Makine Öğrenmesi Tabanlı Akıllı Sera Otomasyon Sisteminin Tasarımı
Machine Learning-Based Smart Greenhouse Automation System Design

Nida Kara[1], *Halil Onur Tutar*[2], *Ammar Urgan*[3], *Levent Ucun*[4]

Kontrol ve Otomasyon Mühendisliği Bölümü
Yıldız Teknik Üniversitesi, İstanbul
[1] onur.tutar@std.yildiz.edu.tr
[2] nida.kara@std.yildiz.edu.tr
[3] ammar@yildiz.edu.tr
[4] lucun@yildiz.edu.tr

Özetçe

Bu çalışma, tarımsal verimliliği artırmak ve kaynak tüketimini azaltmak amacıyla klasik otomasyon sistemlerinin güvenilirliğini veriye dayalı karar yöntemleriyle birleştiren hibrit bir akıllı sera otomasyon sistemi önermektedir. Temel hedef; Nesnelerin İnterneti (IoT), Makine Öğrenmesi (ML) ve otomasyon sistemleri teknolojilerini entegre ederek akıllı ve güvenilir bir sera kontrol yapısı geliştirmektir. Bu çalışma kapsamında oluşturulan gerçek zamanlı sistemde toprak nemi, sıcaklık ve bağıl nem gibi veriler sensörlerle ölçülerek MODBUS TCP/IP protokolü ile mikrodenetleyiciye aktarılır. Burada tek boyutlu Kalman Filtresi ile gürültüden arındırılan veriler, MQTT protokolüyle bulut tabanlı IoT platformuna iletilir. İşlenen veriler, makine öğrenmesi modellerince oluşturulan sulama kararlarını desteklemek için kullanılır ve alınan kararlar programlanabilir mantıksal denetleyiciye (PLC) geri iletilerek otomasyon süreci güvenle yürütülür. Çalışmanın ana katkısı, makine öğrenmesi tabanlı yaklaşımlar kullanılarak bir sera sisteminde kaynakların verimli kullanılmasını hedefleyen modüler bir prototipin geliştirilmesidir. Önerilen bu sistem, gelecekteki Akıllı Tarım 5.0 uygulamaları için referans bir model olma potansiyeli taşımaktadır. Bu çalışmada gerçekleştirilen performans değerlendirmeleri sonucunda başarılı sonuçlar veren SVC+SVR makine öğrenmesi modeli tercih edilmiştir.

Abstract

This study proposes a hybrid smart greenhouse automation system that combines the reliability of classical automation systems with data-driven decision methods in order to increase agricultural productivity and reduce resource consumption. The main objective is to develop a smart and reliable greenhouse control structure by integrating IoT, Machine Learning (ML), and automation systems technologies. In the system, data such as soil moisture, temperature and relative humidity are collected by sensors connected to a PLC and transferred to microcontroller via the MODBUS TCP/IP protocol. Here, the data, cleared of noise using a one-dimensional Kalman Filter, is transmitted to a cloud-based IoT platform via MQTT protocol. The processed data is used by machine learning models to support irrigation decisions, and the resulting decisions are transmitted back to PLC to securely execute the automation process. The main contribution of the study is the development of a modular prototype that optimizes the resources used in greenhouses via machine learning-based approach. This proposed system carries the potential to be a reference model for future Smart Agriculture 5.0 applications. Based on the results of the performance evaluations conducted in this study, the SVC+SVR machine learning model, which yields successful results, is preferred.

1. Giriş

Akıllı sera otomasyon sistemleri ve sürdürülebilir sulama çalışmaları, tarımsal verimliliği artırmak ve su kaynaklarını uzun vadeli yönetmek açısından kritik bir öneme sahiptir [1], [2]. Geleneksel sabit eşik değerlerine dayalı otomasyon yaklaşımlarının sürekli değişen dinamik sera koşullarında yetersiz kalması, eşzamanlı izleme, veri toplama ve uzaktan kontrol imkanı sunan Nesnelerin İnterneti tabanlı esnek altyapıların kullanımını yaygınlaştırmıştır [3], [4], [5].

Akıllı karar verme süreçlerini iyileştirmek amacıyla, sabit kurallara bağlı kalmak yerine çevresel veriler ile sistem davranışları arasındaki karmaşık ilişkileri öğrenebilen makine öğrenmesi teknikleri öne çıkmaktadır [6], [7], [8]. Bu kapsamda, özellikle Destek Vektör Makineleri (SVM) tabanlı yöntemler, doğrusal olmayan çevresel değişkenleri (sıcaklık, nem, toprak nemi) birlikte modelleyerek eyleyicilerin durumlarını ve sürekli kontrol çıktılarını tahmin etmede oldukça etkilidir [9], [10]. Bu süreçte mikrodenetleyiciler, sensör verilerini işleyip bulut platformlarına aktararak yerel kontrol donanımları ile makine öğrenmesi katmanı arasında güvenilir bir IoT ağ geçidi işlevi görmektedir [11], [12].

Programlanabilir Mantıksal Denetleyiciler (PLC), endüstriyel dayanıklılık ve güvenilir eyleyici kontrolü açısından büyük avantajlar sunmasına rağmen, mevcut PLC tabanlı sera sistemlerinde karar mekanizmalarının çoğunlukla sabit kurallarla sınırlandırılması sistemin uyarlanabilirliğini düşürmektedir [13]. Literatür incelendiğinde, IoT tabanlı izleme, makine öğrenmesi tabanlı tahmin ve PLC tabanlı yürütme sistemlerinin genellikle ayrı ayrı ele alındığı; dolayısıyla akıllı karar verme ile endüstriyel düzeyde güvenilir fiziksel kontrol arasında belirgin bir araştırma boşluğu

bulunduğu görülmektedir [14]. Literatürden farklı olarak bu çalışma, PLC, IoT ve makine öğrenmesi teknolojilerini tek bir akıllı sera otomasyon mimarisi çatısı altında entegre etmeyi amaçlamaktadır. Önerilen yapıda PLC, sensör verilerinin okunması ve eyleyicilerin güvenilir bir şekilde kontrol edilmesi için endüstriyel bir yürütme katmanı olarak işlev görmektedir. Raspberry Pi 4 ise PLC, IoT platformu ve makine öğrenmesi katmanı arasındaki veri iletimini sağlayan bir IoT ağ geçidi olarak konumlandırılmıştır. Sistemde sensör verileri işlenerek IoT platformuna iletilirken, eş zamanlı olarak makine öğrenmesi modeli bu verileri değerlendirmekte ve kaynakların verimli kullanımına yönelik optimizasyon kararları üretmektedir. Üretilen bu kararlar, fiziksel sistem üzerinde icra edilmek üzere tekrar PLC'ye gönderilmektedir. Sonuç olarak önerilen bu sistem; IoT'nin uzaktan izleme kapasitesini, makine öğrenmesinin veriye dayalı dinamik karar verme yeteneğini ve PLC tabanlı otomasyonun endüstriyel güvenilirliğini tek bir hibrit yapıda birleştirerek alanındaki literatüre özgün ve uygulanabilir bir mimari katkısı sunmaktadır.

2. Materyal ve Metot

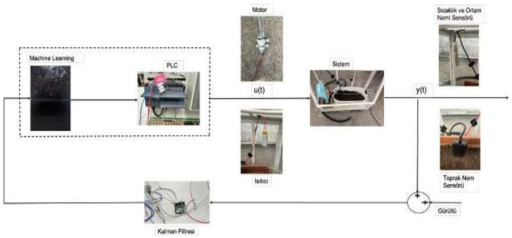
Bu bölümde, çalışmada ele alınan sistem mimarisi, donanım tasarımı, kullanılan iletişim protokolleri ve makine öğrenmesi algoritmaları açıklanacaktır.

2.1. Sistem Mimarisi

Önerilen akıllı sera sistemi; veri toplama, işleme, karar verme ve fiziksel kontrol aşamalarından oluşmaktadır. Sıcaklık ve nem verileri doğrudan mikrodenetleyiciye, toprak nemi verisi ise PLC üzerinden mikrodenetleyiciye aktarılmaktadır. Mikrodenetleyicide Kalman filtresi ile işlenen sensör verileri IoT platformuna gönderilmekte, makine öğrenmesi modeli tarafından değerlendirilerek su pompası ve ısıtıcı için kontrol komutları üretilmektedir. Bu komutlar PLC'ye iletilerek eyleyicilerin kontrolü sağlanmaktadır.

2.2. Donanım Tasarımı

Bu bölümde, gerçek zamanlı sistemin kurulumu ile ilgili olarak donanım tasarımı hakkında bilgiler verilecektir.

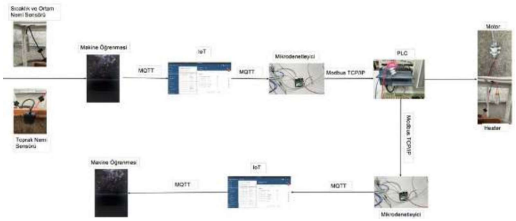


Şekil 1 Sistem Blok Diyagramı

Şekil 1'de, geliştirilen akıllı sera otomasyon sisteminin kapalı çevrim blok diyagramı gösterilmektedir. Sistemde Kalman filtresiyle işlenerek gürültüsü azaltılan sensör verileri, makine öğrenmesi modellerine girdi olarak aktarılmaktadır. Makine öğrenmesi modelleri, sera ortamının mevcut koşullarını değerlendirerek sulama pompası ve ısıtıcının çalışma durumları ile PWM değerlerini belirleyen kontrol komutlarını üretmektedir. Bu komutlar PLC'ye iletilmekte ve PLC tarafından motor ile ısıtıcıya uygulanmaktadır. Motorun çalışması sulama işlemini gerçekleştirerek toprak nemini artırırken ısıtıcının çalışması ortam sıcaklığını ve dolaylı olarak bağıl nemi etkilemektedir. Sera ortamında meydana gelen değişimler, sıcaklık ve bağıl nem sensörü ile toprak nem sensörü tarafından ölçülerek sistem çıkışını oluşturmaktadır. Çevresel etkilerden ve sensörlerden kaynaklanan ölçüm gürültüsünü içeren bu veriler, Kalman filtresinden geçirilir ve yeniden makine öğrenmesi modellerine geri beslenmektedir. Böylece sensör ölçümü, veri filtreleme, makine öğrenmesi tabanlı karar verme ve PLC tabanlı eyleyici kontrolü sürekli olarak tekrarlanarak sistemin güvenilir bir kapalı çevrim yapıda çalışması sağlanmaktadır.

2.3. İletişim Protokolleri

Bu bölümde, gerçek zamanlı sistemin haberleşme tasarımı hakkında bilgiler verilecektir. Mikrodenetleyici, PLC ile Ethernet tabanlı yerel ağ üzerinden Modbus TCP/IP protokolünü kullanarak haberleşmekte; bu iletişimde mikrodenetleyici istemci, PLC ise sunucu olarak çalışmaktadır. Mikrodenetleyici tarafından işlenen sensör verileri, MQTT protokolü yapısı kullanılarak bulut tabanlı IoT platformuna telemetri verisi olarak gönderilmektedir. IoT platformuna aktarılan veriler makine öğrenmesi modelleri tarafından değerlendirilerek motor ve ısıtıcıya ilişkin AÇIK/KAPALI durumları ile PWM kontrol değerleri belirlenmektedir. Üretilen kontrol komutları MQTT aracılığıyla mikrodenetleyiciye geri iletilmekte ve ardından Modbus TCP/IP üzerinden PLC'ye aktarılmaktadır. PLC, alınan komutları sürücü devreleri üzerinden motor ve ısıtıcıya uygulayarak eyleyicilerin güvenilir biçimde kontrol edilmesini sağlamaktadır. Böylece MQTT, mikrodenetleyici ile bulut platformu arasındaki veri alışverişini gerçekleştirirken Modbus TCP/IP, mikrodenetleyici ile PLC arasındaki yerel haberleşmeyi sağlayarak sistemin kapalı çevrim ve çift yönlü çalışmasına olanak tanımaktadır. Şekil 2'de sistemin haberleşme diyagramı verilmiştir.



Şekil 2 Sistem Haberleşme Diyagramı

2.4. Veri Toplama ve İşleme

Bu çalışmada, geliştirilen akıllı sera prototipi üzerinden gerçek zamanlı olarak toplanan sensör okumaları ve üretilen kontrol sinyalleri kaydedilerek bütünleşik bir veri seti oluşturulmuştur. Veri toplama sürecinin sonucunda elde edilen ve toplam 3734 örneklemden oluşan bu veri setinde herhangi bir eksik değer bulunmamaktadır. Veri seti; ortam sıcaklığı, ortam bağıl nemi ve toprak nemi gibi çevresel girdi parametreleri ile su motoru ve ısıtıcı ünitelerine ait çıktı durumlarını (AÇIK/KAPALI ve PWM sinyalleri) zaman damgasıyla senkronize bir biçimde barındırmaktadır. Fiziksel sistem dinamiklerinden kaynaklanan kısıtlar, elde edilen veri setinin karakteristiğini doğrudan etkilemiştir. Örnek olarak, ısıtma süreçlerinin yüksek zaman

sabiti nedeniyle ortam sıcaklığı 25.88 °C ile 27.12 °C arasında değişen dar bir referans bandında seyretmiştir. Benzer şekilde, sulama işlemi sırasında toprak neminin çok hızlı yükselmesi ve ardından kuruma sürecinin uzun zaman alması sebebiyle, su motoru tüm süreç boyunca 20 örneklem içeren bir dilimde aktif durumda kalmıştır. Isıtıcı ünitesi ise ortam sıcaklığını hedeflenen aralıkta tutabilmek adına sürecin yaklaşık %47'sinde devrede olmuştur. Kaydedilen bu eşzamanlı girdi ve çıktı verileri, çalışmada önerilen makine öğrenmesi ve kontrol algoritmalarının eğitilmesi ve sistem performansının test edilmesi amacıyla kullanılmıştır.

Çevresel gürültüyü azaltmak ve makine öğrenmesi modeline arındırılmış veri sunmak için mikrodenetleyici ağ geçidinde tek boyutlu ayrık Kalman Filtresi uygulanmıştır [15]. Bu filtreleme algoritması, öngörü (tahmin) ve düzeltme (güncelleme) adımlarından oluşmakta olup sırasıyla Denklem (1), (2), (3), (4) ve (5) ile ifade edilmektedir:

$$\hat{y}_s^- = \theta_s \hat{y}_{s-1} + b_s u_s \quad (1)$$

$$p_s^- = \theta_s^2 p_{s-1} + q_s \quad (2)$$

$$k_s = \frac{p_s^- h_s}{h_s^2 p_s^- + r_s} \quad (3)$$

$$\hat{y}_s = \hat{y}_s^- + k_s(z_s - h_s \hat{y}_s^-) \quad (4)$$

$$p_s = (1 - k_s h_s) p_s^- \quad (5)$$

Denklem (1), herhangi bir yeni sensör ölçümünden önce sistemin önceki durumunu ($\hat{y}_{s-1}$) ve bilinen dış kontrol girişlerini (u_s) kullanarak s anında mevcut durumun öngörülen tahminini ($\hat{y}_s^-$) hesaplar. Ardından, Denklem (2), tahminin belirsizliğini temsil eden öngörülen tahmin kovaryansını (p_s^-) hesaplar. Bu adım, önceki iterasyondan kaynaklanan belirsizliğin sistem modeli boyunca nasıl yayıldığını gösterir ve yapısal süreç gürültüsünü (q_s) modele dahil eder. Denklem (3), öngörülen tahmine kıyasla yeni elde edilen sensör ölçümüne (z_s) verilen ağırlık derecesini belirleyen kritik bir matematiksel faktör olan Kalman kazancını (k_s) türetir. Bunu takiben Denklem (4), mevcut zaman adımı için nihai filtrelenmiş çıktı olarak görev yapan optimum güncellenmiş durum tahminini ($\hat{y}_s$) üretir. Son olarak Denklem (5), yeni ölçümü entegre ettikten sonra belirsizlikteki azalmayı tanımlayarak güncellenmiş durum tahmini kovaryansını (p_s) günceller. Bu algoritmanın yürütülmesiyle sistem, gürültülü sensör verilerinden net, zamana bağlı ve daha yumuşatılmış çevresel eğilimler elde eder.

2.5. Makine Öğrenmesi Modeli

Bu bölümde çalışma kapsamında ele alınan makine öğrenmesi modeli ile ilgili bilgiler verilmektedir.

2.5.1 Sınıflandırma Modeli

Sistemdeki sulama motoru ve ısıtıcının AÇIK/KAPALI kararlarını belirlemek için iki bağımsız ikili Destek Vektör Sınıflandırması (SVC) modeli kullanılmıştır [4], [6]. Girdi değişkenleri vektörü Denklem (6)'da verilmiştir:

$$x_t = [T_t, RH_t, SM_t, H_{t-1}, M_{t-1}]^T \quad (6)$$

Burada T_t ortam sıcaklığını, RH_t ortam nemini, SM_t toprak nemini, H_{t-1} ısıtıcının önceki durumunu ve M_{t-1} motorun önceki durumunu ifade eder. Isıtıcı ve motor için karar fonksiyonları sırasıyla Denklem (7)'de gösterilmiştir:

$$\hat{H}_t = f_H(\mathbf{x}_t) \qquad \hat{M}_t = f_M(\mathbf{x}_t) \quad (7)$$

Burada H_t ve M_t sırasıyla ısıtıcı ve motor için karar fonksiyonlarını temsil etmektedir.

SVM sınıflandırıcıları verilerin ölçeklerine duyarlı olduğundan, StandardScaler yöntemi ile tüm girdi özellikleri Denklem (8)'de gösterildiği şekilde standardize edilir:

$$z = \frac{\rho - \mu}{\sigma} \quad (8)$$

Burada ρ orijinal özellik değerini, μ ortalama değeri, σ standart sapmayı ve z standardize edilmiş değeri temsil eder.

SVC modelinin doğrusal karar fonksiyonu ve sınıflandırma kararı sırasıyla Denklem (9) ve (10) ile tanımlanır:

$$f(\lambda) = w^T \lambda + b \quad (9)$$

$$\hat{y} = \begin{cases} 1, & f(\lambda) \geq 0 \\ 0, & f(\lambda) < 0 \end{cases} \quad (10)$$

Burada λ girdi değişkenlerini, w ağırlık vektörünü, b sapma değerini ve $f(\lambda)$ karar fonksiyonunu belirtir. y ise modelin ürettiği sınıflandırma kararını (AÇIK için 1, KAPALI için 0) temsil eder.

Doğrusal olmayan karar sınırları oluşturmak için Radyal Tabanlı Fonksiyon (RBF) çekirdeği Denklem (11) ve (12) ile modellenmiştir:

$$K(x_i, x_j) = exp(-\gamma \|x_i - x_j\|^2) \quad (11)$$

$$f_c(x_j) = \sum_{i=1}^{N} \alpha_i \, y_i K(x_i, x_j) + b \quad (12)$$

Burada $K(x_i, x_j)$ iki farklı girdi örneği (x_i ve x_j) arasındaki benzerliği ölçen çekirdek fonksiyonunu, γ çekirdek genişlik parametresini ve $\|x_i - x_j\|^2$ karesel Öklid uzaklığını ifade eder.

Model eğitimindeki asıl optimizasyon problemi, sınıflandırma hatalarını kontrol altında tutarken marjini maksimize etmeyi hedefleyen Denklem (13)'te verilmiştir:

$$\min_{w,b,\xi} \frac{1}{2}\|w\|^2 + C \sum_{i=1}^{n} \xi_i \quad (13)$$

Sera sisteminin dinamik gereksinimleri nedeniyle mekanik kararsızlığı önlemek adına (örneğin eyleyicinin AÇIK'tan KAPALI duruma geçişi) Asimetrik Örneklem Ağırlıkları (q_i) kullanılarak optimizasyon problemi Denklem (14)'deki gibi güncellenmiştir:

$$\min_{w,b,\xi} \frac{1}{2} \| w \|^2 + C \sum_{i=1}^{N} q_i \, \xi_i \quad (14)$$

Optimizasyon formüllerindeki $\frac{1}{2}\|w\|^2$ marjini yüksek tutmaya çalışan temel ifadeyi, ξ_i marjin ihlalini (hata miktarını), C

hatalar için cezalandırma çarpanını ve q_i asimetrik örneklem ağırlık parametresini temsil eder.

2.5.2 Regresyon Modeli

Eyleyicilerin çalışması gerektiği anlarda (AÇIK durumu), uygun Darbe Genişliği Modülasyonu (PWM) seviyesini tahmin etmek için Destek Vektör Regresyonu (SVR) kullanılmıştır [9]. Eğitim verisi kümeleri yalnızca eyleyicilerin aktif olduğu örneklerden, Denklem (15) ve (16) ile oluşturulur:

$$D_h = \{(T_q, RH_q, PWM_q) \mid Heaterstatus_q = 1\} \quad (15)$$

$$D_m = \{(SM_q, PWM_q) \mid Motorstatus_q = 1\} \quad (16)$$

Modelin girdi vektörü ve tahmini çıktı değişkeni sırasıyla Denklem (17) ve (18)'de verilmiştir:

$$\mathbf{x}_q = \begin{bmatrix} T_q \\ RH_q \end{bmatrix} \quad (17)$$

$$y_q = PWM_q \quad (18)$$

Burada T_q ortam sıcaklığını, RH_q ortam bağıl nemini, SM_q toprak nemini ve PW_q eyleyicinin PWM değerini gösterir.

Standardizasyon işlemi ayrı ayrı uygulanarak Denklem (19), (20), (21) ve (22) ile verilerin aynı ölçekte olması sağlanmıştır:

$$z_{vj} = \frac{x_{vj} - \mu_j}{\sigma_j} \quad (19)$$

$$z_{v,1} = \frac{T_v - \mu_T}{\sigma_T} \quad (20)$$

$$z_{v,2} = \frac{RH_v - \mu_{RH}}{\sigma_{RH}} \quad (21)$$

$$\mathbf{z}_v = \begin{bmatrix} \frac{T_v - \mu_T}{\sigma_T} \\ \frac{RH_v - \mu_{RH}}{\sigma_{RH}} \end{bmatrix} \quad (22)$$

Burada x_{vj}, v örneğinin j özelliğini; μ_j ve σ_j bu özelliğin sırasıyla ortalama ve standart sapmasını; z_{vj} ise elde edilen ölçeklenmiş değeri ifade eder.

Eğitilen SVR modelinin tahmin fonksiyonu, destek vektörlerinin ağırlıklı toplamı ve RBF çekirdek fonksiyonu ile Denklem (23)'teki gibi ifade edilir:

$$\hat{Q}(\mathbf{z}) = \sum_{v=1}^{N_s} (\alpha_v - \alpha_v^*) \exp(-\gamma \parallel \mathbf{z}_v - \mathbf{z} \parallel^2) + b \quad (23)$$

Burada $Q(z)$ modelin tahmin ettiği düzeltilmiş PWM değerini (ısıtma veya sulama talebini), N_s destek vektörlerinin sayısını, α_v ve α_v^* SVR tarafından öğrenilen katsayıları, z modele sunulan yeni standardize edilmiş girdi vektörünü, z_v eğitim sonucu elde edilen destek vektörlerini ve $(\alpha_v - \alpha_v^*)$ ağırlık katsayısını ifade eder.

SVR modelinin çözdüğü optimizasyon problemi, tahmin hatasını tolerans aralığında tutarken karmaşıklığı dengeleyen Denklem (24) ile verilmiştir:

$$\min_{\mathbf{w},b,\xi_i,\xi_i^*} \frac{1}{2} \parallel \mathbf{w} \parallel^2 + C \sum_{i=1}^{n} (\xi_v + \xi_v^*) \quad (24)$$

Bu süreçteki tolerans kısıtlamaları ise Denklem (25), (26) ve (27) ile tanımlanır:

$$y_i - f(z_v) \leq \varepsilon + \xi_v \quad (25)$$

$$f(z_v) - y_v \leq \varepsilon + \xi_v^* \quad (26)$$

$$\xi_v, \xi_v^* \geq 0 \quad (27)$$

Denklem (28), epsilon limitini aşan hataların cezalandırılmasını ifade eder:

$$C \sum_{v=1}^{n} (\xi_v + \xi_v^*) \quad (28)$$

Burada ε hata tolerans aralığını, ξ_v ve ξ_v^* ise tolerans limitini aşan hataları temsil eden geçici değişkenleri belirtir.

SVR modelinde radyal tabanlı fonksiyon (RBF) çekirdeği kullanılmış olup, hiperparametreler için scikit-learn kütüphanesinin varsayılan yapılandırması esas alınmıştır [16]. Bu tercih, çalışmanın odağının makine öğrenmesi alt modelinin izole biçimde optimize edilmesi değil, PLC–IoT–makine öğrenmesi bileşenlerinin gerçek zamanlı ve gömülü bir donanım üzerinde bütünleşik biçimde çalışabilirliğinin doğrulanması olmasından kaynaklanmaktadır; bu nedenle hesaplama yükü düşük, yeniden üretilebilir ve az sayıda örnekle aşırı uyum riskini artırmayacak bir temel yapılandırma tercih edilmiştir. Girdi özelliklerinin önceden standardize edilmiş olması (Denklem 19–22) nedeniyle γ = 'scale' seçimi, özellik başına yaklaşık $\gamma \approx 1/n$ değerine karşılık gelmekte ve bu da ısıtıcı modeli ile motor modeli için farklı ama veri ölçeğiyle tutarlı bir çekirdek genişliği sağlamaktadır. Bununla birlikte, sistematik bir hiperparametre optimizasyonunun uygulanmamış olması bu çalışmanın bir kısıtı olarak kabul edilmelidir.

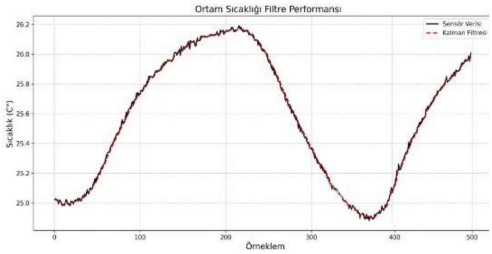
3. Bulgular ve Tartışma

Bu bölümde sistem entegrasyonu sonucunda elde edilen sınıflandırma modeli başarımları ve gerçek zamanlı sistem performansı açıklanmış ve analiz edilmiştir.

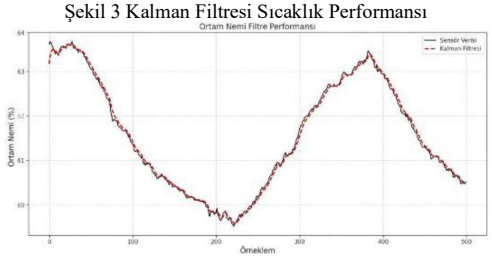
3.1. Sistem Entegrasyonu ve Veri Filtreleme Başarımı

Bu çalışmada PLC, mikrodenetleyici, IoT platformu ve makine öğrenmesi modelleri gerçek zamanlı sistem üzerinde başarılı bir şekilde entegre edilmiştir. Ağ seviyesindeki veri akışı Wireshark uygulaması ile doğrulanmış olup, Modbus TCP/IP ve MQTT protokolleri üzerinden çift yönlü iletişimin sorunsuz çalıştığı kanıtlanmıştır.

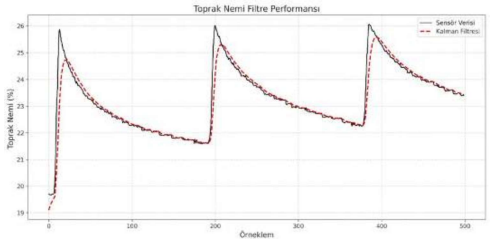
Sensör verilerinin makine öğrenmesi modeline girmeden önce gürültüden mümkün olduğunca arındırılmış hale getirilmesi sistemin başarısı için kritiktir. Uygulanan tek boyutlu Kalman Filtresi, veri dalgalanmasını sıcaklık ölçümlerinde %71.63, nem ölçümlerinde %78.41 ve toprak nemi ölçümlerinde %74.07 oranında azaltmıştır. Bu filtreleme işlemi, sensör verilerinin genel eğilimini korurken, makine öğrenmesi modelleri için daha güvenilir girdiler sağlamıştır. Kalman Filtresinin performansı Şekil 3, 4 ve 5'te gösterilmiştir.



Şekil 3 Kalman Filtresi Sıcaklık Performansı



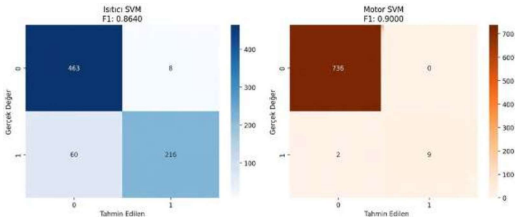
Şekil 4 Kalman Filtresi Ortam Nemi Performansı



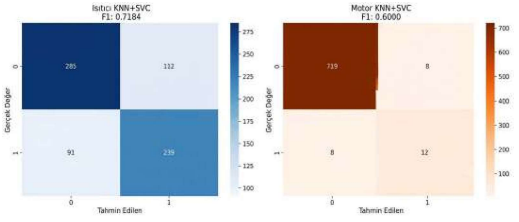
Şekil 5 Kalman Filtresi Toprak Nemi Performansı

3.2. Sınıflandırma Modellerinin Başarımı

Eyleyicilerin AÇIK/KAPALI durumlarını belirlemek için geliştirilen Destek Vektör Sınıflandırması (SVC) modelleri test verileri üzerinde değerlendirilmiştir [8].



Şekil 6 Sınıflandırma SVC Modelinin Hata Matrisi ve F1 Skoru



Şekil 7 KNN+SVC Sınıflandırma SVM Modelinin Hata Matrisi ve F1 Skoru

Kullanılan modellerin F1 skoru ve hata matris çıktıları Şekil 6 ve 7'de verilmiştir. Ele alınan ısıtıcı modeli 0.8640 F1 skoru ile yüksek bir başarım göstermiştir. 463 KAPALI ve 216 AÇIK durumu doğru tahmin eden model, gereksiz ısıtıcı çalışmasını büyük ölçüde engellemeyi başarmıştır.

Ele alınan motor (su pompası) modeli 0.9000 F1-skoru elde etmiş ve yanlış pozitif tahmin (gereksiz sulama) oranını sıfıra indirmiştir.

Bunun yanı sıra gerçekleştirilen zarf testleri, modellerin sınır koşullarında (örneğin sıcaklık alt sınıra düştüğünde ısıtıcının açılması) sistemden beklenen mantıksal ve fiziksel tepkileri tutarlı bir şekilde verdiğini doğrulamıştır.

Çalışma kapsamında SVC modelinin performansını kıyaslamak amacıyla KNN+SVC hibrit modeli de test edilmiştir. Ancak KNN algoritmasının sisteme entegrasyonu, tahmin doğruluğunda belirgin bir düşüşe neden olmuş; hibrit modelin F1-skoru ısıtıcı için 0.7184'e, motor için ise 0.6000'e gerilemiştir. Zarf testlerinde hibrit modelin toprak nemi kritik alt sınıra (%20.2) düştüğünde su pompasını çalıştıramadığı ve güvenli ara sıcaklık aralıklarında (25.5°C) ısıtıcıyı yanlış şekilde kapatarak ısıl sürekliliği bozduğu görülmüştür. KNN algoritmasının anlık dalgalanmalara karşı aşırı duyarlı yapısı karar sınırlarını bulanıklaştırırken, SVC'nin marj maksimizasyonu prensibi uç değerlere karşı kararlı ve daha gürbüz bir otomasyon mantığı sunmuştur.

3.3. Regresyon Modellerinin Başarımı

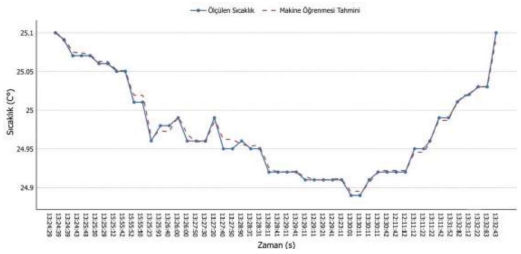
Eyleyicilerin harcayacağı gücü belirleyen Destek Vektör Regresyonu (SVR) modelleri, sistemin sürekli kontrol çıktıları üretmesini sağlamıştır. Isıtıcı için geliştirilen SVR modeli, test verilerinde 2.17 PWM birimlik düşük bir Ortalama Mutlak Hata (MAE) ve 0.8208 R^2 (açıklanabilirlik) değeri sunmuştur. Uygulanan dinamik stres testlerinde, ortam sıcaklığı yükseldikçe (25.0°C'den 26.0°C'ye) modelin ısıtıcı PWM gücünü kademeli ve mantıklı bir şekilde kıstığı gözlemlenmiştir. Su pompası modelinde ise R^2 değeri 1.0000 olarak ölçülmüş olsa da, bu durum veri setindeki aktif pompa örneklerinin azlığından ve PWM değerlerinin dar bir aralıkta (genellikle 99) yoğunlaşmasından kaynaklanmaktadır. SVR modelinin kesintisiz kontrol yeteneğini ağaç tabanlı bir yaklaşımla kıyaslamak için Random Forest (RF) regresyon modeli de değerlendirilmiştir. RF modeli 1.35 PWM birimlik çok düşük bir MAE sunmasına rağmen, genel varyansı SVR kadar pürüzsüz yakalayamamış ve R^2 oranı 0.7255'e düşmüştür. Dinamik stres testlerinde, karar ağaçlarının doğası gereği RF modelinin ayrık ve basamaklı PWM değerleri ürettiği tespit edilmiştir. SVR ise sürekli fonksiyon yapısı sayesinde fiziksel çevresel verilerin soğuma ve doygunluk eğrilerini çok daha hassas ve pürüzsüz bir PWM modülasyonu ile modelleyerek sıcaklık kontrolünde net bir üstünlük göstermiştir. Modellerin sonuçları Tablo 1'de verilmiştir.

Tablo 1 SVR ve RF Model Sonuçları

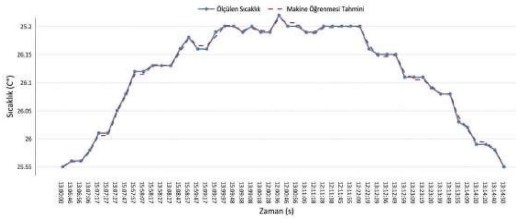
	Test Veri Sayısı	MAE (Mutlak Hata)	MSE (Karesel Hata)	R^2
Isıtıcı RF Model Raporu	351	1.35	10.47	0.7255
Isıtıcı SVR Model Raporu	351	2.17	12.96	0.8208

3.4. Gerçek Zamanlı Sistem Performansı

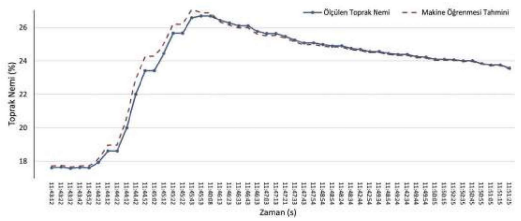
Tasarımı tamamlanan otomasyon sistemi, saha koşullarındaki algoritmik başarımının ve tepki süresinin doğrulanması amacıyla kapsamlı gerçek zamanlı test prosedürlerine tabi tutulmuştur. Bu testler kapsamında, sistemin dinamik çevresel değişimlere verdiği tepkiler; sıcaklık modelinin gerçek zamanlı düşüş ve yükseliş eğrileri ile toprak neminin gerçek zamanlı değişimi Şekil 8, 9 ve 10'da gösterilmiştir.



Şekil 8 Sıcaklık Modelinin Gerçek Zamanlı Yükseliş Eğrisi

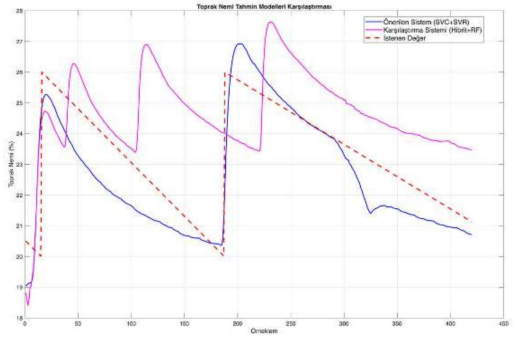


Şekil 9 Sıcaklık Modelinin Gerçek Zamanlı Düşüş Eğrisi



Şekil 10 Toprak Neminin Gerçek Zamanlı Eğrisi

Elde edilen deneysel bulgular ışığında, sistemin karar mekanizmasında görev alan makine öğrenmesi algoritmalarının performansları karşılaştırmalı olarak incelenmiştir. Farklı makine öğrenmesi mimarilerinin sistemin fiziksel davranışı üzerindeki etkilerini bütüncül bir şekilde analiz edebilmek amacıyla, bağımsız gerçek zamanlı test veri setleri tek bir düzlemde birleştirilmiştir. Şekil 11'de sunulan toprak nemi karşılaştırma grafiği bu metodolojiyle oluşturulmuştur. Sistem ilk olarak çalışmanın ana önerisi olan SVC (sınıflandırma) ve SVR (regresyon) modeli ile kontrol edilmiş ardından aynı başlangıç koşullarında, karşılaştırma amacıyla kurgulanmış olan hibrit (KNN+SVC) sınıflandırma ve Random Forest (RF) regresyon modelleriyle çalıştırılmıştır. Elde edilen iki farklı gerçek zamanlı saha verisi, hedeflenen referans nem oranı (İstenen Değer) ile aynı grafik üzerinde çizdirilmiştir.



Şekil 11 ML modelleri ve İdeal Sistem Karşılaştırılması

Bu sayede kullanılan modellerin gerçek zamanlı cevapları karşılaştırılmıştır. Sonuç itibarıyla, kurulan kapalı çevrim sistemin genel verimliliğini ve hesaplama optimizasyonunu maksimize etmek amacıyla tahmin görevlerinde sırasıyla SVC ve SVR modellerinin kullanılması uygun bulunmuştur. Önerilen SVC + SVR modelinin sonucunun istenen değerden farklı olmasının sebebi uygulanan modelin gerçek zamanlı çalışması ve hem iç hem de dış bozucuların dikkate alınmasıdır.

4. Sonuçlar

Bu projede PLC, IoT, Kalman Filtresi ve makine öğrenmesi modellerinin başarıyla entegre edildiği, veriye dayalı bir akıllı sera kontrol mimarisi geliştirilmiştir. Sistem, sadece sabit eşik değerlerine veya kurallara bağlı kalmak yerine, sensör verilerinden öğrenerek kararlar üretebilmekte ve bu sayede kaynak tüketimini en aza indirerek sistemin genel verimliliğini optimize etme potansiyeli taşımaktadır.

Sistemin makine öğrenmesi karar katmanında test edilen alternatif algoritmalar (KNN+SVC ve Random Forest) kıyaslandığında; anlık dalgalanmalara karşı daha gürbüz olan ve ayrık adımlar yerine pürüzsüz sürekli kontrol imkanı sunan SVC+SVR mimarisi tercih edilerek yüksek sistem performansı elde edilmiştir. Bu kapsamda, Random Forest ve SVR gibi birbirinden farklı yapılara sahip algoritmaların gerçek zamanlı uygulamasında karşılaştırmalı analizi sunulmuştur.

Önerilen mimari, IoT destekli veri aktarımı ile endüstriyel PLC güvenilirliğini tek bir hibrit yapıda birleştirerek "Tarım 5.0" konsepti için güçlü bir altyapı sunmaktadır. Çalışmanın başlıca kısıtı, makine öğrenmesi modellerinin eğitiminde kullanılan gerçek sera verisi setinin boyutudur.

Gelecek çalışmalarda, sistemin daha uzun periyotlarda, farklı mevsimsel koşullarda ve daha çeşitli veri setleriyle test edilmesi, önerilen modelin genelleştirme yeteneğini ve ticari ölçekteki seralardaki güvenilirliğini artıracaktır. Ayrıca, bu çalışmada gerçek zamanlı fiziksel uygulama yürütüldüğü ve bu kapsamda 23-27 °C gibi geniş sıcaklık aralıklarına ulaşmak uzun zaman aldığından dolayı testler 25-26 °C'lik dar bir aralıkta tutulmuştur; dolayısıyla sistemin farklı sıcaklık değerlerindeki analizi gelecek çalışmalarda ele alınacaktır.

Kaynakça

[1] J. F. Velasco-Muñoz, J. A. Aznar-Sánchez, A. Batlles-delaFuente ve M. D. Fidelibus, "Sustainable Irrigation in Agriculture: An Analysis of Global Research," *Water*, Cilt: 11, No: 9, Art. no. 1758, 2019.

[2] E. Bwambale, F. K. Abagale ve G. K. Anornu, "Smart Irrigation Monitoring and Control Strategies for Improving Water Use Efficiency in Precision Agriculture: A Review," *Agricultural Water Management*, Cilt: 260, Art. no. 107324, 2022.
[3] G. S. Karabay ve M. Çavaş, "Artificial Intelligence Based Smart Agriculture Applications in Greenhouses," *2024 International Artificial Intelligence and Data Processing Symposium (IDAP)*, 2024.
[4] K. A. Gujar ve S. Jagtap, "Intelligent Irrigation System for Agriculture Using IoT and Machine Learning," *2022 2nd International Conference on Advance Computing and Innovative Technologies in Engineering (ICACITE)*, 2022.
[5] Y. Tace, M. Tabaa, S. Elfilali, C. Leghris, H. Bensag ve E. Renault, "Smart Irrigation System Based on IoT and Machine Learning," *Energy Reports*, Cilt: 8, s:1025-1036, 2022.
[6] Z. Ahmad, O. A. Alwesabi, N. Abdullah, M. A. Omar, B.H. Malik ve G. M. S. Himel, "Support Vector Machines and Intelligent Irrigation Systems: A Scoping Review," *2025 International Conference on Innovation in Artificial Intelligence and Internet of Things (AIIT)*, 2025.
[7] H. Jaiswal, K. R. P., R. Singuluri ve S. A. Sampson, "IoT and Machine Learning Based Approach for Fully Automated Greenhouse," *2019 IEEE Bombay Section Signature Conference (IBSSC)*, 2019.
[8] R. Rajagopal, D. Sumathi, A. Sungheetha, R. Sharma R, S. Mahapatra ve N. Sivakumar, "Explainable AI Model for Automatic Irrigation System Using IoT," *2024 International Conference on IT Innovation and Knowledge Discovery (ITIKD)*, 2025.
[9] Y.-C. Tung, N. W. Syahputri ve I. G. N. A. S. Diputra, "Greenhouse Environment Sentinel with Hybrid LSTM-SVM for Proactive Climate Management," *AgriEngineering*, Cilt: 7, No: 4, s:96, 2025.
[10] A. Risheh, A. Jalili ve E. Nazerfard, "Smart Irrigation IoT Solution Using Transfer Learning for Neural Networks," 2020 10th International Conference on Computer and Knowledge Engineering (ICCKE), 2020.
[11] M. Louta, K. Banti ve I. Karampelia, "Emerging Technologies for Sustainable Agriculture: The Power of Humans and the Way Ahead," *IEEE Access*, Cilt: 12, s:98492-98529, 2024.
[12] T. Benahmed, A. Bourouis, A. Touhami, K. Benahmed ve C. Sabri, "Greenhouse Irrigation System Based IoT," *2024 4th International Conference on Embedded & Distributed Systems (EDiS)*, 2024.
[13] B. Hoxha ve Q. Kabashi, "Design and Implementation of a PLC-Based Greenhouse Climate Control System," 2026 8th International Congress on Human-Computer Interaction, Optimization and Robotic Applications (ICHORA), 2026.
[14] M. J. S. Jas, K. Elavarasi ve B. Sabeshna, "IoT and Machine Learning-Driven Greenhouse Framework for Smart and Sustainable Agriculture," *2026 Second International Conference on Multi-Agent Systems for Collaborative Intelligence (ICMSCI)*, 2026.
[15] R. Faragher, "Understanding the Basis of the Kalman Filter Via a Simple and Intuitive Derivation," *IEEE Signal Processing Magazine*, Cilt: 29, No: 5, s:128-132, 2012.
[16] A.K. Agirman ve K. Tasdemir, "Spatio-temporal Object Features for Wildfire Detection in Dark Videos," *Erciyes Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, Cilt: 38, No: 3, s:434-445, 2022.