

Fotovoltaik Verilerin Tahminlemesinde Hiper-Parametre Etkisinin İncelenmesi

Examination of Hyper-Parameter Effect on Estimation of Photovoltaic Data

 Fikriye Ataman¹

¹ Van Yüzüncü Yıl Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Van, Türkiye.
fataman@yyu.edu.tr

Öz: Günümüzde yenilenebilir enerji kaynaklarına olan ihtiyaç her gün biraz daha artmaktadır. Bu çalışmanın amacı yenilenebilir enerji kaynağı olan fotovoltaik enerji üretiminde, kullanılan tahminleme modelleri için uygun hiper-parametre seçiminin tespit edilmesidir. Çalışma kapsamında gerçek bir fotovoltaik veri seti üzerinde tahminleme yapılmaktadır. Tahminleme için kullanılan dört model seçilmiş ve bu modellerin başarımına etki eden hiper-parametrelerin bulunarak modellerin fotovoltaik veriler için alan adaptasyonu araştırılmıştır. Seçilen modeller Gause Süreç Regresyonu (GSR), Çekirdek Ridge Regresyonu (ÇRR), Destek Vektör Regresyonu (DVR), Çok Katmanlı Algılayıcı (ÇKA)'dır. Yapılan çalışma sonucunda fotovoltaik verilerde kullanılan tahmin modellerinde hiper-parametre optimizasyonunun model başarısına önemli bir etkisi olduğu bulgusuna ulaşılmıştır. GSR modeli %99.9, ÇRR modeli %99.9, DVR modeli %99.4 ve ÇKA modeli %89.3 başarı göstermiştir. Bu çalışma ile, modellerde kullanılan hiper-parametre seçiminin, model tahmin başarısını doğrudan etkilediği ve fotovoltaik verilerin tahminlemesinde kullanılması gereken hiper-parametreler ortaya konulmuştur. Bu çalışma, fotovoltaik veri tahmini üzerinde çalışan diğer çalışmalara önemli bir katkı sağlayacaktır.

Anahtar Kelimeler: Fotovoltaik Enerji, Tahminleme, Yapay Zeka, Hiper-parametre

Abstract: Nowadays, the need for renewable energy resources is increasing daily. This study aims to determine the appropriate hyper-parameter selection for the prediction models used in photovoltaic energy production, a renewable energy source. Within the scope of the paper, predictions are made on a real photovoltaic data set. Four models used for estimation were selected and the field adaptation of the models for photovoltaic data was investigated by finding the hyper-parameters affecting the performance of these models. The used models are Gause Process Regression (GPR), Kernel Ridge Regression (KRR), Support Vector Regression (SVR), and Multilayer Perceptron (MLP). As a result of the study, it was found that hyper-parameter optimization has a significant impact on model success in prediction models used in photovoltaic data. The GPR model showed 99.9% success, the KRR model 99.9%, the SVR model 99.4%, and the MLP model 89.3%. With this study, it has been revealed that the hyper-parameter selection used in the models directly affects the model prediction success and the hyper-parameters that should be used to predict photovoltaic data. This study will significantly contribute to other studies on photovoltaic data prediction.

Key words: Photovoltaic Energy, Forecasting, Artificial Intelligence, Hyper-parameter

1. Giriş

Dünya genelinde enerji kaynağı olarak fosil kaynaklar kullanılmaktadır. Petrol, kömür ve doğal gaz bu kaynakların başlıcalarıdır. Fosil yakıtların, tüketim sonrası atmosfere saldıkları sera gazları, radyoaktif tanecikler ve diğer zararlı atıklar dünya ekosistemine zarar vermektedir. Dünya genelinde fosil yakıtlar hala başı çekmektedir. Ancak alternatif olan yenilenebilir enerji kaynaklarında büyük bir ilerleme gerçekleşmiştir. Dünya çapında, enerji kaynağı olarak yenilenebilir enerji kaynaklarına doğru tercihler artmaktadır.

Günümüzde rüzgar enerjisi, güneş enerjisi vd. yenilenebilir enerji üretim sistemlerinin kurulması ve sürdürülebilir enerji sistemlerinin ortaya çıkarılması oldukça önemlidir. Küresel ısınma ve çevre sorunlarının üstesinden gelebilmek için dünya çehresini yenilenebilir enerji kaynaklarına yöneltmiştir. Dolayısıyla yenilenebilir enerji kaynaklarına olan ihtiyaç her gün gittikçe artmaktadır. Dünya ülkelerinin bu konuda teşvik edici birçok girişimi bulunmaktadır. Dünya ekosisteminin sürdürülebilir bir yaşam döngüsü içinde devam edebilmesi için bu girişimlere daha çok ihtiyaç olduğu tartışmasız açıktır [1].

Fotovoltaik (FV) enerji, güneş ışığından üretilen bir enerjidir. FV enerji; güneş ışığının silikon, kadmium, galyum, bakır indiyum diselenid, tellurid ve arsenit gibi yarı iletken malzemeler üzerine düşürülmesi sonucu elektronların ayrışması yöntemiyle doğru akım enerjisine dönüşmesidir [2]. FV enerji sistemlerinin kurulmasında farklı yöntemler vardır. Devrelerin seri veya paralel bağlanması, ana şebekeye bağlı olup olmaması gibi farklı kurulum türleri vardır. FV enerji sistemlerinde verimlilik birçok faktörden etkilenmektedir. Ortamın nemi, ısı, havadaki kir miktarı [3], panellerin eksen konumları, yönleri, panel miktarları, panellerin bağlanma modelleri gibi birçok farklı faktör vardır [3], [4]. Bir FV sistemi kurulması oldukça maliyetli bir işlemdir [2]. Dolayısıyla kurulum öncesi tahmini verilere sahip olmak, üretim tahminlerini yapabilmek oldukça önem kazanmaktadır. Yatırımcılar, kurulum maliyeti yüksek olan bu sistemleri yüksek verimle çalıştırmalarını isterler. Dolayısıyla güneş ışınım şiddeti veya sıcaklık gibi çevre koşulları ile verimi değişen FV sistemlerin üreteceği maksimum gücün tespiti ve üretime dair tahminlerin gerçekleştirilmesi giderek artan bir ihtiyaçtır.

FV enerji üretim tahmininde kullanılan birçok yöntem mevcuttur. Bu yöntemlerin başında yapay zeka modelleri gelmektedir. Kullanılan yapay zeka tahmin modellerinin hangi durumlarda nasıl bir performans gösterdiğini ifade eden hiper-parametreleri vardır. Tahminleme için kullanılacak verinin de model başarımına ayrıca çok büyük bir etkisi vardır. Güneş enerjisi verisi doğrusal olmayan bir üretim süreci göstermektedir. Üretilen enerji miktarı gün içerisindeki çevresel faktörlere, güneş ışığı miktarına göre değişmektedir. Dolayısıyla bazı durumlarda iyi üretim yapan santral, bazı

zamanlarda çok düşük üretim yapabilmektedir. Dolayısıyla güneş enerjisi sistemlerinde elde edilen veriler ile tahminleme yaparken kullanılan hiper-parametrelerin seçimi de oldukça önem kazanmaktadır.

Bu çalışma ile güneş enerjisi üretim tahmininde hiper-parametre seçiminde alan adaptasyonu araştırılmaktadır. Bu çalışma kapsamında, güneş enerjisi verisinde tahminleme yaparken hiper-parametre etkisine odaklanılmıştır.

Güneş enerjisi verisi tahminlemede kullanılan birçok yapay zeka modeli vardır. İstatistiksel makine öğrenmesi yöntemleri, derin ağ modelleri ve hibrit kullanılan modeller ile karşılaşılmaktadır. Yapay sinir ağları (YSA), Rastgele Orman (RO/ Random Forest (RF)), Uzun-Kısa Süreli Bellek (UKSB / Long Short Term Memory (LSTM)), Aşırı Gradyan Artışı, ÇKA, AdaBoost, DVR, K- En Yakın Komşu Algoritması (K-EYKA / K-Nearest Neighbours (K-NN)), GSR, ÇRR sıklıkla kullanılan makine öğrenmesi ve yapay zeka algoritmalarıdır [5], [6], [7], [8], [9], [10], [11], [12], [13], [14], [15], [16]. Literatürde güncel olarak kullanılan yöntemleri yer aldığı bazı bilimsel çalışmalar şunlardır:

Tobishima vd. yaptıkları çalışmada FV enerji üretimini tahmin etmek için yapay sinir ağlarını kullanmışlardır [7]. YSA ve RO, uydu verilerine dayalı güneş radyasyonu tahmini için bir sinir ağına kullanılması özellikle vurgu yapılarak, verilerden elde edilen verileri ve uydu gözlem verilerini kullanarak güneş radyasyonunu tahmin etmek için çalışmada tanıtılmış ve kullanılmıştır [7]. Akal tarafından yapılan çalışmada FV panellerde üretilen enerji miktarı tahminlemek için DVR kullanılmıştır [9]. RO, DVR, K-EYKA, YSA, ESA, RNN, UKSB, Geçitli Tekrarlayan Birimler (GRU) yine başka bir çalışmada birlikte kullanılarak karşılaştırılmışlardır [12]. Gallardo ve ark. tarafından yapılan çalışmada, doğrusal regresyon, lojistik regresyon, DVR, karar ağaçları, RO gibi makine öğrenmesi algoritmalarının yanı sıra İleri Beslemeli Yapay Sinir Ağları, Tekrarlayan Sinir Ağları, ESA ve topluluk yöntemleri gibi derin öğrenme algoritmaları kullanılmıştır. Klasik makine öğrenmesi modeller ile derin öğrenme modellerini birleştiren hibrit modeller ele alınmıştır [15]. Yapay Sinir Ağı (YSA) ve Destek Vektör Makinesi (DVM), karmaşık ve doğrusal olmayan modelleri ele alma yetenekleri nedeniyle FV enerji tahmininde topluluk modelleri için yaygın olarak kullanılmaktadır. Rahimi ve ark. tarafından yapılan çalışmada rekabetçi ve işbirlikçi topluluk tahmin modelleri ele alınmıştır. Enerji tahminleme için, makine öğrenmesi yöntemlerinden Liner Regresyon, Lojistik Regresyon, Uzak Vektör Makinesi, RO modelleri kullanılmıştır [16]. Demir tarafından yapılan bir çalışmada doğrusal regresyon, DVM, karar ağaçları, RO ve K-EYKA modelleri kullanılmıştır. Çalışmada RO algoritmasının en iyi sonucu verdiği aktarılmıştır [17]. Kantil Regresyonu ve Kantil Regresyon Ormanı kullanılan diğer iki modeldir [18]. Derin Öğrenme modellerinden Evrişimli Sinir Ağları (ESA) ve Üretici Çekişmeli Ağlar (ÜÇA / Generative Adversarial Network (GAN)) ve UKSB ağ modelleri de sıklıkla kullanılmaktadır [19], [20]. Başka bir çalışmada ise ÜÇA ile uydudan türetilmiş güneş ışıması verileri üzerinde Uzamsal Kriging enterpolasyonu kullanılarak tahminleme yapılmıştır [19]. Venkateswaran ve ark. tarafından yapılan çalışmada Tekil Spektrum Analizi (SSA), ESA ve UKSB ağları kullanılarak tahminleme yapılmıştır [20]. Maduabuchi ve ark. tarafından yapılan bir çalışmada ise yapay sinir ağlarının hiper-parametre etkisi araştırılmıştır [21]. İslam ve ark. tarafından yapılan çalışmada enerji tahmininde kullanılmak üzere, ESA ve parçacık sürü optimizasyon algoritması kullanılmıştır [22]. FV

güc çıkışının tahmin edilmesinde UKSB ağı, DVR, RO, Gradyan Artırıcı Ağaçlar ve Markov Zinciri algoritmaları kullanılmıştır. FV enerji üretim sisteminin çalışma prensiplerine dayanan prensip tabanlı tahmin yöntemlerinden de bahsedilmiştir [23]. Makine öğrenimi algoritmaları, Levenberg-Marquardt algoritması, İleri Beslemeli Geri Yayımlı Sinir Ağı, Tam Bağlantılı İleri Beslemeli Geri Yayımlı Sinir Ağı, Momentum Ağırlıklı Gradyan İniş öğrenme fonksiyonunu yine başka bir çalışmada birlikte kullanılmıştır [24].

FV verilerin tahminlemesi ile ilgili yapılan bu çalışmada literatürde sıklıkla kullanılan yöntemlerden Gauss Süreç Regresyonu, Çekirdek Ridge, Regresyonu, Destek Vektör Regresyonu, Çok Katmanlı Algılayıcı model kullanarak bu modellerin alan adaptasyonu üzerinde durulmaktadır. Literatürde yer alan çalışmalara bakıldığında bu modellerin kullanıldığı ancak bu modeller için en iyi sonuçları verecek parametre seçeneklerine dair bilimsel bir verinin bilgisine yer verilmediği tespit edilmiştir. Bu çalışmada FV veri seti üzerinde tahminleme yapılarak, üzerinde çalışılan dört model için alan adaptasyonu sağlanarak literatürde yer alan bu eksikliğin giderilmesi amaçlanmıştır. Ayrıca, en sık kullanılan bu modellerin başarımına etki eden hiper-parametrelerin bulunmasıyla modellerin FV veriler için alan adaptasyonu araştırılmıştır. Çalışma sonucunda FV verilerde kullanılan tahmin modellerinde hiper-parametre optimizasyonunun model başarısına önemli bir etkisi olduğu bulgusuna ulaşılmıştır. GSR modeli %99.9, ÇRR modeli %99.9, DVR modeli %99.4 ve ÇKA modeli %89.3 başarı göstermiştir. Bu çalışma ile, modellerde kullanılan hiper-parametre seçiminin, model tahmin başarısını doğrudan etkilediği ve FV verilerin tahminlemesinde kullanılması gereken hiper-parametreleri ortaya koymuştur. Bu çalışmadan elde edilen bulguların, diğer güneş enerjisi verilerinin tahmini üzerinde de bir fikir vereceği ve alandaki diğer araştırmacılara önemli bir katkı sağlayacağı düşünülmektedir.

2. Materyal ve yöntem

2.1. Veri seti

Bu çalışma kapsamında anlık FV verilerden derlenmiş bir veri seti kullanılmıştır. Veri seti “Yulara” adıyla <https://dkasolarcentre.com.au/download?location=yulara> adresinden temin edilmiştir. Yulara Güneş Sistemi, Orta Avustralya'daki Uluru'da (Ayers Rock) dağıtılmış 1,8 MW'lık dağıtık bir güneş FV tesisidir. Veri seti, 2024 yılına ait Yulara Güneş Paneli Sistemine ait 5 dk. ölçümlerden oluşan 31270 kayıt içermektedir [25]. Veri setinde dağıtık yapıdaki 7 farklı kurulum üzerinden bilgi akışı sağlanmaktadır. Toplam 7 kaynağa ait güç, akım ve enerji ölçümleri ve çevresel faktörler ile toplam üretim bilgileri mevcuttur. Veri setindeki tüm parametreler kullanılmamıştır. Veri setinden 11_LD_PV1_DB_LD_1A_Current_Phase_Average_Mean, 11_LD_PV1_DB_LD_1A_Active_Energy_Delivered_Received, 11_LD_PV1_DB_LD_1A_Active_Power değişkenlerine ait veriler kullanılarak analizler yapılmıştır. Veri seti %20 Test, %80'i eğitim verisi olmak üzere rasgele olarak bölünerek kullanılmıştır.

2.2. Kullanılan yöntemleri

2.2.1. Gauss Süreç Regresyonu(GSR)

GSR çok değişkenli ve doğrusal olmayan problem çözümlerine uygulanabilen bir regresyon modelidir.

Parametrik olmayan bir yöntem olup küçük veri setleri üzerinde etkin olarak kullanılmaktadır [26]. Sonuçlar üzerinde belirsizlik ölçümlerine dayalı olarak tahmin yapmaktadır. Sonuçları oluşturan fonksiyonun, Gausse Süreci olduğu varsayımına dayanır. Dolayısıyla GSR yöntemi, eğitim verisi ile tahmin edilen değişkenlerin olasılık dağılımının tahmini sonuçları ile formüle edilebilir [27], [28], [29], [30], [31], [32].

$$\begin{pmatrix} Y \\ \hat{Y} \end{pmatrix} \sim N(0, \delta)$$

δ : Kovaryans matrisi, N : Gauss dağılım fonksiyonu

X_{train} : Eğitim verisi, X_{test} : Test verisi

Ortak dağılımın ortalama değeri, genellikle kaybetmeden sıfır olarak kabul edilecektir. Çıktı dağılımı sıfırdan farklı bir ortalama civarında olsa bile, varsayımı karşılamak için ortak dağılımdan sıfır ortalama değerinin çıkarılabileceğine dikkat edilmelidir. K , K^* , K^{**} test ve eğitim verilerinden oluşan kombinasyonlar olmak üzere kovaryans matrisi δ Eşitlik 1 ve kombinasyonları Eşitlik 2 ile verilmektedir.

$$\delta = \begin{pmatrix} K & K^* \\ K^T & K^{**} \end{pmatrix} \quad (\text{Eşitlik 1})$$

$$K = K(X_{train}, X_{train})$$

$$K^* = K(X_{train}, X_{test}) \quad (\text{Eşitlik 2})$$

$$K^{**} = K(X_{test}, X_{test})$$

Kovaryans matrisi, pozitif sonlu çekirdek fonksiyonu ile Eşitlik 3'te verildiği şekilde hesaplanır:

$$K(x, x') = -\lambda \exp\left(-\frac{1}{2\sigma^2} \|x - x'\|_2^2\right) \quad (\text{Eşitlik 3})$$

Eşitlikteki λ ve σ GSR modelinin hiper-parametreleridir ve x ve x' girdi çiftleridir. GSR girilen eğitim veri setinin dağılımı üzerinden test verisi için bir dağılım tahminler. Girdi çiftleri arasındaki benzerlik ise K çekirdek fonksiyonu ile bulunur [27], [28], [29], [30], [31], [32]. x ve x' girdi çiftleri arasındaki mesafe veya benzerlik çekirdek fonksiyonu ile ölçülür. GSR, eğitim verilerine dayanarak test verilerinin yeni dağılımını tahmin etmeyi amaçlamaktadır. Bunun için Bayes kuralı sırayla dağılım fonksiyonun beklenen değerine ve kovaryansına aşağıda verilen Eşitlik 4 ve Eşitlik 5 ile uygulanır.

$$E(Y|Y, X_{train}, X_{test}) = K^* K^{-1} Y \quad (\text{Eşitlik 4})$$

$$\delta(Y|Y, X_{train}, X_{test}) = K^{**} - K^* K^{-1} K^* \quad (\text{Eşitlik 5})$$

Tahminlenen verinin dağılımı Eşitlik 4 ve Eşitlik 5 ile sağlanır. GSR modeli yalnızca tahminin beklenen değerini göstermekle kalmaz, aynı zamanda modelin tahminlerine güven sınırları vererek ilişkili bir varyans da sağlar. GSR, yalnızca eğitim verilerine güvenmek yerine, bunları tahminlerde bulunmak için açıkça kullanır [27], [28], [29], [30], [31], [32].

GSR için kullanılan farklı çekirdek fonksiyonları mevcuttur. Bu çalışma kapsamında kullanılan çekirdek fonksiyonları denklemleri ile birlikte Tablo 1'te verilmektedir.

2.2.2. Çekirdek Ridge Regresyonu (ÇRR)

Çekirdek Ridge Regresyonu (ÇRR), çekirdek kullanılan regresyon yöntemlerinden biridir. Temel amaç, bağımsız değişken x_i ile bağımlı değişken y_i arasında bağımlılığı modelleyen doğrusal bir fonksiyon bulmaktır. Doğrusal fonksiyonu bulmanın yöntemi ikinci derece (quadratic) maliyetini en aza indirmektir [33], [34], [35], [36], [37]. Maliyet fonksiyonu Eşitlik 6 ile verilmektedir.

x_i : Bağımsız değişken

y_i : Bağımlı değişken

w_i : Ağırlık matrisi

λ, α : Model parametresi, olmak üzere;

$$C(w) = \frac{1}{2} \sum_{i=1}^n (y_i - w^T x_i)^2 \quad (\text{Eşitlik 6})$$

Ancak, eğer $x_i \rightarrow \Phi(x_i)$ 'ye giden bir özellik uzayında çalışırsak, aşırı uyum problemi ile karşılaşılır ve aşırı uyum problemini bertaraf etmek için veriyi düzenli hale getirmek gerekir. Veriyi düzenli hale getirmek için w ağırlık yüklerini cezalandırma yöntemi kullanılır [33], [34], [35], [36], [37]. α ve λ model hiper-parametreleri olup, α düzenlemenin şiddetini ayarlarken λ değeri, modelin esnekliğinin ne kadar cezalandırılacağını belirtmektedir. α 'nın değeri artarsa model daha düzgün bir forma girip, daha anlaşılır ve kolay olur ancak bazı özniteliklerin gözden kaçmasına da neden olabilir. Buna karşın α değeri azalır ise daha fazla öznitelik ele alınabilir ancak bu durumda model karmaşıklaşır [33], [34], [35], [36], [37]. Cezalandırma yöntemi olarak en çok tercih edilen çapraz doğrulama ve birini dışarıda bırakma yöntemleridir. Dolayısıyla toplam maliyet fonksiyonu Eşitlik 7 ile minimize edilmektedir.

$$C(w) = \frac{1}{2} \sum_{i=1}^n (y_i - w^T x_i)^2 + \frac{1}{2} \lambda \|w\|^2 \quad (\text{Eşitlik 7})$$

Eşitlik 7'nin türevleri alınıp sıfıra eşitlenir ve sonuç olarak ağırlık fonksiyonu w , Eşitlik 8 ile gösterildiği gibi elde edilir.

$$w = \left(\lambda I + \sum_i x_i x_i^T \right)^{-1} \left(\sum_j y_j x_j \right) \quad (\text{Eşitlik 8})$$

Düzenleme terimi, en küçük özdeğerleri sıfırdan sınırlandırarak tersinin sayısal olarak kararlı hale getirilmiş oldu. Ancak veri noktaları kendi özellik vektörleriyle değiştirildiğinde ($x_i \rightarrow \phi_i = \phi(x_i)$), boyutların sayısı veri noktalarının sayısından çok daha büyük olacaktır [33], [34], [35], [36], [37]. Özellik alanının boyutluluğunu veya veri noktalarının sayısını azaltarak, en iyi şekilde tersini elde etmek için Eşitlik 9 ile verilen teknik kullanılır.

$$(P^{-1} + B^T R^{-1} B)^{-1} B^T R^{-1} = P B^T (B P B^T + R)^{-1} \quad (\text{Eşitlik 9})$$

Eşitlik 9 ile verileni uygulamak için $\Phi = \Phi_{ai}$ ve $y = y_i$ olarak tanımlanır. Çözüm Eşitlik 10'daki gibi dönüşür.

$$w = (\lambda I + \Phi \Phi^T)^{-1} (\Phi y) = (\Phi (\Phi^T \Phi + \lambda I))^{-1} y \quad (\text{Eşitlik 10})$$

Bu Eşitlik 10'da $\alpha = (\Phi^T \Phi + \lambda I_n)^{-1} y$ alınmak üzere $w = \sum_i \alpha_i \Phi(x_i)$ olacaktır. Bu denklem, w gibi alternatif bir formda ifade edilebilir ve aslında potansiyel olarak sonsuz uzunlukta olabilecek özellik vektörlerine erişim gerektirmediğini gösterir. Test için tahmin edilen değere ihtiyaç duyulur [33], [34], [35], [36], [37]. Bu tahmin çözüm üzerindeki projeksiyonu (w) ile Eşitlik 11 ile belirlenir.

$$y = w^T \Phi(x) = y(\Phi^T \Phi + I_n)^{-1} \Phi^T \Phi(x) = y(K + I_n)^{-1} k(x) \quad (\text{Eşitlik 11})$$

Eşitlik 11 ile verilen K ve k ifadeleri $K(bx_i, bx_j) = \Phi^T(x_i) \Phi(x_j)$ ve $\Phi(x) = k(x_i, x)$ şeklindedir. Sadece K çekirdeğine erişim sağlamak gerekiyor. ÇRR ile kullanılan farklı çekirdek fonksiyonları mevcuttur. Bu çalışma kapsamında Lineer, Polinom, Sigmoid ve Radyal Temel Fonksiyon (RBF), Laplacian, Kosinüs çekirdeklerinin etkisine bakılmıştır. Kullanılan çekirdeklerin denklemleri Tablo 2'de verilmektedir. Verinin durumuna göre daha az faktör ve sayısal karmaşıklık sağlayacak uygun çekirdeğin seçilmesi önemlidir.

2.2.3. Çok Katmanlı Algılayıcı

Çok Katmanlı Algılayıcı (ÇKA), geri yayılım olarak bilinen algoritmayı kullanan denetimli öğrenme yöntemidir. ÇKA birden fazla düğümden oluşan ağ modelidir. Her bir düğüm doğrusal olmayan bir aktivasyon fonksiyonuna sahip bir nörondur. Bir ÇKA, bir giriş katmanı, bir veya daha fazla gizli katman ve bir çıkış katmanı dahil olmak üzere en az üç nöron katmanından oluşur. Bu katmanlar birbirine bağlıdır ve bilginin giriş katmanından çıkış katmanına akmasına izin vererek modelin öğrenmesini ve tahmin yapmasını sağlar [38], [39], [40], [41], [42], [43], [44]. Algılayıcı, ağırlıklı gerçek değerli girdilerin doğrusal bir kombinasyonunu alır ve çıktı (y) oluşturmak için doğrusal olmayan bir aktivasyon fonksiyonundan geçirir. φ aktivasyon fonksiyonu, b bias, x_i giriş vektörü, w_i ağırlık vektörü olmak üzere y_i çıktısı Eşitlik 12 ile hesaplanmaktadır.

$$y = \varphi\left(\sum_{i=1}^n x_i \cdot w_i\right) + b \quad (\text{Eşitlik 12})$$

ÇKA algoritması ile birlikte birçok farklı aktivasyon fonksiyonu kullanılmaktadır. Hiperbolik tanjant, lojistik sigmoid ve ReLU fonksiyonları sıklıkla kullanılan aktivasyon fonksiyonlarıdır [38], [39], [40], [41], [42], [43], [44]. Bu çalışma kapsamında kullanılan aktivasyon fonksiyonları ve denklemleri Tablo 3'de verilmektedir. ÇKA algoritması, çıkış hatasını en aza indirmek için gizli katmanın ağırlıklarını günceller. Gerçek hata değeri $O_n(t)$ ve istenen hata değeri T_n

olmak üzere, aradaki fark dikkate alınarak hata fonksiyonu Eşitlik 13'deki gibi yazılır.

$$E(O_n(t)) = T_n - O_n(t) \quad (\text{Eşitlik 13})$$

Eğitim, hata değerinin minimize edilmesiyle sağlanmaktadır. Bunun için öğrenme oranı denilen bir eşik değeri belirlenerek, yinelemeli hesaplama adımları optimum yakınsamayı yakalayacak şekilde sınırlanır. Bir katmandan sonraki katmana geçişte ağırlıklar güncellenir. Ağırlıkların güncellenmesi t birim zamanı, w_{ij} ağırlıklar olmak üzere göstermek üzere Eşitlik 14 ile gösterilmektedir.

$$w_{ij}(t+1) - w_{ij}(t) = E(O_j(t)) \quad (\text{Eşitlik 14})$$

2.2.4. Destek Vektör Regresyonu

Destek Vektör Regresyonu (DVR), sınıflandırma ve regresyon analizi için mevcut verilerin analiz edilmesinde kullanılan istatistiksel öğrenmeye dayalı denetimli bir öğrenme modelidir [45], [46], [47], [48]. DVR algoritması, iki farklı sınıftan birine ait olarak etiketlenmiş eğitim verilerini kullanarak, her yeni verinin hangi sınıflandırma sınıfına ait olduğunu belirleyen bir model tasarlar [49], [50], [51].

DVR, verileri sınıflandırmak için yüksek boyutlu bir özellik alanına eşler. Bir hiperdüzlem, sınıflar arasında ayırıcı olarak kullanılır ve kenar boşluğu adı verilen belirli bir mesafe içinde mümkün olduğu kadar çok veri noktasından geçer. Sonuç olarak, tahmindeki hata azaltılır ve bir çekirdek fonksiyonu yardımıyla, girdi ile hedef değişkenler arasındaki doğrusal olmayan ilişki yakalanır [52], [53], [54], [55], [56].

$$T = \{(x_1, y_1), (x_2, y_2), (x_3, y_3), \dots, (x_N, y_N)\} \quad \text{test verisi}$$

olmak üzere; her bir gerçek özellik olan (x_i, y_i) noktaları için DVR ile tahmini bir $(x_i, \hat{y}_i)$ noktası hesaplanır. Tahmini noktalar ile gerçek noktalar arasındaki minimum sapmanın elde edilmesi hedeflenir. Tahmin fonksiyonu $f(x)$; w ağırlık vektörü, $\varphi(x)$ x verisinin özellik fonksiyonu ve b bir sabit olmak üzere Eşitlik 15 ile modellenir [47], [48], [49], [50], [51], [52], [53].

$$f(x) = w^T \varphi(x) + b \quad (\text{Eşitlik 15})$$

Uygun regresyon fonksiyonunu elde etmek için dışbükey optimizasyon probleminin Eşitlik 16 ile çözülmesi gerekir:

$$\min \frac{1}{2} \|w\|^2 = \begin{cases} y_i - w^T \varphi(x_i) - b \leq \varepsilon \\ -y_i + w^T \varphi(x_i) + b \leq \varepsilon \end{cases} \quad (\text{Eşitlik 16})$$

Tüm noktalar Eşitlik 16'daki kısıtları sağlamayabilir. Bu durumda kısıtlar Eşitlik 17'deki gibi gevşetilerek tüm noktalara uyumlu bir fonksiyon bulunur.

$$\min \frac{1}{2} \|w\|^2 + C \sum_{i=1}^N (\xi_i + \xi_i^*) \text{ s.t. } \begin{cases} y_i - w^T \varphi(x_i) - b \leq \varepsilon + \xi_i \\ -y_i + w^T \varphi(x_i) + b \leq \varepsilon + \xi_i^* \end{cases} \quad (\text{Eşitlik 17})$$

Eşitlik 17'de C , model karmaşıklığını ve eğitim seti hatasını dengeleyen ve aşırı uyumun önlenmesine yardımcı olan

önceden belirlenmiş bir cezadır. Burada, ξ_i ve ξ_i^* sırayla pozitif gevşetme parametresi ve negatif gevşetme parametresi olarak yer almaktadır ve $\forall i \in N$ için $\xi_i, \xi_i^* > 0$ olur. Bu optimizasyon problemi $\beta_i, \beta_i^* \in [0, C]$ Lagrange çarpanı olmak üzere Eşitlik 18 ile verilen Karush-Kuhn-Tucker (KKT) koşulunda ikili probleme dönüştürülerek çözülür.

$$\begin{aligned} \max & -\frac{1}{2} \sum_{i,j=1}^N (\beta_i - \beta_i^*)(\beta_j - \beta_j^*) \varphi(x_i)^T \varphi(x_j) \\ & - \varepsilon \sum_{i=1}^N (\beta_i - \beta_i^*) + \sum_{i=1}^N y_i (\beta_i - \beta_i^*) \quad (\text{Eşitlik 18}) \\ \text{s.t.} & \begin{cases} \sum_{i=1}^N (\beta_i - \beta_i^*) = 0 \end{cases} \end{aligned}$$

Bu ikili problem çözümünden sonra, $k(x_i, x_j) = \varphi(x_i)^T \varphi(x_j)$ doğrusal olmayan problemleri doğrusal bir yöntemle çözmeye olanak sağlayan bir çekirdek olmak üzere, DVR algoritması Eşitlik 19'daki hale gelir.

$$f(x) = \sum_{i=1}^N (\beta_i - \beta_i^*) k(x_i, x_j) + b \quad (\text{Eşitlik 19})$$

Tablo 1'de GSR modelinde kullanılan çekirdek fonksiyonları ve denklemleri gösterilmektedir. Tablo 1'de Eşitlik 20 ile RationalQuadratic, Eşitlik 21 ile Matern, Eşitlik 22 ile RBF, Eşitlik 23 ile ExpSineSquared, Eşitlik 24 ile DotProduct ve Eşitlik 25 ile WhiteKernel çekirdek fonksiyonları gösterilmektedir.

Tablo 2'de Çekirdek Ridge Regresyonu modelinde kullanılan çekirdek fonksiyonları gösterilmektedir. Tablo 2'de Eşitlik 26 ile rbf, Eşitlik 27 ile poly, Eşitlik 28 linear, Eşitlik 29 ile polynomial, Eşitlik 30 ile laplacian, Eşitlik 31 ile sigmoid, Eşitlik 32 ile cosine çekirdek fonksiyonu gösterilmektedir.

Tablo 3'de ÇKA ile kullanılan aktivasyon fonksiyonları gösterilmektedir. Tablo 3'de Eşitlik 33 ile Sigmoid (logistic), Eşitlik 34 ile Lineer (identity), Eşitlik 35 ile Hiperbolik Tanjant (tanh), Eşitlik 36 ile Sinüs, Eşitlik 37 ile ReLU (relu) aktivasyon fonksiyonları verilmektedir.

Modellerin başarımlarını değerlendirmesi için hata istatistikleri kullanılmıştır. Başarım ölçütü olarak hata istatistiklerinden Determinasyon Katsayısı (The Coefficient of Determination - R^2), Ortalama Mutlak Hata (Mean Absolute Error - MAE), Ortalama Mutlak Yüzde Hata (Mean Absolute Percentage Error - MAPE), Ortalama Kare Hata (Mean Squared Error - MSE) istatistikleri kullanılmıştır. Hata istatistiklerinin matematiksel denklemleri Tablo 4'te sırayla Eşitlik 38, Eşitlik 39, Eşitlik 40 ve Eşitlik 41 ile verilmiştir.

Tablo 1: GSR modelinde kullanılan çekirdekler

Formülü	Eşitlik No
---------	------------

$k(x_i, x_j) = (1 + \frac{d(x_i, x_j)^2}{2\alpha l^2})^{-\alpha}$ d : öklid uzaklığı, $l > 0$: çekirdeğin uzunluğu, $\alpha > 0$: karışıklık ölçeği	(Eşitlik 20)
$k(x_i, x_j) = \frac{1}{\Gamma(v)2^{v-1}} \left(\frac{\sqrt{2vd}(x_i, x_j)}{l} \right)^v K_v \left(\frac{\sqrt{2vd}(x_i, x_j)}{l} \right)$ K_v : modifiye bessel fonksiyonu, d : öklid uzaklığı, Γ : gamma fonksiyonu, v : matern parametresi	(Eşitlik 21)
$k(x_i, x_j) = e^{-\left(\frac{d(x_i, x_j)^2}{2l^2} \right)}$ $l > 0$: uzunluk ölçeği	(Eşitlik 22)
$k(x_i, x_j) = e^{-\left(\frac{2 \sin^2 \left(\frac{\pi d(x_i, x_j)}{p} \right)}{l^2} \right)}$ p : çekirdeğin periyodu d : öklid mesafesi l : uzunluk ölçeği	(Eşitlik 23)
$k(x_i, x_j) = \sigma_0^2 + x_i x_j, x \sim N(0, \sigma_0^2)$	(Eşitlik 24)
$k(x_i, x_j) = \begin{cases} \sigma^2, x_i = x_j \\ 0, x_i \neq x_j \end{cases}$	(Eşitlik 25)

Tablo 2: ÇRR modelinde kullanılan çekirdek fonksiyonları

Formülü	Eşitlik No
$f(x, y) = e^{-\gamma \ x - y\ ^2}, \gamma = \sigma^{-2}$	(Eşitlik 26)
$f(x, y) = (\gamma x^T y + C_0)^d$	(Eşitlik 27)
$f(x, y) = x^T y$	(Eşitlik 28)
$f(x, y) = (\gamma x^T y + C_0)^d$	(Eşitlik 29)
$f(x, y) = e^{(-\gamma \ x - y\ _1)}$	(Eşitlik 30)
$f(x, y) = \tanh(\gamma x^T y + C_0)$	(Eşitlik 31)
$f(x, y) = \frac{xy^T}{\ x\ \ y\ }$	(Eşitlik 32)
γ : eğim C_0 : kesişme noktası d : çekirdeğin derecesi	

Tablo 3: Aktivasyon fonksiyonları

Formülü	Aralık	Eşitlik No
$f(x) = \sigma(x) = \frac{1}{1 + e^{-x}}$	(0,1)	(Eşitlik 33)

Formülü	Aralık	Eşitlik No
$f(x)=x$	$(-\infty, +\infty)$	(Eşitlik 34)
$f(x)=\frac{e^x - e^{-x}}{e^x + e^{-x}}$	$(-1,1)$	(Eşitlik 35)
$f(x)=\sin(x)$	$(-1,1)$	(Eşitlik 36)
$f(x)=\begin{cases} 0, x < 0 \\ x, x \geq 0 \end{cases}$	$[0, +\infty)$	(Eşitlik 37)

Tablo 4’de yer alan n örneklemin boyutu, y tahmini değerler, y gerçek değerler, i sıra indisi ve $\bar{y}$ gerçek değerlerin ortalamasıdır.

Tablo 4: Hata fonksiyonları

Formülü	Eşitlik No
$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (\bar{y} - y_i)^2}$	(Eşitlik 38)
$MAE = \frac{1}{n} \sum_{i=1}^n y_i - \hat{y}_i $	(Eşitlik 39)
$MAPE = \frac{1}{n} \sum_{i=1}^n \left \frac{y_i - \hat{y}_i}{y_i} \right \cdot 100$	(Eşitlik 40)
$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$	(Eşitlik 41)

3. Bulgular

Bu çalışma kapsamında 4 model için en iyi sonuçları verecek model parametreleri aranmıştır. Elde edilen bulgular her model için ayrı başlıklar altında aşağıda detaylı yorumlanarak açıklanmaktadır. Modellerin başarımlarını ölçütü olarak hata istatistiklerinden Determinasyon Katsayısı (The Coefficient of Determination - R^2), Ortalama Mutlak Hata (Mean Absolute Error - MAE), Ortalama Mutlak Yüzde Hata (Mean Absolute Percentage Error - MAPE), Ortalama Kare Hata (Mean Squared Error - MSE) istatistikleri kullanılmıştır.

3.1. Gausse süreç regresyonu (GSR)

GSR modeli için kullanılan çekirdek kümesi Tablo 5’de verilmektedir. GSR modeli için farklı 10 hibrit çekirdek kullanılmıştır. Bunun yanında alfa hiper-parametresi için {1e-5, 1e-6, 1e-7, 1e-8, 1e-9, 1e-10} kümesi üzerinde arama yapılmıştır. Toplam 60 parametre kombinasyonu üzerinde veri seti ile model eğitilmiştir. Eğitilen modelin arama uzayındaki en iyi 10 sonuca ait parametreler ve modelin test başarımları, eğitim başarımları ve tüm başarımların değerleri Tablo 6’da verilmektedir. Ayrıca en iyi 10 sonuca ait hata istatistikleri Tablo 7 ile verilmektedir. Toplam 60 arama kombinasyonu içerisinde en iyi sonuçları kernel5 çekirdeği vermiştir. Alfa parametresi küçüldükçe başarımların arttığı gözlemlenmektedir. GSR modeli için Tablo 6’dan en iyi 10 sonuç değerine

bakıldığında, bunun 3’ü kernel5, 3’ü kernel9, 3’ü kernel6, 1’i ise kernel3 olarak gözlemlenmiştir. Bu sonuçlar ele alındığında GSR modelinde sırayla kernel5, kernel9, kernel6 ve kernel3 en başarılı çekirdekler olduğu gözlemlenmektedir ve etkin yüksek başarılı bir tahminleme yapmaktadır. Alfa hiper-parametresi küçüldükçe tercih edilen çekirdeğe bağlı olarak daha doğru bir tahminleme yapmaktadır. Dolayısıyla alfa hiper-parametresinin küçük değerleri daha yüksek başarılı bir tahminleme yapmaktadır.

GSR modeli genel başarımlarına bakıldığında R^2 değerleri 1’e oldukça yakındır. FV verilerin tahminlemesinde tercih edilebilir yüksek performanslı bir sonuç vermektedir. Araştırmacılar için Tablo 6’da verilen opsiyonların kullanılması önerilir. GSR modelinin en iyi 10 sonucu için hata metrikleri Şekil 1 ile gösterilmektedir. Şekil 1’e bakıldığında GSR modelinin yüksek bir başarımla sağladığı gözlemlenmektedir. En iyi ilk 10 sonucun tüm parametreler için %99 ile çok iyi düzeyde model başarımları sağlanmıştır. Bu parametreler ile GSR modeli en iyi sonuçları vererek uyum sağlamaktadır. Dolayısıyla benzer veri grupları ile çalışacak araştırmacılar için Tablo 6 ile verilen parametreler önerilmektedir.

Tablo 5: GSR yönteminde kullanılan hibrit çekirdekler


kernel1 = 1.0 * ExpSineSquared(1.0, 5.0, periodicity_bands=(1e-2, 1e1)) + WhiteKernel(1e-1)
kernel2 = 1.0 * RationalQuadratic(length_scale=1.0, alpha=0.1, alpha_bands=(1e-5, 1e15))
kernel3 = 1.0 * ExpSineSquared(length_scale=1.0, periodicity=3.0, length_scale_bands=(0.1, 10.0), periodicity_bands=(1.0, 10.0),)
kernel4 = ConstantKernel(0.1, (0.01, 10.0)) * (DotProduct(sigma_0=1.0, sigma_0_bands=(0.1, 10.0)))**2)
kernel5=1.0*Matern(length_scale=1.0,length_scale_bands=(1e-1, 10.0), nu=1.5)
kernel6 = 1.0 *RBF(length_scale=1.0,length_scale_bands=(1e-1, 10.0))
kernel7 = DotProduct() + WhiteKernel()
kernel8 = (2.0**2 * RBF(length_scale=100.0)* ExpSineSquared(length_scale=1.0, periodicity=1.0, periodicity_bands="fixed"))
kernel9 = 0.5**2 * RationalQuadratic(length_scale=1.0, alpha=1.0)
kernel10 = 0.1**2 * RBF(length_scale=0.1) + WhiteKernel(noise_level=0.1**2, noise_level_bands=(1e-5, 1e5))

Tablo 6: GSR modeli parametre optimizasyon sonuçları

	KÇ	Alfa	Test Başarısı	Eğitim Başarısı	Tüm Başarım
1	Kernel5	1e-10	0.9999995666753888	0.9999996360999129	0.9999995635757206
2	Kernel5	1e-09	0.9999993720640215	0.999999416616922	0.9999993522051118
3	Kernel 9	1e-10	0.9999991425491173	0.999999084232051	0.999998266195003
4	Kernel6	1e-10	0.9999988329861459	0.9999987419472298	0.9999985289073444
5	Kernel5	1e-08	0.9999977180188296	0.9999979337167189	0.999997930758589
6	Kernel9	1e-09	0.9999894678970781	0.9999870519888565	0.99998195195435
7	Kernel6	1e-09	0.9999894676756663	0.9999870517483663	0.9999819515134415
8	Kernel3	1e-08	0.9999862033596446	0.9999841103752487	0.9999777414578157
9	Kernel6	1e-08	0.9999861981838991	0.999984238183998	0.99997808875239
10	Kernel9	1e-08	0.9999861941766368	0.9999842331458716	0.9999780787411638

Tablo 7: GSR modeli parametre optimizasyon sonuçlarına ait hata ölçümleri

Sonuç	R ²	MAPE	MAE	MSE
1	0.9999995635757193	0.02714814417670158	9.293850874592236e-07	4.826169993321797e-12
2	0.9999993522051117	0.1402433073012991	1.178109353997412e-06	7.163598336677436e-12
3	0.999998266193544	5.8506300311038935	2.204208828301445e-06	1.1869911212674655e-11
4	0.9999985289067767	6.278921824531058	2.862304771350019e-06	1.6267990314584437e-11
5	0.999997973075859	1.6025772945703567	2.0861408564890825e-06	2.2414610965196905e-11
6	0.9999819526649717	32.9663816453031	8.897877740341748e-06	1.9957530004966646e-10
7	0.9999819515133506	32.960938644615766	8.897726940794216e-06	1.995880351777695e-10
8	0.9999777414922322	25.1803979003369	9.803625993680196e-06	2.4614428442969144e-10
9	0.9999780887530689	28.119319085944472	1.0439913266969644e-05	2.4230412267848463e-10
10	0.9999780787313216	28.057909628087046	1.0418991121948402e-05	2.424149475309963e-10




Şekil 1: GSR modeli en iyi 10 sonuç için hata değerleri

3.2. Çekirdek Ridge Regresyon

Çekirdek Ridge Regresyon modelinde çekirdekler için { 'linear', 'poly', 'polynomial', 'rbf', 'laplacian', 'sigmoid', 'cosine' } ve alfa parametresi için {0.001, 0.01, 0.1, 0.5, 1.0, 1.5, 2.0} kümesi kullanılmıştır. Model eğitiminde 7*7=49 farklı kombinasyonda en iyi 10 sonucu veren parametreler Tablo 6'da gösterilmektedir. Elde edilen bulgulardan en iyi 10 sonuçtan 4'ü laplacian, 3'ü sigmoid, 3'ü rbf çekirdeği ile sonuçlanmıştır. En iyi sonuçları sırayla laplacian, sigmoid ve rbf çekirdekleri vermiştir. Ayrıca alfa hiper-parametresine bağlı olarak, tüm çekirdekler için alfa parametresi küçüldükçe daha başarılı sonuçlar verdiği gözlemlenmiştir. Dolayısıyla bu alanda

çalışma yapacak araştırmacılara yönelik, daha küçük alfa değerleri ile laplacian çekirdeğini öncelikli olarak tercih etmeleri önerilmektedir. ÇRR modelinin en iyi 10 sonucu veren parametreler ile modelin gösterdiği test başarımı, eğitim başarımı ve tüm başarım değerleri Tablo 8'da verilmektedir. ÇRR modelinin en iyi 10 sonuç için hata değerleri Tablo 9'da verilmektedir. Ayrıca hataların değişimleri Şekil 2 ile gösterilmektedir. Şekil 2'ye bakıldığında ilk 8 parametre sonuçlarının yakın bir aralıkta uyum sağladığı gözlemlenirken, son iki parametre seçeneğinde bir ivme kazanmaktadır. Bu durumda ÇRR modelinin fit olabileceği sınırlı parametre aralıklarının olduğunu söylenebilir. Buna rağmen ilk on parametre sonuçları %99'luk bir başarım sağlamaktadır. Bu da modelin oldukça uyumlu bir model olduğunu göstermektedir. Bu çalışma ile özellikle, model ile kullanılabilecek hiper-parametrelerin seçimi için öneri sunmaktadır. Ayrıca, göreceli olarak ÇRR modelinin çalışmada ele alınan diğer modellere göre performansı ortaya koyulmuştur. FV verileri tahminleme yapacak araştırmacıların kullanacağı başarılı modellerden biri olarak önerilir.



Şekil 2: ÇRR modeli için hata değerleri

Tablo 8: ÇRR modeli parametre optimizasyon sonuçları

Sonuç	Çekirdek	Alfa	Test Başarısı	Eğitim Başarısı	Tüm Başarım
1	laplacian	0.001	0.9999987980460636	0.9999998794470555	0.9999996695638114
2	sigmoid	0.001	0.9999839556191499	0.9999863018702193	0.9999858475415098
3	laplacian	0.01	0.9999830860537541	0.9999900947533114	0.9999887351807252
4	rbf	0.001	0.9999615457754577	0.9999733911439811	0.9999710941026322
5	sigmoid	0.01	0.9998899121754008	0.9999043246986568	0.9999015347481939
6	rbf	0.01	0.9997996077359167	0.9998771869227109	0.999862138856716
7	laplacian	0.1	0.9992639719281444	0.9995665898619557	0.9995078873980036
8	rbf	0.1	0.998213491427882	0.9985560065827508	0.9984896387403313
9	laplacian	0.5	0.9937112722605406	0.9956992974656395	0.9953137689097676
10	sigmoid	0.1	0.9933306326088064	0.9923097269683065	0.9925084744423972

Tablo 9: ÇRR modeli parametre optimizasyon sonuçlarına ait hata ölçümleri

Sonuç	R ²	MAPE	MAE	MSE
1	0.9999996695638114	0.0020068661776795576	3.8695107881889684e-07	3.654107456617858e-12
2	0.9999858475415098	47.941600229388435	1.092281172170866e-05	1.5650405698072931e-10
3	0.9999887351807252	0.008611630323888472	1.7524640543848124e-06	1.2457128341945425e-10
4	0.9999710941026322	27.036120999662106	1.0294452928521803e-05	3.196540171347161e-10
5	0.9999015347481939	126.22611508688267	2.808792304618609e-05	1.0888716889679125e-09
6	0.999862138856716	49.39217539714162	1.7638856096801332e-05	1.5245286349976073e-09
7	0.9995078873980036	0.15906116889612903	1.3680571080890003e-05	5.441995732193181e-09
8	0.9984896387403313	101.57200917118983	5.764198397807113e-05	1.6702233382851197e-08
9	0.9953137689097677	3.200260003124837	6.003163483068043e-05	5.182238676606316e-08
10	0.9925084744423963	847.8405060880547	0.0002461248586839819	8.284455619851612e-08

3.3. Çok Katmanlı Algılayıcı Ağ

Çok katmanlı algılayıcı ağ modeli için gizli katman sayısı için {25,50,75,100,125,150,175,200}, aktivasyon fonksiyonu için {'identity', 'logistic', 'tanh', 'relu'}, optimizasyon fonksiyonu için {'lbfsg', 'sgd', 'adam'}, alfa değeri için {1e-3, 1e-4, 1e-5, 1e-6, 1e-7, 1e-8, 1e-9, 1e-10} ve öğrenme oranı için {'constant', 'invscaling', 'adaptive'} kümesi üzerinde arama yapılmıştır. Bu parametrelerin çapraz eğitimi sonucu toplam $8 \times 3 \times 8 \times 3 \times 4 = 2304$ farklı parametre kombinasyonu üzerinde model eğitilmiştir. En iyi sonucu veren ilk 10 sonuç Tablo 10'da yer almaktadır. Tanh fonksiyonu ve lbfsg optimizasyon fonksiyonu 50 gizli katman ile en iyi sonucu birlikte vermiştir. Alfa değerinin küçüldükçe başarımlarının düştüğü gözlemlenmektedir. ÇKA modelinde alfa hiper-parametresinin büyük değerleri daha yüksek bir

başarımlar sağlamıştır. ÇKA modelinin başarımlarını gösteren hata metrikleri Tablo 11'de verilmiştir. En iyi 10 sonuca ait hata metriklerinin değişimleri ise Şekil 3 ile gösterilmektedir. Şekil 3' baktığında en iyi 10 sonuç için hataların ilk üç parametre seçeneğinden sonra keskin kırılmalar göstererek arttığı görülmektedir. Bu da modelin yeterince esnek olmadığını göstermektedir. R² değeri ilk üç parametre seçeneği için 0,88 değerini göstermiştir. Model başarımları da %89-%87 arasında kalmıştır. Ayrıca, ÇKA modelinin optimizasyonu diğer modellere göre daha fazla bir iş yükü yaratmıştır. Dolayısıyla diğer modeller göz önüne alındığında, ÇKA modelinin tercih edilmemesi önerilmektedir. Buna karşın model tercih edecek araştırmacılara, model ile en iyi sonuçları veren hiper-parametreler verilerek, araştırmacıların daha güvenilir bir sonuca erişimleri sağlanmaktadır.

Tablo 10: ÇKA parametre optimizasyon sonuçları


Sonuç	of	af	alfa	gks	öo	Test Başarımı	Eğitim Başarımı	Tüm Başarım
1	lbfgs	tanh	0.001	50	constant	0.8931093262511726	0.8775163094415739	0.8805523105648849
2	lbfgs	tanh	0.001	50	invscaling	0.8931093262511726	0.8775163094415739	0.8805523105648849
3	lbfgs	tanh	0.001	50	adaptive	0.8931093262511726	0.8775163094415739	0.8805523105648849
4	lbfgs	tanh	0.0001	50	constant	0.892603808542023	0.8768380744642525	0.8799076514554283
5	lbfgs	tanh	0.0001	50	invscaling	0.892603808542023	0.8768380744642525	0.8799076514554283
6	lbfgs	tanh	0.0001	50	adaptive	0.892603808542023	0.8768380744642525	0.8799076514554283
7	lbfgs	tanh	1e-05	50	constant	0.8925496893108172	0.8767691633599937	0.8798416166995398
8	lbfgs	tanh	1e-05	50	invscaling	0.8925496893108172	0.8767691633599937	0.8798416166995398
9	lbfgs	tanh	1e-05	50	adaptive	0.8925496893108172	0.8767691633599937	0.8798416166995398
10	lbfgs	tanh	1e-06	50	constant	0.8925442423357038	0.8767622620146029	0.8798349981729631

of : optimizasyon fonksiyonu, af : aktivasyon fonksiyonu, öo : öğrenme oranı, gks : gizli katman sayısı

Tablo 11: ÇKA modeli parametre optimizasyon sonuçlarına ait hata ölçümleri

Sonuç	R2	MAPE	MAE	MSE
1	0.8805523105648684	3246.695656629084	0.0009996845577681752	1.3209046333891184e-06
2	0.8805523105648684	3246.695656629084	0.0009996845577681752	1.3209046333891184e-06
3	0.8805523105648684	3246.695656629084	0.0009996845577681752	1.3209046333891184e-06
4	0.8799076514554319	3241.297389150151	0.0010021640693171653	1.3280335549165085e-06
5	0.8799076514554319	3241.297389150151	0.0010021640693171653	1.3280335549165085e-06
6	0.8799076514554319	3241.297389150151	0.0010021640693171653	1.3280335549165085e-06
7	0.8798416166995481	3241.2777857555634	0.0010024341465225855	1.328763796040671e-06
8	0.8798416166995481	3241.2777857555634	0.0010024341465225855	1.328763796040671e-06
9	0.8798416166995481	3241.2777857555634	0.0010024341465225855	1.328763796040671e-06
10	0.8798349981729998	3241.2807559016705	0.0010024612786627663	1.328836986593165e-06

ÇKA Modeli- En İyi 10 Sonuçun Hata Metrikleri



Şekil 3: ÇKA modeli en iyi 10 sonuç için hata değerleri

3.4. Destek Vektör Regresyonu


DVR modelinde en iyi performansı veren parametreler çekirdek=rbf, alfa=0.1, c=100.0 olmuştur ve bu parametreler ile modelin verdiği en iyi başarımlar eğitim, test ve tüm başarımlar için sırayla %99.5, %99.4 ve %99.5 şeklinde gerçekleşmiştir. DVR modelinde çekirdek hiper-parametresi için {'linear', 'poly', 'rbf', 'sigmoid'}, DVR çapı (C) için {0.1, 1, 10, 100} ve Gamma değeri için {1, 0.1, 0.01, 0.001} kümesi kullanılarak çapraz olarak $4 \times 4 \times 4 = 64$ sonuç için başarımlar durumlarına bakıldı. Toplam 64 sonuç içerisinde, DVR modeli için en iyi sonucu veren ilk 10 parametre kümesi ve başarımlar sonuçları Tablo 12 ile gösterilmektedir. En iyi 10 sonucun hata ölçümleri Tablo 13'de verilmiştir. Ayrıca sonuçlara göre hata ölçümlerinin değişimleri Şekil 4 ile gösterilmektedir. Şekil 4'e bakıldığında DVR modelinin ilk 5 parametre seçeneğinde oldukça iyi bir tahminleme gösterirken, 5. parametre sonucundan sonra kırılarak hata oranlarının arttığı görülmektedir. R^2 değerleri 0,99 ile başlayıp, 5. Sonuçta 0,98 ve geri kalan sonuçlarda ise 0,84'den 0,55 kadar düşmektedir. Buna karşın DVR modeli %99-%58 arasında kabul edilebilir bir başarımlar göstererek kullanılabilir. Bu çalışmanın önemli bir katkısı olarak, DVR modelinde kullanılacak en yüksek performanslı hiper parametre seçenekleri ortaya konulmuştur. Kullanılan çekirdek kümesinden rbf çekirdeği en iyi performansı göstermiştir. Alfa hiper-parametresi küçüldükçe aynı çap değeri (C) için model başarımları da düşmektedir. Alfa hiper-parametresinin etkisi kullanılan çap değerine ve çekirdeğe göre değişecektir.

Tablo 12: DVR modeli parametre eğitim-test başarımları sonuçları


No	Çekirdek	Alfa	C	Test Başarısı	Eğitim Başarısı	Tüm Başarım
1	rbf	1.0	10.0	0.9947885454724892	0.9945860582845478	0.9946257796900833
2	rbf	1.0	100.0	0.9947885454724892	0.9945860582845478	0.9946257796900833
3	rbf	0.1	100.0	0.9943255151001058	0.9953749868902075	0.9951716503455275
4	rbf	1.0	1.0	0.9922599192882197	0.9925763015565525	0.9925154698382551
5	rbf	0.1	10.0	0.9816089327446099	0.9836538912576811	0.9832582468208101
6	rbf	0.01	100.0	0.8576946196085322	0.8363315260605095	0.8404906550700277
7	rbf	1.0	0.1	0.851021572879882	0.840320375197682	0.8424097930895271
8	rbf	0.1	1.0	0.8305064105919377	0.8119922070796591	0.8156002741140768
9	rbf	0.01	10.0	0.6201768569996875	0.599396032040385	0.6034605282256147
10	poly	1.0	1.0	0.582824940883486	0.5484956153052433	0.5551937324288759

Tablo 13: DVR modeli parametre optimizasyon sonuçlarına ait hata ölçümleri


Sonuç	R2	MAPE	MAE	MSE
1	0.9946257796900833	0.23969086240215334	0.0681175532310015	0.0053742203099168
2	0.9946257796900833	0.23969086240215334	0.0681175532310015	0.0053742203099168
3	0.9951716503455275	0.2093487711535098	0.06202045871613352	0.004828349654472585
4	0.9925154698382551	0.18960868903664588	0.07236799875199258	0.007484530161744912
5	0.9832582468208101	0.4035427240293038	0.10229500310774213	0.016741753179189942
6	0.8404906550700277	0.8194277738401038	0.26320581921108177	0.15950934492997226
7	0.8424097930895271	0.3528848094724646	0.18698872816123796	0.15759020691047293
8	0.8156002741140768	0.6393706926551627	0.24676187971960056	0.1843997258859233
9	0.6034605282256147	0.5403055057860047	0.3393313955905729	0.3965394717743854
10	0.5551937324288759	0.6992699630346573	0.4693528931221485	0.4448062675711242




Şekil 4: DVR modeli en iyi 10 sonuç için hata değerleri



Şekil 5: Modellerin en iyi 10 sonuç için determinasyon katsayısı (R^2) değişimi



Şekil 6: Modellerin en iyi 10 sonuç için Ortalama Mutlak Hata (MAE) değişimi



Şekil 7: Modellerin en iyi 10 sonuç için Ortalama Kare Hata (MSE) değişimi

4. Sonuç ve tartışma

Bu çalışma kapsamında anlık üretilen FV veriler üzerinde 4 yapay zeka modelinin performansları ve performanslarını etkileyen hiper-parametre faktörleri araştırılmaktadır. Çalışmada, Gauss Süreç Regresyonu, Çok Katmanlı Algılayıcı, Çekirdek Ridge Regresyonu, Destek Vektör Makinesi Regresyonu yöntemleri kullanılmıştır. Anlık verilerden akım tahmini yapılarak, modellerin ne kadar performans gösterdiğine bakılmıştır. Modellerin eğitimi farklı parametreler ile yapılarak, farklı boyutlardaki arama uzaylarında parametre bazında öğrenme düzeylerine bakılmıştır.

Şekil 5, Şekil 6, Şekil 7 ile tüm modellerin hata değişimleri birlikte karşılaştırmalı olarak verilmektedir. Şekil 5, modellerin ilk 10 sonuç için R^2 değerinin değişimini göstermektedir. Şekil 6, modellerin ilk 10 sonuç için MAE hata değerinin değişimini göstermektedir. Şekil 7 ise modellerin ilk 10 sonuç için MSE hata değerinin değişimini göstermektedir. Şekil 5, Şekil 6, Şekil 7'e bakıldığında;

GSR modeli, en iyi 10 sonucu ile tahminleme başarımı en yüksek olan model olup, esneklik konusunda geride kalmaktadır. Dolayısıyla hem tahminleme gücü çok yüksek hem de parametre optimizasyonuna diğer modellere göre ihtiyaç duyan bir model olarak ön plana çıkmaktadır. Bu anlamda bu çalışmanın önemini vurgulamaktadır.

Grafiklerdeki kırılma noktaları göz önünde alındığında ÇRR modelinin en esnek model olduğu söylenebilir. Esneklik bakımından, DVR, GSR ve ÇKA modelleri sırayla ÇRR modelini takip etmektedir. Ancak bu en keskin parametre seçiminin önem bakımından tersi bir sırada olduğu anlamına gelir. Çünkü yapısı gereği esnek olabilen modellerde parametre seçimi de daha esnek olabilmektedir. Ancak keskin kırılmaların olduğu modellerde en iyi sonucu verebilecek parametre seçimi oldukça önem kazanacaktır. Dolayısıyla daha az esneklik gösteren modellerde parametre tahmini daha kritik bir anlam taşıyacaktır. ÇRR modelinin alanda tahminleme yapmak için yüksek başarımı olarak kullanılabilir olduğu hata metriklerinden de gözlemlenmektedir. En iyi tahminleme başarımı gösteren ikinci model olarak, GSR modeli ile yakın bir başarımla sağlanmıştır.

DVR modelinin ÇRR modelinden sonra esnek olan ikinci model olduğu gözlemlenmektedir. Ancak başarımla GSR ve ÇRR modelinin arkasında kalmaktadır. DVR için ilk 10 sonuç için R^2 değerleri 0,99 ile 0,55 arasında değişirken, GSR ve ÇRR modelinde 0,99 da, ÇKA modelinde ise 0,88-0,87 arasında değişmektedir. ÇKA modelinin % 89 ile kabul edilebilir bir test başarımı sağlamasına rağmen, GSR, ÇRR ve DVR modellerine kıyasla tercih edilebilir bir model olmadığını gözlemlenmiştir.

Çalışmanın sonucunda, GSR ve ÇRR modelinin FV verilerin tahmininde daha uygun olduğu gözlemlenmiştir. GSR ve ÇRR modeli daha yüksek bir performans ile tahminlemektedir. DVR Regresyon modelinin ise daha düşük bir performans gösterdiği gözlemlenmiştir. Ancak DVR regresyon modelinin belirli parametre seçeneklerinde, yüksek başarımla göstermesinin parametre seçiminin benzer bir veride performansı etkileyeceği bilgisine ulaşılabilir. ÇKA modeli ise kullanılan diğer modellere göre göreceli olarak daha düşük bir performans sergilemekle beraber etkin ve kabul edilebilir bir başarı sağlamaktadır. Ancak bu çalışmanın bulgularına dayanarak, GSR ve ÇRR modellerinin tercih edilmesi önerilir.

5. Referanslar

- [1] F. Birol, "World Energy Outlook.", 2023. [Çevrimiçi]. URL: <https://iea.blob.core.windows.net/assets/26ca51d0-4a42-4649-a7c0-552d75ddfb2/WorldEnergyOutlook2023.pdf> (Erişim zamanı: 04/05/2024)
- [2] M. Ş. Kalay, "Fotovoltaik Enerji Santrallerinde Panellere Ait Verilerin Uzaktan Erişim ile İzlenmesi ve Kayıt Altına Alınması", Marmara Üniversitesi, 2023.
- [3] M. J. Alshareef, "A Comprehensive Review of the Soiling Effects on PV Module Performance", *IEEE Access*, c. 11, sayı 12, ss. 134623–134651, 2023, doi: 10.1109/ACCESS.2023.3337204.
- [4] C. R. Sarin, G. Mani, A. A. Stonier, G. Peter, P. Kumaresan, ve V. Ganji, "An extensive critique on expert system control in solar photovoltaic dominated microgrids", *IET Renewable Power Generation*, c. 17, sayı 14, ss. 1–16, 2023, doi: 10.1049/rpg2.12875.
- [5] J. Gaboitaolelwe, A. M. Zungeru, A. Yahya, C. K. Lebekwe, D. N. Vinod, ve A. O. Salau, "Machine Learning Based Solar Photovoltaic Power Forecasting: A Review and Comparison", *IEEE Access*, c. 11, sayı April, ss. 40820–40845, 2023, doi: 10.1109/ACCESS.2023.3270041.
- [6] I. Shafi vd., "An Artificial Neural Network-Based Approach for Real-Time Hybrid Wind-Solar Resource Assessment and Power Estimation", *Energies*, c. 16, sayı 10, ss. 1–18, 2023, doi: 10.3390/en16104171.
- [7] R. Tobishima ve S. Urano, "Solar radiation estimation for photovoltaic power generation using Geostationary and Low-Earth Orbit Satellite Data", *2023 IEEE Belgrade PowerTech, PowerTech 2023*, ss. 1–6, 2023, doi: 10.1109/PowerTech55446.2023.10202850.
- [8] L. Visser, T. AlSkaif, J. Hu, A. Louwen, ve W. Van Sark, "On the value of expert knowledge in estimation and forecasting of solar photovoltaic power generation", *Solar Energy*, c. 251, sayı 09, ss. 86–105, 2023, doi: 10.1016/j.solener.2023.01.019.
- [9] O. Akı, T. Tez, ve D. Akal, "Destek Vektör Regresyon (SVR) Yöntemi Kullanılarak Haftalık Dönemde Fotovoltaik Panel Enerji Tahmini", içinde *V. International Agricultural, Biological & Life Science Conference*, Edirne, 2023, ss. 1715–1730. [Çevrimiçi]. Available at: <https://agbiol.congress.gen.tr/files/site/16/files/5thAGBIOL23ConferencesProgram9.pdf>
- [10] M. Phiri, M. Mulenga, A. Zimba, ve C. I. Eke, "Deep learning techniques for solar tracking systems: A systematic literature review, research challenges, and open research directions", *Solar Energy*, c. 262, sayı April, s. 111803, 2023, doi: 10.1016/j.solener.2023.111803.
- [11] O. Gandhi vd., "The value of solar forecasts and the cost of their errors: A review", *Renewable and Sustainable Energy Reviews*, c. 189, sayı October 2023, 2024, doi: 10.1016/j.rser.2023.113915.

- [12]J. Tian, R. Ooka, ve D. Lee, “Multi-scale solar radiation and photovoltaic power forecasting with machine learning algorithms in urban environment: A state-of-the-art review”, *Journal of Cleaner Production*, c. 426, sayı 1, September, s. 139040, 2023, doi: 10.1016/j.jclepro.2023.139040.
- [13]J. F. L. De Oliveira vd., “Forecasting Methods for Photovoltaic Energy in the Scenario of Battery Energy Storage Systems: A Comprehensive Review”, *Energies*, c. 16, sayı 18, ss. 1–20, 2023, doi: 10.3390/en16186638.
- [14]A. M. Assaf, H. Haron, H. N. Abdull Hamed, F. A. Ghaleb, S. N. Qasem, ve A. M. Albarrak, “A Review on Neural Network Based Models for Short Term Solar Irradiance Forecasting”, *Applied Sciences (Switzerland)*, c. 13, sayı 14, 2023, doi: 10.3390/app13148332.
- [15]I. Gallardo, D. Amor, ve Á. Gutiérrez, “Recent Trends in Real-Time Photovoltaic Prediction Systems”, *Energies*, c. 16, sayı 15, ss. 1–17, 2023, doi: 10.3390/en16155693.
- [16]N. Rahimi vd., “A Comprehensive Review on Ensemble Solar Power Forecasting Algorithms”, *Journal of Electrical Engineering and Technology*, c. 18, sayı 2, ss. 719–733, 2023, doi: 10.1007/s42835-023-01378-2.
- [17]B. E. Demir, “A New Low-Cost Internet of Things-Based Monitoring System Design for Stand-Alone Solar Photovoltaic Plant and Power Estimation”, *Applied Sciences*, c. 13, sayı 24, s. 13072, 2023, doi: 10.3390/app132413072.
- [18]L. Visser, T. AlSkaif, J. Hu, A. Louwen, ve W. Van Sark, “On the value of expert knowledge in estimation and forecasting of solar photovoltaic power generation”, *Solar Energy*, c. 251, sayı December 2022, ss. 86–105, 2023, doi: 10.1016/j.solener.2023.01.019.
- [19]H. Wen, Y. Du, X. Chen, E. G. Lim, H. Wen, ve K. Yan, “A regional solar forecasting approach using generative adversarial networks with solar irradiance maps”, *Renewable Energy*, c. 216, sayı October 2022, s. 119043, 2023, doi: 10.1016/j.renene.2023.119043.
- [20]D. Venkateswaran ve Y. Cho, “Efficient solar power generation forecasting for greenhouses: A hybrid deep learning approach”, *Alexandria Engineering Journal*, c. 91, sayı February, ss. 222–236, 2024, doi: 10.1016/j.aej.2024.02.004.
- [21]C. Maduabuchi vd., “Renewable Energy Potential Estimation Using Climatic-Weather-Forecasting Machine Learning Algorithms”, *Energies*, c. 16, sayı 4, 2023, doi: 10.3390/en16041603.
- [22]S. Islam ve N. K. Roy, “Renewables integration into power systems through intelligent techniques: Implementation procedures, key features, and performance evaluation”, *Energy Reports*, c. 9, ss. 6063–6087, 2023, doi: 10.1016/j.egy.2023.05.063.
- [23]H. Wang vd., “Distributed Photovoltaic Power Forecast Methods: A Review”, 2023 *IEEE IAS Industrial and Commercial Power System Asia, I and CPS Asia 2023*, ss. 805–809, 2023, doi: 10.1109/ICPSAsia58343.2023.10294618.
- [24]F. Z. Ennaji, A. El Fazziki, H. El Alaoui Abdallaoui, A. Sadiq, M. Sadgal, ve D. Benslimane, “Multi-agent framework for social CRM: Extracting and analyzing opinions”, içinde *Proceedings of IEEE/ACS International Conference on Computer Systems and Applications, AICCSA*, IEEE Computer Society, Tem. 2016. doi: 10.1109/AICCSA.2016.7945700.
- [25]“Yulara Total of all sites | DKA Solar Centre”. Erişim: 24 Temmuz 2024. [Çevrimiçi]. Available at: <https://dkasolarcentre.com.au/source/yulara/yulara-total-of-all-yulara-sites>
- [26]J. Tian, R. Ooka, ve D. Lee, “Multi-scale solar radiation and photovoltaic power forecasting with machine learning algorithms in urban environment: A state-of-the-art review”, *Journal of Cleaner Production*, c. 426, sayı 09, s. 139040, 2023, doi: 10.1016/j.jclepro.2023.139040.
- [27]J. Wang, “An Intuitive Tutorial to Gaussian Process Regression”, *Computing in Science and Engineering*, c. 25, sayı 4, ss. 4–11, 2023, doi: 10.1109/MCSE.2023.3342149.
- [28]P. S. Palar, L. Parussini, L. Bregant, K. Shimoyama, ve L. R. Zuhail, “On kernel functions for bi-fidelity Gaussian process regressions”, *Structural and Multidisciplinary Optimization*, c. 66, sayı 2, ss. 1–22, 2023, doi: 10.1007/s00158-023-03487-y.
- [29]S. Barthelmé, P. O. Amblard, N. Tremblay, ve K. Usevich, “Gaussian Process Regression in the Flat Limit”, *Annals of Statistics*, c. 51, sayı 6, ss. 2471–2505, 2023, doi: 10.1214/23-AOS2336.
- [30]J. Dearmon ve T. E. Smith, “A Local Gaussian Process Regression Approach, to Mass Appraisal of Residential Properties”, *Journal of Real Estate Finance and Economics*, sayı 0123456789, 2024, doi: 10.1007/s11146-024-09980-5.
- [31]Y. Xie, D. Wu, ve Z. Qiang, “A unifying view for the mixture model of sparse Gaussian processes”, *Information Sciences*, c. 660, sayı May 2023, 2024, doi: 10.1016/j.ins.2024.120124.
- [32]B. Jin ve X. Xu, “Forecasting wholesale prices of yellow corn through the Gaussian process regression”, *Neural Computing and Applications*, c. 36, sayı 15, ss. 8693–8710, 2024, doi: 10.1007/s00521-024-09531-2.
- [33]S. Manzhos ve M. Ihara, “Degeneration of kernel regression with Matern kernels into low-order polynomial regression in high dimension”, *Journal of Chemical Physics*, c. 160, sayı 2, 2024, doi: 10.1063/5.0187867.
- [34]J. Li, Y. Liu, ve W. Wang, “Optimal Rates for Agnostic Distributed Learning”, *IEEE Transactions on Information Theory*, c. 70, sayı 4, ss. 2759–2778, 2024, doi: 10.1109/TIT.2023.3344656.
- [35]L. Tang ve Z. H. Zhang, “Nuclear charge radius predictions by kernel ridge regression with odd-even effects”, *Nuclear Science and Techniques*, c. 35, sayı 2, ss. 1–9, 2024, doi: 10.1007/s41365-024-01379-4.

- [36] A. M. Almarzooqi, M. Maalouf, T. H. M. El-Fouly, V. E. Katzourakis, M. S. El Moursi, ve C. V. Chrysikopoulos, "A hybrid machine-learning model for solar irradiance forecasting", *Clean Energy*, c. 8, sayı 1, ss. 100–110, 2024, doi: 10.1093/ce/ckad075.
- [37] L. Ran, Z. Wang, B. Yang, A. Amiri-Margavi, ve N. Alshahrani, "Development of novel computational models based on artificial intelligence technique to predict the viscosity of ionic liquids-water mixtures", *Case Studies in Thermal Engineering*, c. 54, sayı 1, s. 104076, 2024, doi: 10.1016/j.csite.2024.104076.
- [38] W. Wan ve M. Xu, "The implementation of a multi-layer perceptron model using meta-heuristic algorithms for predicting undrained shear strength", *Multiscale and Multidisciplinary Modeling, Experiments and Design*, c. 7, sayı 3, 2024, doi: 10.1007/s41939-024-00435-1.
- [39] C. Liu vd., "End-to-end methane gas detection algorithm based on transformer and multi-layer perceptron", *Optics Express*, c. 32, sayı 1, s. 987, 2024, doi: 10.1364/oe.511813.
- [40] X. Feng, Y. H. Xiu, H. X. Long, Z. T. Wang, A. Bilal, ve L. M. Yang, "Advancing single-cell RNA-seq data analysis through the fusion of multi-layer perceptron and graph neural network", *Briefings in Bioinformatics*, c. 25, sayı 1, ss. 1–13, 2024, doi: 10.1093/bib/bbad481.
- [41] J. Bak, M. Tai, D. Park, ve S. Jeong, "Subsonic Wind Tunnel Wall Interference Correction Method Using Data Mining and Multi-Layer Perceptron", *International Journal of Aeronautical and Space Sciences*, 2024, doi: 10.1007/s42405-023-00704-2.
- [42] X. Wu, G. Yan, W. Zhang, ve Y. Bao, "Prediction Of Compressive Strength Of High-performance Concrete Using Multi-layer Perceptron", *Journal of Applied Science and Engineering (Taiwan)*, c. 27, sayı 7, ss. 2719–2733, 2024, doi: 10.6180/jase.202407_27(7).0004.
- [43] S. Das, S. Moon, R. Kaur, G. Sharma, P. Kumar, ve U. Lavrenčić Štanger, "Artificial neural network modeling of photocatalytic degradation of pollutants: a review of photocatalyst, optimum parameters and model topology", *Catalysis Reviews - Science and Engineering*, c. 00, sayı 00, ss. 1–35, 2024, doi: 10.1080/01614940.2024.2338131.
- [44] A. Olusola, S. Ali Safaa, P. Prashant, A. Mohammad, ve O. Kaiwartya, "Securing Mobile Edge Computing Using Hybrid Deep Learning Method", *Computers*, c. 13, sayı 25, ss. 1–19, 2024, doi: https://doi.org/10.3390/computers13010025.
- [45] C. S. Jiang, X. Chen, B. Y. Jiang, ve G. Q. Liang, "Hybrid genetic algorithm and support vector regression for predicting the shear capacity of recycled aggregate concrete beam", *Soft Computing*, c. 28, sayı 2, ss. 1023–1039, 2024, doi: 10.1007/s00500-023-09380-6.
- [46] Y. Lin, L. Li, S. Yang, X. Chen, X. Li, ve Z. Zhu, "Performance prediction and optimization of hydrogenation feed pump based on particle swarm optimization-least squares support vector regression surrogate model", *Engineering Applications of Computational Fluid Mechanics*, c. 18, sayı 1, 2024, doi: 10.1080/19942060.2024.2315985.
- [47] Y. Huang, Z. Zhou, M. Li, ve X. Luo, "Prediction of Ground Vibration Induced by Rock Blasting Based on Optimized Support Vector Regression Models", *Computer Modeling in Engineering & Sciences*, c. 139, sayı 3, ss. 3147–3165, 2024, doi: 10.32604/cmescs.2024.045947.
- [48] Y. Zhuo ve T. Morimoto, "A Hybrid Model for Forecasting Realized Volatility Based on Heterogeneous Autoregressive Model and Support Vector Regression", *Risks*, c. 12, sayı 1, 2024, doi: 10.3390/risks12010012.
- [49] M. Açikkar, "Fast grid search: A grid search-inspired algorithm for optimizing hyperparameters of support vector regression", *Turkish Journal of Electrical Engineering and Computer Sciences*, c. 32, sayı 1, ss. 68–92, 2024, doi: 10.55730/1300-0632.4056.
- [50] K. K. Yaswanth, V. Sathish Kumar, J. Revathy, G. Murali, ve C. Pavithra, "Compressive strength prediction of ternary blended geopolymer concrete using artificial neural networks and support vector regression", *Innovative Infrastructure Solutions*, c. 9, sayı 2, ss. 1–24, 2024, doi: 10.1007/s41062-023-01343-y.
- [51] L. Sun ve T. Li, "Using Novel Optimization Algorithms with Support Vector Regression to Estimate Pile Settlement Rates", *Indian Geotechnical Journal*, 2024, doi: 10.1007/s40098-024-00901-0.
- [52] B. Sharma ve N. K. Goel, "Streamflow prediction using support vector regression machine learning model for Tehri Dam", *Applied Water Science*, c. 14, sayı 5, 2024, doi: 10.1007/s13201-024-02135-0.
- [53] M. Abroun, A. Jahangiri, A. G. Shamim, ve H. Heidari, "Predicting long-term electricity prices using modified support vector regression method", *Electrical Engineering*, 2024, doi: 10.1007/s00202-023-02174-x.
- [54] J. Gao ve Y. Liu, "Prediction and the influencing factor study of colorectal cancer hospitalization costs in China based on machine learning-random forest and support vector regression: a retrospective study", *Frontiers in Public Health*, c. 12, sayı February, ss. 1–11, 2024, doi: 10.3389/fpubh.2024.1211220.
- [55] J. Yao, Y. Zhang, X. Liang, ve T. Ding, "Investigating the estimation of optimum moisture content through support vector regression in individual and hybrid approaches", *Multiscale and Multidisciplinary Modeling, Experiments and Design*, 2024, doi: 10.1007/s41939-024-00397-4.
- [56] M. Achite, S. Emami, M. Jehanzaib, O. M. Katipoğlu, ve H. Emami, "An election algorithm combined with support vector regression for estimating hydrological drought", *Modeling Earth Systems and Environment*, c. 10, sayı 1, ss. 1395–1405, 2024, doi: 10.1007/s40808-023-01850-y.

Özgeçmişler



Fikriye Ataman received the Computer Engineering degree from the Mersin University, Mersin, Turkey and Master of Science Degree in Computer Engineering in Atatürk University, Erzurum, Turkey, and the PhD degree from the Van Yuzuncu Yıl University, Van. She is currently a full assistant professor with the Computer Engineering in Van Yuzuncu Yıl University, Van, Turkey. She research interests include cloud computing and high performance computing and applied ML/AI.