylece modellerin performansının değerlendirilmesi ve iyileştirilmesini sağlar [5]. Ayrıca, farklı kontrol stratejilerinin etkilerini değerlendirmek ve optimal stratejileri belirlemek için de kullanılabilirler.

1.3.6 Kişiselleştirilmiş Termal Konfor

Kişiselleştirilmiş termal konfor, bireylerin termal ortamlarla ilgili kişisel tercihlerini ve ihtiyaçlarını dikkate alarak iç ortam koşullarının optimize edilmesini ifade eder. Geleneksel HVAC sistemleri, genellikle tüm bina veya bölge için tek bir ayar noktası kullanarak ortalama bir konfor seviyesi sağlamaya çalışır. Ancak, bireyler arasındaki metabolik hız, giyim, aktivite seviyesi ve termal algıdaki farklılıklar nedeniyle, bu yaklaşım herkes için ideal konfor koşullarını sağlamayabilir. Kişiselleştirilmiş termal konfor, bireylerin kendi termal tercihlerini belirlemelerine ve kontrol etmelerine olanak tanıyarak hem enerji verimliliğini artırır hem de kullanıcı memnuniyetini yükseltir.

Bu alanda yapılan çalışmalar, kişiselleştirilmiş termal konforun sağlanmasında farklı yöntemler ve teknolojiler kullanıldığını göstermektedir. Örneğin, giyilebilir sensörler ve akıllı telefon uygulamaları, bireylerin termal algılarını ve tercihlerini gerçek zamanlı olarak izleyebilir ve bu bilgileri HVAC sistemlerine iletebilir. Ayrıca, makine öğrenimi algoritmaları, bireylerin termal tercihlerini ve davranışlarını öğrenerek kişiselleştirilmiş kontrol stratejileri geliştirebilir.

Ancak, kişiselleştirilmiş termal konforun sağlanması bazı zorlukları da beraberinde getirmektedir. Bireylerin termal tercihlerinin sürekli olarak değişebilmesi, kontrol sistemlerinin bu değişimlere hızlı ve doğru bir şekilde uyum sağlamasını gerektirir. Ayrıca, çok sayıda kullanıcının bulunduğu binalarda, kişiselleştirilmiş konforun sağlanması karmaşık bir optimizasyon problemi haline gelebilir. Bu nedenle, bu alanda yapılacak gelecek çalışmaların, bu zorlukların üstesinden gelebilecek yeni yöntemler ve teknolojiler geliştirmesi beklenmektedir.

1.4. Tezin Amacı

Bu tez çalışmasının temel amacı, iç ortam sıcaklık kontrol sistemlerinin optimizasyonunda makine öğrenimi tabanlı bir kontrol algoritması olan Q-learning'in etkinliğini araştırmaktır. Bu amaç doğrultusunda, iç ortam sıcaklıklarını etkileyen çeşitli faktörleri (dış hava sıcaklığı, güneş radyasyonu, nem, bina özellikleri vb.) dikkate alan bir simülatör yazılımı geliştirilecektir. Geliştirilen bu simülatör üzerinde Q-learning algoritması, geleneksel Açık-Kapalı ve PID kontrol yöntemleriyle karşılaştırılarak performansı değerlendirilecektir.

1.5. Tezin Kapsamı

Bu tez çalışması, aşağıdaki konuları kapsamında ele alacaktır:

- İç ortam sıcaklık kontrol sistemlerinden elde edilen verilerin toplanması, temizlenmesi ve analiz için hazırlanması
- Veri setindeki özelliklerden yeni özellikler türetilmesi ve bu özelliklerin makine öğrenimi modellerinin performansına etkisinin incelenmesi
- Q-learning algoritmasının iç ortam sıcaklık kontrolü için eğitimi ve optimizasyonu
- Geliştirilen simülatör yazılımı kullanılarak Q-learning, Açık-Kapalı ve PID kontrol yöntemlerinin performanslarının karşılaştırılması. Karşılaştırma, enerji tüketimi, konfor seviyesi ve iç ortam hava kalitesi gibi farklı metrikler üzerinden yapılacaktır.

1.6. Hipotez

Bu tez çalışmasında, Q-learning tabanlı iç ortam sıcaklık kontrol algoritmasının, geleneksel Açık-Kapalı ve PID kontrol yöntemlerine kıyasla daha iyi performans göstereceği ve enerji tüketimini azaltmada, kullanıcı konforunu artırmada ve iç ortam hava kalitesini iyileştirmede önemli bir rol oynayacağı hipotezi öne sürülmektedir.



2. YÖNTEM

Bu bölümde, iç ortam sıcaklık kontrolü için makine öğrenmesi tabanlı bir simülatör yazılımı geliştirmek amacıyla izlenen yöntemler ve kullanılan teknikler ayrıntılı bir şekilde açıklanmaktadır.

2.1. Veri Toplama ve Ön İşleme

İç ortam sıcaklık kontrol sistemlerinden elde edilen veriler, simülatör yazılımının eğitimi ve değerlendirilmesi için temel oluşturmaktadır. Bu veriler, çeşitli sensörler aracılığıyla gerçek binalardan veya simülasyon yazılımları kullanılarak toplanabilir. Bu tez çalışmasında, simülasyon ortamı kullanılarak veri toplanmıştır. Simülasyon ortamı, dış ortam sıcaklığı, güneş radyasyonu, iç ısı kazanımları ve bina zarfından ısı kaybı gibi faktörlerden etkilenen, basitleştirilmiş bir oda modelini içermektedir. Odanın termal dinamiği, aşağıdaki denklem 2.1’de ifade edilen tek bölgeli bir model olarak kabul edilmiştir:

$$C * dT/dt = Q_{\text{gain}} - Q_{\text{loss}} \quad (2.1)$$

Burada, C odanın ısıl kapasitansını (J/°C), T oda sıcaklığını (°C), t zamanı (saniye), Q_{gain} ısı kazanım hızını (W) ve Q_{loss} ısı kaybı hızını (W) temsil etmektedir. Isı kazanım hızı (Q_{gain}), ısıtıcı tarafından üretilen ısı ve iç ısı kazanımlarının (örneğin, kişilerden veya cihazlardan) toplamı olarak hesaplanmıştır. Isı kaybı hızı (Q_{loss}) ise oda ile dış ortam arasındaki sıcaklık farkına ve bina zarfının ısıl direncine bağlı olarak hesaplanmıştır.

Toplanan veriler, makine öğrenimi algoritmalarına uygun hale getirilmek üzere ön işleme tabi tutulmuştur. Bu adımda, aykırı değerlerin tespiti ve düzeltilmesi, veri normalizasyonu ve özellik ölçeklendirme gibi işlemler gerçekleştirilmiştir. Veri ön işleme, makine öğrenimi modellerinin performansını artırmak için kritik bir adımdır [14]. Özellikle, verilerin temizlenmesi ve eksik değerlerin tamamlanması, modellerin eğitim sürecinde daha doğru sonuçlar elde etmesini sağlar. Veri normalizasyonu ve özellik ölçeklendirme ise, farklı ölçeklerde olan özelliklerin modeller tarafından eşit


şekilde değerlendirilmesini sağlar, bu da modelin öğrenme sürecini hızlandırır ve performansını artırır.

2.2. Dış Ortam Sıcaklığı Verilerinin İnterpolasyonu

Simülasyon ortamında, dış ortam sıcaklığı verilerinin farklı zaman adımlarında değerlendirilmesi gerekebilir. Bu çalışmada, dış ortam sıcaklığı verilerinin daha düzgün bir şekilde temsil edilmesi ve simülasyonların daha gerçekçi sonuçlar üretmesi için Kübik Spline interpolasyonu kullanılmıştır. Kübik Spline interpolasyonu, veri noktaları arasında düzgün ve sürekli bir eğri oluşturarak, ara değerlerin daha doğru bir şekilde tahmin edilmesini sağlar. Kübik Spline interpolasyonu için veri girişi yaptığımız ekran simülatör uygulaması ekranı aşağıdaki Şekil 2.1’de görüldüğü gibi olup örnek veri girişi ile uygulamanın oluşturduğu dış ortam sıcaklığı grafiği Şekil 2.2’de görüldüğü gibidir.

Şekil 2.1. Veri ve parametre giriş ekranı.

Dış Ortam Sıcaklığı Grafiği



Şekil 2.2. Dış ortam sıcaklığı grafiği.

2.3. Özellik Mühendisliği

Veri setindeki özelliklerden yeni özellikler türetilerek, makine öğrenimi modellerinin performansını daha da artırmak hedeflenmiştir [15]. Örneğin, zaman değişkeninden günün saati, haftanın günü gibi özellikler elde edilebilir. Ayrıca, dış hava sıcaklığı ve güneş radyasyonu gibi değişkenler arasındaki etkileşimleri temsil eden yeni özellikler de oluşturulabilir. Özellik mühendisliği, makine öğrenimi modellerinin öğrenme kapasitesini artırabilir ve daha iyi tahminler yapmalarını sağlayabilir.

2.4. Kontrol Algoritmaları

Bu tez çalışmasında, iç ortam sıcaklık kontrolü için üç farklı kontrol algoritması kullanılmıştır: Açık-Kapalı kontrol, PID kontrol ve Q-learning algoritması. Bu algoritmaların her biri, farklı yaklaşımlar kullanarak iç ortam sıcaklığını istenen seviyede tutmaya çalışır.

2.4.1 Açık-kapalı kontrol

Açık-Kapalı kontrol, en basit termostat kontrol algoritmasıdır. Bu algoritma, iç ortam sıcaklığı belirli bir eşik değerinin altına düştüğünde ısıtma sistemini açar ve belirli bir eşik değerinin üzerine çıktığında kapatır. Uygulaması kolay ve uygun maliyetli olsa da Açık-Kapalı kontrol, sıcaklık dalgalanmalarına ve enerji israfına yol açabilir.

2.4.2 PID kontrol

Oransal İntegral Türev (PID) kontrol, hata sinyalinin oransal, integral ve türev bileşenlerini kullanarak daha hassas bir kontrol sağlar. PID kontrol, istenen ve gerçek sıcaklıklar arasındaki hatayı, zaman içinde biriken hatayı (integral) ve hatanın değişim oranını (türev) dikkate alır. HVAC sisteminin çıkışını bu faktörlere göre ayarlayarak, PID kontrol daha hassas sıcaklık regülasyonu sağlayabilir ve Açık-Kapalı kontrole kıyasla enerji verimliliğini potansiyel olarak artırabilir.

PID kontrolün performansı, K_p (oransal kazanç), K_i (integral kazanç) ve K_d (türev kazanç) parametrelerinin doğru bir şekilde ayarlanmasına bağlıdır. Bu parametreler, sistemin dinamiklerine ve kontrol hedeflerine göre belirlenmelidir. Özellikle, ısı kayıp oranının arttığı durumlarda, PID parametrelerinin yeniden ayarlanması gerekebilir. Bu çalışmada, PID parametreleri, farklı ısı kayıp oranları için optimize edilerek sistemin tutarlı bir performans göstermesi sağlanmıştır.

2.4.3. Q-Learning algoritması

Q-learning, bir pekiştirmeli öğrenme algoritmasıdır. Bu algoritma, bir ajanın bir ortamla etkileşim kurarak deneme yanılma yoluyla öğrenmesini sağlar. Q-learning'de, ajan, belirli bir durumda yaptığı eylemler sonucunda aldığı ödüller ve cezalar aracılığıyla öğrenir ve zamanla en yüksek ödülü elde etmek için en iyi eylem stratejisini (politika) geliştirmeye çalışır. Bu tez çalışmasında, Q-learning algoritması, iç ortam sıcaklık kontrolü için eğitilmiş ve optimize edilmiştir.

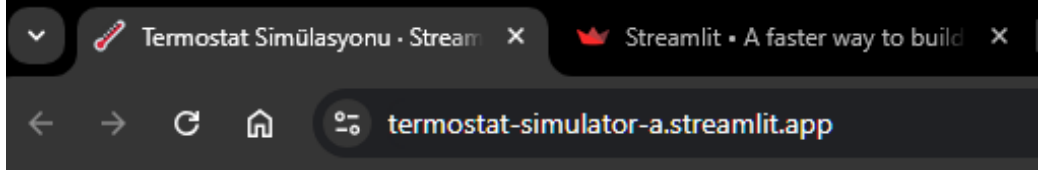
2.5. Simülatör Yazılımı

Bu tez çalışmasında, farklı senaryolarda iç ortam sıcaklık kontrolünü simüle edebilen bir yazılım, Python programlama dili kullanılarak geliştirilmiştir. Geliştirilen bu simülatör yazılımı, kullanıcı dostu bir arayüze sahip olmakla birlikte, farklı hava koşulları, farklı bina özellikleri ve farklı kontrol stratejileri gibi çeşitli senaryolarda iç ortam sıcaklık kontrolünü simüle edebilmektedir. Simülasyonlar, 0.1 saniyelik zaman adımlarıyla 7200 saniye (120 dakika) veya 86400 saniye (1440 dakika) boyunca gerçekleştirilmiştir.

Simülatörün geliştirilmesinde, aşağıdaki Python kütüphanelerinden yararlanılmıştır:

- **Streamlit:** Kullanıcı arayüzünün oluşturulması ve simülasyon sonuçlarının etkileşimli bir şekilde görüntülenmesi için kullanılan açık kaynaklı bir web

uygulaması çerçevesidir (<https://streamlit.io/>). Streamlit, Python kodunu web uygulamalarına dönüştürerek, kullanıcıların simülasyon parametrelerini kolayca değiştirmesine ve sonuçları gerçek zamanlı olarak gözlemlemesine olanak tanır. Uygulamanın tarayıcı üzerinden adres girişi Şekil 2.3'teki gibi olup uygulama ana ekranı ve çalışma süreci Şekil 2.4'teki gibidir.



Şekil 2.3. Tarayıcı üzerinden adres giriş ekranı.

Termostat Simülasyonu

Kontrol Algoritmalarının Karşılaştırılması

Bu interaktif simülasyon, oda sıcaklığını korumak için farklı kontrol algoritmalarının performansını karşılaştırır.

Simülasyon

Simülasyon Türü(lerini) Seçin:

Açma-Kapama x Q-Öğrenme x PID x

Simülasyonları Çalıştır

İterleme: %45

Simülasyonlar çalıştırılıyor...

Şekil 2.4. Uygulama ana ekranı ve çalışma süreci.

- **Matplotlib:** Simülasyon sonuçlarını görselleştirmek için kullanılan popüler bir veri görselleştirme kütüphanesidir. Matplotlib, çizgi grafikleri, dağılım grafikleri, histogram ve daha birçok grafik türünü oluşturmak için geniş bir yelpazede araçlar sunar.
- **Pandas:** Veri işleme ve analiz için kullanılan güçlü bir kütüphanedir. Pandas, veri çerçeveleri (DataFrame) adı verilen yapılar kullanarak verileri kolayca okuma, yazma, filtreleme, dönüştürme ve analiz etme imkânı sağlar.
- **NumPy:** Sayısal hesaplamalar için kullanılan temel bir kütüphanedir. NumPy, çok boyutlu diziler ve matrisler üzerinde hızlı ve verimli işlemler gerçekleştirmek için araçlar sunar.
- **SciPy:** Bilimsel hesaplamalar için kullanılan bir kütüphanedir. SciPy, optimizasyon, interpolasyon, sinyal işleme, istatistik ve daha birçok alanda fonksiyonlar sağlar. Bu çalışmada, dış ortam sıcaklığı verilerinin

interpolasyonu için SciPy kütüphanesinin CubicSpline fonksiyonu kullanılmıştır.

- **Time:** Zamanla ilgili işlemler için kullanılan bir kütüphanedir. Bu çalışmada, `time.sleep()` fonksiyonu, simülasyon adımları arasında belirli bir süre beklemek ve simülasyonun gerçek zamanlı olarak ilerlemesini sağlamak için kullanılmıştır.

Bu kütüphanelerin kullanımı, simülatör yazılımının geliştirilmesini kolaylaştırmış ve kullanıcı dostu bir arayüz oluşturulmasını sağlamıştır. Ayrıca, simülasyon sonuçlarının görselleştirilmesi ve analiz edilmesi için gerekli araçları sunmuştur.

2.6. Performans Değerlendirme Metrikleri

Geliştirilen simülatör yazılımı kullanılarak farklı senaryolarda simülasyonlar gerçekleştirilmiş ve sonuçlar, enerji tüketimi, konfor seviyesi ve iç ortam hava kalitesi gibi farklı metrikler açısından değerlendirilmiştir. Bu metrikler, kontrol algoritmalarının performansını karşılaştırmak ve en uygun kontrol stratejisini belirlemek için kullanılmıştır.

- **Enerji Tüketimi:** HVAC sisteminin çalışması için harcanan enerji miktarını ifade eder.
- **Konfor Seviyesi:** İç ortam sıcaklığının istenen aralıkta kalma süresi ve sıcaklık dalgalanmalarının şiddeti ile ilişkilidir. Konfor seviyesi, "Aşım" ve "Alt Geçiş" değerleri kullanılarak ölçülmüştür. Aşım, iç ortam sıcaklığının termostat ayar noktasının üzerinde kaldığı süreleri, alt geçiş ise iç ortam sıcaklığının termostat ayar noktasının altında kaldığı süreleri ifade eder. Bu değerler, °C-dakika cinsinden hesaplanmıştır.
- **İç Ortam Hava Kalitesi:** Sıcaklık ve nem gibi faktörlerin yanı sıra, HVAC sisteminin filtreleme ve havalandırma performansına bağlıdır. Bu çalışmada, iç ortam hava kalitesi doğrudan değerlendirilmemiştir, ancak sıcaklık ve nem kontrolünün iyileştirilmesinin dolaylı olarak iç ortam hava kalitesini de artıracığı varsayılmıştır.

Bu metrikler, kontrol algoritmalarının performansını değerlendirmek ve karşılaştırmak için kullanılmıştır.

2.7. Simölasyon Çıktıları

Simölator yazılımı kullanılarak elde edilen bazı örnekle çıktıları Tablo 3.1’de sunulmaktadır.





3. BULGULAR VE TARTIŞMA

Bu bölümde, geliştirilen simülatör yazılımı kullanılarak gerçekleştirilen simülasyonların sonuçları sunulmakta ve tartışılmaktadır. Farklı senaryolarda, Açık-Kapalı, PID ve Q-learning kontrol algoritmalarının performansları, enerji tüketimi, konfor seviyesi (aşım ve alt geçiş) ve iç ortam hava kalitesi açısından değerlendirilmiştir. 0,1 °C hassasiyet ayarı sadece Açık-Kapalı kontrol algoritması için geçerlidir ve PID ve Q-learning algoritmalarını etkilemez.

3.1. Simülasyon Ortamı

Simülasyonlar, Python programlama dili kullanılarak geliştirilen ve kullanıcı dostu bir arayüze sahip olan bir simülatör yazılımı üzerinde gerçekleştirilmiştir. Odanın termal dinamiği, denklem 2.1’de ifade edilen tek bölgeli bir model olarak kabul edilmiştir:

Simülasyonlar, 0.1 saniyelik zaman adımlarıyla 7200 saniye (120 dakika) veya 86400 saniye (1440 dakika) boyunca gerçekleştirilmiştir.

Simülatör yazılımı, farklı senaryolarda iç ortam sıcaklık kontrolünü simüle edebilmektedir. Bu senaryolar, başlangıç oda sıcaklığı, termostat ayarı, ısıtıcı gücü, temel ısı kaybı, simülasyon süresi, termostat hassasiyeti, Q-learning eğitim bölümleri, öğrenme oranı, indirim faktörü, keşif oranı, PID parametreleri (K_p , K_i , K_d) gibi çeşitli parametrelerin değiştirilmesiyle oluşturulmuştur. Simülatör, her senaryo için Açık-Kapalı, PID ve Q-learning kontrol algoritmalarının performansını değerlendirerek, enerji tüketimi, konfor seviyesi (aşım ve alt geçiş) ve iç ortam hava kalitesi gibi metrikler açısından sonuçlar üretmektedir.

3.2. Farklı Senaryolarda Simülasyon Sonuçları

Simülasyonlar, farklı başlangıç oda sıcaklıkları, termostat hassasiyetleri, ısı kaybı oranları, simülasyon süreleri ve Q-learning eğitim bölümleri gibi çeşitli senaryolar altında gerçekleştirilmiştir. 0,1 °C hassasiyet ayarı sadece Açık-Kapalı kontrol algoritması için geçerlidir ve PID ve Q-learning algoritmalarını etkilemez. Her senaryo için elde edilen sonuçlar aşağıdaki Tablo 3.1’de sunulmuştur.

Tablo 3.1. Örnek senaryolar ve sonuçları.

Senaryo	Kontrol Algoritması	Aşım (°C-dakika)	Alt Geçiş (°C-dakika)	Toplam Alan (°C-dakika)	Simülasyon Süresi (dakika)
Başlangıç Sıcaklığı					
18 °C	Açık-Kapalı	4,78	6,41	11,19	120
Başlangıç Sıcaklığı					
18 °C	Q-Öğrenme	2,17	3,84	6,01	120
Başlangıç Sıcaklığı					
18 °C	PID	2,68	5,22	7,91	120
Termostat					
Hassasiyeti 0,1 °C	Açık-Kapalı	3,57	4,66	8,22	120
Termostat					
Hassasiyeti 0,1 °C	Q-Öğrenme	0,81	1,68	2,49	120
Termostat					
Hassasiyeti 0,1 °C	PID	0,31	6,72	7,03	120
Isı Kaybı 0,1 °C/dakika	Açık-Kapalı	15,33	15,83	31,16	120
Isı Kaybı 0,1 °C/dakika	Q-Öğrenme	0,81	1,68	2,49	120
Isı Kaybı 0,1 °C/dakika	PID	0,31	6,72	7,03	120
Öğrenme 5000	Açık-Kapalı	4,78	6,41	11,19	120
Öğrenme 5000	Q-Öğrenme	2,17	3,84	6,01	120
Öğrenme 5000	PID	2,68	5,22	7,91	120
Öğrenme 100	Açık-Kapalı	4,78	6,41	11,19	120
Öğrenme 100	Q-Öğrenme	2,17	3,84	6,01	120
Öğrenme 100	PID	2,68	5,22	7,91	120
120 Dakika	Açık-Kapalı	14,89	16,72	31,61	120
120 Dakika	Q-Öğrenme	0,31	2,34	2,65	120
120 Dakika	PID	0,00	395,85	395,85	120
120 Dakika					
İnterpolasyon	Açık-Kapalı	14,82	16,67	31,49	120
120 Dakika					
İnterpolasyon	Q-Öğrenme	0,51	1,90	2,41	120
120 Dakika					
İnterpolasyon	PID	0,00	9,29	9,29	120
1440 Dakika	Açık-Kapalı	183,30	184,70	368,00	1440
1440 Dakika	Q-Öğrenme	10,66	2,75	13,41	1440
1440 Dakika	PID	3,54	9,15	12,68	1440
1440 Dakika					
İnterpolasyon	Açık-Kapalı	181,45	187,85	369,30	1440

3.3. Enerji Tüketimi, Konfor Düzeyi ve İç Ortam Hava Kalitesi Analizi

Bu çalışmada, enerji tüketimi doğrudan ölçülmemiştir; ancak, aşım ve alt geçiş değerleri, dolaylı olarak enerji tüketimi hakkında bilgi sağlamaktadır. Aşım, iç ortam sıcaklığının termostat ayar noktasının üzerinde kaldığı süreleri, alt geçiş ise iç ortam sıcaklığının termostat ayar noktasının altında kaldığı süreleri ifade eder. Bu değerler,

°C-dakika cinsinden hesaplanmıştır. Aşım ve alt geçiş değerleri, kontrol algoritmalarının iç ortam sıcaklığını istenen aralıkta tutma başarısını gösterir. Aşım ve alt geçiş değerleri ne kadar düşükse, kontrol algoritmasının performansı o kadar iyi ve dolayısıyla enerji tüketimi o kadar düşüktür.

Konfor seviyesi, iç ortam sıcaklığının istenen aralıkta kalma süresi ve sıcaklık dalgalanmalarının şiddeti ile ilişkilidir. Bu çalışmada, konfor seviyesi, aşım ve alt geçiş değerleri kullanılarak değerlendirilmiştir. Toplam alan, aşım ve alt geçiş değerlerinin toplamını ifade eder ve konfor seviyesinin bir göstergesi olarak kullanılabilir. Toplam alan değeri ne kadar küçükse, konfor seviyesi o kadar yüksektir.

İç ortam hava kalitesi, sıcaklık ve nem gibi faktörlerin yanı sıra, HVAC sisteminin filtreleme ve havalandırma performansına bağlıdır. Bu çalışmada, iç ortam hava kalitesi doğrudan değerlendirilmemiştir, ancak sıcaklık ve nem kontrolünün iyileştirilmesinin dolaylı olarak iç ortam hava kalitesini de artıracığı varsayılmıştır.

3.4. Karşılaştırmalı Analiz: Makine Öğrenmesi Tabanlı Kontrol ve Geleneksel Kontrol

Bu çalışmada, Q-learning algoritmasının performansı, geleneksel Açık-Kapalı ve PID kontrol yöntemleriyle karşılaştırılmıştır. Simülasyon sonuçları, Q-learning algoritmasının, özellikle uzun süreli simülasyonlarda ve değişken koşullar altında, diğer kontrol yöntemlerine göre daha iyi performans gösterdiğini ortaya koymuştur.

Açık-Kapalı kontrol, en basit ve en yaygın kullanılan kontrol yöntemidir. Ancak, bu yöntem, sıcaklık dalgalanmalarına ve aşım/alt geçişlere neden olabilir, bu da enerji israfına ve konforsuzluğa yol açar. PID kontrol, Açık-Kapalı kontrole göre daha iyi bir performans sergiler, ancak parametrelerinin doğru şekilde ayarlanması gerekir ve değişken koşullara uyum sağlamakta zorlanabilir.


Q-learning algoritması ise, pekiştirmeli öğrenme yoluyla ortamı öğrenir ve en iyi kontrol stratejisini belirler. Bu sayede, değişken koşullara daha iyi uyum sağlayabilir ve hem enerji verimliliğini hem de konfor seviyesini artırabilir. Simülasyon sonuçları, Q-learning algoritmasının, özellikle uzun süreli simülasyonlarda (1440 dakika) ve ısı kaybı oranının yüksek olduğu durumlarda, Açık-Kapalı ve PID kontrol yöntemlerine göre önemli ölçüde daha düşük aşım ve alt geçiş değerlerine sahip olduğunu göstermektedir. Bu, Q-learning algoritmasının daha iyi bir konfor seviyesi ve daha düşük enerji tüketimi sağladığını gösterir.

Örnek senaryolar:

- Başlangıç Sıcaklığı 18°C Senaryosu: Q-learning, toplam alan metriği açısından Açık-Kapalı kontrol ve PID kontrol yöntemlerine göre daha iyi performans göstermiştir (6,01 °C-dakika). Bu, Q-learning'in iç ortam sıcaklığını istenen aralıkta daha iyi tutabildiğini ve daha yüksek bir konfor seviyesi sağlayabildiğini gösterir. Bu senaryo için uygulamada kullanılan parametreler Tablo 3.2'de yer almaktadır. Uygulama ekran alıntıları Şekil 3.1, Şekil 3.2, ve Şekil 3.3'teki gibidir.

Tablo 3.2. Başlangıç Sıcaklığı 18°C Senaryosu parametreleri.

Parametre	Değer
Başlangıç Oda Sıcaklığı (°C)	18
Termostat Ayarı (°C)	20
Isıtıcı Gücü (°C/dakika)	0,50
Temel Isı Kaybı (°C/dakika)	0,10
Simülasyon Süresi (Dakika)	120
Termostat Hassasiyeti (°C)	0,10
Q-Learning Parametreleri	
Eğitim Bölümleri	1000
Öğrenme Oranı	0,10
İndirim Faktörü	0,95
Keşif Oranı	0,10
PID parametreleri	
Kp (Oransal Kazanç)	1
Ki (İntegral Kazanç)	0,1
Kd (Türev Kazanç)	0,01



Şekil 3.1. Başlangıç Sıcaklığı 18°C Senaryosu oda sıcaklığı grafiği.


Konfor ve Enerji Metrikleri

Aşım ve Alt Geçiş Değerleri:

Açma-Kapama - Aşım: 4.78 °C*dakika, Alt Geçiş: 6.41 °C*dakika

Q-Öğrenme - Aşım: 2.17 °C*dakika, Alt Geçiş: 3.84 °C*dakika

PID - Aşım: 2.68 °C*dakika, Alt Geçiş: 5.22 °C*dakika



Toplam Aşım ve Alt Geçiş Karşılaştırması


Toplam Alan Değerleri:

Açma-Kapama - Toplam Alan: 11.19 °C*dakika

Q-Öğrenme - Toplam Alan: 6.01 °C*dakika

PID - Toplam Alan: 7.91 °C*dakika

Şekil 3.2. Başlangıç Sıcaklığı 18°C Senaryosu konfor ve enerji tüketimi grafiği.




Şekil 3.3. Başlangıç Sıcaklığı 18°C Senaryosu toplam konfor grafiği.

- Termostat Hassasiyeti 0,1°C Senaryosu: Q-learning, yine en düşük toplam alan değerine (2,49 °C-dakika) sahip olarak en iyi performansı göstermiştir. Bu, Q-learning'in termostat hassasiyetindeki değişikliklere daha iyi uyum sağlayabildiğini ve daha stabil bir sıcaklık kontrolü sağlayabildiğini gösterir. Bu senaryo için uygulamada kullanılan parametreler Tablo 3.3'te yer almaktadır. Uygulama ekran alıntıları Şekil 3.4, Şekil 3.5, ve Şekil 3.6'teki gibidir.

Tablo 3.3. Termostat Hassasiyeti 0,1°C Senaryosu parametreleri.

Parametre	Değer
Başlangıç Oda Sıcaklığı (°C)	19
Termostat Ayarı (°C)	20
Isıtıcı Gücü (°C/dakika)	0,30
Temel Isı Kaybı (°C/dakika)	0,10
Simülasyon Süresi (Dakika)	120
Termostat Hassasiyeti (°C)	0,10
Q-Learning Parametreleri	
Eğitim Bölümleri	1000
Öğrenme Oranı	0,10
İndirim Faktörü	0,95
Keşif Oranı	0,10
PID parametreleri	
Kp (Oransal Kazanç)	1
Ki (İntegral Kazanç)	0,1
Kd (Türev Kazanç)	0,01



Şekil 3.4. Termostat Hassasiyeti 0,1°C Senaryosu oda sıcaklığı grafiği.


Konfor ve Enerji Metrikleri

Aşım ve Alt Geçiş Değerleri:

Açma-Kapama - Aşım: 3.57 °C*dakika, Alt Geçiş: 4.66 °C*dakika

Q-Öğrenme - Aşım: 0.81 °C*dakika, Alt Geçiş: 1.68 °C*dakika

PID - Aşım: 0.31 °C*dakika, Alt Geçiş: 6.72 °C*dakika



Toplam Aşım ve Alt Geçiş Karşılaştırması


Toplam Alan Değerleri:

Açma-Kapama - Toplam Alan: 8.22 °C*dakika

Q-Öğrenme - Toplam Alan: 2.49 °C*dakika

PID - Toplam Alan: 7.03 °C*dakika

Şekil 3.5. Termostat Hassasiyeti 0,1°C senaryosu konfor ve enerji tüketimi grafiği.




Şekil 3.6. Termostat Hassasiyeti 0,1°C Senaryosu toplam konfor grafiği.

- Isı Kaybı 0,1°C/dakika Senaryosu: Isı kaybı oranının artmasıyla birlikte, Açık-Kapalı kontrolün performansı önemli ölçüde düşmüştür (toplam alan: 31,16 °C-dakika). Q-learning ise, bu senaryoda da en iyi performansı göstererek, en düşük toplam alan değerine (2,49 °C-dakika) sahip olmuştur. Bu, Q-learning'in değişken ısı kaybı koşullarına daha iyi uyum sağlayabildiğini gösterir. Bu senaryo için uygulamada kullanılan parametreler Tablo 3.4'te yer almaktadır. Uygulama ekran alıntıları Şekil 3.7, Şekil 3.8, ve Şekil 3.9'daki gibidir.

Tablo 3.4. Isı Kaybı 0,1°C/dakika Senaryosu parametreleri.

Parametre	Değer
Başlangıç Oda Sıcaklığı (°C)	19
Termostat Ayarı (°C)	20
Isıtıcı Gücü (°C/dakika)	0,30
Temel Isı Kaybı (°C/dakika)	0,10
Simülasyon Süresi (Dakika)	120
Termostat Hassasiyeti (°C)	0,50
Q-Learning Parametreleri	
Eğitim Bölümleri	1000
Öğrenme Oranı	0,10
İndirim Faktörü	0,95
Keşif Oranı	0,10
PID parametreleri	
Kp (Oransal Kazanç)	1
Ki (İntegral Kazanç)	0,1
Kd (Türev Kazanç)	0,01



Şekil 3.7. Isı Kaybı 0,1°C/dakika Senaryosu oda sıcaklığı grafiği.


Konfor ve Enerji Metrikleri

Aşım ve Alt Geçiş Değerleri:

Açma-Kapama - Aşım: 15.33 °C*dakika, Alt Geçiş: 15.83 °C*dakika

Q-Öğrenme - Aşım: 0.81 °C*dakika, Alt Geçiş: 1.68 °C*dakika

PID - Aşım: 0.31 °C*dakika, Alt Geçiş: 6.72 °C*dakika



Toplam Aşım ve Alt Geçiş Karşılaştırması


Toplam Alan Değerleri:

Açma-Kapama - Toplam Alan: 31.16 °C*dakika

Q-Öğrenme - Toplam Alan: 2.49 °C*dakika

PID - Toplam Alan: 7.03 °C*dakika

Şekil 3.8. Isı Kaybı 0,1°C/dakika Senaryosu konfor ve enerji tüketimi grafiği.




Şekil 3.9. Isı Kaybı 0,1°C/dakika Senaryosu toplam konfor grafiği.

- **1440 Dakika Simülasyon Senaryosu:** Uzun süreli simülasyonlarda (1440 dakika), Q-learning'in üstünlüğü daha da belirginleşmiştir. Açık-Kapalı kontrolün toplam alan değeri 368,00 °C-dakika iken, Q-learning'in toplam alan değeri sadece 13,41 °C-dakikadır. Bu, Q-learning'in uzun vadede önemli ölçüde daha iyi bir konfor seviyesi ve enerji tasarrufu sağlayabileceğini gösterir. Bu senaryo için uygulamada kullanılan parametreler Tablo 3.5'te yer almaktadır. Uygulama ekran alıntıları Şekil 3.10, Şekil 3.11, ve Şekil 3.12'deki gibidir.

Tablo 3.5. 1440 Dakika Simülasyon Senaryosu parametreleri.

Parametre	Değer
Başlangıç Oda Sıcaklığı (°C)	19
Termostat Ayarı (°C)	20
Isıtıcı Gücü (°C/dakika)	0,30
Temel Isı Kaybı (°C/dakika)	0,20
Simülasyon Süresi (Dakika)	1440
Termostat Hassasiyeti (°C)	0,10
Q-Learning Parametreleri	
Eğitim Bölümleri	1000
Öğrenme Oranı	0,10
İndirim Faktörü	0,95
Keşif Oranı	0,10
PID parametreleri	
Kp (Oransal Kazanç)	1
Ki (İntegral Kazanç)	0,1
Kd (Türev Kazanç)	0,01



Şekil 3.10. 1440 Dakika Simülasyon Senaryosu oda sıcaklığı grafiği.


Konfor ve Enerji Metrikleri

Aşım ve Alt Geçiş Değerleri:

Açma-Kapama - Aşım: 181.45 °C*dakika, Alt Geçiş: 187.85 °C*dakika

Q-Öğrenme - Aşım: 7.52 °C*dakika, Alt Geçiş: 4.56 °C*dakika

PID - Aşım: 4.20 °C*dakika, Alt Geçiş: 10.83 °C*dakika



Toplam Aşım ve Alt Geçiş Karşılaştırması


Toplam Alan Değerleri:

Açma-Kapama - Toplam Alan: 369.30 °C*dakika

Q-Öğrenme - Toplam Alan: 12.08 °C*dakika

PID - Toplam Alan: 15.03 °C*dakika

Şekil 3.11. 1440 Dakika Simülasyon Senaryosu konfor ve enerji tüketimi grafiği.



Şekil 3.12. 1440 Dakika Simülasyon Senaryosu toplam konfor grafiği.

Ancak, Q-learning algoritmasının öğrenme süreci, diğer yöntemlere göre daha uzun ve karmaşık olabilir. Ayrıca, algoritmanın performansı, ödül fonksiyonunun doğru bir şekilde tasarlanmasına ve hiper parametrelerin uygun şekilde ayarlanmasına bağlıdır. Bu nedenle, Q-learning algoritmasının gerçek dünya uygulamalarında kullanılması, daha fazla araştırma ve geliştirme gerektirebilir.

3.5. Çalışmanın Sınırlamaları ve Gelecekteki Çalışmalara Yönelik Öneriler

Bu tez çalışması, iç ortam sıcaklık kontrolünde Q-learning algoritmasının etkinliğini değerlendirmek için önemli bir adım olsa da bazı sınırlamaları vardır. Öncelikle, simülasyon ortamı, gerçek dünya koşullarını tam olarak yansıtmayabilir. Simülasyonlarda kullanılan oda modeli basitleştirilmiştir ve bazı faktörler (örneğin, güneş radyasyonunun bina içerisindeki dağılımı, kullanıcıların aktivite seviyeleri vb.) göz ardı edilmiştir. Bu nedenle, elde edilen sonuçların gerçek binalara genellenebilirliği sınırlı olabilir.

İkinci olarak, bu çalışmada sadece üç kontrol algoritması (Açık-Kapalı, PID ve Q-learning) karşılaştırılmıştır. Literatürde, iç ortam sıcaklık kontrolü için kullanılan başka makine öğrenimi tabanlı kontrol algoritmaları da bulunmaktadır (örneğin, bulanık mantık kontrol, genetik algoritmalar vb.). Bu algoritmaların da performanslarının karşılaştırılması, gelecekteki çalışmalar için bir öneri olabilir.

Son olarak, bu çalışmada enerji tüketimi doğrudan ölçülmemiştir. Gelecekteki çalışmalarda, simülatör yazılımına enerji tüketimi hesaplama özelliği eklenerek, kontrol algoritmalarının enerji verimliliği üzerindeki etkileri daha doğrudan değerlendirilebilir.

Bu sınırlamalara rağmen, bu tez çalışması, Q-learning algoritmasının iç ortam sıcaklık kontrol sistemlerinin optimizasyonunda kullanılmasının potansiyelini göstermiştir. Gelecekteki çalışmalar, bu algoritmanın gerçek binalarda uygulanmasını ve performansını değerlendirmeyi hedefleyebilir. Ayrıca, farklı makine öğrenimi algoritmalarının ve kontrol stratejilerinin performans karşılaştırmaları yapılarak, iç ortam sıcaklık kontrolünün daha da optimize edilmesi sağlanabilir.





4. SONUÇ VE ÖNERİLER

Bu tez çalışması, iç ortam sıcaklık kontrol sistemlerinin optimizasyonunda makine öğrenimi tabanlı bir kontrol algoritması olan Q-learning'in etkinliğini geleneksel yöntemlerle karşılaştırmalı olarak incelemiştir. Bu amaç doğrultusunda geliştirilen simülatör yazılımı, farklı senaryolarda iç ortam sıcaklık kontrolünü simüle etmiş ve Q-learning algoritmasının performansı, geleneksel Açık-Kapalı ve PID kontrol yöntemleriyle karşılaştırılmıştır.

4.1. Tezin Özgün Katkıları

Bu tez çalışması, aşağıdaki özgün katkıları sağlamıştır:

- İç ortam sıcaklık kontrolü için Q-learning algoritmasının eğitimi ve optimizasyonu: Q-learning algoritması, iç ortam sıcaklık kontrolü problemine uyarlanmış ve simülasyon ortamında eğitilerek optimize edilmiştir.
- Farklı senaryolarda iç ortam sıcaklık kontrolünü simüle edebilen bir yazılımın geliştirilmesi: Python programlama dili kullanılarak geliştirilen simülatör yazılımı, kullanıcı dostu bir arayüze sahiptir ve farklı senaryolarda iç ortam sıcaklık kontrolünü simüle edebilir.
- Geliştirilen simülatör yazılımı kullanılarak Q-learning, Açık-Kapalı ve PID kontrol yöntemlerinin performanslarının karşılaştırılması: Simülasyon sonuçları, Q-learning algoritmasının, özellikle uzun süreli simülasyonlarda ve değişken koşullar altında, diğer kontrol yöntemlerine göre daha iyi performans gösterdiğini ortaya koymuştur.
- Kullanılan Q-learning algoritmasının ve simülatör yazılımının açık kaynak kodlu olarak sunulması: Bu, diğer araştırmacıların ve mühendislerin çalışmayı tekrarlamasına, doğrulamasına ve geliştirmelerine olanak tanır.

4.2. Gelecekteki Çalışmalar İçin Öneriler

Bu tez çalışmasının sonuçları, gelecekteki araştırmalar için aşağıdaki önerileri sunmaktadır:

- **Daha Gelişmiş Makine Öğrenimi Modelleri:** Derin öğrenme gibi daha gelişmiş makine öğrenimi modellerinin iç ortam sıcaklık kontrolünde kullanımı araştırılabilir. Bu modeller, daha karmaşık ilişkileri modelleyebilir ve daha iyi tahmin performansı sağlayabilir.
- **Gerçek Zamanlı Uygulama:** Geliştirilen simülatör yazılımı, gerçek binalarda HVAC sistemlerinin kontrolünü optimize etmek için gerçek zamanlı olarak kullanılabilir. Bu, simülatörün gerçek dünya koşullarında performansını değerlendirmek ve enerji tasarrufu potansiyelini belirlemek için önemli bir adım olacaktır.
- **İnsan-Makine Etkileşimi:** Kullanıcıların tercihlerini ve davranışlarını öğrenerek iç ortam sıcaklık kontrolünü kişiselleştirebilen sistemler geliştirilebilir. Bu, kullanıcı konforunu daha da artırabilir ve enerji tüketimini optimize edebilir.
- **Diğer Kontrol Sistemleriyle Entegrasyon:** Geliştirilen makine öğrenimi tabanlı kontrol algoritmaları, aydınlatma, havalandırma ve gölgelendirme gibi diğer bina kontrol sistemleriyle entegre edilebilir. Bu, bina genelinde enerji verimliliğini artırmak için bütüncül bir yaklaşım sağlayabilir.

4.3. Genel Değerlendirme

Bu tez çalışması, iç ortam sıcaklık kontrol sistemlerinin optimizasyonunda makine öğrenimi tabanlı kontrol algoritmalarının kullanımının potansiyelini göstermiştir. Geliştirilen simülatör yazılımı ve elde edilen sonuçlar, bu alandaki gelecekteki çalışmalara ışık tutacak ve daha enerji verimli ve konforlu binaların tasarımına katkı sağlayacaktır.

KAYNAKLAR

- [1] Wang, X., Fang, F., Zhang, X., Liu, Y., Wei, L., & Shi, Y. (2019). LSTM-based short-term load forecasting for building electricity consumption. In IEEE Int. Symp. Ind. Electron., Vol. 2019-June. pp. 1418–1423. <http://dx.doi.org/10.1109/ISIE.2019.8781349>.
- [2] Shin, M., Kim, S., Kim, Y., Song, A., Kim, Y., & Kim, H. Y. (2024). Development of an HVAC system control method using weather forecasting data with deep reinforcement learning algorithms. *Building and Environment*, 248, 111069. Available online 28 November 2023
- [3] Dounis, A. I., & Caraiscos, C. (2009). Advanced control systems engineering for energy and comfort management in buildings. *Renewable and Sustainable Energy Reviews*, 13(6-7), 1246-1261.
- [4] Zhao, H. X., & Magoulès, F. (2012). A review on the prediction of building energy consumption. *Renewable and Sustainable Energy Reviews*, 16(6), 3586-3592.
- [5] Crawley, D. B., Hand, J. W., Kummert, M., & Griffith, B. T. (2008). Contrasting the capabilities of building energy performance simulation programs. *Building and Environment*, 43(4), 661-673.
- [6] Wei, Y., Zhang, X., Shi, Y., Xia, L., & Pan, G. (2018). A review of data-driven approaches for prediction and classification of building energy consumption. *Renewable and Sustainable Energy Reviews*, 82, 1027-1047.
- [7] Wang, H., Chen, X., Vital, N., Duffy, E., & Razi, A. (2024). Energy optimization for HVAC systems in multi-VAV open offices: A deep reinforcement learning approach. *Applied Energy*, 356, 122354. Available online 23 November 2023
- [8] Brandi, Silvio, Marco Savino Piscitelli, Marco Martellacci, and Alfonso Capozzoli, "Deep reinforcement learning to optimise indoor temperature control and heating energy consumption in buildings." *Energy and Buildings* 224 (2020): 110225.
- [9] Wei, Tianshu, Yanzhi Wang, and Qi Zhu. "Deep reinforcement learning for building HVAC control." *Proceedings of the 54th annual design automation conference* 2017.
- [10] Pérez-Lombard, L., Ortiz, J., & Pout, C. (2008). A review on buildings energy consumption information. *Energy and Buildings*, 40(3), 394-398.
- [11] Amasyali, K., & El-Gohary, N. M. (2018). A review of data-driven building energy consumption prediction studies. *Renewable and Sustainable Energy Reviews*, 81, 1192-1205.

- [12] ASHRAE. (2017). ASHRAE Guideline 14-2017: Measurement of Energy, Demand, and Water Savings. Atlanta, GA: American Society of Heating, Refrigerating and Air-Conditioning Engineers.
- [13] Wu, Y., & Wang, W. (2018). A review of building energy data preprocessing methodologies. *Energy and Buildings*, 162, 240-251.
- [14] Liu, M., & Henze, G. P. (2018). Feature engineering for improving building energy prediction. *Energy and Buildings*, 175, 130-141.
- [15] Taheri, S., Hosseini, P., & Razban, A. (2022). Model predictive control of heating, ventilation, and air conditioning (HVAC) systems: A state-of-the-art review. *Journal of Building Engineering*, 60, 105067. Available online 26 August 2022
- [16] Montgomery, D. C., Peck, E. A., & Vining, G. G. (2021). Introduction to linear regression analysis (6th ed.). John Wiley & Sons.
- [17] Smola, A. J., & Schölkopf, B. (2004). A tutorial on support vector regression. *Statistics and computing*, 14(3), 199-222.
- [18] Aggarwal, C. C. (2018). Neural networks and deep learning. Springer.
- [19] Breiman, L., Friedman, J., Stone, C. J., & Olshen, R. A. (1984). Classification and regression trees. Wadsworth International Group.
- [20] Raschka, S. (2018). Model evaluation, model selection, and algorithm selection in machine learning. arXiv preprint arXiv:1811.12808.

EKLER

EK A. Termostat simülasyonu uygulaması yazılımı sözde kodu



EK A. Termostat simülasyonu uygulaması yazılımı sözde kodu

1. Veri İşleme ve Parametre Alma:

- `load_data()`:
 - Kullanıcıdan CSV dosyası al.
 - CSV'yi Pandas DataFrame'e dönüştür.
 - "Outdoor Temp (C)" sütununun varlığını ve eksik değerleri kontrol et, hataları göster.
 - Dış ortam sıcaklığı değerlerini döndür.
- `get_simulation_parameters()`:
 - Streamlit sidebar'ından simülasyon parametrelerini al (başlangıç sıcaklığı, termostat ayarı, ısıtıcı gücü, ısı kaybı, simülasyon süresi, termostat hassasiyeti).
 - Parametreleri bir sözlükte döndür.
- `get_q_learning_parameters()`:
 - Streamlit sidebar'ından Q-öğrenme parametrelerini al (eğitim bölümleri, öğrenme oranı, indirim faktörü, keşif oranı).
 - Parametreleri bir sözlükte döndür.
- `get_pid_parameters()`:
 - Streamlit sidebar'ından PID parametrelerini al (K_p , K_i , K_d).
 - Parametreleri bir sözlükte döndür.
- `get_outdoor_temperature_data()`:
 - Kullanıcıdan dış ortam sıcaklığı veri kaynağını seçmesini iste (CSV veya interpolasyon).
 - CSV seçilirse, `load_data()` kullanarak verileri yükle.
 - İnterpolasyon seçilirse, kullanıcıdan saatlik sıcaklık değerlerini al ve kübik spline interpolasyon fonksiyonunu oluştur.
 - Dış ortam sıcaklığı değerlerini veya interpolasyon fonksiyonunu döndür.

2. Simülasyon Yardımcı Fonksiyonları:

- `get_state(temperature)`:
 - Sıcaklığı ayrıklaştırılmış bir duruma dönüştür.
- `get_action(state, q_table, exploration_rate)`:
 - Epsilon-greedy politikasına göre bir eylem seç (ısıtıcıyı aç veya kapat).
- `get_reward(state, action, thermostat_setting)`:
 - Durum, eylem ve termostat ayarına göre ödülü hesapla.
- `get_outdoor_temp(minute, outdoor_temp_values, interpolation_func)`:
 - Veri kaynağına göre belirli bir dakika için dış ortam sıcaklığını al (CSV veya interpolasyon).
- `calculate_area_between_temp(time, room_temperatures, set_temp)`:
 - Oda sıcaklığı ve ayarlanan sıcaklık arasındaki alanı hesapla (konfor metriği).
- `calculate_overshoot_area(time, room_temperatures, set_temp)`:
 - Aşım alanını hesapla (ayarlanan sıcaklığın üzerindeki alan).
- `calculate_undershoot_area(time, room_temperatures, set_temp)`:
 - Alt geçiş alanını hesapla (ayarlanan sıcaklığın altındaki alan).

3. Simülasyon Fonksiyonları:

- `run_on_off_simulation(params, outdoor_temp_values, interpolation_func)`:
 - Açma-kapama kontrol algoritması ile simülasyonu çalıştır.
 - Her zaman adımında:
 - Dış ortam sıcaklığını al.
 - Termostat ayarına göre ısıtıcıyı aç veya kapat.
 - Isı kaybını ve ısıtıcı çıkışını hesapla.
 - Oda sıcaklığını güncelle.
 - Konfor, aşım ve alt geçiş metriklerini hesapla ve döndür.
- `run_q_learning_simulation(params, outdoor_temp_values, q_params, interpolation_func)`:
 - Q-öğrenme kontrol algoritması ile simülasyonu çalıştır.
 - Belirtilen sayıda bölüm boyunca Q-tablosunu eğit.
 - Her bölümde:
 - Her zaman adımında:
 - Dış ortam sıcaklığını al.
 - Q-tablosuna göre eylem seç.
 - Isıtıcıyı aç/kapat ve oda sıcaklığını güncelle.
 - Ödülü hesapla ve Q-tablosunu güncelle.
 - Eğitim sonrası öğrenilen Q-tablosu ile son bir simülasyon çalıştır ve metrikleri döndür.
- `run_pid_simulation(params, outdoor_temp_values, pid_params, interpolation_func)`:
 - PID kontrol algoritması ile simülasyonu çalıştır.
 - Her zaman adımında:
 - Dış ortam sıcaklığını al.
 - PID kontrol çıkışını hesapla (orantılı, integral, türev terimleri).
 - Isı kaybını ve ısıtıcı çıkışını hesapla.
 - Oda sıcaklığını güncelle.
 - Konfor, aşım ve alt geçiş metriklerini hesapla ve döndür.

4. Sonuçları Görselleştirme ve İndirme:

- `convert_results_to_csv(results)`:
 - Simülasyon sonuçlarını CSV formatına dönüştür.
- `run_simulations(simulation_types, outdoor_temp_values, sim_params, q_params, pid_params, interpolation_func)`:
 - Seçilen simülasyonları çalıştır (`run_on_off_simulation`, `run_q_learning_simulation`, `run_pid_simulation`).
 - Sonuçları görselleştir:
 - Oda sıcaklığı grafiği
 - Aşım ve alt geçiş çubuk grafiği
 - Toplam aşım ve alt geçiş karşılaştırması
 - Dış ortam sıcaklığı grafiği (veri varsa)
 - Sonuçları indirme seçeneği sun.

5. Ana Uygulama:

- Streamlit uygulamasını başlat.

- Sidebar'da veri yükleme, parametre alma ve algoritma seçimini yap.
- "Simülasyonları Çalıştır" butonuna basıldığında:
 - Simülasyonları çalıştır ve sonuçları görselleştir.



ÖZGEÇMİŞ

Ad-Soyad : Aydın BOSTANCI

ÖĞRENİM DURUMU:

- **Lisans** : 2010, Sakarya Üniversitesi, Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü

MESLEKİ DENEYİM VE ÖDÜLLER:

- 2012 yılından itibaren Daikin Isıtma ve Soğutma Sistemleri San.Tic A.Ş. Ar-Ge merkezinde çalışmakta. Ar-Ge Bölüm Müdürlüğü yapmaktadır.