

Hindistan'daki Turistik Şehirlerin İklim Değişkenlerinin Tahminine Yönelik Hibrit ConvGRU Modeli

Hybrid ConvGRU Model for Prediction of Climate Variables of Touristic Cities in India

¹Anıl UTKU

¹Munzur Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Tunceli, Türkiye

anilutku@munzur.edu.tr

Araştırma Makalesi/Research Article

ARTICLE INFO

Article history

Received : 8 May 2024

Accepted : 9 July 2024

Keywords:

Climate Variables,
Convolutional Neural Network,
Gated Recurrent Unit, Deep
Learning, Machine Learning

ABSTRACT

Weather prediction is very important in terms of ensuring effectiveness and efficiency in areas such as agriculture, health, transportation, tourism, air quality and industrial production. Traditional weather forecast models are inadequate for long-term predictions. Artificial intelligence methods can produce successful predictions for the future by learning complex relationships between climate variables such as temperature, humidity, wind speed and air pressure. In this study, it was aimed to predict long-term climate variables such as temperature, humidity and dew point of Agra, Jaipur, Jodhpur, New Delhi and Rishikesh, which are important tourism cities of India. For this purpose, the developed ConvGRU hybrid model was comprehensively compared with RF, SVM, CNN, LSTM and GRU models. A real-time and up-to-date data set between 2010 and 2024 was used. In order for the models to obtain the best results, the hyper-parameters of the models were optimized using grid search. Experimental results show that ConvGRU outperforms benchmarked models with R^2 values above 0.9 for all cities and climate variables.

© 2024 Bandırma Onyedi Eylül University, Faculty of Engineering and Natural Science. Published by Dergi Park. All rights reserved.

MAKALE BİLGİSİ

Makale Tarihleri

Gönderim : 8 Mayıs 2024

Kabul : 9 Temmuz 2024

Anahtar Kelimeler:

İklim Değişkenleri,
Convolutional Neural Network,
Gated Recurrent Unit, Derin
Öğrenme, Makine Öğrenmesi

ÖZET

Hava durumu tahmini tarım, sağlık, ulaşım, turizm, hava kalitesi ve endüstriyel üretim gibi alanlarda etkinliğin ve verimliliğin sağlanabilmesi açısından oldukça önemlidir. Geleneksel hava durumu tahmin modelleri uzun vadeli tahminlerde yetersiz kalmaktadır. Yapay zekâ yöntemleri, sıcaklık, nem, rüzgâr hızı ve hava basıncı gibi iklim değişkenleri arasındaki karmaşık ilişkileri öğrenerek geleceğe dönük başarılı tahminler üretebilmektedir. Bu çalışmada, Hindistan'ın önemli turizm şehirlerinden olan Agra, Jaipur, Jodhpur, New Delhi ve Rishikesh'in sıcaklık, nem ve çığ noktası gibi uzun vadeli iklim değişkenlerinin tahmin edilmesi amaçlanmıştır. Bu amaçla, geliştirilen ConvGRU hibrit modeli, RF, SVM, CNN, LSTM ve GRU modelleriyle kapsamlı bir şekilde karşılaştırılmıştır. 2010-2024 yılları arasına ait gerçek zamanlı ve güncel bir veri seti kullanılmıştır. Modellerin en iyi sonuçları elde edebilmeleri için ızgara arama kullanılarak modellerin hiper-parametreleri optimize edilmiştir. Deneysel sonuçlar, ConvGRU'nun tüm şehirler ve iklim değişkenleri için 0,9'un üzerinde R^2 değeriyle karşılaştırılan modellerden daha başarılı olduğunu göstermiştir.

© 2024 Bandırma Onyedi Eylül Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi. Dergi Park tarafından yayınlanmaktadır. Tüm Hakları Saklıdır.

1. GİRİŞ

Hava durumu, sıcaklık, nem, rüzgâr hızı ve yönü ve atmosferik basınç gibi değişkenlere göre atmosferin belirli bir zamandaki ve yerdeki durumu olarak tanımlanmaktadır [1,2]. Bu bileşenler kullanılarak belirli bir bölgenin herhangi bir andaki hava durumunu tanımlanmaktadır. Bu değişen parametreler, atmosferik süreçlere ilişkin bilgiyle birlikte, meteorologların yakın gelecekte havanın nasıl olacağını tahmin etmelerine yardımcı olur. Hava sıcaklığı, çeşitli ölçeklerden herhangi biri cinsinden ifade edilen ve ısı enerjisinin kendiliğinden akacağı yönü gösteren sıcaklık veya soğukluk ölçüsüdür [3]. İklim ise sıcaklık, toprak nemi, rüzgâr hızı ve yönü gibi değişkenler de dâhil olmak üzere atmosferde, okyanusta ve karada belirli durumlarının beklenen sıklığı olarak tanımlanır [4]. İklim, farklı zaman dilimlerindeki hava durumlarını kapsar ve aynı zamanda dünya sisteminin bileşenleri arasındaki karşılıklı etkileşimlerle de ilgilidir. Nem, atmosferdeki su buharı miktarını ifade etmektedir [5]. Havanın nem kapasitesi sıcaklığa göre belirlendiğinden, atmosferin su buharı içeriği bölgeye ve zamana göre değişiklik gösterir [6]. Çiy noktası havanın doyma noktasına ulaştığı ve buharın yoğunlaşarak sıvı hâle geçtiği sıcaklığı ifade eder [7,8].

Havanın insan yerleşim düzenleri, turizm, endüstriyel üretim ve hava kalitesi üzerinde doğrudan etkisi vardır [9]. Aşırı sıcaklık ve nem hastalıkların bulaşmasına riskini arttırabilir. Benzer şekilde şiddetli yağmur sele neden olabilir, insanları can ve mal kaybına uğratabilir, ekonomik faaliyetleri kesintiye uğratabilir. Fırtınalar, kasırgalar ve dolu, mahsullere, binalara, ulaşım yollarına ve araçlara zarar verebilir. Kıyı bölgelerinde yaşanan tropikal kasırgalar ise aşırı yağışa ve su baskınına, gemilere, binalara, ağaçlara, tarımsal ürünlere, iletişim ve ulaşım ağlarına büyük hasarlar verebilir [10].

Hava olaylarının değişkenliği, insanlığın gelecekteki hava koşulları ve tahminleri konusunda uzun süredir devam eden bir araştırma içinde olmasına neden olmaktadır. Geleneksel hava tahmin modelleri, iklim değişkenleri, fiziksel prensipler ve bilgisayar destekli modellemeler yoluyla tahmin yapmaktadır [11,12]. Ancak geleneksel hava tahmin yöntemleri, uzun vadeli tahminlerin yapılması konusunda sınırlıdır. İklim değişikliğinin etkileri arttıkça hava tahminlerinin tutarlılığı daha da kritik hale gelmektedir. Bu sebeple yapay zekâ yöntemlerinin hava tahmininde kullanımı ön plana çıkmaktadır. Yapay zekâ yöntemleri, hava durumu parametreleri arasındaki karmaşık ilişkileri öğrenerek ve belirli bölgelere ait hava durumu modellerini üreterek hava tahmininde başarılı sonuçlar üretmektedir.

Bu çalışmada, Hindistan'ın turizm şehirlerinden olan Agra, Jaipur, Jodhpur, New Delhi ve Rishikesh'in iklim parametrelerinin tahmin edilmesi amaçlanmıştır. Agra, Hindistan'ın en ünlü turistik şehirlerinden biridir. Dünyanın yedi harikasından biri olan Babür mimari eseri Tac Mahal, Agra kalesi ve Jama Mescidi turistlerin ilgi odağı olmaktadır [13]. Hindistan'ın pembe şehri olarak bilinen Jaipur, Amber kalesinin yanı sıra batık kumaşları, seramikleri ve zümrüt zanaatı ile turistlerin ve tasarımcıların ilgilerini çekmektedir [14]. Jodhpur, Mehrangarh kalesi, Mandore bahçeleri ve Jaswant Thada anıtına ev sahipliği yapan bölgedeki en önemli mimari alanlardan biridir [15]. Hindistan'ın başkenti olan New Delhi moda, sanat, yemek ve teknoloji ile öne çıkmaktadır. Ayrıca Kutub Minar, Jantar Mantar ve Hindistan Kapısı gibi dünyanın en ünlü turistik yerleri New Delhi'de bulunmaktadır [16]. Rishikesh, Hindular tarafından bir hac yeri olarak görülmekte ve Hindistan'da yoganın doğduğu yer olarak bilinmektedir [17].

Bu gibi turistik önemleri nedeniyle Agra, Jaipur, Jodhpur, New Delhi ve Rishikesh şehirleri için iklim değişkenlerinin belirlenmesi amaçlanmıştır. Turistlerin bu şehirlere yönelik seyahat planlamalarını yapabilmeleri ve yerel yönetimlerin hava durumlarına göre stratejiler geliştirebilmeleri açısından hava durumunun doğru bir şekilde tahmin edilmesi önemlidir. Bu çalışmada, tahmin başarısını ve doğruluğunu arttırmak amacıyla Convolutional Neural Network (CNN) ve Gated Recurrent Unit (GRU) modelleri kullanılarak hibrit ConvGRU modeli geliştirilmiştir. Geliştirilen model, Random Forest (RF), Long Short-Term Memory (LSTM), CNN, Support Vector Machine (SVM) ve GRU ile kapsamlı bir şekilde karşılaştırılmıştır. Karşılaştırılan modeller, Hindistan'ın en önemli turizm şehirlerinden olan Agra, Jaipur, Jodhpur, New Delhi ve Rishikesh'in hava durumu verileri kullanılarak test edilmiştir.

Bu çalışmanın literatüre olan katkıları aşağıdaki gibi sıralanabilir:

- Hindistan'ın en önemli turizm şehirleri için iklim değişkenlerinin tahminine yönelik veri odaklı bir yaklaşım sunulmuştur.
- Uzun vadeli hava durumu verileri analiz edilerek iklim değişikliği eğiliminin belirlenmesi amaçlanmıştır.
- Tahmin başarısını arttırmak amacıyla CNN ve GRU modelleri kullanılarak ConvGRU hibrit modeli geliştirilmiştir.
- Geliştirilen model, 2010-2024 yıllarına ait saatlik, güncel ve gerçek zamanlı veriler kullanılarak geleneksel modellerle kapsamlı bir şekilde test edilmiştir.
- Agra, Jaipur, Jodhpur, New Delhi ve Rishikesh şehirlerine ait bu veri seti kullanılarak yapılan literatürdeki ilk çalışmadır.

2. LİTERATÜRDEKİ ÇALIŞMALAR

Literatürde, hava durumu tahmini ve iklim değişkenlerinin modellenmesi ile uzun vadeli eğilimlerin belirlenmesi için yapay zekâ yöntemlerinin kullanıldığı çalışmalar bulunmaktadır. Bu bölümde, hava ve iklim değişkenlerinin tahminine yönelik literatürdeki çalışmalar incelenmiştir.

Bekkar ve ark. hava kalitesi tahmini için derin öğrenme modellerinin karşılaştırmalı bir analizini sunmuştur [18]. Çalışmada CNN ve LSTM ile CNN ve GRU modelleri kullanılarak hibrit modeller oluşturulmuştur. Oluşturulan hibrit modeller, temel modeller ve çift yönlü LSTM ile karşılaştırılmıştır. Deneysel sonuçlar, CNN-LSTM'nin günlük tahminde 0,989 R² ve haftalık tahminde 0,979 R² ile karşılaştırılan modellerden daha iyi performans verdiğini göstermiştir.

Abirami ve Chitra, Delhi'nin hava kalitesi tahminine yönelik DL-Air adı verilen bir model önermiştir [19]. Önerilen model kodlayıcı, LSTM ve kod çözücü bileşenlerinden oluşmaktadır. Önerilen model, temel modellere kıyasla RMSE ve MAE değerlerinde %37 azalma ve R2 değerinde ise %8 iyileşme sağlamıştır.

Patil ve Liyama, Japonya'daki Tohoku bölgesindeki deniz yüzeyi sıcaklığının tahminine yönelik derin öğrenme modellerinin karşılaştırmalı bir analizini sunmuştur [20]. Çalışmada Multilayer Perceptron (MLP), LSTM ve 2D CNN karşılaştırılmıştır. Deneysel sonuçlar, 2D CNN'in 0,25 RMSE ile karşılaştırılan modellerden daha başarılı olduğunu göstermiştir. Ravindirani ve ark., hava kalitesi tahmini için XGBoost, LightGBM, Catboost, RF ve Adaboost algoritmalarının karşılaştırmalı bir analizini sunmuştur [21]. Çalışmada, Hindistan'daki Visakhapatnam şehrinin yaklaşık 5 yıllık hava kalitesi verileri kullanılmıştır. Deneysel sonuçlar, Catboost'un 0,9998 R2 ile karşılaştırma modellerinden daha başarılı olduğunu göstermiştir.

Ayus ve ark., hava kalitesi indeksinin tahminine yönelik Recurrent Neural Networks (RNN), Bidirectional Gated Recurrent unit (Bi-GRU), Bidirectional Long Short-Term Memory (BiLSTM), Convolutional Neural Network BiLSTM (CNN-BiLSTM), Convolutional BiLSTM (Conv1D-BiLSTM) ve eXtreme Gradient Boosting (XGBoost) modellerinin karşılaştırmalı bir analizini sunmuştur. Çalışmada Çin'deki 10 büyük şehrin verileri kullanılmıştır. Deneysel sonuçlar, XGBoost'un karşılaştırılan modellerden daha başarılı bir tahmin performansına sahip olduğunu göstermiştir [22].

Kumar ve Pande hava kalitesi tahminine yönelik k-Nearest Neighbour (kNN), Gaussian Naive Bayes (GNB), SVM, RF ve XGBoost modellerinin karşılaştırmalı bir analizini sunmuştur. Çalışmada Hindistan'daki 23 şehre ait hava kalitesi verileri kullanılmıştır. Deneysel sonuçlar, XGBoost'un karşılaştırılan modeller arasında en iyi performansa sahip olduğunu göstermiştir [23].

Naz ve ark., azot dioksit, ozon, kükürt dioksit, PM_{2.5} ve PM₁₀ gibi hava kirleticilerin değerlerinin tahminine yönelik GRU, LSTM ve AutoRegressive Integrated Moving Average (ARIMA) modellerinin uygulamalı bir analizini sunmuştur. Çalışmada, Kuzey İrlanda'da yer alan Belfast şehrinin hava kalitesi verileri kullanılmıştır. Deneysel sonuçlar, derin öğrenme modellerinin ve özellikle LSTM'in tüm hava kirleticiler açısından ARIMA'dan daha başarılı olduğunu göstermiştir [24]. Barthwal ve Goel, Hindistan'ın başkenti Delhi'deki hava kirliliğinin ve iklim değişkenlerinin tahmin edilmesi amacıyla Deep Convolutional Neural Network (DCNN) ve LSTM kullanarak DCNN-LSTM modelini geliştirmiştir. Çalışmada hava kalitesi tahmini için Delhi genelindeki 14 lokasyondan elde edilen karbon monoksit PM_{2.5} ve PM₁₀ konsantrasyonları kullanılmıştır. Ayrıca Delhi için sıcaklık, nem ve atmosferik basınç gibi iklim değişkenleri tahmin edilmiştir. DCNN-LSTM mimarisi, %97,48'lik sınıflandırma doğruluğuyla literatürdeki çalışmalardan daha başarılı olmuştur [25].

Mohammadi ve ark., PM_{2.5} tahminine yönelik Artificial Neural Networks (ANN), kNN, SVM ve RF'in uygulamalı bir analizini sunmuştur. Çalışmada İran'ın İsfahan şehrinde bulunan 7 hava kalitesi izleme istasyonundan elde edilen veriler kullanılmıştır. Çalışmada 2020 yılı için tahmin edilen veriler ArcGIS yazılımına dahil edilerek ve Inverse Distance Weighting (IDW) yöntemi kullanılarak İsfahan şehri için interpolasyon yapılmış ve yılın her ayı için kirlilik haritası çizilmiştir. Deneysel sonuçlar, ANN'in %90,1 sınıflandırma doğruluğuyla karşılaştırılan modellerden daha başarılı olduğunu göstermiştir [26].

Krivoguz ve ark., hava sıcaklığı tahminine yönelik derin tekrarlı sinir ağları ve GRU'yu kullanarak hibrit bir model geliştirmiştir [27]. Çalışmada, Deep Recurrent Neural Network (DRNN), DRNN-GRU, LSTM ve Robust Stacked LSTM (RSLSTM) karşılaştırılmıştır. Çalışmada yaklaşık 63 yıllık sıcaklık, basınç ve yağış seviyelerini içeren bir veri seti kullanılmıştır. Deneysel sonuçlar, geliştirilen modelin 0,06 MAE değeriyle karşılaştırılan modellerden daha başarılı olduğunu göstermiştir.

Mishra ve Gupta, hava kalitesi tahmini için istatistiksel modeller ile makine öğrenmesi ve derin öğrenme modellerinin karşılaştırmalı bir analizini sunmuştur [28]. Çalışmada, Pekin'in 2014-2018 yılları arasındaki hava kalitesi verileri kullanılarak LSTM, Decision Tree (DT), ARIMA, Huber Regressor, kNN ve Dummy Regressor karşılaştırıldı. Deneysel sonuçlar, LSTM'nin kısa vadeli tahminlerde karşılaştırılan modellerden daha başarılı bir performansa sahip olduğunu göstermiştir.

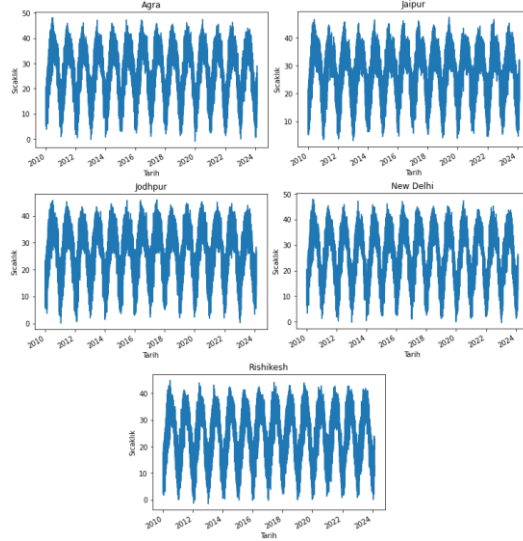
3. MATERYAL VE METOT

Bu çalışmada, geliştirilen hibrit ConvGRU modeli ile Hindistan'ın turistik şehirlerinin iklim değişkenlerinin uzun vadeli trendlerinin analiz edilmesi amaçlanmıştır. Bu bölümün devamında, kullanılan veri seti ile ilgili detaylı analizler sunulmuştur. Ayrıca geleneksel tahmin modelleri ve geliştirilen hibrit ConvGRU modelinin mimarisi açıklanmıştır.

3.1. Veri Seti

Bu çalışmada Hindistan'ın turistik şehirlerinden olan Agra, Jaipur, Jodhpur, New Delhi ve Rishikesh şehirlerinin Ocak 2010-Şubat 2024 dönemini kapsayan saatlik, güncel ve gerçek zamanlı saatlik hava durumu verileri


kullanılmıştır [29]. Kullanılan veri seti sıcaklık, nem, çığ noktası, yağış, rüzgâr hızı ve atmosfer basıncı gibi hava durumu parametrelerini içermektedir. Şekil 1’de, Agra, Jaipur, Jodhpur, New Delhi ve Rishikesh şehirlerinin Ocak 2010 ile Şubat 2024 arasındaki sıcaklık değerlerinin değişimi görülmektedir.



Şekil 1. Şehirlerin sıcaklık değerlerinin değişimi.

Şekil 1’de görülen grafikler, şehirlerin genel sıcaklık trendinin belirlenmesi ile ani sıcaklık değişimlerini veya anomalilerin belirlenmesi açısından önemlidir. Şekil 1’de görüldüğü gibi Agra, genel olarak ılıman bir iklime sahiptir. Yaz aylarında sıcaklık değerleri oldukça yüksekken kış aylarında sıcaklık değerleri düşüktür. Jaipur ise kurak bir iklime sahiptir ve mevsimsel değişimler oldukça belirgindir. Yaz aylarında oldukça yüksek sıcaklık değerlerine sahipken kış aylarında bile sıcaklık değerleri hızlı bir şekilde yükselmektedir. Jodhpur, sıcak ve kurak bir iklime sahiptir. Yaz aylarında yüksek sıcaklıklar görülürken kış aylarında ise ılıman bir iklime sahiptir. New Delhi subtropikal bir iklime sahiptir. Yaz aylarında sıcaklık oldukça yüksekken kış aylarında sıcaklık düşüşleri yaşanmaktadır ancak genellikle ılıman bir iklime sahiptir. Rishikesh ise ılıman bir iklime sahiptir. Yaz ve kış aylarında ılıman bir iklim görülmektedir. Sıcaklık değerleri yıl boyunca genellikle dengelidir.

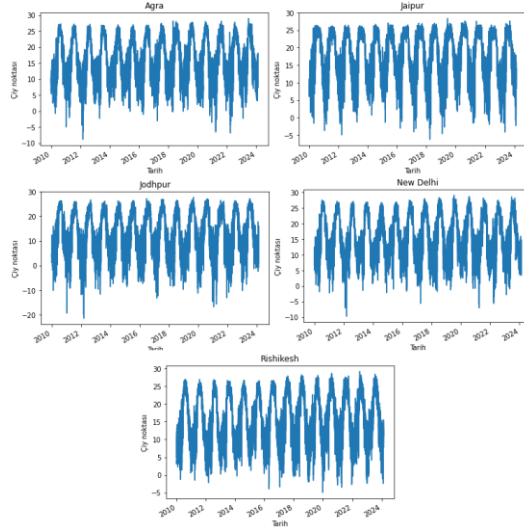
Şekil 2’de, Agra, Jaipur, Jodhpur, New Delhi ve Rishikesh şehirlerinin Ocak 2010 ile Şubat 2024 arasındaki nem değerlerinin değişimi görülmektedir.



Şekil 2. Şehirlerin nem değerlerinin değişimi.

Şekil 2’de görüldüğü gibi Agra genel itibariyle ılıman bir nem seviyesine sahiptir. Özellikle muson mevsiminde ve yaz aylarında nem yüksektir ancak kış aylarında daha düşüktür. Jaipur sıcak ve kuru iklimi nedeniyle genellikle düşük nem seviyelerine sahiptir. Jodhpur çöl iklimi nedeniyle genellikle düşük nem seviyelerine sahiptir. New Delhi’nin nem grafiği, genellikle orta düzeyde nem seviyelerini göstermektedir. Özellikle muson mevsiminde ve yaz aylarında nem yüksektir ancak kış aylarında düşmektedir. Rishikesh’in nem grafiği, genellikle orta düzeyde nem seviyelerini gösterir. Şehir, Himalayaların eteklerinde yer aldığı için, nem seviyeleri diğer şehirlere göre daha yüksek olabilir.

Şekil 3'te, Agra, Jaipur, Jodhpur, New Delhi ve Rishikesh şehirlerinin Ocak 2010 ile Şubat 2024 arasındaki çiy noktası değerlerinin değişimi görülmektedir.



Şekil 3. Şehirlerin çiy noktası değerlerinin değişimi.

Şekil 3'te görüldüğü gibi çiy noktası grafikleri genel itibariyle şehirlerin nem durumunu göstermektedir. Agra şehrinin grafiği genellikle havanın nemli olduğunu göstermektedir. Özellikle muson mevsiminde ve yaz aylarında çiy noktası yüksektir. Kış aylarında ise çiy noktası düşebilir ancak genellikle nemli ortam korunur. Jaipur şehrinin çiy noktası grafiği, genellikle düşük nem seviyelerini göstermektedir. Jaipur'un iklimi sıcak ve kuru olduğu için çiy noktası genellikle düşüktür. Yaz aylarında, muson yağmurları sırasında çiy noktası biraz artabilir ancak genel olarak düşük kalır. Jodhpur'un çiy noktası grafiği, genellikle çok düşük nem seviyelerini yansıtır. Şehrin çöl iklimi, çiy noktasının düşük kalmasına neden olur. New Delhi'nin çiy noktası grafiği, şehrin subtropikal iklimi ile uyumlu olarak genellikle orta düzeyde nem seviyelerini yansıtır. Rishikesh'in çiy noktası grafiği, genellikle orta düzeyde nem seviyelerini gösterir. Himalayaların eteklerinde yer almasından dolayı, çiy noktası diğer şehirlere göre biraz daha yüksek olabilir. Yaz aylarında çiy noktası artabilir ancak genel olarak ortalama düzeyde seyrederek.

3.2. Veri Ön-İşleme

Veri ön-İşleme aşamasında veri setindeki eksik ve hatalı alanların kontrolü yapılmıştır. Bu çalışmada kullanılan veri seti, zamana bağlı olarak iklim parametrelerinin değerlerini içeren bir zaman serisi veri setidir. Zaman serisi verilerinin makine öğrenmesi ve derin öğrenme modelleri tarafından işlenebilmesi için regresyon problemi yapısına dönüştürülmesi gereklidir. Bu amaçla kayan pencere yöntemi kullanılmaktadır. Kayan pencere yöntemi, belirlenen pencere boyutu kadar gözlem verisinin girdi, bir sonraki zaman adımındaki gözlem verisinin ise çıktı olarak yapılandırılması sağlar [30]. Örnek olarak 3 boyutunda bir kayan pencerede t_1 , t_2 ve t_3 zaman adımındaki gözlem verileri girdi, t_4 zaman adımındaki gözlem verisi ise çıktı olacaktır. Yapılan deneysel çalışmalar, kayan pencere boyutu 9 olduğunda en düşük RMSE değerlerinin elde edildiğini göstermiştir. Girdi-çıktı örnekleri şeklinde regresyon problemi yapısına dönüştürülen veri seti, min-max scaler kullanılarak ölçeklendirilmiştir. Veri setinin %33'ü test ve %67'si ise eğitim için kullanılmıştır. Bu oranlar yapılan deneysel çalışmalar neticesinde belirlenmiştir. Eğitim verilerinin %10'u ise model hiper-parametrelerinin ızgara arama (grid search) ile optimize edilmesi için kullanılmıştır. Hiper-parametreler, modellerin performansını, doğruluğunu ve genelleme kapasitesini önemli ölçüde artırmaktadır. Model hiper-parametrelerinin belirlenmesinde yaygın olarak ızgara arama ve rastgele arama yöntemleri kullanılmaktadır. ızgara arama belirlenen hiper-parametrelerin olası tüm kombinasyonlarını sistematik bir şekilde arar ve her bir kombinasyon için modeli eğiterek performansını değerlendirir. Her model için optimize edilecek hiper-parametreler ve bu parametrelerin olası değer aralıkları belirlenir. Belirlenen hiper-parametrelerin tüm olası kombinasyonları oluşturulur ve her kombinasyon için model eğitilerek doğrulama veri seti üzerinde performansı değerlendirilir. En iyi performansı gösteren hiper-parametre kombinasyonu seçilerek model oluşturulur. Rastgele arama ise hiper-parametre uzayından rastgele örnekler seçerek bu kombinasyonları dener. ızgara aramadaki gibi sistematik bir tarama yerine, belirlenen deneme sayısı kadar rastgele kombinasyon uygulanır. Ancak rastgele arama en iyi hiper-parametrelerin belirleneceğine dair garanti vermez ve en uygun hiper-parametrelerin belirlenme olasılığı ızgara aramaya göre düşüktür. Bu sebeple modellerin hiper-parametreleri ızgara arama kullanılarak belirlenmiştir. Tablo 1'de uygulanan geleneksel modeller için kullanılan hiper-parametreler görülmektedir.

Karşılaştırılan her bir model, Tablo 1'de sunulan hiper-parametre kombinasyonları uygulanarak oluşturulmuştur. Bu sayede modellerin adil bir şekilde karşılaştırılarak en iyi sonuçlara sahip olması amaçlanmıştır.

Tablo 1. Uygulanan geleneksel modeller için kullanılan hiper-parametreler.

Model	Hiper-parametre
RF	Ağaç sayısı: 100, maks. Derinlik: 5, min. örnek sayısı: 2
SVM	C:1.5, gamma:1e-07, epsilon:0.1, kernel: linear
CNN	Filtre sayısı: 64, katman sayısı: 2, aktivasyon fonksiyonu: relu, yığın boyutu: 64, öğrenme oranı: 0.001, eğitim sayısı: 100
LSTM	Katman sayısı: 2, nöron sayısı: 80, yığın boyutu: 64, öğrenme oranı: 0.001, eğitim sayısı: 100, optimizasyon: Adam, aktivasyon fonksiyonu: ReLU
GRU	Katman sayısı: 3, nöron sayısı: 100, yığın boyutu: 64, öğrenme oranı: 0.001, eğitim sayısı: 200, optimizasyon: Adam, aktivasyon fonksiyonu: ReLU

3.3. Tahmin Modelleri

RF, rastgele seçilmiş veri noktaları ve özellikleri kullanarak oluşturulmuş birden fazla karar ağacını birleştiren bir topluluk öğrenme algoritmasıdır [31]. Eğitim aşamasında, çok sayıda karar ağacı oluşturur ve regresyon problemlerinde her bir ağacın ortalama tahminini, sınıflandırma problemlerinde ise sınıfların modunu alır. Temel prensip, çeşitli ağaç kümeleri oluşturmak ve tahmin doğruluğunu artırmak için tahminlerini birleştirmektir [32]. RF farklı ağaçların, verilerin farklı varyasyonlarını görmesine olanak tanıyan çeşitli alt kümeler oluşturur. Her düğümde, tüm özellikleri dikkate almak yerine bölme için rastgele bir özellik alt kümesi dikkate alınır. Tüm karar ağaçları oluşturulduktan sonra toplu olarak karar ağaçlarının tahminleri alınır. Sınıflandırma problemlerinde, ağaçların sınıflara verdikleri oyların çoğunluğunu alan sınıf nihai tahmin olur. Regresyon problemlerinde, nihai çıktıyı elde etmek üzere tüm ağaçlardan gelen tahminlerin ortalaması alınır [33].

SVM'nin temel amacı, veri noktalarını sınıflar arasında bir sınır çizerek ayırmaktır. Bu sınır, genellikle karar sınırı olarak adlandırılır ve sınıflar arasındaki en geniş marjı elde etmek için optimize edilir [34]. Destek vektörleri, hiper düzleme daha yakın olan noktaları ifade etmektedir. Marj, karar sınırından her iki sınıfın en yakın veri noktasına olan mesafedir. SVM, verileri sınıflar arasında kolaylıkla ayrılabilir daha yüksek boyutlara dönüştürmek için çekirdek fonksiyonlarını kullanır [35].

CNN, genellikle sınıflandırma problemlerinde olmak üzere görüntü verilerini işleme konusundaki yetenekleriyle öne çıkan bir modeldir [36]. CNN, konvolüsyon, havuzlama ve tam bağlı katmanlar gibi yapıları sayesinde özelliklerin hiyerarşik olarak öğrenilmesini sağlar. Konvolüsyon katmanları, görüntüler üzerinde belirli bir boyutta filtre kullanarak evrişim işlemi uygular. Havuzlama katmanları evrişim sonrası elde edilen özellik haritasının boyutunu küçültmek için kullanılır. Düzleştirme katmanı, matris formatında işlenen verilerin tek boyuta indirgenmesini sağlar [37].


LSTM, kaybolan gradyan sorununu çözmek ve sıralı verilerdeki uzun vadeli bağımlılıkları belirlemek için tasarlanmış bir tekrarlı sinir ağı modelidir. LSTM mimarisi, verilerin uzun diziler boyunca saklanmasına olanak tanıyan özel mekanizmalar içerir [38]. LSTM, bilgileri uzun diziler halinde saklayabilen ve her zaman adımında güncellenebilen hücre durumlarına sahiptir [39]. Gizli durum, hücre durumundaki bilgilerin seçici olarak hatırlanmasını veya unutulmasını sağlar. Giriş kapısı, hücre durumuna bilgi akışını kontrol eder [40]. Çıkış kapısı, her zaman adımında çıkışı üretmek için kullanılan bilgiyi kontrol eder.

GRU, LSTM'den farklı olarak gizli durumda seçici olarak bilgi güncelleme ve sıfırlamayı mümkün kılan geçiş mekanizmalarını içerir [41]. Bu mekanizma, GRU'ya temel bilgileri tutma ve ilgisiz verileri unutma yetkisi vererek uzun vadeli bağımlılıkların öğrenilmesini kolaylaştırır [42]. Sıfırlama kapısı, önceki gizli durumdan hangi bilgilerin unutulması gerektiğine karar verir. Aday gizli durum, geçmişteki unutulmuş bilgileri filtrelenmiş yeni girişle harmanlayarak bir sonraki gizli durum için aday oluşturur. Güncelleme kapısının hesaplanması GRU'nun ilk adımındır. Önceki gizli durumun ne kadar güncellenmesi gerektiğine karar vermek için mevcut girişi ve önceki gizli durumu kullanır [43]. Burada sigmoid fonksiyonu kullanılmaktadır. Güncelleme kapısına benzer şekilde sıfırlama kapısı da hesaplama için sigmoid fonksiyonunu kullanır. Sıfırlama kapısı hesaplamasından sonra, hiperbolik tanjant fonksiyonu (tanh) kullanılarak aday gizli durum hesaplanır [44]. Sıfırlama kapısının değeri önceki gizli durumun etkisini belirler. Nihai gizli durum, doğrusal enterpolasyon yoluyla tanımlanır. Bu enterpolasyon önceki gizli durumu ve olası gizli durumu içerir.

3.4. Geliştirilen Hibrit ConvGRU Modeli

ConvGRU modeli ile CNN ve GRU modellerinin öne çıkan etkili özelliklerini bir araya getirerek daha yüksek tahmin doğruluğuna sahip bir model geliştirilmesi amaçlanmıştır. CNN, özellik çıkarma aşamasında başarılıdır. GRU ise zaman serisi verilerindeki zamana olan bağımlılıkları etkili bir şekilde modellemektedir. ConvGRU, şehirlerin sıcaklık, nem ve çiy noktası verilerini girdi olarak almaktadır. ConvGRU Şekil 5'te görüldüğü gibi konvolüsyon katmanları, maksimum havuzlama katmanları, GRU katmanları ve yoğun katmandan oluşmaktadır. Modelin çıktısı, tahmin edilen sıcaklık, nem ve çiy noktası değerleridir. Model hiper-parametrelerinin optimizasyonu amacıyla ızgara arama kullanılarak en uygun hiper-parametre kombinasyonlarının belirlenmesi amaçlanmıştır. Geliştirilen modelin mimarisi Şekil 4'te görülmektedir.

ConvGRU, GRU'ya girdi olan alt dizileri yorumlamak için CNN katmanlarını kullanmaktadır. CNN, giriş verilerinden özellikleri çıkararak tek değişkenli giriş verilerini konvolüsyon ile çok boyutlu veri gruplarına dönüştürür ve tahmin için GRU'ya iletir.



Şekil 4. Geliştirilen modelin mimarisi.

ConvGRU modelinin performansını optimize etmek için öncelikle Tablo 2’de görüldüğü gibi hiper-parametre aralıkları belirlenmiştir.

Tablo 2. ConvGRU modeli için kullanılan hiper-parametreler ve değer aralıkları.

Hiper-parametre	Değer aralığı
Konvolüsyon katmanlarındaki filtre sayısı	[16, 32, 64]
Havuzlama boyutu	[2, 3, 4]
GRU katman sayısı	[1, 2, 3, 4, 5]
GRU nöron sayısı	[10, 20, 30, 40, 50, 60, 70, 80, 90, 100]
Yığın boyutu	[1, 4, 8, 16, 32, 64, 128]
Öğrenme oranı	[0.001, 0.01, 0.1]
Eğitim sayısı	[10, 25, 50, 75, 100, 200, 300, 400, 500]

ConvGRU modeli için Tablo 2’de görülen hiper-parametre kombinasyonları test edilerek en uygun hiper-parametrelerin belirlenmesi amaçlanmıştır. Belirlenen aralıklardaki hiper-parametreler kullanılarak tüm olası kombinasyonlar oluşturulmuştur. Her kombinasyon için modelin doğrulama veri seti üzerinde performansı değerlendirilmiştir. Tüm kombinasyonlar arasında en düşük RMSE değerine sahip olan kombinasyon seçilmiştir. ConvGRU’nun CNN bileşeni, çekirdek boyutu 1 ve 64 filtreye sahip 1D konvolüsyon katmanına sahiptir. Düzleştirme katmanı, konvolüsyon ve havuzlama katmanında çıkarılan özelliklerin GRU’ya iletilmeden önce tek boyuta indirgenmesini sağlar. Hiper-parametre optimizasyonu sonucunda CNN 32 filtreden oluşan 2 adet tek boyutlu konvolüsyon katmanından, çekirdek boyutu 1 ve havuzlama boyutu 2 olan 2 adet maksimum havuzlama katmanından oluşmakta ve ReLU aktivasyon fonksiyonunu kullanmaktadır. GRU bileşeni ise her biri 50 nöron içeren 3 katmandan oluşmaktadır. GRU için eğitim sayısı 200, yığın boyutu 64, öğrenme oranı 0.001, aktivasyon fonksiyonu ReLU, optimizasyon Adam ve kayıp fonksiyonu RMSE’dir. Izgara arama yöntemi ile optimize edilen hiper-parametreler, ConvGRU modelinin performansını önemli ölçüde iyileştirmiştir. En iyi hiper-parametre kombinasyonunun seçilmesi, modelin doğruluğunu ve genelleme kapasitesini artırmıştır.

4. DENEYSEL SONUÇLAR

Bu çalışmada, Agra, Jaipur, Jodhpur, New Delhi ve Rishikesh şehirlerinin sıcaklığını, nemini ve çiy noktalarının tahmin edilmesi amaçlanmıştır. Geliştirilen ConvGRU modeli, RF, LSTM, CNN, SVM ve GRU ile kapsamlı bir şekilde karşılaştırılmıştır. Tablo 3 ve Şekil 5’te, Agra şehri için deneysel sonuçlar görülmektedir.

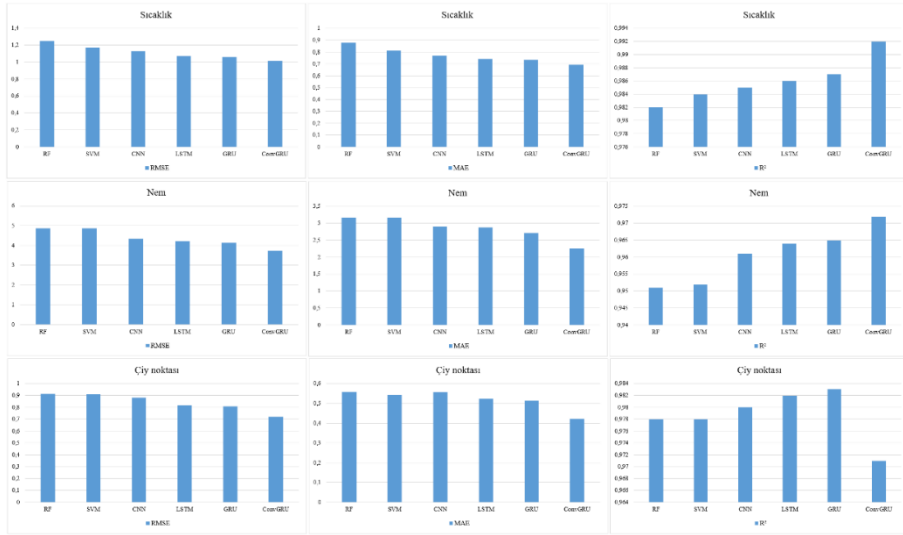
Tablo 3 ve Şekil 5’te görüldüğü gibi ConvGRU sıcaklık tahmininde $0,992 R^2$, nem tahmininde $0,972 R^2$ ve çiy noktası tahmininde $0,971 R^2$ ile karşılaştırılan modellerden daha başarılı olmuştur. ConvGRU’nun ardından sırasıyla GRU, LSTM, CNN, SVM ve RF başarılı olmuştur. Tablo 4 ve Şekil 6’da Agra şehri için deneysel sonuçlar görülmektedir.

Tablo 3. Agra şehri için deneysel sonuçlar

Model	Sıcaklık			Nem			Çiy noktası		
	RMSE	MAE	R ²	RMSE	MAE	R ²	RMSE	MAE	R ²
RF	1,247	0,878	0,982	4,878	3,175	0,951	0,914	0,558	0,978
SVM	1,171	0,812	0,984	4,857	3,170	0,952	0,909	0,542	0,978
CNN	1,133	0,769	0,985	4,341	2,901	0,961	0,882	0,557	0,980
LSTM	1,071	0,742	0,986	4,212	2,879	0,964	0,817	0,522	0,982
GRU	1,061	0,734	0,987	4,121	2,713	0,965	0,808	0,514	0,983
ConvGRU	1,011	0,692	0,992	3,724	2,255	0,972	0,719	0,422	0,971

Tablo 4 ve Şekil 6’da görüldüğü gibi ConvGRU sıcaklık tahmininde $0,989 R^2$, nem tahmininde $0,970 R^2$ ve çiy noktası tahmininde $0,988 R^2$ ile karşılaştırılan modellerden daha başarılı olmuştur. ConvGRU’nun ardından sırasıyla GRU, LSTM, CNN, SVM ve RF başarılı olmuştur. Tablo 5 ve Şekil 7’de, Agra şehri için deneysel sonuçlar görülmektedir.

Tablo 5 ve Şekil 7’de görüldüğü gibi ConvGRU sıcaklık tahmininde $0,989 R^2$, nem tahmininde $0,975 R^2$ ve çiy noktası tahmininde $0,991 R^2$ ile karşılaştırılan modellerden daha başarılı olmuştur.



Şekil 5. Agra şehri için deneysel sonuçlar.

Tablo 4. Jaipur şehri için deneysel sonuçlar.

Model	Sıcaklık			Nem			Çiy noktası		
	RMSE	MAE	R ²	RMSE	MAE	R ²	RMSE	MAE	R ²
RF	1,345	0,923	0,970	5,195	3,540	0,953	0,945	0,576	0,979
SVM	1,326	0,909	0,972	5,166	3,448	0,954	0,930	0,554	0,980
CNN	1,202	0,825	0,976	5,133	3,314	0,954	0,925	0,542	0,980
LSTM	1,157	0,814	0,979	4,743	3,235	0,961	0,881	0,530	0,982
GRU	1,038	0,802	0,981	4,564	3,155	0,964	0,858	0,519	0,983
ConvGRU	0,933	0,728	0,989	4,165	2,994	0,970	0,785	0,482	0,988




Şekil 6. Jaipur şehri için deneysel sonuçlar.

ConvGRU'nun ardından sırasıyla GRU, LSTM, CNN, SVM ve RF başarılı olmuştur. Tablo 6 ve Şekil 8'de, Agra şehri için deneysel sonuçlar görülmektedir.

Tablo 5. Jodhpur şehri için deneysel sonuçlar.

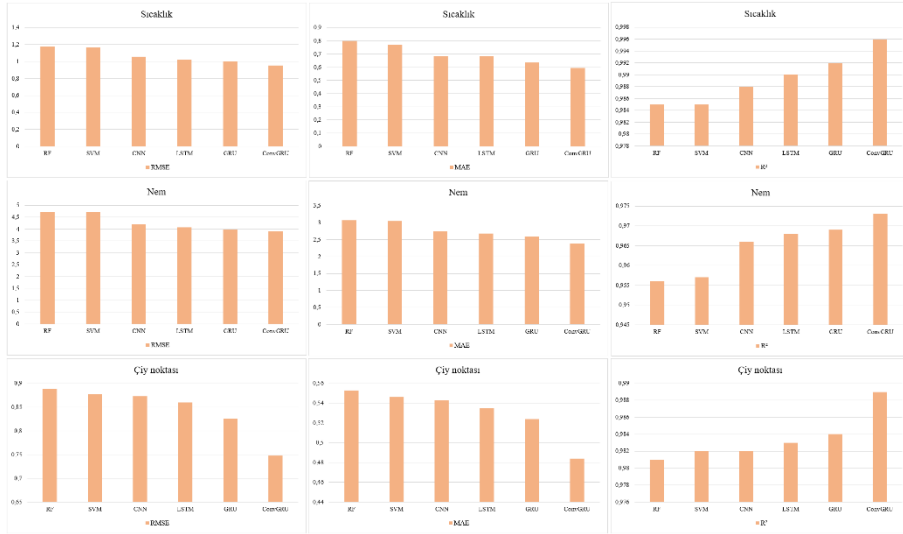
Model	Sıcaklık			Nem			Çiy noktası		
	RMSE	MAE	R ²	RMSE	MAE	R ²	RMSE	MAE	R ²
RF	1,245	0,818	0,977	4,304	2,755	0,962	1,019	0,571	0,983
SVM	1,227	0,816	0,978	4,288	2,752	0,963	1,008	0,570	0,983
CNN	1,061	0,670	0,983	4,234	2,742	0,965	0,997	0,598	0,984
LSTM	1,026	0,662	0,984	3,954	2,563	0,968	0,896	0,556	0,987
GRU	1,020	0,638	0,985	3,936	2,558	0,969	0,888	0,542	0,987
ConvGRU	0,991	0,563	0,989	3,822	2,489	0,975	0,845	0,458	0,991



Şekil 7. Jodhpur şehri için deneysel sonuçlar.

Tablo 6. New Delhi şehri için deneysel sonuçlar.

Model	Sıcaklık			Nem			Çiy noktası		
	RMSE	MAE	R ²	RMSE	MAE	R ²	RMSE	MAE	R ²
RF	1,180	0,798	0,985	4,724	3,070	0,956	0,889	0,553	0,981
SVM	1,164	0,771	0,985	4,719	3,045	0,957	0,877	0,546	0,982
CNN	1,056	0,684	0,988	4,195	2,741	0,966	0,873	0,543	0,982
LSTM	1,022	0,682	0,990	4,072	2,682	0,968	0,860	0,535	0,983
GRU	1,002	0,637	0,992	3,990	2,596	0,969	0,826	0,524	0,984
ConvGRU	0,954	0,595	0,996	3,912	2,382	0,973	0,748	0,484	0,989

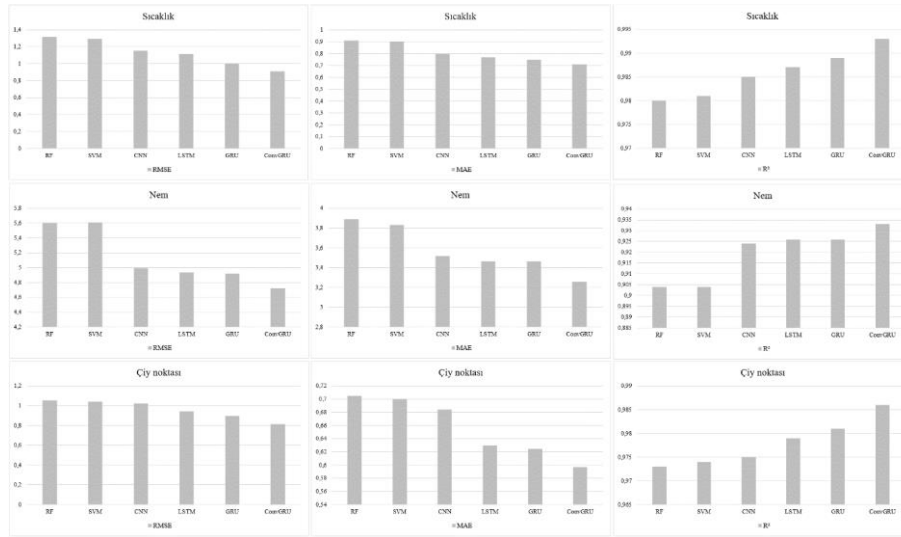


Şekil 8. New Delhi şehri için deneysel sonuçlar.

Tablo 6 ve Şekil 8’de görüldüğü gibi ConvGRU sıcaklık tahmininde 0,996 R², nem tahmininde 0,973 R² ve çiy noktası tahmininde 0,989 R² ile karşılaştırılan modellerden daha başarılı olmuştur. ConvGRU’nun ardından sırasıyla GRU, LSTM, CNN, SVM ve RF başarılı olmuştur. Tablo 7 ve Şekil 9’da Agra şehri için deneysel sonuçlar görülmektedir.

Tablo 7. Rishikesh şehri için deneysel sonuçlar.

Model	Sıcaklık			Nem			Çiy noktası		
	RMSE	MAE	R ²	RMSE	MAE	R ²	RMSE	MAE	R ²
RF	1,317	0,910	0,980	5,607	3,890	0,904	1,055	0,705	0,973
SVM	1,293	0,902	0,981	5,608	3,834	0,904	1,042	0,700	0,974
CNN	1,153	0,796	0,985	4,994	3,518	0,924	1,025	0,684	0,975
LSTM	1,117	0,769	0,987	4,937	3,463	0,926	0,945	0,630	0,979
GRU	1,003	0,747	0,989	4,919	3,461	0,926	0,898	0,625	0,981
ConvGRU	0,911	0,708	0,993	4,725	3,254	0,933	0,812	0,597	0,986



Şekil 9. Rishikesh şehri için deneysel sonuçlar.

Tablo 7 ve Şekil 9'da görüldüğü gibi ConvGRU sıcaklık tahmininde $0,993 R^2$, nem tahmininde $0,933 R^2$ ve çiy noktası tahmininde $0,986 R^2$ ile karşılaştırılan modellerden daha başarılı olmuştur. ConvGRU'nun ardından sırasıyla GRU, LSTM, CNN, SVM ve RF başarılı olmuştur.

ConvGRU, CNN ve GRU'nun başarılı olan özelliklerinden faydalanmaktadır. CNN, zaman serisi verilerindeki örüntülerin çıkarılmasında etkilidir. GRU ise, zamana bağlı ilişkilerin ve uzun vadeli bağımlılıkların belirlenmesini sağlar. ConvGRU, verilerdeki zamansal ilişkileri yakalama yeteneği sayesinde LR, RF ve SVM'den daha başarılı oldu. LR, verilerdeki karmaşık ilişkileri öğrenmede sınırlıyken RF ve SVM, verilerdeki karmaşık ilişkileri yakalamada sınırlıdır. ConvGRU'nun CNN, LSTM ve GRU'dan daha başarılı olması, modelin hem özellik çıkarma yeteneği hem de zamana bağlı özellikleri öğrenme yeteneği ve genelleme yeteneği ile yorumlanabilir.

Tablo 8'de incelenen literatürdeki çalışmalarda kullanılan yöntemler ve performans değerlendirme metrikleri görülmektedir.

Tablo 8. Literatürdeki çalışmalarda kullanılan yöntemler ve değerlendirme sonuçları.

Referans	Kullanılan yöntemler	Başarılı olan model
18	CNN, LSTM, GRU, Bi-LSTM, CNN-GRU ve CNN-LSTM	CNN-LSTM
19	DL-Air ve LSTM	DL-Air
20	MLP, LSTM ve 2D CNN	2D CNN
21	XGBoost, LightGBM, Catboost, RF ve Adaboost	Catboost
22	RNN, Bi-GRU, Bi-LSTM, CNN-BiLSTM, Conv1D-BiLSTM ve XGBoost	XGBoost
23	KNN, GNB, SVM, RF ve XGBoost	XGBoost
24	GRU, LSTM ve ARIMA	LSTM
25	DCNN-LSTM, LSTM ve DCNN	DCNN-LSTM
26	ANN, kNN, SVM ve RF	ANN
27	DRNN, DRNN-GRU, LSTM ve RSLSTM	RSLSTM
28	LSTM, DT, ARIMA, Huber Regressor, kNN ve Dummy Regressor	LSTM
Bu çalışma	RF, SVM, CNN, LSTM, GRU, ConvGRU	ConvGRU

Tablo 8'de görüldüğü gibi hava durumu ve hava kalitesi tahminine yönelik yapılan çalışmalarda ağırlıklı olarak derin öğrenme modelleri uygulanmıştır. Özellikle geliştirilen hibrit modeller, karşılaştırılan temel modellere göre daha başarılı sonuçlara sahip olmuştur. Bu çalışmada CNN ve GRU modelleri kullanılarak ConvGRU hibrit modeli geliştirilmiştir. ConvGRU, 1D konvolüsyon katmanları ve GRU katmanlarından oluşan mimarileri birleştirerek, iklim verilerindeki uzun vadeli ilişkileri yakalamak için daha etkili bir yaklaşım sunmaktadır. Yapılan karşılaştırmalı analizlerde, ConvGRU modelinin geleneksel modellere göre belirgin bir şekilde daha yüksek R^2 değerleri elde ettiği gözlemlenmiştir. Özellikle, ConvGRU'nun tüm şehirler ve iklim değişkenleri için $0,9$ 'un üzerinde R^2 değerleri elde etmesi, önerilen modelin başarısını doğrulamaktadır. Ayrıca, ConvGRU'nun genel olarak daha istikrarlı ve güvenilir tahminler ürettiği ve uzun vadeli iklim değişkenlerinin tahmininde diğer modellere göre daha başarılı olduğu gözlemlenmiştir.

5. SONUÇLAR

Hava durumu tahmini, atmosferdeki meteorolojik koşulların gelecekte belirli bir zaman diliminde nasıl olacağını öngörülmesidir. Hava tahminleri, hava sıcaklığı, nem, rüzgâr hızı ve yönü, bulut örtüsü ve yağış miktarı gibi çeşitli faktörleri içerebilir. Sıcaklık, nem ve çiy noktası gibi iklim değişkenleri, doğru ve etkili hava durumu tahminleri oluşturmak için kullanılan birincil parametrelerdir. Atmosferdeki su buharı sürekli olarak buharlaşma yoluyla

üretildiğinden ve yoğunlaşma yoluyla uzaklaştırıldığından, su döngüsünün ayrılmaz bir parçasıdır. Çiy noktası, havanın doyma noktasına ulaştığı ve buharın yoğunlaşarak sıvı hâle geçtiği sıcaklığı ifade eder. Hava çiy noktasının altına kadar soğumaya devam ederse, havadaki su çiy şeklinde yoğunlaşmaya başlayacaktır. Çiy noktası meteoroloji istasyonu verilerinin önemli bir parçasıdır çünkü çiy noktası, don, sis, minimum gece sıcaklıkları ve hatta yağmur, fırtına ve kasırga oluşumunu tahmin etmek için kullanılmaktadır. Yapay zekâ yöntemleri, büyük miktarlarda atmosferik veriyi hızlı ve etkili bir şekilde analiz ederek hava durumu tahminini kolaylaştırmaktadır. Yapay zekâ yöntemleri, uydulardan, radarlardan ve hava istasyonlarından gelen sıcaklık, nem, rüzgâr hızı ve hava basıncı gibi verileri tahmin modellerini geliştirmek için kullanılmaktadır. Oluşturulan tahmin modelleri, gelecekteki hava olaylarını tahmin etmek için geçmiş hava durumu örüntülerini ve mevcut koşulları analiz eder.

Agra, Jaipur, Jodhpur, New Delhi ve Rishikesh, Hindistan'daki tarihi mimariler ve kültür turizmi açısından önemli olan şehirlerdir. Bu şehirler her yıl milyonlarca turiste ev sahipliği yapmaktadır. Turistler seyahat planlamalarını hava koşullarına göre düzenlemektedir. Ayrıca hava durumunun tahmin edilmesi, ulaşım ağlarının optimizasyonu, önleyici tedbirler ve yerel yönetimlerin planlamaları açısından önemlidir. Bu çalışmada, Hindistan'da turizm açısından önemli şehirlerden olan Agra, Jaipur, New Delhi ve Rishikesh'in uzun vadeli iklim değişkenlerini tahmin etmek için ConvGRU hibrit modeli geliştirilmiştir. ConvGRU modelinde, zaman serisi verilerindeki özellikleri etkili bir şekilde çıkarmak için CNN'den, zaman serisi verilerindeki ilişkileri ve uzun vadeli bağımlılıkları öğrenmek için GRU'dan faydalanılmıştır. ConvGRU, RF, SVM, CNN, LSTM ve GRU modelleriyle, şehirlerin yaklaşık 15 yıllık güncel ve gerçek zamanlı iklim değişkenlerinden oluşan bir veri seti kullanılarak test edilmiştir. Deneysel sonuçlar, ConvGRU'nun tüm şehirler ve iklim değişkenleri için 0,9'un üzerinde R^2 değeriyle karşılaştırılan modellerden daha başarılı olduğunu göstermiştir.

Yazar Katkıları

Anıl Utku: Makalenin kapsamı, yöntemi, araştırmanın uygulanması, sonuçların değerlendirilmesi ve makalenin yazımının tamamına katkı sağlamıştır.

Çıkar Çatışması

Makale yazarları aralarında herhangi bir çıkar çatışması olmadığını beyan ederler.

KAYNAKÇA

- [1] K.U. Jaseena, and B.C. Kovoov, "Deterministic weather forecasting models based on intelligent predictors: A survey", *Journal of King Saud University-Computer and Information Sciences*, vol. 34, no. 6, pp. 3393-3412, 2022.
- [2] C.H. Huang, H.H. Tsai, and H.C. Chen, "Influence of weather factors on thermal comfort in subtropical urban environments", *Sustainability*, vol. 12, no. 5, 2020.
- [3] M. Bulté, T. Duren, O. Bouhon, E. Petitclerc, M. Agniel, and A. Dassargues, "Numerical modeling of the interference of thermally unbalanced Aquifer Thermal Energy Storage systems in Brussels (Belgium)", *Energies*, vol. 14, no. 19, 2021.
- [4] J.S. Nanditha, B. Rajagopalan, and V. Mishra, "Combined signatures of atmospheric drivers, soil moisture, and moisture source on floods in Narmada River basin, India", *Climate Dynamics*, vol. 59, no. 9, pp. 2831-2851, 2022.
- [5] X. Yang, L.L. Peng, Y. Chen, L. Yao, and Q. Wang, "Air humidity characteristics of local climate zones: A three-year observational study in Nanjing", *Building and Environment*, no. 171, 2020.
- [6] L. Gimeno, J. Eiras-Barca, A.M. Durán-Quesada, F. Dominguez, R. van der Ent, H. Sodemann, and J.W. Kirchner, "The residence time of water vapour in the atmosphere", *Nature Reviews Earth & Environment*, vol. 2, no. 8, pp. 558-569, 2021.
- [7] J. Lin, K. Thu, S. Karthik, M.W. Shahzad, R. Wang, and K.J. Chua, "Understanding the transient behavior of the dew point evaporative cooler from the first and second law of thermodynamics", *Energy Conversion and Management*, no. 244, 2021.
- [8] M.W. Shahzad, J. Lin, B.B. Xu, L. Dala, Q. Chen, M. Burhan, and K.C. Ng, "A spatiotemporal indirect evaporative cooler enabled by transiently interceding water mist", *Energy*, no. 217, 2021.
- [9] X. Zuo, "Impact of air pollution: tourists' decision making behaviour during rural tourism", *Journal of Environmental Engineering and Science*, vol. 40, pp. 1-6, 2024.
- [10] M.V. Sivakumar, "Climate extremes and impacts on agriculture", *Agroclimatology: Linking Agriculture to Climate*, vol. 60, pp. 621-647, 2020.
- [11] K.U. Jaseena, and B.C. Kovoov, "Deterministic weather forecasting models based on intelligent predictors: A survey", *Journal of King Saud University-Computer and Information Sciences*, vol. 34, no. 6, pp. 3393-3412, 2022.
- [12] W. Fang, Q. Xue, L. Shen, and V.S. Sheng, "Survey on the application of deep learning in extreme weather prediction. *Atmosphere*, vol. 12, no. 6, 2021.
- [13] S. Srivastava, "Economic potential of tourism: A case study of agra", *Tourismos*, vol. 6, no. 2, pp. 139-158, 2011.
- [14] B.K. Sharma, S. Kulshreshtha, and A.R. Rahmani, "Faunal Heritage of Rajasthan", *Indian Journal*, 2011.
- [15] G. Kaur, A. Ahuja, S.N. Thakur, M. Pandit, R. Duraiswami, A. Singh, and S. Garg, "Jodhpur sandstone: an architectonic heritage stone from India", *Geoheritage*, vol. 12, pp. 1-17, 2020.
- [16] S.S. Shukla, D.K. Goswami, "Indian tourism industry overview of Indian tourism", *International Journal of*

- Technology Management & Humanities (IJTMH), vol. 1, no. 1, 2015.
- [17] P. Kanungo, "Construction and Transformation of a Sacred Urban Complex of Hardwar-Rishikesh, North India", *Archiv für Religionsgeschichte*, vol. 25, no. 1, pp. 211-226, 2023.
- [18] A. Bekkar, B. Hssina, S. Douzi, and K. Douzi, "Air-pollution prediction in smart city, deep learning approach", *Journal of big Data*, vol. 8, pp. 1-21, 2021.
- [19] S. Abirami, and P. Chitra, "Regional air quality forecasting using spatiotemporal deep learning", *Journal of cleaner production*, vol. 283, 2021.
- [20] K.R. Patil, and M. Iiyama, "Deep learning models to predict sea surface temperature in Tohoku region", *IEEE Access*, vol. 10, pp. 40410-40418, 2022.
- [21] G. Ravindiran, G. Hayder, K. Kanagarathnam, A. Alagumalai, and C. Sonne, "Air quality prediction by machine learning models: A predictive study on the indian coastal city of Visakhapatnam", *Chemosphere*, vol. 338, 2023.
- [22] I. Ayus, N. Natarajan, and D. Gupta, "Comparison of machine learning and deep learning techniques for the prediction of air pollution: a case study from China", *Asian Journal of Atmospheric Environment*, vol.17, no. 1, 2023.
- [23] K. Kumar, and B.P. Pande, "Air pollution prediction with machine learning: a case study of Indian cities", *International Journal of Environmental Science and Technology*, vol. 20, no. 5, pp. 5333-5348, 2023.
- [24] F. Naz, C. McCann, M. Fahim, T.V. Cao, R. Hunter, N. T. Viet, and T. Q. Duong, "Comparative analysis of deep learning and statistical models for air pollutants prediction in urban areas", *IEEE Access*, vol. 11, 2023.
- [25] A. Barthwal, and A.K. Goel, "Advancing air quality prediction models in urban India: a deep learning approach integrating DCNN and LSTM architectures for AQI time-series classification", *Modeling Earth Systems and Environment*, pp. 1-21, 2024.
- [26] F. Mohammadi, H. Teiri, Y. Hajizadeh, A. Abdolahnejad, and A. Ebrahimi, "Prediction of atmospheric PM2. 5 level by machine learning techniques in Isfahan, Iran", *Scientific Reports*, vol. 14, no. 1, 2024.
- [27] D. Krivoguz, A. Ioshpa, S. Chernyi, A. Zhilenkov, A. Kustov, A. Zinchenko, P. Tsareva, "Enhancing Long-Term Air Temperature Forecasting with Deep Learning Architectures", *Journal of Robotics and Control (JRC)*, vol. 5, no. 3, pp. 706-716, 2024.
- [28] A. Mishra, and Y. Gupta, "Comparative analysis of Air Quality Index prediction using deep learning algorithms", *Spatial Information Research*, vol. 32, no. 1, pp. 63-72, 2024.
- [29] Kaggle, "Indian Cities Weather 2010-2024: Dive In!", [Çevrimiçi]. Erişim: <https://www.kaggle.com/datasets/mukeshdevrath007/indian-5000-cities-weather-data/data>
- [30] A. Utku, "Deep learning based hybrid prediction model for predicting the spread of COVID-19 in the world's most populous countries" *Expert Systems with Applications*, vol. 231, 2023.
- [31] M.M. Ghiasi, and S. Zendehboudi, "Application of decision tree-based ensemble learning in the classification of breast cancer", *Computers in biology and medicine*, vol. 128, 2021.
- [32] V. Rodriguez-Galiano, M. Sanchez-Castillo, M. Chica-Olmo, and M.J.O.G.R. Chica-Rivas, "Machine learning predictive models for mineral prospectivity: An evaluation of neural networks, random forest, regression trees and support vector machines", *Ore Geology Reviews*, vol. 71, pp. 804-818, 2015.
- [33] A.M. Prasad, L.R. Iverson, and A. Liaw, "Newer classification and regression tree techniques: bagging and random forests for ecological prediction", *Ecosystems*, vol. 9, pp. 181-199, 2006.
- [34] J. Cervantes, F. Garcia-Lamont, L. Rodríguez-Mazahua, and A. Lopez, "A comprehensive survey on support vector machine classification: Applications, challenges and trends", *Neurocomputing*, vol. 408, pp. 189-215, 2020.
- [35] M.A. Chandra, S.S. Bedi, "Survey on SVM and their application in image classification. *International Journal of Information Technology*, vol. 13, no. 5, pp. 1-11, 2021.
- [36] Y. Liu, H. Pu, and D.W. Sun, "Efficient extraction of deep image features using convolutional neural network (CNN) for applications in detecting and analysing complex food matrices", *Trends in Food Science & Technology*, vol. 113, pp. 193-204, 2021.
- [37] C. Chen, C. Meng, Y. Ma, M. Zhu, X. Wang, X. Xie, and C. Chen, "MGFFCNN: Two-dimensional matrix spectroscopy combined with multi-channel gradient feature fusion convolutional neural network means to diagnose glioma and esophageal cancer patients", *Journal of Raman Spectroscopy*, vol. 54, no. 4, pp. 385-396, 2023.
- [38] S.M. Al-Selwi, M.F. Hassan, S.J. Abdulkadir, A. Muneer, "LSTM inefficiency in long-term dependencies regression problems", *Journal of Advanced Research in Applied Sciences and Engineering Technology*, vol. 30, no. 3, pp. 16-31, 2023.
- [39] B. Lindemann, T. Müller, H. Vietz, N. Jazdi, and M. Weyrich, "A survey on long short-term memory networks for time series prediction", *Procedia Cirp*, vol. 99, pp. 650-655, 2021.
- [40] F. Landi, L. Baraldi, M. Cornia, and R. Cucchiara, "Working memory connections for LSTM", *Neural Networks*, vol. 144, pp. 334-341, 2021.
- [41] Y. Khalifa, D. Mandic, and E. Sejdić, "A review of Hidden Markov models and Recurrent Neural Networks for event detection and localization in biomedical signals", *Information Fusion*, vol. 69, pp. 52-72, 2021.
- [42] T. Wadhera, J. Bedi, and S. Sharma, "Autism spectrum disorder prediction using bidirectional stacked gated recurrent unit with time-distributor wrapper: an EEG study", *Neural Computing and Applications*, vol. 35, no. 13, pp. 9803-9818, 2023.
- [43] Z. Zainuddin, and M.H. Hasan, "Predicting machine failure using recurrent neural network-gated recurrent unit (RNN-GRU) through time series data", *Bulletin of Electrical Engineering and Informatics*, vol. 10, no. 2, pp. 870-878, 2021.
- [44] L.Y. Chen, Y.T. Chen, Y.H. Chen, and D.S. Lee, "Applicability of energy consumption prediction models in a department store: A case study", *Case Studies in Thermal Engineering*, vol. 49, 2023.