

Makine Öğrenimi Tabanlı Kısa Vadeli Fotovoltaik Çıkış Gücü Tahminlemesi Machine Learning Based Short Term Photovoltaic Output Power Prediction

¹Berrin ERYILMAZ¹, ²Heybet KILIÇ^{2*}, ³Fatih Koçyiğit³

¹Dicle Üniversitesi Fen Bilimleri Enstitüsü, Yenilenebilir Enerji Kaynakları Ana Bilim Dalı,
Diyarbakır, Türkiye

¹berrin.eryilmaz@gmail.com, ²heybet.kilic@dicle.edu.tr, ³fatihkocycigit21@hotmail.com

Öz

Fosil yakıt kaynaklarının sınırlı olması ve çevreye zararlı etkilerinin olması nedeniyle fotovoltaik (PV) sistemlerinin kurulmasına olan ihtiyaç giderek artmaktadır. PV sistemlerinin hava koşullarına bağımlılığı PV güç çıkışlarında kararsızlığa, gerilim, frekans dalgalanmaları ve kesintilere neden olmaktadır. Bu durum ise PV enerjisinin şebekelere entegrasyonunu zorlaştırmaktadır. Bu yüzden PV güç çıkışını önceden kısa süreli tahmin etmek karşılaşılan zorlukların üstesinden gelmek için çok önemlidir. Bu çalışmanın amacı, literatürde makine öğrenimi modellerinde yaygın olan aşırı öğrenme ve yavaş öğrenme dezavantajlarının üstesinden gelerek daha hızlı öğrenen ve yüksek doğrulukta performans gösteren Gürbüz Düzenlenmiş Rastgele Vektör Fonksiyon Bağlantı (GD-RVFL) ağı modelini kısa vadeli PV çıkış gücünü tahmin etmede kullanmak ve bu kapsamda önerilen modeli 10 farklı makine öğrenimi yöntemi olan Bayesian Ridge Regressor (BRR), Linear Regressor (LR), Gaussian Process Regressor (GPR), Support Vector Machine (SVM), Extreme Learning Machine (ELM), Yapay Sinir Ağı (YSA), Gradient Boosting Regressor (GBR), Random Forest Regressor (RFR), Lasso Regressor (LAR) ve Ridge Regressor (RR) yöntemleri ile karşılaştırılarak modellerinin performansını değerlendirmektir. Yapılan bu karşılaştırma sonucunda GD-RVFL'nin etkinliği diğer 10 makine öğrenimi modeline göre önemli ölçüde daha iyi performans gösterdiği görülmüştür.

Anahtar kelimeler: GD-RVFLN, KKA, Makine öğrenimi, PV çıkış gücü tahmini

Abstract

The need for the installation of photovoltaic (PV) systems is increasing due to the limited resources of fossil fuels and their harmful effects on the environment. The dependence of PV systems on weather conditions causes instability, voltage, frequency fluctuations and interruptions in PV power outputs. This situation complicates the integration of PV energy into the grids. Therefore, short-term forecasting of PV power output is crucial to overcoming the challenges. The aim of this study is to use the Robust Arranged Random Vector Function Interconnect (GD-RVFL) network model, which learns faster and performs with high accuracy, overcoming the excessive learning and slow learning disadvantages that are common in machine learning models in the literature, to predict the short-term PV output power and in this context. Bayesian Ridge Regressor (BRR), Linear Regressor (LR), Gaussian Process Regressor (GPR), Support Vector Machine (SVM), Extreme

Learning Machine (ELM), Artificial Neural Network (ANN), Gradient To evaluate the performance of the models by comparing them with the Boosting Regressor (GBR), Random Forest Regressor (RFR), Lasso Regressor (LAR) and Ridge Regressor (RR) methods. As a result of this comparison, it was seen that the efficiency of GD-RVFL significantly outperformed the other 10 machine learning models.

Keywords: RR-RVFLN, CCA, Machine Learning PV output prediction


1. Giriş

Sanayinin gelişimi, hızlı kentleşme ve teknolojik büyüme enerjeye olan talebi gün geçtikçe daha önemli hale getirmektedir. Bu sürekli artan enerji talebini karşılamak için elektrik üretimi ve dağıtımına ihtiyaç vardır. Bilindiği gibi enerji üretimi yenilenebilir enerji kaynakları (YEK) (güneş, rüzgâr, su, biyokütle ve jeotermal gibi kaynaklar) ve yenilenebilir olmayan fosil enerji kaynakları (doğal gaz, kömür, nükleer ve petrol) tarafından üretilmektedir. Ancak fosil enerji kaynaklarının yapılarında hidrokarbon ve yüksek oranda karbon bulundurmaları atmosfere tehlikeli sera gazı (CO₂) yayılmalarına yol açmakta bu durum ise çevre ve insan sağlığı için büyük risk oluşturmaktadır. Nitekim, Dünya Meteoroloji Örgütü'nün (DMÖ) "Küresel İklimin Durumu 2020 raporu", sera gazı konsantrasyonlarının, son on yılda emsalsiz artan küresel sıcaklığın sonucunda kara ve okyanus sıcaklarının yükselmesine, buzulların erimesine ve aşırı hava olaylarına (sel baskınları, yoğun kar yağışları, şiddetli fırtınalar ve kuraklıklar gibi) neden olduğunu belgelemektedir [1]. Fosil enerji kaynaklarının çevreye olan tehlikeli etkileri ve gittikçe tükenmesi nedeniyle bu enerji kaynaklarına sınırlandırmalar getirilmiş, sürdürülebilirliği ve çevreye olan zararsız etkisi nedeniyle yenilenebilir enerji kaynaklarına dünya çapında bir yönelim söz konusu olmuş ve yenilenebilir enerji alanında çok büyük yatırımlar yapılmıştır. Dünya Enerji Konseyi (DEK) (World Energy Council)'nin 2021 Yenilenebilir Enerji Küresel Durum Raporuna göre, Yenilenebilir enerji kaynaklarına yapılan küresel yatırımlar 2020'de toplam 303,5 milyar ABD dolarına ulaşmıştır. Gelişmekte olan ülkeler ise yenilenebilir enerji yatırımında 153,4 milyar ABD dolarına ulaşmıştır. Yapılan bu yatırımların 148,6 milyar ABD doları güneş ve rüzgâr enerjisine yapılarak yenilenebilir enerji yatırımlarının neredeyse yarısını oluşturmuştur [2]. Uluslararası Enerji Ajansının (UEA) Dünya Enerji Yatırımı 2022'e göre, yenilenebilir enerji kaynakları, toplam enerji sektörü yatırımının %80'inden fazlasını oluşturduğunu, güneş enerjisi,

bu yatırımların neredeyse yarısını oluşturduğunu ve 2022'de yenilenebilir enerji kaynaklarına yatırımın 1,4 trilyon ABD dolarını aşması beklendiğini raporlamıştır [3]. Dahası DEK'e göre; elektrik enerjisi talebi 2060 yılına kadar iki katına çıkacağı ve elektrik enerjisi üretimi yenilenebilir kaynaklardan üretilmesi için uygun politikalar çıkarılarak önemli yatırımlar yapılacağı, yapılacak bu yatırımların da liderliğini güneş ve rüzgâr enerjilerinin yapacağı tahmin edilmektedir [2]. Güneş ve rüzgâr enerjisinde yaşanan ya da olumlu yatırım artışları daha fazla enerji tesisinin kurulmasını artırmakta bu da bu tesislerin merkezi şebekelere entegrasyonunu gerektirmektedir.

Ancak, PV santrallerin hava koşullarına bağımlılığı nedeniyle panellerde elektrik elde edimi ve dağıtımı zor olmaktadır. Gün boyunca güneş ışınımı yoğunluğunun istikrarsız doğası, PV güç üretiminde dalgalanmalara neden olmaktadır [4]. PV güç üretimindeki beklenmedik bu dalgalanmalar, santrallerin ya aşırı elektrik üretmesine ya da hiç elektrik üretmemesinden dolayı şirketlerin ek elektrik satın almasına neden olabilmektedir [5]. Sonuç olarak, PV gücünün yüksek entegrasyonu, yaşanan dalgalanmalar (aşırı elektrik üretimi veya elektrik üretilmemesi) nedeniyle mevcut şebeke sistemlerinin çalışması için birçok yeni sorunları da beraberinde getirmektedir [6]. Bu sorunlar, PV güç kaynağının meteorolojik koşullara duyarlılığını, yüksek kurulum maliyetlerini ve elektrik üretiminin kesintisini içerir [7]. Yaşanan bu sorunlara PV güç santrallerinden üretilen enerjinin depolanması bir çözüm olarak görülürken, sistemi önceden kontrol için mevcut enerjinin kesin bir tahmini gerekmektedir [4]. Bu duruma etkili bir çözüm ise PV güç çıkışı için doğru bir tahmin modeli bulmaktır.

Bu çalışmanın amacı makine öğrenimi ile PV çıkış gücünü kısa dönemli (10 dakika) olarak tahmin etmektir. Çıkış gücü tahmin etmek için literatürde birçok çalışma vardır. Bu çalışmada amaç literatürde kullanılan yöntemlerin geç öğrenme, aşırı öğrenme gibi iki temel dezavantajının üstesinden gelip tahmini daha kolay ve yüksek doğrulukta yapmaktır. Bu çalışmada giriş parametrelerini azaltmak için her PV santralde ulaşılabilen güneş ışınımı, güneşlenme süresi, rüzgâr hızı, ortam sıcaklığı, panel yüzey sıcaklığı, bulutluluk oranı, DC akım, gerilim ve bağıl nem 9 özellik(parametre) kullanılarak hava tipi modellenmiş ve 4 hava tipi modeli oluşturulmuştur. Bu hava tipi modelleri de kullanılarak GD-RVFLN yardımıyla PV çıkış gücü tahmini yapılmaya çalışılmıştır.



Şekil 3: Güneş ölçüm istasyonunun yandan görünümü

Güneş enerjisinden yararlanan sistemler, yatırımcı tarafından uygun maliyetli olarak kabul edilmeyen yüksek bir ilk yatırım maliyetine sahip olabilmektedir. Bu amaçla, bölgedeki güneş enerjisi projelerine para yatırmadan önce bölgenin güneş enerjisi potansiyelini değerlendirmek çok önemlidir. Dünya çapında güneş enerjisi ile ilgili temel bilgileri bilmek, herhangi bir bölgedeki güneş enerjisi uygulamaları için araştırma, planlama ve tasarım konusunda son derece yardımcı olacaktır.

Türkiye'de güneş ışınım verileri meteorolojik genel müdürlüğü (MGM) tarafından ölçülmektedir. Bu verilerin ölçümü için MGM illerde ölçüm istasyonları kurmuştur. Ekonomik ya da MGM yapısındaki değişikliklerden ötürü son yıllarda Türkiye'deki bazı illerde güneş ışınımı ile ilgili ölçüm istasyonların veri sağlamamaktadır [41]. Bu illerden bir tanesi olan Diyarbakır'da 2009 yılından itibaren bu veriler sağlanmaktadır. Belirtilen nedenlerden ötürü şekil 3'te gösterilen Dicle Üniversitesi bünyesindeki ölçüm istasyonu Diyarbakır iline ait güneş ışınım verileri ölçen tek istasyon konumundadır. Sonuç olarak Diyarbakır ve çevresinde ışınım verilerini sağlamasından ötürü şekil 3'te gösterilmiş bahsi geçen ölçüm istasyonu hem akademik araştırmalar hem de ticari uygulamalar açısından büyük önem taşımaktadır.

Bu çalışmada, Türkiye'de bulunan ve konum itibariyle güneş enerjisi açısından oldukça yüksek bir potansiyele sahip olan Diyarbakır iline ait güneş enerjisi verileri analiz edilmiştir. Daha sonra ilin ışınım değerleri ve güneşlenme süreleri güneş enerjisi açısından enerji üretimine elverişli olup olmadığı incelenmiştir [5]. Bu çalışmadaki diğer bir amaç ise Diyarbakır ili için güneşlenme süresi ve global ışınım verilerini elde ederek hem ticari çalışmalara hem de literatüre katkı sunmaktır.

1.1. PV Çıkış Gücü Tahmin Yaklaşımları

PV güç çıkışı için doğrudan ve dolaylı olmak üzere iki ana tahmin yaklaşımı vardır [8, 9, 10, 11]. Doğrudan tahmin yöntemleri [12-13], PV güç çıkışını tahmin etmek için genellikle meteorolojik ve PV çıkış gücü gibi geçmiş verileri kullanır. Bu yöntem için kullanılan teknikler [14-17], YSA, hibrit YSA, çok katmanlı algılayıcı sinir ağı (MLPNN), tek örtülü katmanlı ileri beslemeli sinir ağı (single shrouded layer feed-forward neural network) (SLFN), tekrarlayan sinir ağı (RNN), ileri beslemeli sinir ağı (FFNN), Geri Beslemeli sinir ağıdır (FBNN), aşırı öğrenme makine (ELM) ve destek vektör regresyonu (SVR) gibi yöntemlerdir. Doğrudan yöntemlerin dolaylı yöntemlere kıyasla gün öncesi PV güç çıkışı tahmini açısından daha iyi sonuç verdiği kanıtlanmıştır [18]. Dolaylı tahmin yöntemleri [8, 19, 20] güneş radyasyonu, ortam sıcaklığı gibi meteorolojik parametreleri ve çevresel parametreleri matematiksel modeller kullanarak tahmin eder. Dolaylı tahmin yöntemlerindeki sonraki adım eşdeğer diyot modeli, basit verimlilik modeli ve Sandia modeli gibi modelleri kullanarak PV çıkış gücü tahmin etmektir. Dolaylı tahmin için kullanılan teknikler [21-22] Sayısal Hava Tahmini (SHT), uydu gökyüzü görüntüsü, hibrit yapay sinir ağı ve istatistiksel tabanlı yöntemlerdir.

Yukarıda isimleri verilen modeller PV güç çıkışı tahminlemede faydalı olsa da her modelin kendi zorlukları vardır. Değinen bu modellerden SVR modeli [23-25] hem büyük hesaplama sürecine ihtiyaç duyar hem de büyük veri kullanımı durumlarına yanıt vermez. Öte yandan, YSA modeli [26-27], iyi bir performans göstermesi için kullanıcıların ağ topolojisini ve parametreleri belirlemesine ihtiyaç duyar.

Kıscacası tahminleme için kullanılan modeller doğru kullanılmadığı takdirde iyi sonuçlar vermeyebilir. Bu yüzden tahminleme için iyi bir model seçimi gerekmektedir. Literatürde PV çıkış gücü tahminlemesi için oldukça fazla sayıda çalışma vardır. Bu kapsamda kısa vadeli PV çıkış gücü tahmini için yapılan bilimsel çalışmaların bir kısmı aşağıda verilmiştir.

Zhou ve ark. [18], PV çıkış gücünü tahmin etmek için aşırı öğrenme makinesi (ELM), genetik algoritma (GA) ve özelleştirilmiş Benzer Gün Analizi (BGA) tabanlı bir hibrit model (BGA-GA-ELM) geliştirilmiştir. BGA için beş meteorolojik girdiye dayalı olarak farklı günler arasındaki benzerliği ölçmek için Pearson Korelasyon katsayısı kullanılmış. Yüksek korelasyona sahip parametreler ELM için eğitim seti olarak seçilmiştir. Daha sonra tahmin doğruluğunu iyileştirmek için ELM' de gizli önyargı ve girdi ağırlığının optimal değerleri GA tarafından belirlenmiştir. Önerilen tahmin modelinin performansı, regresyon katsayısı (R2), ortalama mutlak hata (OMH) ve normalleştirilmiş ortalama karekök hata (nOKH) ile değerlendirilmiştir. Sonuçlar, BGA-GA-ELM modelinin gün öncesi PV çıkış gücü tahmininde daha yüksek doğruluk ve kararlılığa sahip olduğunu göstermiştir. VanDeventer ve ark. [28], kısa vadeli PV gücü tahmini için Genetik algoritmaya dayalı bir support vektör makinesi (GASVM) modeli geliştirdiler. GASVM modelinde, başlangıçta SVM sınıflandırıcı olarak geçmiş hava durumu verileri sınıflandırılmış, daha sonra genel uyum tekniği kullanılarak genetik algoritma (GA) tarafından optimize edilmiştir. Önerilen GASVM modelinin tahmin doğruluğu, OKH ve OMYH temelinde değerlendirilmiştir. Deneysel sonuçlar, önerilen GASVM modelinin, OKH değerinde yaklaşık 669.624W ve OMYH hatasının %98,76'lık farkla geleneksel SVM modelinden daha iyi performans gösterdiğini göstermiştir. Massaoui ve ark. [29], Bayesian Ridge Regresyon (BRR) modelini, Sürekli Dalgacık Dönüşümünü (SDD) ve Gradient Boosting kategorik özelliklerle (Catboost) birleştiren bir BBR-SDD-Catboost hibrit modelini önermişlerdir. Bu modelde, en alakalı özellikleri seçmek için bir Bayesian Ridge Regresyon modeli kullanır. Ardından, SSD ayrıştırma tekniği seçilen özellikleri bir zaman-frekans alanına dönüştürür. Catboost modeli, bir gün öncesi için tahmin çıktısını üretir. Son olarak sonuçlar, ters SSD kullanılarak çıkarılır. Hibrit model, OKH=3.81 ile kısa vadeli 24 saat ilerisi tahmininde doğru sonuçlar elde etmiştir. Gutiérrez ve ark. [30], fotovoltaik güç üretimini tahmin etmek için Makine Öğrenimi ve Yapay Zekâ yöntemleriyle uyumlu tekniklerden dört tahmin modeli önermiştir: K-En Yakın Komşular (KNN), Doğrusal Regresyon (LR), Yapay Sinir Ağları (ANN) ve Destek Vektör Makineleri (SVM). Elde edilen sonuçlar, dört yöntemin yeterli fotovoltaik enerji üretimi tahminleri ürettiğini ancak OKH ve OMH'ye göre en iyi tahmin YSA tahmin modeline ait olduğunu göstermiştir. Afzal ve ark. [31], termal faktörlere dayalı enerji tesisin üretimini tahmin etmek için Ridge, Lineer regresör (LR) ve destek vektör regresörü (SVR) algoritmalarını kullanmışlardır. Kombine çevrim santralini enerji çıktı verileri egzoz vakumu, ortam sıcaklığı, bağıl nem ve ortam basıncı gibi termal girdi değişkenlerinin bir faktörü olarak toplanmıştır. İlk olarak, Ridge algoritması tabanlı modelleme ayrıntılı olarak gerçekleştirilmiş ve ardından SVR (LR) olarak adlandırılan SVR tabanlı LR, SVR tabanlı radyal tabanlı fonksiyon—SVR (RBF) ve SVR tabanlı polinom regresyon SVR (Poly.) algoritmalar uygulanmıştır. Enerji çıkış verilerinin modellenmesinden, diğer algoritmalara kıyasla çok yakın tahminler sağlamada SVR'nin (RBF) en uygun olduğu

görülmüştür. Elde edilen SVR (RBF) eğitimi $R2 = 0,98$ iken diğer tüm eğitimler 0,9-0,92 olmuştur. Khalyasmaa ve ark. [32], meteorolojik verilere dayalı fotovoltaik enerji santrallerinin üretim tahmin için Random Forest regresörü, Gradient Boosting Regressor, Lineer Regresyon ve Karar Ağaçları regresyonu dahil olmak üzere farklı makine öğrenimi algoritmalarının uzaktan elde edilen verilere uygulanmasını incelemiştir. Hiper parametre optimizasyonu ve algoritmaların ardışık düzeni ile ilgili hesaplama deneylerine dayanarak, PV santral enerji çıktısı tahmin sisteminin optimal yapısı ve ayarları, algoritmaların her biri için uygulama kısıtlamaları ile birlikte belirlenip uygulanmıştır. Bu hesaplamalar sonucu performans iyileştirme Lineer Regresyon için %55'ten %94'e ve karar ağaçları için %88'den %91'e, topluluk algoritmalarının doğruluğu ise, Random Forest regresörü, Gradient Boosting Regressor gibi, önemli ölçüde değişmediği görülmüştür. Chahboun ve Maaroufi [33], Fotovoltaik gücün saatlik tahmini için birkaç güncel makine öğrenme algoritmasının performansı karşılaştırmışlardır. Kullanılan yöntemler, bayesian regularized sinir ağları, k-nearest neighbors, gradient boosting, random forest, support vector regresyon ve multivariate adaptive regression olmuştur. Daha sonra bu yöntemler R2, OKH ve OMH ile değerlendirilmiştir. Sonuçlar, bayesian regularized sinir ağlarının en iyi tahmin doğruluğuna $R^2=99,99\%$ sahip olduğunu göstermiştir. Bu çalışmada önerilen yöntem, bir tek örtülü katmanlı ileri beslemeli sinir ağı (single shrouded layer feed-forward neural network) (SLFN) türü olan Rastgele Vektör Fonksiyonel Bağlantı(link) Ağ (Network) olarak adlandırılan RVFLN'nin gerekli algoritmalara geliştirmiş hali olan Robust Regularized Random Vector Functional Link Network (GD-RVFLN) modelidir. Yapılan diğer literatür araştırmalarında RVFLN modelini kullanarak PV gücü tahmini yapan iki çalışmaya rastlanılmıştır. Arpit ve Tripathi [34], PV gücünü tahmin etmek için tek örtülü katmanlı ileri beslemeli sinir ağı (single shrouded layer feed-forward neural network) (SLFN), rastgele ağırlıklı tek örtülü ileri beslemeli sinir ağı (random weight single shrouded layer feed-forward neural network) (RWSLNF) ve rastgele vektör fonksiyonel bağlantı ağı (random vector functional link) (RVFL) olmak üzere üç modeli karşılaştırmıştır. Bu karşılaştırma sonucunda RVFL' nin diğer RWSLNF' lerden ve SLFN' lerden daha iyi performans gösterdiği tespit edilmiştir. Mishra ve ark. [35], güneş ışınımı, PV çıkış gücünü ve rüzgâr hızının tahmin etmek için Gürbüz Düzenleştirilmiş Rastgele Vektör Fonksiyonel bağlantı (GD-RVFL) ağı olarak bilinen ultra kısa bir Tahmin modeli önermişlerdir. Önerilen metodolojinin doğruluğunu elde etmek için test, farklı atmosfer koşullarında çeşitli zaman aralıklarında gerçekleştirilmiştir. Önerilen yöntemin diğer modellere (yani Rastgele vektör fonksiyonel bağlantı (RVFL) ve Robust Extreme learning machine (R-ELM) vb.) kıyasla çok üstün performans gösterdiği görülmüştür.

Bu çalışmanın amacı, literatürde makine öğrenimi modellerinde yaygın olan aşırı öğrenme ve yavaş öğrenme dezavantajlarının üstesinden gelerek daha hızlı öğrenen ve yüksek doğrulukta performans gösteren GD-RVFL ağı modelini kısa vadeli PV çıkış gücünü tahmin etmede kullanmak ve bu kapsamda önerilen modeli, 10 farklı makine öğrenimi yöntemi olan BRR, LR, GPR, SVM, ELM, YSA, GBR, RFR, LAR ve RR yöntemleri ile karşılaştırılarak modellerinin performansını değerlendirmektir.

Bu çalışmanın yapısı sırasıyla şu şekilde sıralanmıştır: Bölüm 2, bölgenin konumu, iklimi hakkında ve data seti hakkında bilgi vermektedir. Önerilen yöntem ve karşılaştırma

yöntemleri açıklanmıştır. Bölüm 3'te tahmin sonuçları verilip değerlendirilmiştir. Bölüm 4'te çalışma sonuca bağlanmıştır.

2. Materyal ve Metot

2.1. PV Santral


Bu çalışmadaki tarihsel veriler Şekil 1'de gösterildiği üzere, Diyarbakır ili Dicle Üniversitesi kampüsünde bulunan bir PV elektrik santralinden [36-38] ve meteorolojik istasyondan [39-42] Mayıs 2019-Nisan 2022 tarihleri aralığında elde edilmiştir.



Şekil 1: PV güç istasyonunun veri toplama sistemi [36]

2.2. Güneş ölçüm istasyonu

Bu çalışmadaki girdi verileri güneş ışıması(R), ortam sıcaklığı(T), panel yüzey sıcaklığı, güneşlenme süresi, bulutluluk oranı, Rüzgâr hızı (W), DC akım, gerilim ve bağıl nem (H) parametreleridir. Bu veriler, şekil 2'de gösterilen, Diyarbakır (Enlem: 37°55' D, Boylam: 40°14' K) Dicle Üniversitesi Bilim ve Teknoloji Uygulama ve Araştırma Merkezi (DÜBTAM) binası çatısında bulunan güneş ölçüm istasyonundan alınmıştır. Bu istasyonda elde edilen veriler 10 dakikalık periyotlarla elde edilmiştir. Bu veriler üzerinde K katlamalı çapraz doğrulama tekniği uygulanmıştır.




Şekil 2: Dicle Üniversitesi güneş ölçüm istasyonu [40]

Bu teknikte, modellerin çalışma sürecinde eksik ve aşırı öğrenmeyi tespit edip önleyerek test aşamasında en iyi modeli oluşturmayı amaçlamaktadır. Bu teknikte veri seti eğitim seti ve test seti olarak ayrılmış, eğitim seti k adet alt kümeye bölünmüştür. Bu işlem k- kez tekrarlanır. Her tekrarda sıradaki alt küme eğitim setinden çıkarak test seti olarak kullanılır.

$$E = \frac{1}{k} \sum_{i=1}^k E_i \quad (1)$$

Bu işlem tamamlandığında modelin başarısı veya genel hatası (E), eşitliğindeki gibi k kadar ortalaması alınarak bulunur. Bu çalışmada k=10 alınarak veri seti için veri setinin %75'i eğitim verisi (Mayıs 2019- Temmuz 2021), %25'i ise test verisi (Ağustos 2021- Nisan 2022) olarak kullanılmıştır.

Şekil 3 Mayıs 2021-Nisan 2022 tarihleri arası her ayın 2'sindeki PV güç çıkış eğrilerini göstermektedir. PV güç çıkış eğrilerindeki dalgalanmaların nedeni PV santrallerinin meteorolojik koşullara bağlılığından kaynaklanmaktadır.



Şekil 3: Her ayın 2'sinde PV çıkış gücü eğrileri

2.3. Kanonik Korelasyon Analizi (KKA) ile Hava Tipi Sınıflandırması

KKA yöntemi, girdi parametrelerini hava tipine göre sınıflandırmak için kullanılmıştır. Kanonik korelasyon analizi, iki değişken grubu arasındaki ilişkileri belirlemek ve ölçmek için kullanılan istatistiksel bir tekniktir [43,44]. Kanonik korelasyon analizi kümeler içindeki ve kümeler arasındaki değişkenliği en iyi açıklayan bir dizi kanonik değişkeni, her bir küme içindeki değişkenlerin ortogonal doğrusal kombinasyonlarını belirlemeye yarar. [45]. Bu çalışma Kanonik korelasyon analizine bağlı olarak, bir günün gündüz dilimlerini yarımsaatlik periyotlara böler ve ardından her yarımsaatlik periyodu meteorolojik koşullara göre sınıflandırır ve etiketler. Burada dikkat edilmesi gereken husus, zaman aralığı uzunluğu yerel meteorolojik koşullara bağlı olduğu için zaman aralığı uzunluğu tüm bölgeler için farklılık göstermektedir. Genellikle, zaman aralığının uzun olması, meteorolojik koşulların stabil olma durumuna bağlıdır. Bu çalışmada, ilk adımda belli bir günün gündüz dilimleri yarımsaatlik zaman aralıklarına bölündü. İkinci adımda, her bir yarımsaatlik zaman aralığına 4 farklı hava tipi etiketleri verildi. Üçüncü adımda bu hava tiplerinin yarımsaatlik zaman aralıkları 4 farklı PV güç çıkış seviyesine göre sınıflandırıldı. Etiketler ve bunlara karşılık gelen sınıflandırmalar sırasıyla şu şekildedir; PV güç üretimlerine göre Hava Tipi A (HT-A) en uygun, Hava Tipi B (HT-B) en uygun ikinci hava tipidir ve bu şekilde en az uygun tip olan Hava Tipi D (HT-D)'e kadar devam eder. Çalışmada belli bir tarih ve saatin hava tipini belirlemek için önceki yıllara ait en yakın benzer günlerden alınan zaman aralığındaki veri kümesinin bir bölümü seçildi. Bu veri kümeleri, 10 dakikalık

PV güç çıkış verileri ile güneş ışınımı, ortam sıcaklığı, panel yüzey sıcaklığı, güneşlenme süresi, bulutluluk oranı, rüzgâr hızı, DC akım, gerilim ve bağıl nem verilerinden oluşmaktadır. Tablo 1’de PV güç çıkışlarının A-D hava tiplerine göre dört seviyede sınıflandırılabileceği gösterilmektedir.

Tablo 1: PV güç çıkış seviyesine göre dört tip hava durumu sınıflandırması


Hava Tipi	Formül
Hava Tipi A	$y_i > AVGy + \frac{MAXy - AVGy}{2}$
Hava Tipi B	$VGy < y_i \leq AVGy + \frac{MAXy - AVGy}{2}$
Hava Tipi C	$VGy - \frac{AVGy - MINy}{2} < y_i \leq AVGy$
Hava Tipi D	$0 < y_i \leq AVGy - \frac{AVGy - MINy}{2}$

Bu çalışmada kullanılan hava tipi sınıflandırma yöntemi diğer geleneksel yöntemlere göre kullanımı daha kolaydır ve istenildiği takdirde zaman aralıkları uzunluğuna göre dörtten daha az veya daha fazla seviyeye değiştirilebilir.

$$AVGy = \frac{1}{n} \sum_{i=1}^n y_i \quad y_i \in T \quad (2)$$

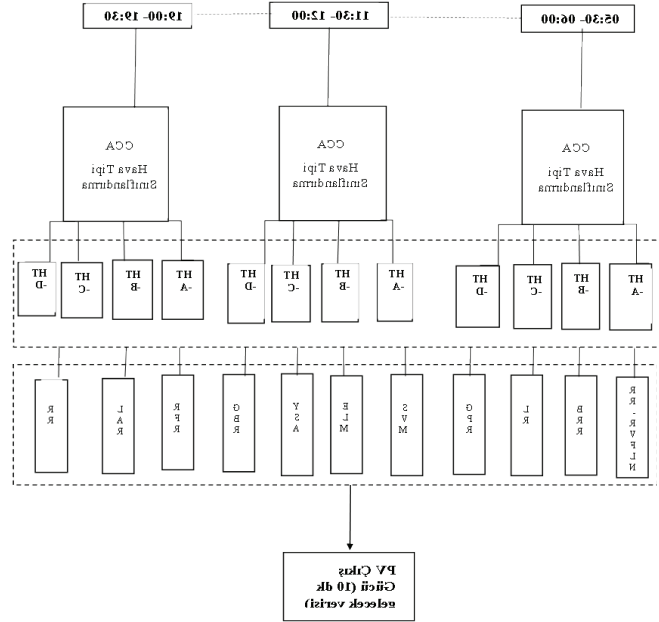
Denklem 2’de T, 2 Haziran 05:30- 06:00 gibi yarımsaatlik bir zaman aralığında seçilen veri setini ifade eder. Sırasıyla; n veri noktalarının sayısını, y_i PV çıkış gücünü ($y_i \in T$), AVGy veri setinin ortalama PV çıkış gücünü temsil eder ve MAXy ve MINy ise sırasıyla seçilen veri setinin maksimum PV güç çıkışını ile minimum PV güç çıkışını temsil eder.

Bu çalışmanın algoritması Şekil 4’de gösterildiği gibidir. Bu çalışmada Gürbüz Düzenlenmiş Random Vektör Fonksiyon ağı (GD-RVFLN) modelinin işlevi, hava tipini belirleyen verileri girdi olarak kullanıp PV çıkış gücünü tahmin etmektir. Bu çalışmada ilk olarak, Kanonik Korelasyon Analizi kullanarak girdi parametreleri ile PV güç çıktısı arasındaki korelasyonlar belirlendi, son günlere ait her yarım saatte bir PV güç çıkış verileri ile bu verilere karşılık gelen meteorolojik veriler veri setleri olarak toplandı daha sonra, geçmiş veri setlerinden öznitelikler çıkarıldı, sonra her yarım saatlik dilimlere hava tipi etiketleri verildi ve ardından GD-RVFLN modeli eğitildi (Şekil 5).



Şekil 4: KKA'ya bağlı hava tipi sınıflandırma süreci

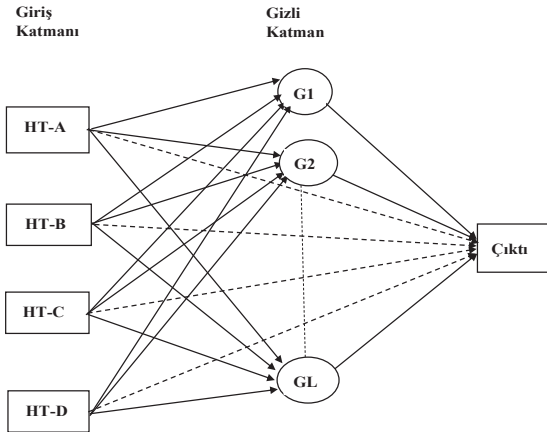
Şekil 5'te gösterilen tahmin süreci, eğitim ve tahmin olmak üzere iki adımdan oluşur.



Şekil 5: Hava tipi sınıflandırmasına dayalı PV tahmin yöntemi

2.4. Orijinal Rastgele Vektör Fonksiyon Bağlantı (RVFL) Ağ Modeli

Rastgele Vektör Fonksiyon Bağlantı (RVFL) ağı, sınıflandırma, görsel izleme, regresyondan tahmine kadar çeşitli alanlardaki üstün performansı nedeniyle araştırmacılar arasında önemli ölçüde ilgi görmüştür. RVFL, gizli nöronların ağırlıklarının ve sapmalarının uygun bir aralıkta rastgele oluşturulduğu ve çıktı ağırlıkları basit bir kapalı form çözümü ile hesaplanırken sabit tutulduğu tek katmanlı ileri beslemeli bir sinir ağı (SLFN)'dır [46, 47]. RVFL ağında giriş katmanından çıkış katmanına doğrudan bağlantılardan büyük ölçüde yararlanır. Doğrudan bağlantıların işlevi, rastgeleleştirme için bir düzenleme yapmasıdır. Ayrıca Extreme Learning Machine (ELM) gibi diğer muadillerine kıyasla RVFL ağı, giriş katmanı ile gizli katman arasındaki ağırlıkları rastgele ataması ve ayarlama işlemine ihtiyaç duymaması nedeniyle model karmaşıklığının düşük tutulmasına yardımcı olur [48]. Şekil 6 Hava tipine dayalı RVFL ağ modelini göstermektedir.



Şekil 6: Hava tipi sınıflandırmasına dayalı PV tahmin yöntemi

Eğitim örneklerinin belirli bir veri seti göz önünde bulundurulduğunda $S = \{(X_i, Y_i | i = 1, \dots, N)\} \subset R^d \times R$, RVFLN, aşağıdaki gibi L gizli düğümüne sahip özel bir tek katmanlı ileri beslemeli bir sinir ağı türü olarak tanımlanabilir.

$$f(x) = \sum_{j=1}^L \beta_j h_j(v_j, b_j, x) \quad (3)$$

(3) nolu denklemde v_j ve b_j , sırasıyla gizli düğüm parametreleri olan girdi ağırlığı ve gizli katman düğüm sapmasını ifade eder. β_j, j 'nci gizli katman düğümü ile çıktı düğümü arasındaki çıktı ağırlığını ve h_j , aktivasyon fonksiyonunu temsil eder. Genel olarak, aşağıdaki radyal tabanlı fonksiyon kullanılabilir.

$$h_j = h\left(\frac{\|x - v_j\|}{b_j}\right) \quad v_j \in R^d, b_j \in R^+ \quad (4)$$

N örnek $(x_i, y_i) \subset R^d \times R$ için, karesel hataların toplamı olarak kullanılır.

$$J = \sum_{i=1}^N \left\| \sum_{j=1}^L \beta_j h_j(v_j, b_j, x) - y_i \right\|^2 \quad (5)$$

RVFLN'de gizli düğüm parametreleri olan v_j ve b_j rastgele atanabilir, burada ağ yaklaşımı performansını sağlamak için yalnızca çıkış katmanının doğrusal parametrelerinin analitik olarak hesaplanması gerekir. Böylece denklem (5) aşağıdaki gibi ikinci dereceden optimizasyon problemi olarak tanımlanabilir.

$$J \arg \min_{\beta} = \|G\beta - Y\|^2 \quad (6)$$

Burada

$$G = \begin{bmatrix} h(v_1, b_1, x_1) & \dots & h(v_L, b_L, x_1) \\ \vdots & \ddots & \vdots \\ h(v_1, b_1, x_N) & \dots & h(v_L, b_L, x_N) \end{bmatrix}_{N \times L} \quad (7)$$

$$\beta = \begin{bmatrix} \beta_1 \\ \vdots \\ \beta_L \end{bmatrix}_{L \times 1} \quad \text{Ve} \quad Y = \begin{bmatrix} y_1 \\ \vdots \\ y_L \end{bmatrix}_{N \times 1} \quad (8)$$

G , gizli katman çıktısıdır. Y ve β sırasıyla örneklenen çıktı ve çıktı ağırlığını temsil eder. Genel olarak, optimal çıktı ağırlığı β aşağıdaki gibi tanımlanabilir.

$$\beta = G^+ Y \quad (9)$$

Burada G^+ , G matrisinin Moore-Penrose'a göre genelleştirilmiş transpozesidir, yani tersidir.

2.5. Regularized RVFLN (Düzenlenmiş RVFL Ağı)

Düzenlenmiş (D)-RVFL ağıının avantajı, modelin etkili bir şekilde uyum göstermesinin yanında çıktı ağırlığının büyüklüğünü azaltarak model karmaşıklığını da azaltmasıdır. Normal düzenlenmiş RVFLN, hedef fonksiyonunda düzenlenmiş terimi (l_2 normu) tanıtan ridge regresyon yöntemi [49] kullanılarak oluşturulabilir. Belirli bir N farklı örnek için (x_i, y_i) , l_2 normlu D-RVFL ağı denklem 10'daki gibi tanımlanabilir.

$$\begin{aligned} \min: J & \\ &= \frac{1}{2} \|\beta\|^2 \\ &+ \frac{C}{2} \sum_{i=1}^N \varepsilon_i^2, \quad s. t: h(x_i)\beta \\ &= y_i - \varepsilon_i, \quad \forall i. \end{aligned} \quad (10)$$

Burada C , eğitim hatasını ve çıktı ağırlık normunu dengeleyen düzenleme parametresini temsil eder. $\sum_{i=1}^N \varepsilon_i^2$ Ampirik kaybı $\|\beta\|^2$ yapısal kaybı temsil eder. Düzenlenmiş en küçük kareler algoritmasına göre, çözüm β aşağıdaki gibi ifade edilebilir:

$$\beta = \begin{cases} \left(G^T G + \frac{I}{C}\right)^{-1} G^T Y, & N \geq L \\ G^T \left(G G^T + \frac{I}{C}\right)^{-1} Y, & N < L \end{cases} \quad (11)$$

Denklem (11) düzenlenmiş RVFLN' nin çevrimdışı öğrenme formu olarak ifade edilir. Çevrimiçi öğrenme formu ise, eşitlik 12'de tanımlanan özyinelemeli bir çözüme atıfta bulunur.

$$\beta \begin{cases} J_k = J_{k-1} + G_k^T G \\ \beta_k = \beta_{k-1} + J_k^{-1} G_k^T (Y_k - G_k \beta_{k-1}) \end{cases} \quad (12)$$

Burada G_k, k 'nci örnek için oluşturulmuş gizli katman çıktısını belirtir. Modelin başlangıç değerleri aşağıdaki gibidir:

$$\begin{cases} J_0 = G_0^T G_0 + \frac{I}{C} \\ \beta_0 = J_0^{-1} G_0^T Y_0 \end{cases} \quad (13)$$

Gizli düğüm sayısından daha fazla sayıda örnek gerektiren geleneksel RVFLN' nin aksine, düzenlenmiş RVFLN, modeli az miktarda örnek kullanarak başlatabilir. Ayrıca, düzenlenmiş RVFLN' nin çıktı ağırlığı normu nispeten küçük olduğundan, model iyi performans göstermektedir. Ancak aykırı değerli verilerle karşılaştığında, düzenlenmiş RVFLN' nin kalitesi bozulabilir ve model uyumsuzluğuna yol açabilir. Bu yüzden C düzenleme parametresini tam olarak kullanmayabilir. Bu nedenle, RVFLN 'nin geliştirilmesine ihtiyaç duyulmuştur. Aşağıdaki bölümde, sağlam

düzenleştirilmiş (Robust Regularized) RVFLN sunulmaktadır [50].

2.6. Gürbüz Düzenlenmiş Rastgele Vektör Fonksiyon Bağlantı Ağı (GD-RVFLN)

RVFLN modelinin sağlamlığını iyileştirmek için kernel density estimation (NKDE) yöntemi ve ağırlıklı ampirik kayıplı ridge-tip düzenlenmiş RVFL ağı yöntemleri çalışmaya dahil edilmiştir. Gürbüz Düzenlenmiş RVFLN yönteminde, ampirik kayıp ağırlıkları, NKDE yönteminin tahmin ettiği örnek güvenilirliğe göre belirlenmektedir. Böylelikle yüksek ve düşük örnek güvenilirliğe sahip kayıp ağırlıklarının değerlerinin düşürülmesi ve artırılması istenmeyen aykırı değerlerin etkisini azaltmakta veya ortadan kaldırmaktadır [51].

Bir optimizasyon yöntemi olan Robust regularized RVFLN yöntemi, belirli bir N farklı örnek (x_i, y_i) için, aşağıdaki matematiksel formülle ifade edilebilir.

$$\beta \min: \frac{1}{2} \|\beta\|_2^2 + \frac{C}{2} \sum_{i=1}^N p_i \|\varepsilon_i\|_2^2 \quad (14)$$

$$s. t: h(x_i)\beta = y_i - \varepsilon_i, \forall i.$$

Bu formüldeki p_i , i 'nci örneğin ampirik kayıp ağırlığını ifade eder. β optimal çıkış ağırlığıdır. C , düzenleme parametresidir ve ε , artık hatadır. Karush-Kuhn-Tucker (KKT) teoremine göre, yukarıdaki optimizasyon formülü matematiksel olarak aşağıdaki ikili optimizasyon formülüyle ifade edilebilir.

$$J_{\ell_2}(\beta, \varepsilon, \alpha) = \frac{1}{2} \|\beta\|_2^2 + \frac{1}{2} C \sum_{i=1}^N p_i \varepsilon_i^2 - \sum_{i=1}^N \alpha_i (h(x_i)\beta - y_i + \varepsilon_i) \quad (15)$$

Burada i 'nci giriş örneği için α_i , Lagrange çarpanı ve h aktivasyon fonksiyonudur. Burada, β , ε , α değerleri, yukarıdaki ikili optimizasyon formülünün kısmi türevi alınarak bulunabilir. Dolayısıyla, formül şu şekilde türetilebilir:

$$\frac{\partial J_{\ell_2}}{\partial \beta} = 0 \rightarrow \beta = G^T \alpha \quad (16)$$

$$\frac{\partial J_{\ell_2}}{\partial \varepsilon} = 0 \rightarrow \alpha = CP\varepsilon \quad (17)$$

$$\frac{\partial J_{\ell_2}}{\partial \alpha} = 0 \rightarrow G\beta - Y + \varepsilon = 0 \quad (18)$$

Burada, P ampirik kayıp ağırlık matrisini ifade eder. Farklı büyüklükteki eğitim örneği setleri için yukarıdaki formüllere aşağıdaki alternatif çözümler elde edilebilir. $N < L$ olduğu durumda formül (18)'den. (19) formül elde edilir:

$$PG\beta - PY + P\varepsilon = 0 \quad (19)$$

(17) ve (18) formüllerden formül (20) ulaşılır.

$$\left(\frac{1}{C} + PGG^T\right) \alpha = PY \quad (20)$$

(20)'deki α 'yı yalnız bırakır 16. Formüldeki yerine koyarsak formül (21) elde edilir.

$$\beta = G^T \left(\frac{1}{C} + PGG^T\right)^{-1} PY \quad (21)$$

$N > L$ olduğu durumda (17)'deki α değerini (18)'de yerine yazıldığında formül (22) elde edilir.

$$\beta = G^T CP\varepsilon \quad (22)$$

(22)'deki $P\varepsilon$ aşağıda gösterildiği gibi yalnız bırakılır.

$$P\varepsilon = \frac{1}{C} (G^T)^{-1} \beta \quad (23)$$

(23), (19)'da yerine yazılarak (24) elde edilir.

$$PG\beta - PY + \frac{1}{C} (G^T)^{-1} \beta = 0 \quad (24)$$

Böylece,

$$G^T PG\beta - G^T PY + \frac{1}{C} \beta = 0 \quad (25)$$

(25)'deki β yalnız bırakıldığında aşağıdaki (26) elde edilir.

$$\beta = \left(\frac{1}{C} + G^T PG\right)^{-1} G^T PY \quad (26)$$

Sonuç olarak, yukarıdaki çıktı ağırlıkları β kısaca aşağıdaki formüldeki gibidir.

$$\beta = \begin{cases} G^T \left(\frac{1}{C} + PGG^T\right)^{-1} PY, & N < L \\ \left(\frac{1}{C} + G^T PG\right)^{-1} G^T PY, & N \geq L \end{cases} \quad (27)$$

$i=1, \dots, N$ sayıda örneklem için Ampirik kayıp ağırlığı p_i , C parametresi hariç optimal çıkış ağırlığı β çözümü için oldukça önemli bir parametredir. Çünkü model sağlamlığının iyileştirilmesi p_i 'nin hesaplanmasıyla elde edilir. Burada p_i örneklerin çözüme katkısıdır. Dolayısıyla, amaca ulaşmak için bu katkının örneğin güvenilirliğine yakın olmasına izin verildi. Örnek güvenilirliği, artık olasılık yoğunluk fonksiyonu kullanılarak NKDE yöntemi ile tahmin edilebilir. Bu yolla, düşük yoğunluklu aykırı değerler ayarlanarak çözüme küçük ya da sıfır katkı sağlanır. Artık olasılık dağılımı ise Robust regularized RVFLN yöntemindeki P 'nin bir birim matrisi olarak ayarlanması ile elde edilebilir. Yani;

$$\varepsilon_j = \sum_{i=1}^L \beta_i h_i(v_i, b_i, x_i) - y_j \quad j = 1, 2, \dots, N \quad (28)$$

Daha sonra, artıkların olasılık yoğunluğu $f(x)$, aşağıdaki gibi NKDE yöntemi ile elde edilir.

$$f(x) = \frac{1}{hN} \sum_{j=1}^N \phi\left(\frac{x-\varepsilon_j}{h}\right) \quad (29)$$

$$\phi(x) = \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}x^2} \quad (30)$$

Burada, sırasıyla ϕ , Gauss çekirdek fonksiyonu, $\hat{\sigma}$ artıkların standart sapmasını ve $h=1.06\hat{\sigma}N^{-1/5}$ tahmin edilen pencere genişliğini ifade etmektedir. Formül (27) kullanılarak, her artık hata ε_i 'nin olasılığı, yani, $f(\varepsilon_i)$ elde edilebilir. Diğer taraftan $f(\varepsilon_i)$ fonksiyonu ile örneğin güvenilirliği doğru orantılıdır. Yani, $f(\varepsilon_i)$ 'nin değeri yüksek olduğunda örnek güvenilirliği yüksek olur, küçük olduğunda örnek güvenilirliği de küçük olur. Bu nedenle, $f(\varepsilon_i)$ 'yi ayarlanarak doğrudan pi ağırlığı da ayarlanabilir.

Çıktı ağırlığı hesaplama formülü (27) ile numune ağırlığı değerlendirme denklemi formül (29) arasındaki yinelemeli değişim, yenilemeli olmayan yöntemle göre daha doğru örnek güvenilirliği sağlamaktadır. Ancak yinelemeli değişim daha yüksek hesaplama yüküne sahip olduğu için bu çalışmada yinelemeli olmayan yöntem kullanılmıştır.

2.7. Karşılaştırma Yöntemleri

Bu çalışmada önerilen modelin doğruluğunu karşılaştırmak için 10 farklı makine öğrenme modeli kullanılmıştır. Bu modeller sırasıyla şu şekildedir; Bayesian Ridge Regressor (BRR), Linear Regressor (LR), Gaussian Process Regressor (GPR), Support Vector Machine (SVM), Extreme Learning Machine (ELM), Yapay Sinir Ağı (YSA), Gradient Boosting Regressor (GBR), Random Forest Regressor (RFR), Lasso Regressor (LAR) ve Ridge Regressor (RR). Tüm bu modeller kendi avantaj ve dezavantajlarına sahiptir. Bu çalışmada modellerin tahmin süresi şekil 3.5'te gösterildiği gibidir. Buna göre ilk olarak, güneş ışınımı, güneşlenme süresi, rüzgâr hızı, ortam sıcaklığı, panel yüzey sıcaklığı, bulutluluk oranı, DC akım, gerilim ve bağıl nem parametreleri Konikal Korelasyon Analizi (KKA) modeli kullanarak hava tipi seviyelerine göre dört sınıfa ayrılmıştır. Bu modeller, bu dört sınıfa ayrılan hava tipini giriş olarak kullanılarak kısa vadeli 10 dakika ileri zaman çözünürlüğüne sahip PV çıkış gücünü tahmin etmiştir.

3. Bulgular ve Tartışma

PV çıkış gücü, güneş radyasyonu, ortam sıcaklığı ve rüzgâr hızı vb. gibi meteorolojik parametrelerle yakından ilişkilidir. Bu çalışmada 10 dakika aralıklara sahip Makine öğrenimi modellerini test etmek için kullanılan eğitim verileri, Mayıs 2019 ile Nisan 2022 arasındadır. Bu çalışmada farklı modellerin tahmin performansını göstermek ve karşılaştırmak için her ayın 2'si seçildi.

3.1. Değerlendirme Endeksleri

Bir modelin tahmin doğruluğunu değerlendirmeye ve kıyaslamaya, standartlaştırılmış performans ölçüleri, yardımcı olur. Sırasıyla denklem (4.1) ve (4.2)'de gösterildiği gibi Ortalama Mutlak Yüzdeler Hata (OMYH/OMYH) ve Ortalama Karesel Hatası (OKH), bu çalışmadaki modellerinin doğruluğunu değerlendirmede kullanılmıştır: OMYH, tahminin doğruluğunu ölçen ve gerçek veri kümeleri için tahmin çeşitliliğini doğrulayan standart bir tahmin tekniğidir.

$$OMYH = \frac{1}{N} \sum_{i=1}^n \frac{|P_{Gerçek}(i) - P_{Tahmin}(i)|}{P_{Gerçek}(i)} \times 100\% \quad (31)$$

Ortalama görelî hatanın aralıklarına karşılık gelen ifadeler sırasıyla şu şekildedir;

$$\begin{aligned} 0 \leq OMYH \leq 10 & \text{ mükemmel tahmin doğruluğu,} \\ 10 \leq OMYH \leq 20 & \text{ iyi tahmin doğruluğu,} \\ 20 \leq OMYH \leq 50 & \text{ idare eder, tahmin doğruluğu,} \\ OMYH \geq 50 & \text{ ise yanlış tahmini ifade etmektedir.} \end{aligned}$$

OKH, tahmin edilen değerler ile gerçek gözlemler arasındaki karesel farklılıkların ortalamasının karekökünü kullanarak hatanın ortalama değerini tahmin eder. Bu nedenle, özellikle istenmeyen büyük sapmalarla baş etmede daha sağlamdır ve araştırmacıya aykırı değerleri belirleme ve ortadan kaldırma yeteneği verir.

OKH

$$OKH = \sqrt{\frac{1}{N} \times \sum_{i=1}^N (P_{Tahmin}(i) - P_{Gerçek}(i))^2} \quad (32)$$

Yukardaki formüllere göre P_{Tahmin} ve $P_{Gerçek}$ sırasıyla PV tahmin gücünü, ölçülen PV gücünü temsil eder. N, veri ölçümlerinin sayısıdır. OKH değeri $0 \leq OKH < \infty$ a kadar değişebilir. Negatif eğilimli düşük değerler daha iyi performans gösterir. OKH=0 olma durumu modelin hatasız olduğunu gösterir.

3.2. Tahmin Sonuçları

Bu çalışmada kullanılan büyük veri kümesi, Dicle üniversitesi kampüsünde kurulu olan PV güç santralinden ve güneş istasyonundan toplanmıştır; makine öğrenimi modellerinin büyük verilere ihtiyaç duymasının nedeni test sonuçlarının diğer koşullara uygulanabilir olması için etkin bir şekilde eğitilmesi içindir. Bu aşamada, modellerin tahmin doğruluğunu değerlendirmede kullanmak için her ayın 2'si seçilmiştir.


3.2.1. Hava tipi sınıflandırmasına dayalı GD-RVFLN modeli tahmin sonuçları

Modelin performans doğruluğunu artırmak için klasik RVFLN modeli geliştirilerek oluşturulan ve hava tipi sınıflandırmasına dayalı olan GD-RVFLN modelini önerilmiştir. Önerilen bu modelin tahmin sonuçları göstermiştir ki Mayıs 2022-Nisan 2021 tarihleri arasındaki tüm aylarda GD-RVFLN modeli $0 \leq OMYH \leq 10$ aralığında değerler olarak mükemmel tahmin doğruluğuna sahiptir (tablo 4.1'de gösterildiği gibidir). Aşağıdaki şekiller GD-RVFLN modelinin mükemmel doğruluk gösterdiği ay ile nispeten daha az mükemmellik gösterdiği aylardan alınan ve bu modelin ölçülen gerçek PV çıkış gücü sonuçlarıyla karşılaştırıldığı tahmin sonuçlarını göstermektedir.


Tablo2: PV güç çıkış seviyesine göre dört tip hava durumu sınıflandırması

Tarih	OMYH (%)	OKH
2.04.2022	3,919	1,646
2.03.2022	1,724	1,684
2.02.2022	1,687	1,680


2.01.2022	9,767	1,398
2.12.2021	8,886	1,445
2.11.2021	1,895	1,732
2.10.2021	2,254	1,499
2.08.2021	1,861	1,345
2.07.2021	1,811	1,664
2.06.2021	4,741	1,570
2.05.2021	5,407	1,358




Şekil 6: 02.03.2022 tarihinde ölçülen gerçek PV çıkış gücü ile GD-RVFLN modelinin tahmin sonucunun karşılaştırması



Şekil 7: 02.02.2022 tarihinde ölçülen gerçek PV çıkış gücü ile GD-RVFLN modelinin tahmin sonucunun karşılaştırması



Şekil 8: 02.01.2022 tarihinde ölçülen gerçek PV çıkış gücü ile GD-RVFLN modelinin tahmin sonucunun karşılaştırması



Şekil 9: 02.12.2021 tarihinde ölçülen gerçek PV çıkış gücü ile GD-RVFLN modelinin tahmin sonucunun karşılaştırması

Yukarıdaki şekillerde görüldüğü üzere önerilen GD-RVFLN modeli gerçek PV çıkış gücü ile yüksek doğrulukta performans göstermiştir. Şekillere bakıldığında bazı aylar arasında ölçüm sonuçlarında uyumsuzluk görülmektedir. Örneğin, şekil 4.6 ile şekil 4.8'e bakıldığında, Ocak 2022 de modelin tahmin doğruluğu OMYH=9,76 iken, Şubat 2022'deki doğruluk değeri, OMYH=1,68 çıkmıştır. Şekil 4.8'deki grafiğe bakıldığında grafikte PV çıkış gücünde inişler çıkışlar görülmektedir ayrıca o gün PV çıkış gücünün en yüksek değeri yaklaşık 35 kW'tır. PV sistemleri büyük oranda meteorolojik koşullara bağlıdır. Havanın bulutlu ya da yağmurlu olduğu günlerde PV çıkış gücü ya hiç üretilmemekte ya da düşük değerler üretmektedir bu da PV çıkış gücünde iniş ve çıkışlara neden olmaktadır. Şekil 4.8'deki grafiğin inişli çıkışlı olmasının nedeni de bu durumdan kaynaklanmaktadır. Bu yüzden Ocak 2022 ile Şubat 2022 arasındaki tahmin sonuçlarının farkının yüksek olmasının nedeni Ocak ayının 2'sinde yaşanan hava durumunun tutarsızlığından kaynaklanmaktadır. Buna rağmen havanın kararsız olduğu günlerde bile GD-RVFLN modeli $0 \leq OMYH \leq 10$ aralığında kalmaya devam ederek gerçek PV çıkış gücüyle yüksek benzerlik göstermiştir.

Hava tipi sınıflandırma yönteminin modellerde kullanılması çoğu makine öğrenimi modelinde kısa vadeli PV çıkış gücü tahmininin doğruluğunu artırdığı göstermiştir. Bununla birlikte hem hava tipi sınıflandırmasının hem de PV çıkış gücü tahmininin, güneş radyasyonu ile yüksek korelasyona sahip olduğu bilinmektedir. Dolayısıyla kararsız hava koşullarında güneş radyasyonundaki yüksek dalgalanmalar modellerin doğruluğunu önemli ölçüde etkilemiştir. Şekillerden ve tablolardan (tablo 3 ve tablo 4) da anlaşıldığı gibi en iyi performans gösteren ilk dört model, GD-RVFLN, BRR, LR, GPR'dir. Tüm modeller arasında ise mükemmel doğruluk gösteren model bu tezde önerilen model olan GD-RVFLN modeli olmuştur.

Bu çalışmada veriler her ayın belli bir gününde alındığı için PV çıkış gücü, o günün meteorolojik koşullarına bağlı olarak önemli ölçüde farklılık göstermektedir. Meteorolojik koşulların sabit olduğu günlerde bu çalışmada önerilen model olan GD-RVFLN'nin ortalama mutlak yüzdelik hata değerleri sırasıyla, 1,68; 1,72; 1,81; 1,86 ve 1,89 olmuştur. Öte yandan neredeyse tüm modeller meteorolojik koşulların sabit olduğu günlerde yüksek performans göstermiştir. Meteorolojik koşulların kötü olduğu günlerde ise (2 Ocak ve 2 Aralık) modellerin çoğu daha az iyi performans göstermiştir. Bu duruma rağmen önerilen GD-RVFLN modeli $0 \leq OMYH \leq 10$ aralığında kalarak mükemmel doğruluk gösterme performansını korumuştur. Makine öğrenmesi modellerinde çıktılar tahmin etme,

Tablo3: On bir makine öğrenimi modeli için OMYH (%) değerleri

TARİH	GD-RVFLN	BRR	LR	GPR	SVM	ELM	YSA	GBR	RFR	LAR	RR
2.04.2022	3,919	5,497	8,477	10,599	12,288	12,020	13,022	11,714	14,613	15,251	12,175
2.03.2022	1,724	2,752	3,768	4,265	5,691	6,489	7,527	6,585	8,595	8,963	10,972
2.02.2022	1,687	2,564	3,031	3,777	4,762	6,347	7,806	7,771	7,656	10,954	10,654
2.01.2022	9,491	12,270	20,295	23,472	20,146	27,062	26,831	35,706	35,566	39,002	39,930
2.12.2021	4,861	7,858	9,662	13,114	10,997	19,920	27,952	18,916	21,252	22,488	29,255
2.11.2021	1,895	1,989	2,842	4,002	3,954	4,391	5,423	6,334	4,418	6,208	10,337
2.10.2021	2,254	3,364	4,021	4,921	5,453	6,170	8,564	8,647	7,910	8,949	9,722
2.08.2021	1,861	3,987	4,946	7,583	7,707	6,411	9,887	10,690	7,873	11,531	9,667
2.07.2021	1,811	3,137	4,020	4,337	5,102	6,620	6,235	6,549	9,427	8,490	9,901
2.06.2021	2,293	3,478	6,125	4,940	7,569	7,676	9,531	10,243	7,780	11,007	11,395
2.05.2021	3,828	7,947	7,255	6,047	11,172	10,434	12,828	6,654	8,777	7,068	9,723

Tablo3: Tablo 4.3 On bir makine öğrenimi modeli için OKH değerleri

TARİH	GD-RVFLN	BRR	LR	GPR	SVM	ELM	YSA	GBR	RFR	LAR	RR
2.04.2022	1,646	2,498	3,519	4,016	5,112	5,897	6,506	7,046	7,968	8,859	7,569
2.03.2022	1,684	2,590	3,368	4,369	5,117	5,894	7,180	8,202	9,022	9,295	10,806
2.02.2022	1,680	2,485	3,266	3,771	4,678	5,631	6,532	7,769	7,921	9,495	10,221
2.01.2022	1,789	2,450	3,425	4,282	4,382	5,994	6,197	7,349	8,165	8,981	9,498
2.12.2021	1,617	2,354	3,038	4,160	4,243	6,139	7,524	7,277	7,845	8,618	8,962
2.11.2021	1,732	2,419	3,162	4,402	5,109	5,643	6,573	6,675	7,071	8,696	9,859
2.10.2021	1,499	2,248	3,134	3,973	4,353	5,640	6,630	7,445	7,845	8,981	10,053
2.08.2021	1,345	2,458	3,244	4,179	4,832	4,984	6,560	7,448	7,237	8,650	9,102
2.07.2021	1,664	2,468	3,215	3,873	4,707	5,824	6,354	6,881	8,533	9,354	9,760
2.06.2021	1,574	2,563	3,383	3,934	5,182	5,436	6,761	7,260	7,346	8,765	9,562
2.05.2021	1,351	2,173	2,585	3,128	4,104	4,993	5,564	5,630	5,899	6,068	7,506

öncelikle büyük miktarda verilerin eğitilmesi ile gerçekleşir, ancak verilerdeki düzensizlikler tahmin doğruluğunu olumsuz etkileyen ana faktördür. Bu nedenle modellerde kullanılan verilerin en iyi hava koşullarında elde edilen verilerden oluşması önem arz etmektedir. Ancak bu çalışmada modellerin performansını analiz etmek için her ayın belli bir günü tercih edildi. Bu yüzden modellerin değerlendirmesi seçilen günün hava koşulunun iyi veya kötü olma durumuna bağlı olarak aylık değil tek bir gün için değerlendirmeler yapıldı. Bu anlamda, hava durumunun iyi olduğu günlerde diğer bir değişle, havanın yağışsız, gökyüzünün açık olduğu günlerde PV çıkış gücü tahmini tüm modellerde nispeten yüksek performans göstermiştir. Öte yandan, gökyüzünün bulutlu ve yağışlı olduğu kararsız hava koşullarının olduğu günlerde elde edilen eğitim ve tahmin veri setlerinde büyük dalgalanmalar olmaktadır. Bu dalgalanmalar daha düşük bir tahmin doğruluğuna yol açmaktadır. Kararsız hava koşullarında en iyi modeller arasında en iyi PV çıkış gücü tahmini sağlayan model GD-RVFLN modelidir.

4. Sonuçlar

Bu çalışmada, gün öncesi PV çıkış gücünü tahmini on bir farklı makine öğrenimi modelleri üzerinde çalışıldı. İleri sürülen algoritmalar, PV çıkış gücünü tahmin etmek için hava koşullarına bağımlı olan meteorolojik verilerinin kullanılmasında, hava koşullarının belirsizliği nedeniyle modellerin tahmin sonucunda hem periyodik hem de rastgele değişimlere sebep olduğunu göstermiştir. Bu yüzden istikrarı yakalamak için birden fazla saatlik meteorolojik veriler üzerinde hava tipi sınıflandırması yapmak gerekmektedir. Bu çalışmada hava tipi sınıfını bulmak ve PV çıkış gücü tahmini iyileştirmek için GD-RVFLN modeli önerildi ve analiz için 10 farklı makine öğrenimi modeli seçildi. Çıkan sonuçlarda, 11 farklı makine öğrenimi içinde en iyi performansı gösteren modellerin önerilen model GD-RVFLN ve BRR modelleri olduğu bulundu.

Bu çalışmadaki yenilik, geleneksel yapay zekâ modellerinde karşılaşılan sorunların; örneğin çok büyük sayıda veri kullanımından kaynaklı bazı verilerin göz ardı edilmesi, verilerdeki uyumsuzluk ve yetersiz genelleme gibi birtakım sorunların üstesinden gelmek için PV çıkış gücünün meteorolojik verilerle korelasyonu göz önüne alınarak makine öğrenimi modellerini birleştirmektir. Önerilen modeller, Diyarbakır Dicle üniversitesi kampüsünde bulunan PV güç santraline kısa vadeli PV güç tahmini uygulanarak analiz edildi. Sonuçlar, önerilen hava tipi sınıflandırmasına dayalı makine öğrenme modellerinin göstermiş oldukları yüksek doğrulukları nedeniyle pratik uygulamalar için büyük potansiyele sahip olduğunu göstermiştir.

PV çıkış gücünün sürekli değişmesi şebekede gerilim, frekans dalgalanmaları ve güç kalitesi problemlerine neden olmaktadır. İletim ve dağıtım şebekelerinde gerilim ve frekans kontrolü kısa zamanlı (saniyeler ve dakikalar seviyelerinde) yapılması gerektiği için kısa dönemli PV çıkış gücü tahminine ihtiyaç duyulmaktadır. Literatürde de hem PV çıkış gücü tahmini hem de gerilim ve frekans kontrolü yapan çalışmalar az sayıda bulunmaktadır. Bundan dolayı PV çıkış gücü tahmini, kontrol çalışmaları, güç iletim ve dağıtımda ciddi öneme sahiptir. Gelecek çalışmalarda PV çıkış gücü tahmin tabanlı gerilim, frekans kontrolü çalışmaları ve güç kalitesi iyileştirme çalışmaları yapılabilir.

5. Kaynaklar

- [1] P. Markuse, Provisional Report on the State of the Global Climate 2020, World Meteorological Organization (WMO), 2021. Erişim Tarihi: 21 Ocak 2022. https://library.wmo.int/index.php?lvl=notice_display&id=21804#.YwThLEdBxPZ
- [2] H.E. Murdock, D. Gibb, T. André vd. Renewables 2021 Global Status Report, World Energy Council, REN21, 2021. Erişim Tarihi: 21 Ocak 2022. <https://www.ren21.net/reports/global-status-report/>
- [3] T. Gould, J. Coppel, T. Bienassis vd., World Energy Investment 2022, International Energy Agency, 2022. Erişim Tarihi: 21 Ocak 2022. <https://www.iea.org/reports/world-energy-investment-2022>
- [4] F. Barbieri, S. Rajakaruna, ve A. Ghosh. "Very short-term photovoltaic power forecasting with cloud modeling: A review," Renewable and Sustainable Energy Reviews, 75, Aug. 2017, s. 242-263.
- [5] G. Gowrisankaran, S. S. Reynolds ve M. Samano, "Intermittency and the value of renewable energy," Journal of Political Economy, vol. 124, no.4, Aug 2016, s. 1187-1234.
- [6] G. Stein ve T. M. Letcher, "Integration of PV generated electricity into national grids. In A comprehensive guide to solar energy systems" Academic Press, 2018, s.321-332.
- [7] G. Cervone, L. Clemente-Harding, S. Alessandrini, ve L. Delle Monache, "Short-term photovoltaic power forecasting using Artificial Neural Networks and an Analog Ensemble," Renewable Energy, vol.108, Aug. 2017, s. 274-286.
- [8] Z.L. Yang, M. Mourshed, K. Liu, vd., "A novel competitive swarm optimized RBF neural network model for short-term solar power generation forecasting," Neurocomputing, vol. 397, Jul. 2020, s.415-421.
- [9] D. Li and K. Sun, "Random Forest solar power forecast based on classification optimization," Energy, vol. 187, Nov. 2019, s. 1-11.
- [10] I. A. Ibrahim ve T. Khatib, "A novel hybrid model for hourly global solar radiation prediction using random forests technique and firefly algorithm," Energy Convers Manag, 2017, s.409-422.
- [11] H.Z. Wang, H.Y. Yi, J.C. Peng, vd., "Deterministic and probabilistic forecasting of photovoltaic power based on deep convolutional neural network," Energy Convers Manag, vol. 153, Dec. 2017, s.409-422.
- [12] H.Z. Wang, Z.X. Lei, X. Zhang, vd., "A review of deep learning for renewable energy forecasting," Energy Convers Manag, vol. 198, Oct 2019, s.1-16.
- [13] M.R. Douiri, "Particle swarm optimized neuro-fuzzy system for photovoltaic power forecasting model," Sol Energy, vol. 184, s.91-104, 2019.
- [14] Y.T. Li, Y. He, Y. Su, vd., "Forecasting the daily power output of a grid connected photovoltaic system based on multivariate adaptive regression splines," Appl Energy, vol.180, 15 Oct. 2016, s.392-401.
- [15] H. Wang ve J. Shen, "An Improved Model Combining Evolutionary Algorithm and Neural Networks for PV Maximum Power Point Tracking," in IEEE Access, vol. 7, 2019, s. 2823-2827.
- [16] Duman Altan , B. Diken ve B. Kayışoğlu , "Prediction of Photovoltaic Panel Power Outputs using Time Series and Artificial Neural Network Methods", Tekirdağ Ziraat Fakültesi Dergisi, c. 18, sayı. 3, ss. 457-469, Eyl. 2021, doi:10.33462/jotaf.837446
- [17] K. Tümay Ateş , "Çok Katmanlı Yapay Sinir Ağı Modeli ve Kültürel Algoritma Modeli Kullanılarak Geliştirilen Melez Yöntem ile Kısa Vadeli Fotovoltaik Enerji Santrali Çıkış Gücü Tahmini", Osmaniye Korkut Ata Üniversitesi Fen Bilimleri Enstitüsü Dergisi, c. 5, sayı. 1, ss. 342-354, Mar. 2022, doi:10.47495/okufbed.1028813

- [18] K.J. Wang, X.X. Qi, H.D. Liu, vd., "Deep belief network-based k-means cluster approach for short-term wind power forecasting," *Energy*, vol. 168, Dec. 2018, s. 840-852.
- [19] K.J. Wang, X.X. Qi, ve H.D. Liu, "A comparison of day-ahead photovoltaic power forecasting models based on deep learning neural network," *Appl Energy*, vol. 251, Oct. 2019.
- [20] L.Y. Liu, Y. Zhao, D.L. Chang, vd., "Prediction of short-term PV power output and uncertainty analysis," *Appl Energy*, vol. 228, Oct. 2018, s.700-711
- [21] G. Cervone, L. Clemente-Harding, S. Alessandrini, vd., "Short-term photovoltaic power forecasting using artificial neural networks and an analog ensemble," *Renew Energy*, vol. 108, Aug. 2017, s.274-284.
- [22] S. Sobri, S. Koohi-Kamali, ve N. Rahim Abd, "Solar photovoltaic generation forecasting methods: a review," *Energy Convers Manag*, vol.156, Jan. 2018, s. 459-497.
- [23] M.Q. Raza, M. Nadarajah, ve C. Ekanayake, "Review on recent advances in PV output power forecast," *Sol Energy*, vol. 136, Oct. 2016, s.125-144.
- [24] L.W. Zheng, Z.K. Liu, J.N. Shen, vd., "Very short-term maximum Lyapunov exponent forecasting tool for distributed photovoltaic output," *Appl Energy*, vol. 229, Nov. 2018, s.1128-1139.
- [25] X. Zhao, H. Wei, H. Wang, vd., "3d-cnn-based feature extraction of ground-based cloud images for direct normal irradiance prediction," *Sol Energy*, vol.181, 2019, s.510-518.
- [26] Y. Zhou, N. Zhou, L. Gong, vd., "Prediction of photovoltaic power output based on similar day analysis, genetic algorithm and extreme learning machine," *Energy*, vol. 204, 2020, s. 117894.
- [27] R. Ahmed, V. Sreeram, Y. Mishra, vd., "A review and evaluation of the state-of-the-art in PV solar power forecasting: techniques and optimization," *Renew Sustain Energy Rev*, vol. 24, May 2020, s.1-26.
- [28] W. VanDeventer, E. Jamei, G. S. Thirunavukkarasu, vd., "Short-term PV power forecasting using hybrid GASVM technique," *Renewable energy*, vol.140, 2019, s.367-379.
- [29] M. Massaoudi, S. S. Refaat, H. Abu-Rub, vd., "A Hybrid Bayesian Ridge Regression-CWT-Catboost Model For PV Power Forecasting," 2020 IEEE Kansas Power and Energy Conference (KPEC), 2020, s. 1-5
- [30] L. Gutiérrez, J. Patiño, ve E. Duque-Grisales, "A Comparison of the Performance of Supervised Learning Algorithms for Solar Power Prediction," *Energies*, vol.14, no. 15, 2021, s. 4424,
- [31] A. Afzal, S. Alshahrani, A. Alrobaian, vd., "Power plant energy predictions based on thermal factors using ridge and support vector regressor algorithms" *Energies*, vol.14, no. 21, 2021, 7254.
- [32] A. I. Khalyasmaa, S. A. Eroshenko, V. A. Tashchilin, vd., "Industry experience of developing day-ahead photovoltaic plant forecasting system based on machine learning," *Remote Sensing*, vol. 12, no.20, 2020, 3420.
- [33] S. Chahboun ve M. Maaroufi, "Novel comparison of machine learning techniques for predicting photovoltaic output power," *International Journal of Renewable Energy Research (IJRER)*, vol.11, no.3, 2021, s. 1205-1214.
- [34] A. Aggarwal ve M. M. Tripathi, "Short-term solar power forecasting using Random Vector Functional Link (RVFL) network," *In Ambient Communications and Computer Systems*, Springer, Singapore, 2018, s.29-39.
- [35] S. P. Mishra, P. P. Padhi, J. Naik, vd., "An efficient Robust Random Vector Functional Link network for Solar Irradiance, Power and Wind speed prediction," 2021 1st Odisha International Conference on Electrical Power Engineering, Communication and Computing Technology(ODICON), 2021, s. 1-7.
- [36] C. Haydaroglu, "Dicle Üniversitesi Güneş Enerjisi Santralinin Performans Analizi," (Yayımlanmamış Yüksek Lisans Tezi), Dicle Üniversitesi, Fen Bilimler Enstitüsü, 2017.
- [37] C. Haydaroglu ve B. Gümüş, "Dicle Üniversitesi güneş enerjisi santralının PVsyst ile simülasyonu ve performans parametrelerinin değerlendirilmesi," *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, vol. 7, no. 3, 2016. s. 491-500.
- [38] C. Haydaroglu ve B. Gümüş, "Investigation of the effect of short-term environmental contamination on energy production in photovoltaic panels: Dicle University solar power plant example," *Applied Solar Energy*, vol.53, no.1, 2017, s.31-34.
- [39] H. Kılıç, "Güneş Enerjisi ile İlgili Meteorolojik Verilerin Tahmini İçin Yöntem Geliştirilmesi," (Yayımlanmamış Yüksek Lisans Tezi), Dicle Üniversitesi, Fen Bilimler Enstitüsü, 2016.
- [40] B. Gumus ve H. Kilic, "Time dependent prediction of monthly global solar radiation and sunshine duration using exponentially weighted moving average in southeastern of Turkey," *Thermal Science*, vol.22, no.2, 2018, s. 943-951.
- [41] H. Kılıç, B. Gümüş ve M. Yılmaz, "Diyarbakır İli İçin Güneş Enerjisi Verilerinin Meteorolojik Standartlarda Ölçülmesi ve Analizi," *EMO Bilimsel Dergi*, vol.5, no.10, 2016, s.15-19.
- [42] M. Yılmaz, B. Gümüş, H. Kılıç ve M. E. Asker, "Chaotic analysis of the global solar irradiance," 2017 IEEE 6th International Conference on Renewable Energy Research and Applications (ICRERA), 2017, s. 1058-1066
- [43] C. Shen, M. Sun, M., Tang, ve C. E. Priebe, "Generalized canonical correlation analysis for classification," *Journal of Multivariate Analysis*, vol.130, 2014, s. 310-322.
- [44] W. Zuobin, M. Kezhi ve G.-W. Ng, "Feature Regrouping for CCA-Based Feature Fusion and Extraction Through Normalized Cut," 2018 21st International Conference on Information Fusion (FUSION), 2018, s. 2275-2282.
- [45] A. Affifi, V. A. Clark ve Susanne May, Canonical Correlation Analysis | R Data Analysis Examples, UCLA: Statistical Consulting Group,2004, Erişim tarihi: 12 Temmuz 2022. <https://stats.oarc.ucla.edu/t/dae/canonical-correlation-analysis/>
- [46] Y. H. Pao ve Y. Takefuji, "Functional-link net computing: theory, system architecture, and functionalities," in *Computer*, vol. 25, no. 5, May 1992, s. 76-79.
- [47] Y.H. Pao, G.H. Park, ve D.J. Sobajic, "Learning and generalization characteristics of the random vector functional-link net," *Neurocomputing*, vol.6, no.2, 1994, s.163-180.
- [48] Q. Shi, R. Katuwal, P. N. Suganthan, ve M. Tanveer, "Random vector functional link neural network based ensemble deep learning" *Pattern Recognition*, vol.117, 2021, s.107978.
- [49] A. E. Hoerl ve R. W. Kennard, "Ridge regression: Applications to nonorthogonal problems," *Technometrics*, vol. 12, no. 1, 1970, s. 69-82.
- [50] H. T. Huynh ve Y. Won, "Regularized online sequential learning algorithm for single-hidden layer feedforward neural networks," *Pattern Recognit. Lett.*, vol. 32, no. 14, Oct. 2011, s. 1930-1935.
- [51] W. Dai, Q. Chen, F. Chu, X. Ma ve T. Chai, "Robust Regularized Random Vector Functional Link Network and Its Industrial Application," in *IEEE Access*, vol. 5, 2017, s. 16162-16172.

Özgeçmişler



Berrin Eryılmaz, 1989 doğumlu, B.Sc. Gediz Üniversitesi Elektrik-elektronik Mühendisliği bölümünden 2014 yılında mezun oldu. Yüksek Lisans derecesini 2022 yılında Dicle Üniversitesi Fen Bilimleri Enstitüsü Yenilenebilir Enerji Kaynakları Anabilim Dalı'nda almıştır. Araştırmaları Makine öğrenimi tabanlı enerji tahminlemesi konularına odaklanmaktadır.



Dr. Heybet Kılıç, Gaziantep Üniversitesi'nde 2009 yılında Elektrik Elektronik Mühendisliği alanında lisans derecesini, 2016 yılında Elektrik ve Elektronik Mühendisliği alanında yüksek lisans derecesini ve 2021 yılında enerji sistemleri alanında doktora derecesini Dicle Üniversitesi'nden elde etmiştir. 2015 yılından bu yana Dicle Üniversitesi Elektrik Güç ve Enerji Bölümü'nde Yardımcı Doçent olarak görev yapmaktadır ve güç sistemleri, güç elektroniği ve yenilenebilir enerji sistemleri konularında dersler vermektedir. 2018-2020 yılları arasında ise Hollanda'daki TU Delft Elektrik Mühendisliği, Matematik ve Bilgisayar Bilimleri Fakültesi'nde Elektrikli Sürdürülebilir Enerji Departmanı'nda doktora araştırmacısı olarak görev yaptı. Araştırma ilgi alanları arasında fotovoltaikler, rüzgar enerjisinin dönüştürülmesi, güç sistemleri, mikro şebekeler, siber-fiziksel enerji sistemleri ve veri bilimi bulunmaktadır.



Fatih Koçyiğit, 1977 doğumlu, B.Sc. Dicle Üniversitesi Makine Mühendisliği bölümünden 2000 yılında mezun oldu. Yüksek Lisans ve Doktora derecelerini sırasıyla 2008 ve 2012 yıllarında Elazığ Fırat Üniversitesi Fen Bilimleri Enstitüsü Enerji Anabilim Dalı'nda almıştır. Halen Diyarbakır Dicle Üniversitesi'nde Doçent olarak çalışmaktadır. Araştırmaları ısı transferi, termodinamik, enerji, ekserji ve termal iletkenlik konularına odaklanmaktadır.

