

PAPER DETAILS

TITLE: Kisa dönem güneş isinim tahmininde farklı hibrit yöntem oluşturma stratejilerinin başarılarının karşılaştırılması

AUTHORS: Nazmiye Bozok, Emre Akarslan, Said Mahmut Çınar

PAGES: 75-92

ORIGINAL PDF URL: <https://dergipark.org.tr/tr/download/article-file/3947916>

Kısa dönem güneş ışınlam tahmininde farklı hibrit yöntem oluşturma stratejilerinin başarılarının karşılaştırılması

Comparison of successes of different hybrid method formation strategies in short-term solar radiation prediction

Nazmiye BOZOK*¹, Emre AKARSLAN¹, Said Mahmut ÇINAR¹

¹Afyon Kocatepe Üniversitesi, Mühendislik Fakültesi, Elektrik Mühendisliği Bölümü, 03200, Afyonkarahisar

• Geliş tarihi / Received: 22.05.2024

• Kabul tarihi / Accepted: 17.01.2025

Öz

Güneş ışınlam değeri, güneşten sağlayabileceğimiz enerji miktarı konusunda önemli bir bilgi taşır ve uygun bir planlama için ışınlamın gelecek değerinin kestirilebilmesi gerekir. Bu kapsamda çok farklı tahmin modelleri geliştirilmiş olup, son dönemde, farklı modellerin üstünlüklerinden faydalanmak amacıyla geliştirilen hibrit modeller ön plana çıkmaktadır. Bu çalışmada farklı hibrit model oluşturma stratejilerinin güneş ışınlam tahminindeki başarısı incelenmiştir. Bu kapsamda iki regresyon modeli (AR ve RIDGE) ile iki yapay zekâ yöntemi (Yapay Sinir Ağı (YSA) ve Elman Sinir Ağı (ENN)) referans yöntemler olarak seçilmiştir. Bu dört yöntemden farklı hibrit model oluşturma stratejileri kullanılarak 4 farklı hibrit model oluşturulmuştur. Güneş ışınlam verileri önce her bir yöntem bireysel kullanılarak modellenmiş sonra aynı süreç oluşturulan hibrit modeller ile gerçekleştirilmiştir. Hibrit modeller ile elde edilen sonuçlar hem birbirleri ile hem de bireysel modellerden elde edilen sonuçlar ile karşılaştırılmış ve performansları değerlendirilmiştir.

Anahtar kelimeler: Güneş ışınlamı, Hibrit strateji, Regresyon modeli, Yapay sinir ağı modeli

Abstract

The solar radiation value carries important information about the amount of energy we can obtain from the sun, and predicting the future value of radiation is necessary for proper planning. In this context, various prediction models have been developed, and recently, hybrid models developed to take advantage of the strengths of different models have come to the forefront. This study examines the success of different hybrid model formation strategies in solar radiation prediction. Two regression models (AR and RIDGE) and two artificial intelligence methods (Artificial Neural Network (ANN) and Elman Neural Network (ENN)) were selected as reference methods. Four different hybrid models were created using different hybrid model formation strategies from these four methods. Solar radiation data were first modeled individually using each method and then the same process was carried out using the created hybrid models. The results obtained with the hybrid models were compared both with each other and with the results obtained from individual models, and their performances were evaluated.


Keywords: Solar radiation, Hybrid strategy, Regression model, Artificial neural network model

*Nazmiye BOZOK; nazmiyebozok@gmail.com

1. Giriş

1. Introduction

Son yıllarda, sanayileşme, nüfus artışı ve yaşam standardındaki gelişmeler gibi etkenlerden dolayı küresel enerji talebi önemli ölçüde artmıştır (Vecan & Özerdem, 2011). Günümüzde, enerji üretimi modern sanayileşmiş toplumlar için hâlâ sınırlı kaynaklara bağlıdır. Bununla beraber enerji talebi gün geçtikçe artmaktadır ve yapılan projeksiyonlara göre artmaya da devam edecektir. Bu durum, alternatif enerji kaynaklarının araştırılmasını günümüzde önemli bir konu haline getirmiştir. Fosil yakıtların azalması ile güneş ışığı, rüzgâr, su, gelgit ve jeotermal ısı gibi yenilenebilir enerji kaynaklarına yönelim sağlanmıştır (Al-Shamisi vd., 2013). Artan enerji talebinin yanı sıra çevre bilincinin gelişmesi de yenilenebilir enerjiyi ön plana çıkarmıştır (Akarslan vd., 2014). Son yıllarda özellikle de fosil kaynakların kullanılmasından kaynaklanan atmosfer sıcaklığının artması ile oluşan sera etkisinin azaltılması çalışmalarında, yenilenebilir enerji önemli bir rol üstlenmektedir. Yenilenebilir enerji kaynakları arasında güneş enerjisi çeşitli üstünlükleri sebebiyle ön plana çıkmaktadır (Akarslan & Hocaoglu, 2016). Güneş enerjisinin düşük fiyatı ve evrensel bulunabilirliği bu üstünlükler arasında sayılabilir (El-Amarty vd., 2023). Güneş enerjisi, fotovoltaik güneş pilleri ve yoğunlaştırılmış güneş enerjisi gibi çeşitli yöntemlerle elektrik üretiminde kullanılmaktadır. Türkiye’de güneş enerjisinde geline son noktaya bakıldığında; Enerji ve Tabii Kaynaklar Bakanlığı verilerine göre, 2018 yılında 5063 MW olan güneş enerjisi kurulu gücü, Haziran 2022 itibariyle 8479 MW seviyelerine yükselmiştir. Aynı dönemde güneş enerjisinin Türkiye’deki toplam elektrik üretimi içindeki yüzdelik payı da artarak 2018 yılında %5,72’den, 2022 yılı itibariyle %8.35’e çıkmıştır. Bu artışlar, Türkiye’nin güneş enerjisi alanındaki büyümesini ve bu temiz enerji kaynağının elektrik üretim portföyündeki önemini vurgulamaktadır. Güneş enerjisinden daha etkili bir şekilde yararlanabilmek için güneş ışınımının özellikleri ile belirli bir zaman ve yerdeki miktarını bilmek gerekir (Vecan & Özerdem, 2011). Güneş ışınımı, değişken atmosferik koşullara, özellikle bulutlara ve aerosollere bağlı olarak oldukça stokastik bir olgudur (Thaker & Höller, 2022). Bu sebeple belirli bir zaman ve yerdeki miktarını belirlemek oldukça güçtür. Bu alanda literatürde gerçekleştirilmiş birçok çalışma mevcuttur. Bu çalışmalarda farklı teknikler kullanılmış olup, bu tekniklerin sınıflandırılmasına ilişkin bir şema Şekil 1’de sunulmuştur.



Şekil 1. Tahminleme metodolojileri

Figure 1. Forecasting methodologies

Literatürde, geliştirilen güneş ışıınım tahmini yöntemlerini inceleyen birçok önemli araştırma bulunmaktadır. Bunlardan bazıları şu çalışmaları kapsamaktadır:

(Deniz & Kemal, 2007) ele aldığı çalışmada, güneş ışıınımı şiddetini tahmin etmek için yapay sinir ağları (YSA) ve regresyon analiz yöntemleri karşılaştırılmıştır. Bu kapsamda, Zonguldak iline ait 1995 ile 2004 yılları arasındaki aylık ortalama veriler kullanılarak regresyon analiz yöntemi ve YSA ile modeller geliştirilmiştir. Regresyon analiz yöntemleri kullanıldığında ölçülen ve hesaplanan değerler arasında %1.28'lik bir ortalama bağıl hata belirlenirken, YSA kullanımında ise bu hata oranının %3.25 olduğu tespit edilmiştir. Al-Shamisi ve ark. (Al-Shamisi vd., 2013) tarafından yapılan bu çalışma yatay bir yüzeydeki aylık küresel güneş radyasyonunu tahmin etmek için bir YSA yaklaşımı sunmaktadır. YSA modelleri, 1995 ile 2007 yılları arasında 13 yıllık ölçülen meteorolojik veriler üzerinde uygulanmıştır. Modelleme için çok katmanlı algılayıcı (MLP) ve radyal tabanlı fonksiyon (RBF) sinir ağları kullanılmıştır. Elde edilen tahmin sonuçları regresyon modelleri ile karşılaştırılmıştır, sonuçlara göre YSA modeli diğer modellere göre daha iyi tahmin yaptığı görülmektedir. Akarslan ve ark. (Akarslan vd., 2014) tarafından ele alınan bir diğer çalışmada saatlik güneş radyasyonu tahmini için yeni bir yaklaşım geliştirilmiştir. Yıl boyunca saatlik olarak ölçülen ortam sıcaklığı ve dünya dışı ışıınım verileri 2 boyutlu görüntü formlarına dönüştürülmüştür. Daha sonra veri noktaları görüntülerin pikselleri olarak değerlendirilmiştir. Ardından farklı MD (Çok Boyutlu) doğrusal tahmin filtre modelleri tasarlanmıştır. Sıcaklık, dünya dışı ışıınım ve bu verilerin türevlerinin önerilen MD doğrusal tahmin filtrelerine dahil edilmesiyle tahmin doğruluğunun artırılmasının mümkün olduğu gösterilmiştir. Çalışmada 14 farklı model ve 9 farklı filtre-musluk konfigürasyonu tasarlanmış ve test edilmiştir. Sonuçlar daha önce geliştirilen doğrusal tahmin filtre modelleri ve geleneksel yöntemlerle karşılaştırıldığında farklı MD modelleri için %1 ila %30 aralığında daha iyi tahmin doğruluğu sağladığını göstermektedir. Gutierrez-Corea ve ark. (Gutierrez-Corea vd., 2016) tarafından yapılan bir diğer YSA tabanlı tahminleme modelinde, 900'e kadar girdiyle Yapay Sinir Ağları kullanılarak mekânsal-zamansal kısa vadeli güneş ışıınım tahmininin modellenmesi, ilgili çalışmalarda elde edilen hata oranlarını azaltarak %20'nin altında doğruluk seviyesi elde etmiştir. Akarslan ve Hocaoglu (Akarslan & Hocaoglu, 2017) tarafından gerçekleştirilen yeni bir kısa vadeli güneş ışıınımı tahmin metodolojisi ile geçmiş veri kayıtlarını kullanarak istenilen saatlere ait güneş ışıınımı değerleri tahmin edilmiştir. Tahmin için, geçmişteki tahmin gününe benzer bir gün aranmış ve tahmin saatine kadar ölçülen güneş ışıınımı verilerini içeren bir arama vektörü oluşturulmuştur. Daha sonra, benzer bir güne ait verilerin sapma bilgileri kullanılarak tahmin gerçekleştirilmiştir. Cho ve ark. (Cho vd., 2020) tarafından yapılan bir diğer çalışmada ise mevcut enerji üretim verilerine dayanarak, güneş radyasyonu ve sistem dönüştürme verimliliği ile Paralel Elman Sinir Ağını (PENN) kullanan saatlik alan güneş enerjisi tahmin modeli önerilmektedir. K-ortalama değerlendirmesi ve ters mesafe ağırlıklandırmayı içeren yerleşik değerlendirme algoritması kullanılmıştır. Elde edilen sonuçlara göre önerilen PENN algoritmasının RMSE ve MAPE açısından Geri Yayılım Yapay Sinir Ağı (BP-NN) ve ENN den daha iyi olduğu görülmektedir. Guher ve ark. (Guher vd., 2020) ele aldığı çalışmada, Kahramanmaraş ve Isparta illerinin saatlik ışıınımını tahmin etmek için Makine Öğrenmesi (ML) algoritmaları aynı enlemdeki iki coğrafi konumun saatlik ortalama güneş ışıınımını tahmin etmek için kullanılmıştır ve elde edilen sonuçlarla karşılaştırmalı bir değerlendirme yapılmıştır. Gabralı ve Arslan (Gabralı vd., 2020) ise İstanbul Büyükşehir Belediyesi İlçesi Eskice Bölgesine ait 2016 yılı meteorolojik verilerini kullanarak güneş radyasyonu için ileriye yönelik kısa ve orta vadeli bir tahmin çalışması yapmıştır. Modellemede YSA kullanılmıştır. Sonuçlar, güneş radyasyonu tahmininde YSA modellerinin diğer regresyon modelinden daha başarılı olduğunu göstermektedir. Arseven ve Çınar (Arseven & Çınar, 2023) tarafından yapılan bu çalışmada, Oto Regresif Entegreli Hareketli Ortalama (ARIMA), Ridge ve Lasso regresyon modelleri ile, 1 saatlik zaman ufkunda güneş ışıınımı tahmini işlemi gerçekleştirilmiştir. Ayrıca Dünya Dışı Işıınım Filtresinin (DDIF) kullanılan yöntemte entegrasyonu ile tahmin sonuçları iyileştirilmiştir. (Gök vd., 2019) tarafından ele alınan çalışmada Kahramanmaraş'taki GES üretimleri Yapay Sinir Ağları (YSA) tabanlı Levenberg-Marquardt algoritmasıyla eğitilmiş ve bulutluluk tahmin verileri ile geçmiş üretim verileri kullanılarak test edilmiştir. Analizler sonucunda, bulutluluk tahmini eklenen modelin, sadece geçmiş üretim verilerini kullanan modele göre daha başarılı olduğu bulunmuştur. (Alkan vd., 2018) tarafından gerçekleştirilen çalışmada rüzgâr ve güneş enerjisi santralleri için kısa dönem enerji üretim tahmin modelleri geliştirilmiş ve doğrulukları test edilmiştir. RMSE ve R2 gibi metriklerle yapılan analizlerde, tahmin modellerinin %99 güvenilir olduğu belirlenmiştir. Ayrıca, MAPE değerinin %10'un altında çıkması, modellerin doğruluğunu teyit etmiştir. (Demirgöl vd., 2024) yaptığı bu çalışmada Türkiye'deki 3600 grid noktasına ait solar radyasyon değerleri MARS ve LSSVR makine öğrenmesi teknikleriyle tahmin edilmiştir. Bu yöntemlerin, geleneksel yöntemlere kıyasla daha kolay ve alternatif bir çözüm sunduğu gösterilmiştir. (Çevik vd., 2017) tarafından ele alınan bu çalışmada, Trabzon'da gün öncesi güneş radyasyonu tahmini için bir yapay sinir ağı (YSA) geliştirilmiş ve benzer gün seçimi algoritması kullanılmıştır. MATLAB'da eğitilen YSA,

yağışlı ve bulutlu hava koşullarında güneş ışınlamını kabul edilebilir hata oranıyla tahmin edebilmiştir. %9,88 OMYH ve 0,94 korelasyon katsayısı ile başarı değerlendirilmiş, bağıl nem ve sıcaklık verileri kullanılarak tahmin doğruluğu artırılmıştır.

Yukarıdaki sunulan literatür incelendiğinde, yapay zekâ yöntemleri ile regresyon yöntemlerinin güneş ışınlam tahmini alanında sıkça kullanıldığı ve bu yöntemlerle başarılı sonuçlar elde edildiği görülmektedir. Bununla beraber daha başarılı sonuçlar elde etmek hedefiyle, literatürde, iki veya daha fazla farklı teknik veya yaklaşımın entegrasyonunu içeren hibrit yöntemlerin geliştirildiği görülmektedir. Bu modeller, her modelin gücünü ve faydalarını birleştirerek farklı tahmin problemleri için bağımsız bir modelden daha iyi performans sağlama yetenekleri nedeniyle son zamanlarda oldukça önemli hale gelmiştir (El-Amarty vd., 2023). Tahminde hibrit modelin temel fikri, verilerdeki farklı kalıpları yakalamak için her modelin benzersiz özelliğini kullanmaktır. Hem teorik hem ampirik bulgular, farklı modellerin birleştirilmesinin tahmin performansını iyileştirmenin etkili bir yolu olabileceğini göstermektedir (Ji & Chee, 2011). Literatürde hibrit yöntemlerin kullanıldığı birçok çalışma mevcuttur ve bunlardan bazıları aşağıda özetlenmiştir.

Ji ve Chee (Ji & Chee, 2011) tarafından yapılan çalışmada saatlik güneş ışınlam serisini tahmin etmek için Otoregresif ve Hareketli Ortalama (ARMA) modeli ile tartışmalı Zaman Gecikmeli Sinir Ağı (TDNN)'ni birleştiren hibrit bir model kullanılmıştır. Sonuç olarak güneş ışınlamının değişken bileşenleri sebebiyle, bu hibrit modelin hem ARMA hem de TDNN'nin avantajlarından yararlanabileceğini göstermektedir. (Benmouiza, Cheknane, & Management, 2013)'in ele aldığı çalışmada k -means algoritması ile Doğrusal Olmayan Otoregresif (NAR) ağını birleştiren yeni bir hibrit yöntem önerilmiş ve bu yöntem ile saatlik küresel güneş radyasyonu zaman serisinin birkaç saat önceden tahmini yapılmıştır. Sonuçlar yöntemin oldukça başarılı bir performans ortaya koyduğu göstermektedir. Akarslan ve Hocaoglu (Akarslan & Hocaoglu, 2016) yaptıkları çalışmada, saatlik güneş radyasyonu tahmini için iki farklı uyarlanabilir yaklaşım geliştirmiş ve test etmiştir. İlk yaklaşımda veriler mevsimlere ayrılmış ve doğrusal ve ampirik yöntemler kullanılmıştır. İkinci yaklaşımda açıklık indeksi, doğrusal yöntemin mi yoksa ampirik yöntemin mi daha başarılı olacağına karar vermek adına kullanılmıştır. Her iki stratejiyi de içeren yöntemin, doğrusal tahmin filtre yaklaşımından daha iyi performans sergilediği gösterilmiştir. Gairaa ve ark. (Gairaa vd., 2016) tarafından ele alınan bir diğer hibrit yöntemde günlük küresel güneş ışınlamını tahmin etmek için ARMA modeli ile doğrusal olmayan YSA modelini birleştiren yeni bir model önerilmiştir. Gözlemlenen ve tahmin edilen verilerin ARIMA ve YSA ile karşılaştırılması, hibrit modelin başarılı bir model olduğunu ortaya koymuştur. Hocaoglu ve Serttas (Hocaoglu & Serttas, 2017) tarafından yapılan çalışmada, Mycielski ve Markov modellerini kullanan yeni bir hibrit yöntem önermişlerdir. Mycielski modeli geçmişte tekrarlanan en uzun diziye bağlı olarak gelecek ışınlam değerini belirlerken, Markov modeli, Mycielski modelinin kararsızlık oluşan durumları için olasılıksal bir çözüm sunmaktadır. Önerilen yaklaşımın güneş ışınlam tahmininde yüksek bir performans sağladığı görülmektedir. Mukaram ve Yusof (Mukaram vd., 2017), Malezya'ya ait aylık ortalama güneş radyasyonu verileri Mevsimsel Otoregresif Entegre Hareketli Ortalama (SARIMA) modeli, YSA modeli ile hibrit yöntem kullanarak modellemiştir. SARIMA modeli mevsimsel verileri tahmin etmede güvenilir bir araç iken, YSA modelinin doğrusal olmayan verileri tahmin etmede iyi bir model olduğu kanıtlanmıştır. Her iki modeli birleştirerek daha doğru bir model elde edilmiştir.

Sansa ve ark. (Sansa vd., 2021) tarafından ARMA ve NARX olmak üzere iki modeli birleştiren yeni bir güneş radyasyonu tahmin yaklaşımı sunulmuştur. Önerilen model, haftalık güneş ışınlam ortalamlarını tahmin etmedeki etkinliğini yansıtan bazı farklı araştırmalarla karşılaştırıldığında daha iyi sonuçlar göstermiştir. Maham ve Akarslan (Maham & Akarslan, 2022) tarafından yapılan çalışmada, saatlik güneş ışınlam tahmini için yeni bir hibrit yaklaşım önerilmiştir. Önerilen hibrit yöntemde, ilk olarak bulutluluk indeksi hesaplanarak yapay sinir ağları ile tahmin edilmiş ve buna göre kullanılacak yönteme karar verilmiştir. Bu kapsamda YSA, NARX ve RR yöntemleri baz alınarak geliştirilen hibrit yöntemin performansı, aynı veri setinde her bir yöntemin bireysel performansı ile karşılaştırılmıştır. Karşılaştırma sonucunda hibrit yöntemin daha başarılı sonuçlar sağladığı gösterilmiştir. Rangel ve ark. (Rangel-Heras vd., 2022), NARX modeli ve Düzeltici Vektör Çarpanı (CVM) modelini güneş ışınlam tahmini için hibrit bir model olarak kullanmıştır. Hibrit NARX-CVM modeli, doğrusal olmayan bir otoregresif sinir ağı ve kalıcılık modeliyle karşılaştırılmıştır. Sonuçlar, hibrit modelin daha başarılı olduğunu göstermektedir. Yalçın ve Herdem (Yalçın & Herdem, 2022), hava durumu parametreleri ile güneş ışınlamını tahmin etmek için bir LSTM (Uzun Kısa Süreli Bellek) -CNN (Evrişimli Sinir Ağı) hibrit derin öğrenme modeli önermiştir. Önerilen algoritma Python kodlama dilinde gerçekleştirilmiş ve mevcut LSTM ve CNN tabanlı algoritmalar ile karşılaştırılmıştır. Sonuçlara göre önerilen yöntem en az hata oranına sahiptir. Belmahdi ve ark. (Belmahdi vd., 2023) tarafından yapılan çalışmada, iki şehirdeki günlük

küresel güneş radyasyonunun tahmini, MATLAB simülasyon platformunda modellenen FFBP (İleri Beslemeli Geri Yayılım), ARIMA, ARMA, hibrit ARMA-FFBP ve hibrit ARIMA-FFBP gibi beş yaklaşımla değerlendirilmiş ve karşılaştırılmıştır. Sonuçlar; hibrit ARIMA-FFBP modelinin, hibrit ARMA-FFBP ve diğer modellere nazaran daha başarılı bir performans ortaya koyduğunu göstermektedir.

Literatürden elde edilen veriler ışığında güneş ışıınımı tahmininde hibrit yöntemlerin başarısının yüksek olduğu gözlemlenmektedir. Bu kapsamda sunulan bu çalışmada, farklı hibrit model oluşturma stratejilerinin saatlik güneş ışıınımının tahminindeki başarısı incelenmiştir. Sunulan çalışmada değerlendirilen hibrit yöntemlerde kullanılan bireysel yöntemlerin tamamı aynı amaç (aynı değeri tahmin etmek) için kullanılmaktadır. Bütün bireysel yöntemler aynı değeri tahmin etmeye çalışırken, hibrit yöntem ya bunların ortalaması üzerinden bir tahmin değeri üretir ya da yöntemlerden birinin sonucunu seçer. Bu kapsamda, kullanılan güneş ışıınım verileri, Meteoroloji Genel müdürlüğünden alınmış olup Van iline ait 2013 ve 2014 yıllarını kapsayan iki senelik verilerdir. Bu verileri modellemek için, doğrusal olan AR (Auto Regressive), Ridge Regresyon ve stokastik olan Yapay Sinir Ağları (YSA), Elman Sinir Ağları (ENN) olmak üzere dört yöntem seçilmiştir. Daha sonra veriler her bir yöntem ile modellenerek başarısı gözlemlenmiştir. Ardından model çıktıların ortalaması ve ağırlıklandırılmış ortalamalarının alınarak tahminlerin gerçekleştirildiği hibrit bir model stratejisi uygulanmıştır. Sonrasında veri seti mevsimlere ve aylara göre ayrılıp her bir yöntemin ilgili mevsim ve aydaki tahmin başarısı karşılaştırılmıştır. Her mevsim ve aydaki yüksek performansa sahip modelleri belirleyerek uygun modeli seçen hibrit bir strateji uygulanarak nihai tahminler gerçekleştirilmiştir. Uygulanan dört farklı hibrit yöntem stratejisi ile elde edilen sonuçlar karşılaştırılarak değerlendirilmiştir. Sunulan makalenin akışı şu şekilde kurgulanmıştır; ikinci bölümde kullanılan veriler ve özellikleri sunularak tahmin için kullanılan modeller açıklanmış ve sonuçları değerlendirmede kullanılan değerlendirme kriterleri sunulmuştur. Üçüncü bölümde gerçekleştirilen simülasyon çalışmaları detaylıca anlatılıp sonuçlar paylaşılmıştır. Son bölümde ise elde edilen sonuçlar değerlendirilmiş ve tartışılmıştır.

2. Materyal ve metot


2. Material and method

Bu bölümde, öncelikle çalışmada kullanılan Van iline ait güneş ışıınımı veri setine ilişkin bilgiler sunulmuştur. Ardından çalışmada kullanılan AR, Ridge Regresyon, Yapay Sinir Ağları ve Elman Sinir Ağları tahmin modelleri ayrıntılı olarak ele alınmıştır. Güneş ışıınım verisinin doğrusal ve doğrusal olmayan karakteristikleri içeren doğası sebebiyle çalışmada, doğrusal olmayan karakteristikli veriyi modellemedeki başarısı dikkate alınarak yapay zeka yöntemleri (Yapay Sinir Ağları ve Elman Sinir Ağları) ve doğrusal karakteristikli veriyi modellemedeki başarısı dikkate alınarak regresyon yöntemleri (AR ve Ridge Regresyon) seçilmiştir. Sonrasında çalışmada kullanılan hibrit model oluşturma stratejileri anlatılarak, yöntemlerin başarılarını yorumlamada kullanılacak değerlendirme kriterlerinden bahsedilmiştir.

2.1. Kullanılan veriler


2.1. Data used

Bu çalışmada, kullanılan veri seti, Türkiye Meteoroloji Genel Müdürlüğü tarafından sağlanan Van ili 2013 ve 2014 yıllarına ait saatlik güneş ışıınım verilerini kapsamaktadır. Van ili; Türkiye'nin doğusunda, 38,48914° kuzey enlemi ve 43,40889° doğu boylamında konumlanmış olup deniz seviyesinden 1727 metre yüksekliktedir. Van iline ait ölçülen bir yıllık güneş ışıınım değerinin değişim grafiği Şekil 2'de verilmiştir. Şekilden görüleceği gibi özellikle kış ve bahar aylarında değişkenliğin oldukça fazla olduğu anlaşılmaktadır. Şekil 3'te Türkiye'ye ilişkin güneşlenme haritası sunulmuştur. Haritadan da anlaşılabacağı üzere Van, ülkemiz geneline kıyasla güneş enerjisi potansiyeli oldukça yüksek bir ildir. Güneş enerjisi üzerine yatırımlar genellikle güneş potansiyelinin yüksek olduğu bölgelerde yoğunlaşır ve ister yatırım planlama amacıyla olsun ister yönetim amacıyla olsun, bu bölgeler için farklı ölçeklerde tahmin çalışmalarına ihtiyaç duyulur. Sunulan çalışmada güneşlenme potansiyeli yüksek bir bölge olması sebebiyle Van iline ait veriler kullanılmıştır.



Şekil 2. 2013 yılı güneş ışıınım değerleri
Figure 2. 2013 solar radiation values

Bu çalışmada 2013 yılına ait 8760 adet güneş ışıınım verisi (1 Ocak 2013- 31 Aralık 2013) eğitim için kullanılırken, 2014 yılına ait 8760 adet güneş ışıınım verisi ise (1 Ocak 2014- 31 Aralık 2014) tahmin modellerinin yeteneğini test etmek amacıyla kullanılmıştır. Çalışmada doğrusal model olarak otoregresif ve ridge regresyon olmak üzere iki model, stokastik model olarak ise ileri besleme geri yayımlı yapay sinir ağları (YSA) ve elman sinir ağları kullanılmıştır.



Şekil 3. Güneş enerjisi potansiyeli haritası Van ili (GEPA) (EİGM)
Figure 3. Solar energy potential map Van province (GEPA) (EİGM)

2.2. Otoregresif (AR) model

2.1.1. Autoregressive (AR) model

Otoregresif (AR) modeli, bir zaman serisi analizi yöntemidir ve bir değişkenin geçmiş değerlerinin, kendisiyle lineer bir ilişkisi olduğunu varsaymaktadır. Bu model, bir değişkenin geçmiş gözlemlerine dayanarak gelecekteki değerleri tahmin etmeye çalışan ve zaman serileri analizinde yaygın olarak kullanılan istatistiksel bir araçtır. Aynı zamanda durağan zaman serileri için oldukça doğru tahminler sağlamakta ve az veriye ihtiyaç

duymaktadır. AR modelleri, birçok avantaja sahiptir: AR modelleri, diğer zaman serisi modellerine kıyasla daha basit bir yapıya sahiptir ve kullanımı kolaydır. AR modelleri, diğer zaman serisi modellerine kıyasla daha az veriye ihtiyaç duyar. AR(p) modeli, p geçmiş değeri kullanarak bir sonraki zaman adımının değerini tahmin etmeye çalışır. Otoresif model denklem (1) ile hesaplanmaktadır (Filik & Filik, 2017; Zhen-Yu & Lian-Wen, 2008).

$$y(t) = c + \sum (\varphi(i)y(t-i)) + \varepsilon(t) \quad (1)$$

Bu denklemde $y(t)$ değişkenin t anındaki değerini, c Sabit terimi, $\varphi(i)$ birinci gecikme için katsayısı, $y(t-i)$ değişkenin $t-i$ zamanındaki değerini ve $\varepsilon(t)$ t zamanındaki hata terimini temsil etmektedir.

2.3. Ridge regresyon

2.3. Ridge regression

Ridge regresyon (RR) yöntemi ilk defa 1970 yılında Technometrics dergisinde yayınladıkları iki makale ile Hoerl ve Kennard tarafından geliştirilmiştir (Büyükuysal, 2010) Amaç, regresyon katsayılarını küçültmek veya sınırlamak suretiyle modelin aşırı uyum (overfitting) sorununu çözmektir. Regresyon modellerinde amaç, bağımlı değişkeni (tahmin edilmek istenen değişkeni) en iyi açıklayan katsayıları bulmaktır. Ridge regresyonda, En Küçük Kareler yöntemiyle hesaplanan regresyon katsayılarına bir ceza eklenir. Katsayıların karelerinin toplamı modelin hata fonksiyonuna eklenir. Bu cezalandırma, katsayıların çok büyük değerlere ulaşmasını engeller, böylece daha genel, dayanıklı ve daha iyi genelleme yeteneğine sahip bir model elde edilir. Bu ceza, katsayıların büyüklüğünü sınırlayarak modelin karmaşıklığını azaltır. Bu sayede, modelin varyansını düşürerek aşırı uyumu azaltır ve daha genelleştirilebilir bir model elde edilir. Ridge regresyonun formülü denklem (2) de verilmektedir.

$$L_{ridge}(\beta) = \arg \min \left\{ \sum_{i=1}^N (y_i - \beta_0 - \sum_{j=1}^p x_{ij}\beta_j)^2 + \lambda \sum_{j=1}^p \beta_j^2 \right\} \quad (2)$$

L_{ridge} Ridge regresyonu ile tahmin edilen regresyon katsayıları vektörünü ifade ederken

$\sum_{i=1}^N (y_i - \beta_0 - \sum_{j=1}^p x_{ij}\beta_j)^2$ ifadesi En Küçük Kareler yöntemi tarafından minimize edilen hatanın karesini

belirtmektedir. λ ise Ridge regresyonunun düzenleme parametresi veya katsayısıdır.


Ridge regresyon, özellikle bağımsız değişkenler arasında çoklu doğrusal bağımlılıkların olduğu durumlarda ve aşırı uyumun olduğu durumlarda faydalıdır. Bu yöntem, modelin kararlılığını artırır ve genelleme performansını iyileştirir.

2.4. Yapay Sinir Ağları (YSA)

2.4. Artificial Neural Networks (ANN)

Yapay sinir ağları (YSA), insan beyninin bilgi işleme süreçlerine benzer bir yapıya sahip matematiksel modellerdir. Bu modeller, yapay nöron adı verilen temel işlem birimlerinden oluşur ve bu nöronlar katmanlar halinde düzenlenir. YSA'ların temelinde, giriş verilerini işleyerek çıktı üreten karmaşık bir ağ yapısı bulunur. Bu ağ yapısı genellikle üç ana katmandan oluşur: giriş katmanı, gizli katman ve çıktı katmanı. Giriş katmanı, dış dünyadan gelen bilgileri alırken, çıktı katmanı ise sonuçları sunar. Aradaki gizli katmanlar ise karmaşık ara hesaplamaları gerçekleştirir ve bilgiyi işler (Belmahdi vd., 2023).

Yapay sinir ağları, belirli bir öğrenme algoritması kullanılarak veri örneklerinden öğrenirler ve ağırlıklarını bu öğrenme süreci boyunca güncellerler. Bu sayede, girdi verilerinden çıktı tahminleri yapabilirler (Benmouiza et al., 2013). Yapay sinir ağları, geniş bir uygulama alanına sahiptir ve modelleme, tahminleme ve kontrol gibi birçok alanda kullanılmaktadır. Özellikle de YSA'lar karmaşık ve doğrusal olmayan ilişkileri modelleme konusunda önemli bir araç olarak kabul edilmektedir. Şekil.4'te YSA'nın genel modeli gösterilmektedir.



Şekil 4. YSA matematiksel modeli

Figure 4. ANN mathematical model

Giriş verileri $x = (x_1, x_2, x_3, \dots, x_n)$ doğrudan giriş katmanına verilir. Her bir gizli katmandaki her bir sinir hücresi, giriş verilerinden ve önceki katmandaki sinir hücrelerinden gelen ağırlıklı toplamı alır, ardından bir aktivasyon fonksiyonuna (genellikle sigmoid, ReLU, tanh vb.) uygular. Her bir sinir hücresinin çıktısı, bir sonraki katmandaki sinir hücrelerine giriş olarak kullanılır. Son gizli katmandan gelen çıktılar, çıktı katmanına beslenir. Çıktı katmanındaki her bir sinir hücresi, gizli katmandaki sinir hücrelerinden gelen ağırlıklı toplamı alır ve yine bir aktivasyon fonksiyonuna uygular. Matematiksel gösterimi denklem (3) de verilmektedir.


$$z = \sum_{i=1}^n w_i x_i + b \quad (3)$$

Z ağırlıklı girdi toplamını, w_i girişlerin ağırlıklarını, x_i giriş değerlerini, b sinir hücresinin sapmasını (bias), n ise giriş sayısını belirtmektedir.

2.5. Elman Sinir Ağları

2.5. Elman neural networks

Elman sinir ağları, yapay sinir ağlarının bir türüdür ve geri beslemeli (recurrent) yapılara sahip bir sinir ağıdır (Cho et vd., 2020). Bu yapı, geçmiş zamandaki durumları hatırlayarak mevcut girdiyi işlemek için kullanılmaktadır. Elman sinir ağlarının mimarisi genel olarak dört katmandan oluşur: giriş, gizli katman, geri besleme bağlantıları ve gizli katman (Jallal et vd., 2019). Giriş katmanından gelen bilgiler gizli bir katmana iletilir ve ardından bir çıktı katmanı tarafından işlenir. Elman ağlarının gizli katmanında, her bir birim, önceki zaman adımlarında alınan çıktıları saklamak için bir bağlam birimi ile birleştirilir. Bu bağlam birimi, giriş katmanından gelen bilgilerle birleştirilerek ağız gizli katmanına geri besleme yapar. Bu yapı, ağız önceki zaman adımlarında aldığı bilgileri mevcut işlem için kullanmasını sağlar, böylece zaman serileri gibi zaman bağımlı verileri işleyebilir. ENN; dil işleme, zaman serileri tahmini ve kontrol uygulamaları gibi birçok alanda başarıyla kullanılmaktadır. Şekil.5'te Elman sinir ağlarının modeli sunulmaktadır.



Şekil 5. Elman sinir ağları

Figure 5. Elman neural networks

Genel olarak, bir Elman sinir ağı formülü denklem (4) ile hesaplanmaktadır.

$$h_t = f(W_{ih}x_t + W_{hh}h_{t-1} + b_h) \quad (4)$$

$$y_t = g(W_{ho}h_t + b_o)$$

Bu denklemlerde h_t t zaman adımındaki gizli katman çıktısı, x_t t zaman adımındaki girdi vektörü, W_{ih} girdi katmanı ile gizli katman arasındaki ağırlık matrisi, W_{hh} gizli katman içindeki geri besleme bağlantıları için ağırlık matrisi, W_{ho} Gizli katman ile çıktı katmanı arasındaki ağırlık matrisi, b_h ve b_o sırasıyla gizli ve çıktı katmanlardaki bias terimleri ve f ve g aktivasyon fonksiyonları olarak tanımlanmaktadır.

2.6. Hibrit yöntem

2.6. Hybrid method

Bu çalışmada; saatlik güneş radyasyonunu tahmin etmek için AR, Ridge Regresyon, YSA ve ENN modelleri kullanılarak farklı hibrit model oluşturma stratejileri ile hibrit yöntemler oluşturulmuştur. Bu kapsamda ilk olarak dört model ile bireysel tahminler yapıp sonuçlar değerlendirilmiştir. İlk hibrit model oluşturma stratejisinde kullanılan yöntemlerden elde edilen tahmin değerlerinin aritmetik ortalaması alınarak tahminler gerçekleştirilir. İkinci hibrit modelde ise eğitim aşamasındaki hata oranları dikkate alınarak her bir modelden elde edilen sonuçlar ağırlıklandırılıp ortalama değer alınarak tahmin değeri elde edilmiştir. Ağırlıklandırılma yapılırken en başarılı yöntemin en yüksek ağırlığa sahip olacak şekilde ağırlıklar belirlenmiş ve bu ağırlıklarla çarpılıp ortalaması alınarak ağırlıklı ortalama tahmin değeri elde edilmiştir. Üçüncü modelde kullanılan her bir yöntemin farklı mevsimlerdeki eğitim seti üzerindeki performansları incelenerek, her bir mevsimde en başarılı yöntemler belirlenmiştir. Mevsimlerde güneş karakteristiği birbirinden farklılık göstereceği için farklı modeller farklı mevsimlerde başarılı olabilirler. Bunu dikkate alarak mevsime dayalı bir hibrit yapma yöntemi kullanılmıştır. Tahmin aşamasında ise eğitim setinden elde edilen bilgiler kullanılarak, her mevsimde o mevsimde en başarılı yöntemin çıktısı hibrit yöntemin tahmini olarak belirlenmiştir. Dördüncü strateji de ise benzer bir yaklaşım aylık bazda değerlendirilmiştir. Eğitim setinde bireysel yöntemlerin her bir aydaki tahmin performansları incelenerek, her ay için en başarılı yöntem belirlenmiştir. Tahmin aşamasında her ay için, o aya ilişkin en başarılı yöntemin çıktısı hibrit yöntemin çıktısı olarak atanmıştır. Şekil 6'da sürece ilişkin bir prensip şema sunulmuştur.



Şekil 6. Geliştirilen yaklaşımın prensip şeması

Figure 6. Principle diagram of the developed approach

2.7. Değerlendirme kriterleri

2.7. Evaluation criteria

Bu çalışmada, kullanılan modellerin başarısını değerlendirmek için üç farklı değerlendirme kriteri kullanılmıştır: Kök Ortalama Kare Hatası (RMSE), Korelasyon Katsayısı (r) ve Ortalama Sapma Hatası (MBE). RMSE, bir modelin tahminlerinin gerçek değerlerden ne kadar uzak olduğunu ölçen bir performans metriğidir ve hatanın büyüklüğü ile ilgili ortalama bir değer sunar. Bu metrik, özellikle tahminlerin ne kadar doğru olduğunu anlamak için yaygın olarak kullanılır. RMSE değeri ne kadar düşükse, toplam hata değeri o kadar küçük ve tahmin değerleri gerçek değerlere o kadar yakındır. Bu nedenle, RMSE değeri düşük olan bir model, daha iyi bir performans sergiliyor olarak değerlendirilir. RMSE'ye ait matematiksel formül denklem (5) de verilmiştir.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (5)$$

Burada, n örneğin sayısını, y_i gerçek değeri ve $\hat{y}_i$ modelin tahmin ettiği değeri temsil etmektedir. Korelasyon Katsayısı, iki değişken arasındaki ilişkinin gücünü ve yönünü ölçen istatistiksel bir ölçüdür. Bu katsayı, genellikle Pearson Korelasyon Katsayısı olarak bilinir ve -1 ile 1 arasında bir değer alır. Pozitif bir korelasyon, bir değişkenin artışıyla diğer değişkenin de arttığını gösterirken, negatif bir korelasyon ise bir değişkenin artışıyla diğer değişkenin azaldığını gösterir. Korelasyon katsayısı 1'e yaklaşıyorsa, değişkenler arasında mükemmel bir pozitif ilişki olduğu anlaşılırken, -1'e yaklaşıyorsa, mükemmel bir negatif ilişki olduğu anlaşılır. Ancak, 0'a yaklaştıkça, değişkenler arasında bir ilişki olmadığına işaret eder. Korelasyon katsayısı, modelin tahminlerinin gerçek değerlerle ne kadar güçlü bir ilişkisi olduğunu yada tahmin değerlerinin gerçek değerler ile ne kadar uyumlu olduğunu belirlemek için kullanılır. Korelasyon katsayısı değeri denklem (6) ile hesaplanır.

$$r = \frac{\sum (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum (x_i - \bar{x})^2 \sum (y_i - \bar{y})^2}} \quad (6)$$

x_i ve y_i , sırasıyla iki değişkenin i . gözlemlerini, $\bar{x}$ ve $\bar{y}$ ise sırasıyla x , y değişkenlerinin ortalamalarını ifade etmektedir. MBE ise, bir tahminleme modelinin tahminlerinin gerçek değerlerden ortalama sapmasını ölçen bir hata ölçüsüdür. MBE hatanın büyüklüğünden ziyade, tahminlerin ne kadar sapma eğiliminde olduğunu gösterir ve pozitif veya negatif sapmaları dikkate alır. MBE, bir tahminleme modelinin sistemik sapma eğilimini değerlendirmek için kullanılır. MBE'nin sifıra yakın olması daha dengeli (stabil) tahminler yapıldığını ifade eder. MBE değeri denklem (7) kullanılarak hesaplanır.

$$MBE = (1/n) * \sum (y - \hat{y}) \quad (7)$$


n örneklemin büyüklüğünü, y gerçek değerleri, $\hat{y}$ ise tahmin edilen değerleri temsil etmektedir.

3. Deney sonuçları


3. experiment results

Bu çalışmada, Türkiye Meteoroloji Genel Müdürlüğü'nden elde edilen Van iline ait güneş ışınlam verileri kullanılmıştır. 2013 yılına ait (01 Ocak 2013- 31 Aralık 2013) 8760 veri, eğitim amacıyla kullanılırken, 2014 yılına ait (01 Ocak 2014- 31 Aralık 2014) 8760 veri ise test için ayrılmıştır. Güneş ışınlamı tahminleri için, doğrusal ve stokastik modellerden oluşan çeşitli yöntemler kullanılmıştır. Bu yöntemler arasında otoregresif (AR) model, ridge regresyon (RR), Yapay Sinir Ağları (YSA) ve Elman Sinir Ağları (ENN) bulunmaktadır. Çalışmada, bu modellerin güneş ışınlamı tahmini üzerindeki performanslarını değerlendirme, sonrasında ise bu performansları da dikkate alarak geliştirilen hibrit yöntemlerin performanslarını karşılaştırmak temel alınmıştır. Her bir model oluşturulurken sadece güneş ışınlam değeri kullanılmıştır. 1-5 saat önceki ışınlam değerleri (5 girdi) kullanılarak gelecek ışınlam değeri tahmin edilmiştir.

Çalışmada yer alan tüm doğrusal ve stokastik tahminleme modelleri MATLAB programı aracılığıyla gerçekleştirilmiştir. Bu bağlamda Otoregresif model ve Ridge regresyon için ilgili parametreler ayarlanırken YSA ve ENN için ise en uygun model parametreleri deneme/yanılma yoluyla ampirik olarak belirlenmiştir. YSA ve ENN için başarıları yüksek olan sonuçların, 1 gizli katmanlı 12 nöronlu yapıda olduğu gözlemlenmiştir. YSA ve ENN modellerine ilişkin prensip şemalar Şekil 7 ve Şekil 8 de sunulmuştur.



Şekil 7. YSA modelinin yapısı
Figure 7. The structure of the ANN model



Şekil 8. Elman sinir ağı modelinin yapısı
Figure 8. Structure of the Elman neural network model

İlk olarak eğitim verisi kullanılarak modeller eğitilmiş, sonrasında ise tahminler gerçekleştirilmiştir. Sonuçlar RMSE, korelasyon katsayısı ve MBE kriterleriyle değerlendirilmiştir. Oluşturulan modellere ait sonuçlar Tablo 1’de sunulmuştur.


Tablo 1. Modellerin başarı oranları
Table 1. Success rates of the models

Model	RMSE	RMSE eğitim	Korelasyon	MBE
AR	79.14485	82.05	0.963401	-11.0083
Ridge Regresyon	76.66111	78.7	0.965059	5.3440
YSA	64.80544	60.04	0.974994	0.08203
ENN	64.30195	58.8	0.975416	1.1244

Her bir yöntem için tahmin edilen değerler ile gerçek değerleri gösteren grafikler Şekil 9’da görülmektedir. Şekilde mavi ile renklendirilen grafik ölçülen değerleri temsil ederken, kırmızı ile gösterilen grafik tahmin edilen değerleri temsil etmektedir. Genel olarak değerlendirildiğinde, aralarında farklılıklar olmakla beraber, yöntemlerin tamamında ölçülen değerler ile tahmin edilen değerler arasında iyi bir örtüşme olduğu görülmektedir. Mavi rengin baskın olarak görüldüğü noktalarda tahmin edilen değerler, ölçülen değerlerin altında kalmıştır. Sadece kırmızı rengin görüldüğü kısımlarda ise ya tahmin değeri ölçülen değerden daha yüksek bir değerdedir ya da aralarında iyi bir uyum söz konusudur. Daha net bir değerlendirme için Tablo 1 incelendiğinde, kullanılan 4 farklı yöntem içerisinde en başarılı sonuçların ENN ile elde edildiği görülmektedir. Ayrıca beklendiği üzere stokastik modeller ile daha başarılı sonuçlar elde edilirken, regresyon yöntemleri ile nispeten başarısız tahminler yapıldığı anlaşılmaktadır. Korelasyon değerleri incelendiğinde, dört yöntemde de 0,96 üzerinde bir korelasyon değeri elde edildiği görülmektedir ve bu durum tahmin değerlerinin gerçek değerlerle korelasyonunun oldukça yüksek olduğunu göstermektedir. MBE değerleri açısından bakıldığında ise ENN ve YSA’da sıfıra yakın değerler elde edildiği görülmektedir. Bu durum gerçekleştirilen tahminlerin gerçek değerlerin üstünde ve altında olduğu durumların iyi bir denge içerisinde olduğuna işaret

etmektedir. Ridge regresyon için tahminlerin gerçek değerlerden genel olarak daha yüksek olduğu, AR için ise tahminlerin gerçek değerlerden genel olarak daha düşük olduğu anlaşılmaktadır.

Çalışmanın ikinci aşamasında, kullanılan bireysel yöntemlerden 4 farklı strateji kullanılarak hibrit yöntemler oluşturulmuş ve bu yöntemlerin performansları karşılaştırılmıştır. İlk stratejide bireysel yöntemlerden elde edilen sonuçların ortalaması alınarak tahmin değeri elde edilmiştir. Buradaki temel mantık Tablo 1 incelendiğinde daha iyi anlaşılabilir. Bireysel yöntemlerden elde edilen sonuçlar MBE kriteri üzerinden değerlendirildiğinde, yöntemlerin tahminlerinin genel olarak gerçek değerlerin altında yada üstünde olabildiği anlaşılmaktadır. Ortalama alınarak tahmin sonuçları bir denge noktasına taşınabilir ve bu daha başarılı bir tahmin performansı sağlayabilir. İkinci strateji de ise her bir yöntem eğitim aşamasındaki performansına bağlı olarak ağırlıklandırılarak yine bir ortalama değer hesaplanmış ve bu şekilde tahminler gerçekleştirilmiştir. Bu strateji aslında ilk stratejide açıkça görülebilecek bir zayıflığı da ortadan kaldırmayı amaçlamaktadır. İlk stratejide tüm yöntemlerden elde edilen tahminlerin ortalaması alınarak tahmin değeri belirlenir. Ancak Tablo 1’den açıkça görülmektedir ki, yöntemlerin başarıları birbirlerinden oldukça farklı olabilmektedir. Bu durumda ortalama almak belirgin şekilde başarılı olan yöntemden daha düşük başarıda bir tahmin sonucu elde etmeye sebep olabilir. Bu sebeple ikinci stratejide ortalama alınırken yöntemlerin eğitim aşamasındaki performansları dikkate alınarak ağırlıklandırılmışlardır. Bu kapsamda Tablo 1’den anlaşılacağı üzere en yüksek ağırlık ENN’e verilirken en düşük ağırlık AR’da olmuştur. Ağırlık değerleri eğitimdeki RMSE değerlerine uyumlu olarak belirlenmiştir. Üçüncü stratejide, mevsimler dikkate alınarak bir hibrit yöntem oluşturulmuştur. Bu yaklaşımda önce eğitim seti üzerinde mevsimsel olarak her bir bireysel yöntemin performansı incelenir ve tahmin aşamasında her mevsimde, o mevsimde en başarılı yöntemin çıktısı, hibrit yöntemin çıktısı olur. Tablo 2’de mevsimsel olarak çalışmada kullanılan yöntemlerin eğitim aşamasındaki performansları görülmektedir.



Şekil 9. Modellerin tahmin grafikleri. (a) AR tahmin modeli grafiği. (b) Ridge regresyon tahmin modeli grafiği. (c) Elman tahmin modeli grafiği. (d) YSA tahmin modeli grafiği.

Figure 9. Prediction graphs of the models. (a) AR prediction model plot. (b) Ridge regression prediction model plot. (c) Elman prediction model plot. (d) ANN prediction model plot.


Tablo 2. Mevsimsel hibrit yöntem RMSE sonuçları
Table 2. Seasonal hybrid method RMSE results

Mevsimler	AR	Ridge	YSA	ENN
İlkbahar	108.69	103.53	83.3685	82.1712
Yaz	71.9207	67.5360	42.1261	39.9406
Sonbahar	74.9652	72.0625	53.9464	52.1362
Kış	65.0799	65.0097	52.5106	52.3476

Tablodan da görüldüğü gibi bütün mevsimlerde en başarılı yöntem ENN olmuştur. Dolayısıyla bu çalışmada kullanılan veri seti için ENN ve hibrit yöntemin sonuçları aynı olacaktır. Ancak farklı yöntem ve veri setlerinde bu durumun değişebileceği unutulmamalıdır. Dördüncü stratejide ise aylar dikkate alınarak hibrit bir yöntem oluşturulmuştur. Bu kapsamda bireysel yöntemlerin aylık bazda performansları eğitim seti üzerinde incelenerek her bir ay için en başarılı yöntemler belirlenir. Modelin çıktısı ise, o ay için belirlenen yöntemin çıktısı olarak atanır. Tablo 3'te eğitim setinde bireysel yöntemlerin performansları sunulmuştur. Tablodan görüleceği gibi Ocak ve Mayıs aylarında en başarılı sonuçlar YSA ile elde edilirken diğer aylarda en başarılı yöntemin ENN olduğu anlaşılmaktadır. Bu durumda hibrit yöntemin çıktısında Ocak ve Mayıs ayları için YSA'dan, diğer aylar için ENN'den elde edilen tahmin çıktıları kullanılacaktır. AR ve Ridge regresyon ise hiçbir ayda en başarılı performansı elde edemedikleri için bu stratejide kullanılamamıştır.

Tablo 3. Mevsimsel hibrit yöntem RMSE sonuçları
Table 3. Seasonal hybrid method RMSE results

Aylar	AR	Ridge	YSA	ENN
Ocak	64.1254	64.1297	50.1653	51.2772
Şubat	80.1277	78.1512	63.0817	62.1438
Mart	86.8231	83.3796	67.3497	66.7724
Nisan	102.26	97.0089	77.4779	71.2895
Mayıs	131.80	125.40	101.32	103.19
Haziran	94.2612	89.6249	63.6680	60.9452
Temmuz	57.6717	53.2817	25.7597	23.1439
Ağustos	58.5352	54.0718	26.0800	24.5795
Eylül	78.8739	74.1987	52.9434	49.5977
Ekim	81.5111	78.0869	58.2792	58.0952
Kasım	62.9289	62.8161	50.1496	47.9340
Aralık	48.8296	51.3799	43.5070	42.8649



Şekil 10. Uygulanan stratejilere ait regresyon grafikleri. (a) Ortalama regresyon grafiği. (b) Ağırlıklı ortalama regresyon grafiği. (c) Mevsimler regresyon grafiği. (c) Aylar regresyon grafiği.

Figure 10. Regression graphs of the applied strategies. (a) Average regression plot. (b) Weighted average regression plot. (c) Seasons regression plot. (c) Months regression plot.

Şekil 10’da 4 farklı strateji ile elde edilen tahmin sonuçları ile gerçek değerlerin regresyonunu gösteren grafikler sunulmuştur. Şekilden de görülebileceği üzere veriler genellikle diyagonal ekseninde yoğunlaşmış ve dar bir alanda toplanmıştır. Bu durum tahmin başarısını ortaya koymaktadır. Dört farklı strateji ile oluşturulan hibrit yöntemden elde edilen sonuçlar Tablo 4’te sunulmuştur.

Tablo 4. Farklı stratejilerle birleştirilen yöntemlere ait değerlendirme sonuçları

Table 4. Evaluation results of the methods combined with different strategies

Model	RMSE	Korelasyon	MBE
Ortalama	64.1209	0.9736	-1.0628
Ağırlıklı Ortalama	63.4150	0.9744	-0.7711
Mevsimler	64.3019	0.9754	1.1245
Aylar	64.3878	0.9753	0.3808

Tablo 4’ten görülebileceği gibi RMSE kriteri dikkate alındığında en başarılı sonuçlar ağırlıklı ortalamanın kullanıldığı stratejide elde edilmiştir. Bununla beraber dört farklı strateji ile oluşturulan hibrit yöntemin performanslarının birbirine oldukça yakın olduğu da anlaşılmaktadır. Özellikle yukarıda ifade edildiği gibi ağırlıklı ortalama stratejisi, ortalama stratejisini iyileştirmek için geliştirilmiş olup, elde edilen sonuç, amaca ulaşıldığını göstermektedir. Çizelge 1’de sunulan bireysel yöntemler ile başarılar karşılaştırıldığında, Ortalama ve Ağırlıklı ortalama stratejileri ile tüm bireysel yöntemlerden daha başarılı sonuçlar elde edildiği görülmektedir. Mevsimlere göre oluşturulan stratejide ise daha öncede açıklandığı üzere, tüm mevsimlerde en başarılı sonuçlar ENN ile elde edildiği için, ENN ile aynı hata değeri elde edilmiştir. Aylara göre oluşturulan hibrit yaklaşımda ise ENN dışındaki tüm bireysel yöntemlerden daha başarılı bir performans sergilendiği

görülmektedir. Çalışmada, bir yıllık veri eğitim için kullanılırken, bir yıllık veri test için kullanılmıştır. Özellikle mevsim ve aylara göre hibrit yöntemin oluşturulduğu yaklaşımlarda, yıllara göre mevsimsel farklılıklar gözlemlendiği için bu durum tahmin başarısını olumsuz etkileyebilir. Daha uzun zamana yayılan eğitim verisi o mevsim yada aya ilişkin başarılı yöntemi seçmede daha tutarlı bir seçim yapmaya olanak sağlayacağına dikkat etmek gerekir. Korelasyon katsayısı kriteri dikkate alındığında ise dört strateji için de 0,97 üzerinde korelasyon katsayı değeri elde edildiği görülmektedir. Bu, tahmin edilen değerler ile ölçülen değerlerin uyumlu bir şekilde değişim gösterdiğine işaret eder. Aralarında çok küçük değişimler olmakla beraber en yüksek korelasyon değeri aylara göre oluşturulan hibrit strateji ile elde edilmiştir. MBE kriteri dikkate alındığında ise, dört farklı hibrit strateji ile de dengeli sonuçlar elde edildiği görülmektedir. Dört farklı strateji ile de sıfıra oldukça yakın MBE değerleri elde edilmiştir. Bu, yapılan tahminlerin gerçek değerlerin üstünde ve altında olduğu durumların bir denge içerisinde olduğunu gösterir. Sıfıra en yakın MBE değerinin aylara göre oluşturulan hibrit stratejide elde edildiği görülmektedir. Ayrıca sunulan çalışmada kullanılan hibrit yöntemlerin başarısını ortaya koymak amacıyla elde edilen sonuçlar literatürde daha önce yayınlanmış hibrit yöntem kullanan çeşitli makalelerdeki sonuçlar ile Tablo 5'te karşılaştırılmıştır. Tablo 5'ten de görüleceği gibi çalışmada kullanılan hibrit yaklaşımlar önemli bir başarı seviyesine sahiptir.

Tablo 5. Diğer yapılan çalışmalarla yapılan karşılaştırma sonuçları

Table 5. Comparison results with other studies

Kaynak	Kullanılan Yöntem	RMSE Değeri (%)
Voyant vd., (2014)	MLP- ARMA	40.32
Sansa vd., (2021)	ARMA - NARX	18.63
Rangel – Heras vd., (2022)	NARX-CVM	18.15
Yapılan Bu Çalışma	Ağırlıklı Ortalama	17.78

4. Tartışma ve sonuçlar

4. Discussion and conclusions

Yapılan bu çalışmada, doğrusal ve stokastik modeller kullanılarak farklı stratejilerle hibrit yöntemler oluşturulup, bu yöntemlerin başarıları değerlendirilmiştir. Çalışmada, Türkiye Meteoroloji Genel Müdürlüğü'nden alınmış Van iline ait iki yıllık (2013-2014) güneş ışınım verileri kullanılmıştır. AR, ridge, YSA ve ENN yöntemleri referans alınmış, veriler ilk olarak bu yöntemler ile modellenerek, sonuçlar elde edilmiştir. Ardından veriler, mevsimlere ve aylara ayrılarak, ilgili mevsim yada ayda en başarılı yöntemler tespit edilmiştir. Elde edilen sonuçlar değerlendirilerek, ortalama ağırlıklı ortalama, aylara ve mevsimlere göre hibrit yöntem oluşturma stratejileri uygulanmıştır. Bireysel ve hibrit yöntemler incelendiğinde RMSE kriterine göre en başarılı sonuçların 63,4150 değeri ile ağırlıklı ortalama stratejisinden elde edildiği görülmektedir. Ortalama stratejisi kullanılarak elde edilen sonuçlar da, tüm bireysel yöntemlerden daha yüksek bir performansı işaret etmektedir. Mevsimlere göre oluşturulan hibrit stratejide elde edilen hata değeri, her mevsimde ENN'in yüksek performans vermesi sebebi ile, ENN yönteminden elde edilen hata ile aynı orandadır. Aylara göre oluşturulan hibrit yaklaşımda ise ENN dışındaki tüm bireysel yöntemlerden daha başarılı bir performans elde edilmiştir. Bununla beraber korelasyon ve MBE kriterleri dikkate alındığında tüm hibrit yöntem oluşturma stratejisi ile daha dengeli tahmin sonuçları elde edildiği görülmektedir. Tüm bu hususlar dikkate alındığında, elde edilen sonuçlar, hibrit oluşturma stratejilerinin kullanılması ile daha başarılı yaklaşımlar elde edilebileceğini gösterir niteliktedir. Sunulan çalışmada değerlendirilen hibrit yöntemlerde kullanılan bireysel yöntemlerin tamamı aynı amaç (aynı değeri tahmin etmek) için kullanılmaktadır. Bütün bireysel yöntemler aynı değeri tahmin etmeye çalışırken, hibrit yöntem ya bunların ortalaması üzerinden bir tahmin değeri üretir ya da yöntemlerden birinin sonucunu seçer. Dolayısıyla performans değerlendirmesi yapılan hibrit yöntemler bu kapsam ile sınırlandırılmıştır. Çalışmanın bundan sonraki aşamasında ilgili hibrit yöntemlerin başarısını artıracak stratejiler geliştirilmeye çalışılacaktır.

Teşekkür*Acknowledgement*

Bu çalışmada kullanılan verilerin Türkiye Meteoroloji Genel Müdürlüğü tarafından sağlanmış olması nedeniyle kendilerine teşekkürlerimizi sunarız.

Yazar katkısı*Author contribution*

Bu çalışmanın bölümlerine tüm yazarlar tarafından katkı sağlanmıştır.

Etik beyanı*Declaration of ethical code*

Bu makalenin yazarları, bu çalışmada kullanılan materyal ve yöntemlerin etik kurul izni ve / veya yasal-özel izin gerektirmediğini beyan etmektedir.

Çıkar çatışması beyanı*Conflicts of interest*

Yazarlar herhangi bir çıkar çatışması olmadığını beyan eder.

Kaynaklar*References*

- Alkan, Ö., Öztürk, A., & Tosun, S. (2018). Rüzgâr ve güneş santrallerinde kısa dönem enerji üretim tahmini için matematiksel modellerin oluşturulması. *Düzce Üniversitesi Bilim Ve Teknoloji Dergisi*, 6(1), 188-195. <https://doi.org/10.29130/dubited.359698>
- Akarşlan, E., & Hocaoglu, F. O. (2017). A novel method based on similarity for hourly solar irradiance forecasting. *Renewable Energy*, 112, 337–346. <https://doi.org/10.1016/j.renene.2017.05.058>
- Akarşlan, E., Hocaoglu, F. O., & Edizkan, R. (2014). A novel M-D (multi-dimensional) linear prediction filter approach for hourly solar radiation forecasting. *Energy*, 73, 978–986. <https://doi.org/10.1016/j.energy.2014.06.113>
- Akarşlan, E., & Hocaoglu, F. O. (2016). A novel adaptive approach for hourly solar radiation forecasting. *Renewable Energy*, 87, 628–633. <https://doi.org/10.1016/j.renene.2015.10.063>
- Al-Shamisi, M. H., Assi, A. H., & Hejase, H. A. N. (2013). Artificial neural networks for predicting global solar radiation in al ain city-UAE. *International Journal of Green Energy*, 10(5), 443–456. <https://doi.org/10.1080/15435075.2011.641187>
- Arseven, B., & Çınar, S. M. (2023). Dünya dışı ışınlımlarla iyileştirilmiş ARIMA, ridge regresyon ve lasso regresyon yöntemlerinin saatlik ışınlım tahmininde kullanılması. *Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi* 12(3), 733-742. <https://doi.org/10.28948/ngumuh.1249503>
- Başaran Filik, Ü., & Filik, T. (2017). Kısa-Dönem Rüzgâr Hızının Tahmininde Otoregresif ve Yapay Sinir Ağları Tabanlı Yeni Bir Hibrit Yaklaşım. *Karaelmas Fen ve Mühendislik Dergisi*, 7(2), 419-427.
- Belmahdi, B., Louzazni, M., Marzband, M., & El Bouardi, A. (2023). Global Solar Radiation Forecasting Based on Hybrid Model with Combinations of Meteorological Parameters: Morocco Case Study. *Forecasting*, 5(1), 172–195. <https://doi.org/10.3390/forecast5010009>
- Benmouiza, K., Cheknane, A. %J E. C., & Management. (2013). Forecasting hourly global solar radiation using hybrid k-means and nonlinear autoregressive neural network models. *Energy Conversion and Management* 75, 561–569. <https://doi.org/10.1016/j.enconman.2013.07.003>
- Büyükuysal, M. C. (2010). *Ridge regresyon analizi ve bir uygulama*. [Yüksek Lisans Tezi, Uludağ Üniversitesi Sağlık bilimleri Enstitüsü]

- Cho, M., Chang, J., & Huang, C. (2020). Application of parallel Elman neural network to hourly area solar PV plant generation estimation. *International Transactions on Electrical Energy Systems*, 30(8), e12470. <https://doi.org/10.1002/2050-7038.12470>
- Çevik, S., Çakmak, R., & Altaş, İ. H. (2017, September). A day ahead hourly solar radiation forecasting by artificial neural networks: A case study for Trabzon province. In *2017 international artificial intelligence and data processing symposium (IDAP)* (pp. 1-6).
- Demirgöl, T., Demir, V., & Sevimli, M. F. (2024). Farklı makine öğrenmesi yaklaşımları ile Türkiye'nin solar radyasyon tahmini. *Geomatik*, 9(1), 106-122. <https://doi.org/10.29128/geomatik.1374383>
- Deniz, E., & Kemal, A. bilimi ve tekniği dergisi. (2007). Güneş Işınım Şiddeti Tahminlerinde Yapay Sinir Ağları Ve Regresyon Analiz Yöntemleri Kullanımının İncelenmesi. *Isı Bilimi ve Tekniği Dergisi* 27(2), 15–20.
- El-Amarty, N., Marzouq, M., El Fadili, H., Bennani, S. D., & Ruano, A. (2023). A comprehensive review of solar irradiation estimation and forecasting using artificial neural networks: data, models and trends. *Environmental Science and Pollution Research*, 30(3), 5407–5439. <https://doi.org/10.1007/s11356-022-24240-w>
- Ehmeind Maham, F., & Akarslan, E. (2022). Güneş Işınım Tahmini için Farklı Güneşlenme Durumlarından Faydalanan Hibrit Bir Yöntem Tasarımı. *Afyon Kocatepe Üniversitesi Fen Ve Mühendislik Bilimleri Dergisi*, 22(3), 588-596. <https://doi.org/10.35414/akufemubid.1074290>
- Gabralı, D., & Aslan, Z. (2020). Güneş Enerjisi Potansiyelinin Çoklu Lineer Regresyon ve Yapay Sinir Ağları ile Modellenmesi. *AURUM Journal of Engineering Systems and Architecture*, 4(1), 23-36.
- Gairaa, K., Khellaf, A., Messlem, Y., & Chellali, F. (2016). Estimation of the daily global solar radiation based on Box–Jenkins and ANN models: A combined approach. *Renewable and Sustainable Energy Reviews*, 57, 238–249. <https://doi.org/https://doi.org/10.1016/j.rser.2015.12.111>
- Guher, A. B., Tasdemir, S., & Yaniktepe, B. (2020). Effective Estimation of Hourly Global Solar Radiation Using Machine Learning Algorithms. *International Journal of Photoenergy*, 2020, 8843620. <https://doi.org/10.1155/2020/8843620>
- Gutierrez-Corea, F.V., Manso Callejo, M. A., Moreno Regidor, M. P., & Manrique Sancho, M.T. (2016). Forecasting short term solar irradiance based on artificial neural networks and data from neighboring meteorological stations. *Solar Energy*, 134, 119–131. <https://doi.org/10.1016/j.solener.2016.04.020>
- Gök, A. O., Yıldız, C., & Şekeli, M. (2019). Yapay sinir ağları kullanarak kısa dönem güneş enerjisi santrali üretim tahmini: Kahramanmaraş örnek çalışması. *Uluslararası Doğu Anadolu Fen Mühendislik ve Tasarım Dergisi*, 1(2), 186-195.
- Hocaoglu, F. O., & Serttas, F. (2017). A novel hybrid (Mycielski-Markov) model for hourly solar radiation forecasting. *Renewable Energy*, 108, 635–643. <https://doi.org/10.1016/j.renene.2016.08.058>
- Jallal, M. A., Chabaa, S., Yassini, A. E., Zeroual, A., Ibnyaich, S., & Raoufi, M. (2019). Elman Neural Network for Solar Radiation Components Forecasting based on the Desired Tilt Angle. *2019 7th International Renewable and Sustainable Energy Conference (IRSEC)*, 1–5. <https://doi.org/10.1109/IRSEC48032.2019.9078281>
- Ji, W., & Chee, K. C. (2011). Prediction of hourly solar radiation using a novel hybrid model of ARMA and TDNN. *Solar Energy*, 85(5), 808–817. <https://doi.org/10.1016/j.solener.2011.01.013>
- Mukaram, M.Z., & Yusof, F. (2017). Solar radiation forecast using hybrid SARIMA and ANN model. *Malaysian Journal of Fundamental and Applied Sciences*, 13, 346-350.
- Rangel-Heras, E., Angeles-Camacho, C., Cadenas-Calderón, E., & Campos-Amezcu, R. (2022). Short-term forecasting of energy production for a photovoltaic system using a NARX-CVM hybrid model. *Energies*, 15(8), 2842. <https://doi.org/10.3390/en15082842>
- Sansa, I., Boussaada, Z., & Bellaaj, N. M. (2021). Solar radiation prediction using a novel hybrid model of ARMA and NARX. *Energies*, 14(21), 6920. <https://doi.org/10.3390/en14216920>
- Thaker, J., & Höller, R. (2022). A comparative study of time series forecasting of solar energy based on irradiance classification. *Energies*, 15(8), 2837. <https://doi.org/10.3390/en15082837>

- Vecan, D., (2011). *Measurement and Comparison of Solar Radiation Estimation Models for İzmir/Turkey: İzmir Institute of Technology Case* [Master Thesis, Izmir Institute of Technology].
- Yalçın, S., & Herdem, M. S. (2022). Prediction and Analysis of Weather Parameters with Global Horizontal Solar Irradiance Using LSTM-CNN Based Deep Learning Technique. *Bilecik Şeyh Edebali Üniversitesi Fen Bilimleri Dergisi*, 9(1), 340–356. <https://doi.org/10.35193/bseufbd.1037563>
- Zhen-Yu, H., & Lian-Wen, J. (2008). Activity recognition from acceleration data using AR model representation and SVM. *2008 International Conference on Machine Learning and Cybernetics*, 4, 2245–2250. <https://doi.org/10.1109/ICMLC.2008.4620779>