



Rüzgâr Hızı Tahminine Yönelik Hibrit ConvLstm Modeli: Hindistan'ın En Yüksek Rüzgâr Hızına Sahip Şehirleri için Bir Vaka Çalışması

Anıl UTKU¹, Sinem AKYOL²

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

² Yazılım Mühendisliği, Mühendislik Fakültesi, Fırat Üniversitesi, Elazığ, Türkiye

✉: sakyol@firat.edu.tr ¹ 0000-0002-7240-8713 ² 0000-0001-9308-3500

Geliş (Received): 07.10.2024

Düzeltilme (Revision): 13.11.2024

Kabul (Accepted): 26.11.2024

ÖZ

Rüzgâr hızı tahmini lojistik, enerji üretimi ve yenilenebilir enerji kaynakları, havacılık ve denizcilik, tarım, afet yönetimi, çevresel izleme, inşaat, yaşam planlama ile ekonomik faaliyetler için oldukça önemlidir. Bu çalışmada, Hindistan'ın en yüksek rüzgâr hızına sahip şehirlerinden olan Jaisalmer, Kochi, Mangalore, Puri ve Rameswaram şehirlerinin rüzgâr hızlarının tahmin edilmesi amaçlanmıştır. Rüzgâr hızı tahminine yönelik CNN ve LSTM modellerinin etkin özelliklerinden faydalanarak ConvLSTM hibrit modeli geliştirilmiştir. ConvLSTM ile mekânsal ve zamansal verileri aynı anda işleyerek rüzgâr hızının dinamiklerini daha iyi belirlemek amaçlanmıştır. ConvLSTM, RF, SVM, ANFIS, CNN ve LSTM ile rüzgâr hızının 10 metre ve 100 metre yüksekliklerdeki ölçümlerinden oluşan yaklaşık 15 yıllık saatlik bir veri seti kullanılarak kapsamlı bir şekilde test edilmiştir. Deneysel sonuçlar, ConvLSTM'in her bir şehir ve rüzgâr hızı parametresinin neredeyse tamamında 0,9'un üzerinde R^2 değerine sahip olduğunu, RMSE ve MAE hata metrikleri açısından ise en düşük hata değerlerine sahip olarak karşılaştırılan modellerden daha başarılı olduğunu göstermiştir.

Anahtar Kelimeler: CNN, Derin öğrenme, Makine öğrenmesi, LSTM, Rüzgâr hızı

Hybrid ConvLSTM Model for Wind Speed Prediction: A Case Study for India's Highest Wind Speed Cities

ABSTRACT

Wind speed prediction is very important for logistics, energy production and renewable energy sources, aviation and maritime, agriculture, disaster management, environmental monitoring, construction, life planning and economic activities. In this study, it was aimed to predict the wind speeds of Jaisalmer, Kochi, Mangalore, Puri and Rameswaram, which are among the cities with the highest wind speeds in India. ConvLSTM hybrid model was developed by taking advantage of the effective features of CNN and LSTM models for wind speed prediction. With ConvLSTM, it is aimed to better determine the dynamics of wind speed by processing spatial and temporal data simultaneously. ConvLSTM has been extensively tested using an approximately 15-year hourly dataset consisting of RF, SVM, ANFIS, CNN and LSTM and wind speed measurements at 10 meters and 100 meters' altitudes. Experimental results show that ConvLSTM has R^2 values above 0.9 for almost all of the city and wind speed parameters, and outperforms the compared models with the lowest error values in terms of RMSE and MAE error metrics.

Keywords: CNN, Deep learning, Machine learning, LSTM, Wind speed

GİRİŞ

Meteoroloji, atmosferik olayları ve meydana gelme biçimlerini inceleyen bir bilim dalıdır. Meteoroloji hava durumunu ve iklim değişkenlerinin gelecekteki değerlerini öngörmeyi amaçlamaktadır [1]. Meteoroloji uzmanları, meteorolojik olguları belirleyebilmek için fiziksel, istatistiksel ve bilgisayar destekli modeller kullanmaktadır. Rüzgâr, yüksek basınç bölgelerinden düşük basınç bölgelerine doğru hava kütlelerinin hareketidir [2]. Rüzgârın hızı ve yönü, atmosferdeki

basınç farkları, sıcaklık değişiklikleri ve dünyanın dönüşü gibi faktörlerden etkilenir. Rüzgâr, hava tahminlerinde önemli bir rol oynar. Rüzgâr hızları ve yönleri, hava sistemlerinin nasıl hareket edeceğini ve hangi bölgelerde etkili olacağını belirlemede kullanılır [3]. Meteorologlar, rüzgâr verilerini analiz ederek yağış, sıcaklık ve diğer iklim değişkenlerinin durumunu öngörürler. Rüzgâr, atmosferdeki basınç farkları nedeniyle meydana gelmektedir. Rüzgârın yönü ve hızı, dünyanın dönmesi ile dağ, vadi ve binalar gibi etkenlerden dolayı değişmektedir [4]. Rüzgârlar, nemli

havayı sürükleyerek yağışların meydana gelmesine neden olur. Rüzgâr hareketlerini gözlemleyebilmek amacıyla radarlar ve uydular kullanılmaktadır. Rüzgâr hızını ölçmek için ise anemometre cihazları kullanılmaktadır [5].

Kuvvetli rüzgârlar, fırtına ve kasırgalara sebep olarak ciddi can ve mal kayıplarına neden olabilir [6]. Özellikle hava ve deniz ulaşımı olmak üzere ulaşım güvenliğini tehlikeye düşürebilir. Kuvvetli rüzgârlar neticesinde elektrik şebekelerinde arızalar yaşanabilir, binalar zarar görebilir [7]. Bitki örtüsünün seyrek olduğu bölgelerde toprağı aşındırarak erozyona ve çölleşmeye neden olabilir. Tarımsal ürünlere zarar vererek üretim verimliliğinin düşmesine ve kullanılan kimyasalların farklı bölgelere taşınmasına neden olabilir [8]. Ayrıca, hava kirliliğine neden olan toz ve partikül maddelerin taşınmasına neden olarak hava kalitesine olumsuz etki edebilir.

Fırtınalardan kaynaklanan şiddetli rüzgârlar, büyük ölçekli orman hasarları, elektrik kesintileri ve bina hasarı gibi önemli hasarlara neden olur [9, 10]. Fırtına, kasırga, dolu ve kuvvetli rüzgârlar, tarımsal üretim alanlarının yanı sıra günlük yaşamı da olumsuz etkileme potansiyeline sahip doğal tehlikelerdir. Bu nedenle rüzgâr hızı tahmini, gelişmiş hava uyarıları almak için önemli bir görevdir. Çeşitli sektörler için oldukça önemli olan rüzgâr hızı tahmininde yapay zekâ teknolojilerinin kullanımı, tahmin doğruluğunun ve verimliliğinin artırılması açısından önemlidir. Rüzgâr hızı tahmini yenilenebilir enerji optimizasyonu, güvenlik ve risk yönetimi, afetlere yönelik stratejiler geliştirilmesi, tarımsal üretim, açık hava etkinlikleri ve hava kirliliği açısından önemlidir [11].

Doğru rüzgâr hızı tahminleri, rüzgâr santrallerinin operasyonlarının optimize edilmesine yardımcı olur. Enerji üretiminin daha iyi planlanmasına olanak tanır. Rüzgâr türbinlerinin verimli çalışmasını sağlayarak aşınmayı ve yıpranmayı azaltır. Ayrıca elektrik şebekelerinde arz ve talebin dengelenmesine, rüzgar enerjisinin daha güvenilir bir şekilde entegre edilmesine ve fosil yakıtlara olan bağımlılığın azaltılmasına yardımcı olur [12]. Havacılık sektöründe uçakların kalkışları ve inişleri ile uçuş planlaması ve güvenliği açısından kritik öneme sahiptir [13, 14]. Benzer şekilde denizcilik faaliyetlerinde, navigasyon ve rota planlaması ile gemilerin ve mürettebatın güvenliğinin sağlanması için hayati öneme sahiptir [13].

Fırtına ve kasırga tahminleri, kasırgalar ve fırtınalar için erken ve doğru uyarılar sağlayarak şiddetli hava olaylarına hazırlıklı olunmasını, potansiyel can ve mal kaybının önlenmesini sağlar [15]. Tarımsal üretim süreçlerinde çiftçilerin kimyasal uygulamalarının ve sulama süreçlerinin planlanması ve mahsullerin rüzgârın zararından korunması gibi faaliyetler açısından önemlidir [16]. Benzer şekilde rüzgâr hızı tahminleri yelken, sörf ve yamaç paraşütü gibi açık hava sporlarının planlanması açısından önemlidir. Ayrıca rüzgâr düzenlerini anlamak, hava kirleticilerin dağılımını modellemek ve hava kalitesi yönetimini iyileştirmek için önemlidir [17].

Rüzgâr hızı tahmininde yapay zekâ yöntemlerinin kullanımı daha yüksek tahmin doğruluğu, uyarlanabilir öğrenme, çoklu veri kaynaklarının entegrasyonu, gerçek zamanlı işleme ve ölçeklenebilirlik sağlar [18]. Yapay zekâ yöntemleri, büyük miktarlarda geçmiş ve gerçek zamanlı verileri işleyerek geleneksel yöntemlere göre daha yüksek tahmin doğruluğu sağlamaktadır. Yapay zekâ yöntemleri sürekli olarak yeni verileri öğrenerek ve uyum sağlayarak zaman içinde tahmin yeteneklerini geliştirir [19]. Bu sayede, değişen hava koşulları ve anomalilerin tespit edilmesi kolaylaşmaktadır. Yapay zekâ yöntemleri, uydu görüntüleri, hava durumu istasyonları ve IoT cihazları dahil olmak üzere çeşitli kaynaklardan gelen verileri entegre ederek rüzgâr düzenlerinin kapsamlı bir şekilde anlaşılmasını sağlayabilir [20]. Ayrıca yapay zekâ yöntemleri, geniş coğrafi alanları kapsayacak şekilde ölçeklenebilir ve küresel hava durumu modellerinin karmaşıklığını ele alarak yerel, bölgesel ve küresel düzeylerde tahminler sağlayabilir [21].

Bu çalışmada, Hindistan'ın en yüksek rüzgâr hızına sahip şehirlerinden olan Jaisalmer, Kochi, Mangalore, Puri ve Rameswaram şehirlerinin rüzgâr hızlarının tahminine yönelik Convolutional Neural Network (CNN) ve Long Short-Term Memory (LSTM) modelleri kullanılarak hibrit ConvLSTM modeli geliştirilmiştir. Çalışmada, şehirlerin 01-01-2010 ile 21-02-2024 tarihleri arasındaki rüzgâr hızının 10 metre ve 100 metre yüksekliklerdeki ölçümlerinden oluşan saatlik, güncel bir veri seti kullanılmıştır. ConvLSTM modeli, Adaptive Neuro Fuzzy Inference Systems (ANFIS), Random Forest (RF), Support Vector Machine (SVM), CNN ve LSTM ile uygulamalı olarak karşılaştırılmıştır. Bu çalışmanın literatüre sunduğu yenilikler aşağıdaki gibi özetlenebilir:

- Tahmin doğruluğunu ve etkinliğini arttırmak amacıyla hibrit ConvLSTM modeli geliştirilmiştir.
- Bu veri seti ve şehirler kullanılarak yapılmış literatürdeki ilk çalışmadır.
- ConvLSTM modeli ile RF ve SVM gibi geleneksel makine öğrenmesi yöntemleri, CNN ve LSTM gibi derin öğrenme modelleri ile yapay sinir ağları ile bulanık mantık sistemlerini birleştiren hibrit bir model olan ANFIS kapsamlı olarak karşılaştırılmıştır.

İLİŞKİLİ ÇALIŞMALAR

Derin öğrenme modelleri, özellikle uzun kısa süreli hafıza ağları rüzgâr hızı tahmininde önemli başarı göstermiştir. Bu modeller, zaman serisi verilerindeki karmaşık kalıpların yakalanmasında çok iyi sonuçlar verdiği için rüzgâr hızı tahmininde ideal bir araç olarak kullanılmaktadır. Bu bölümde derin öğrenme yöntemleri kullanılarak rüzgâr hızı tahmini yapılmasına yönelik yapılan çalışmalar ele alınmaktadır.

Subbiah ve diğ., rüzgâr hızı tahmini için non-lineerlik, boyutsallık, belirsizlik ve aşırı uyum sorunlarını giderdikleri BFS-Bi-LSTM modelini önermişlerdir [22]. Önerdikleri modeli LSTM, BFS-LSTM, MLP ve BFS-MLP modelleri ile karşılaştırmışlardır. Geliştirilen model, 0.530 Mean Absolute Error (MAE), 0.784 Root

Mean Squared Error (RMSE) ve 0.8766 R-Squared (R^2) değerleri ile karşılaştırılan modellerden daha başarılı bir performans sergilenmiştir.

Chen ve Han, kanat yarıçapındaki değişimi dikkate alan ve aerodinamiğin haritasını yeniden oluşturan bir yöntem önermişlerdir [23]. Rüzgâr türbininin mevcut verileri kullanılarak, başlangıç olarak radyal bazlı fonksiyonları temel alan iki sinir ağı modeli eğitilmiştir. Modeller sırasıyla etkili yarıçapı tahmin ederek, aerodinamik haritalama yüzeyini yeniden oluşturmuşlardır. Ardından, mevcut rüzgâr hızını anlık olarak etkili bir şekilde tahmin edebilen ve gelecek zaman adımıdaki rüzgâr hızını öngörebilen LSTM tabanlı bir model eğitilmiştir. Deneysel sonuçlar, önerilen yöntemin rüzgâr hızı tahmin doğruluğunu ortalama %70'in üzerinde geliştirdiğini göstermektedir.

Chen ve diğ., yeni bir çekirdek MSE kayıp fonksiyonu önermişlerdir [24]. Çekirdek MSE kayıp fonksiyonunun, derin öğrenme hatalarının doğrusal olmama durumunu diğer kayıp fonksiyonlarına kıyasla daha doğru bir şekilde doğrudan ölçebildiğinden bahsetmişlerdir. Yeni kayıp fonksiyonunu doğrulamak için, temel modeller olarak Recurrent Neural Network (RNN), LSTM ve Gated Recurrent Unit (GRU) kullanılmıştır. Üç farklı veri seti üzerinde gerçekleştirilen deneysel çalışmalar, yeni kayıp fonksiyonunun genellikle daha verimli ve üstün olduğunu ortaya koymuştur. Bu da, çok adımlı tahminlerde elde edilen hata oranının %95 MSE'den daha düşük olabileceği sonucunu doğurmuştur.

Han ve diğ., pearson korelasyon katsayısına, uyarlanabilir gürlütle tam topluluk ampirik mod ayrıştırmasına ve dikkat mekanizması ve grid arama yöntemine sahip algoritmalara dayanan yeni bir hibrit derin öğrenme modelini rüzgâr hızını tahmin etmek için önermişlerdir [25]. Elde ettikleri sonuçlara göre, MAE, Mean Absolute Percentage Error (MAPE) ve RMSE değerleri düzeltilmeden sonra 0,1042 m/s, %4,63 ve 0,1309 m/s olup, 94,13 oranında azalmıştır.

Khodayar ve diğ., kısa vadeli rüzgâr hızı tahmini için bir yöntem önermişlerdir [26]. Önerilen yöntem, yeni bir özellik çıkarma katmanıyla birlikte bulanık tip II çıkarım sistemine sahip yeni bir gerçek değerli derin inaç ağından oluşmaktadır. Western Wind veri seti test edilerek RMSE ve MAPE metrikleri için alınan deneysel sonuçlar, önerilen algoritmanın başarılı sonuçlar verdiğini göstermiştir.

Hao ve diğ., karma frekans verilerinin değerini dikkate alarak, tahmin etkinliğini artırmak amacıyla karma frekans modellemeye dayalı bir derin öğrenme modeli geliştirmişlerdir [27]. İlk olarak, orijinal düşük ve yüksek frekanslı rüzgâr hızlarını ayrıştırmak ve yeniden oluşturmak için bir veri ön işleme modülü tasarlanmıştır. Yapılan simülasyon sonuçları, tasarlanan birleşik modelin Saha 1 ve Saha 2'de karşılaştırılan diğer tüm modellere göre daha iyi performans sergilediğini göstermektedir.

Özellikle, geliştirilen modelin Saha 1'de MAE, RMSE, MAPE, IA ve U1 değerleri sırasıyla 0,2897, 0,4010, 3,8261 %, 0,9771 ve 0,0249 iken, Saha 2'de bu değerler

sırasıyla 0,2352, 0,2912, 3,8972 %, 0,9944 ve 0,0209 olarak hesaplanmıştır.

ConvLSTM, zaman serisi verilerindeki uzun vadeli bağımlılıkları öğrenme kapasitesini CNN'in mekânsal özellik çıkarma yeteneği ile birleştirerek, karmaşık ve dinamik verilerin tahmininde önemli avantajlar sunar. Literatürde ConvLSTM'e benzer yöntemler kullanılmakla birlikte, bu çalışmanın ayırt edici özelliği, Hindistan'ın en yüksek rüzgâr hızına sahip beş şehirden alınan 15 yıllık veri setinin analiz edilmesi ve bu kadar uzun süreli bir saatlik verinin daha önce çalışılmamış olmasıdır. Bu bağlamda, ConvLSTM modeli, yalnızca doğruluk performansı açısından değil, aynı zamanda mekânsal ve zamansal veri işleme kapasitesiyle de literatüre önemli bir katkı sunmaktadır. ConvLSTM, RF ve SVM gibi geleneksel yöntemlerden yalnızca doğruluk değerleri açısından değil, karmaşık veri örüntülerini işleyebilme kapasitesi sayesinde de ayrılmaktadır. Örneğin, ANFIS modeli bulanık mantık sistemlerine dayansa da yüksek boyutlu mekânsal ve zamansal verilerde sınırlı kalmıştır. Bu durum ConvLSTM'in hibrit yapısının önemini göstermektedir.

Bu çalışmanın özgünlüğü, geliştirilen modelin rüzgâr hızı tahmininde kullanılarak, daha önce benzer bir veri setinde ve bu bağlamda test edilmemiş olmasıdır. Literatürdeki mevcut çalışmalarda, genellikle tek bir coğrafi bölge veya daha kısa süreli veriler kullanılmışken, bu çalışmada Hindistan'daki farklı şehirlerden alınan 15 yıllık veri setiyle, mekânsal ve zamansal bağımlılıkların daha kapsamlı bir şekilde işlenmesi sağlanmıştır. Çalışmada kullanılan 15 yıllık rüzgâr hızı verisi, Hindistan'ın farklı coğrafi bölgelerinden alınmış olup, daha önce literatürde bu tür bir veri seti kullanılmamıştır. Kullanılan veri seti, modelin genelleme kapasitesinin test edilmesi açısından literatüre önemli bir katkıdır. Bu veri seti, rüzgâr enerjisi sektöründe daha doğru tahminler yapılabilmesine olanak tanıyacak ve yenilikçi bir yaklaşım olarak öne çıkmaktadır.

Literatürdeki çalışmaların çoğunda, genellikle tek bir şehir veya ülkeye ait veriler kullanılmıştır. Bu durum, modelin genelleme kapasitesini sınırlayabilir. Ancak bu çalışmada, Hindistan'ın farklı iklim koşullarına sahip beş şehirden alınan verilerle yapılan tahminler, ConvLSTM'in geniş bir coğrafyada nasıl performans gösterdiğini ortaya koymaktadır ve modelin gerçek dünya uygulamaları açısından önemlidir.

MATERYAL ve YÖNTEM

Bu çalışmada Hindistan'ın en yüksek rüzgâr hızına sahip şehirlerinden olan Jaisalmer, Kochi, Mangalore, Puri ve Rameswaram'ın 10 metre ve 100 metre yükseklikte ölçülen rüzgâr hızlarının tahmin edilmesi amaçlanmıştır. Veri seti olarak şehirlerin Ocak 2010 ile Şubat 2024 tarihleri arasındaki hava durumu verileri kullanılmıştır. Geliştirilen ConvLSTM modeli, RMSE, MAE ve R^2 metrikleri kullanılarak RF, SVM, ANFIS, CNN ve LSTM ile uygulamalı olarak karşılaştırılmıştır. ConvLSTM modelini değerlendirmek için karşılaştırılan

tekniklerin seçiminde farklı model yaklaşımlarını temsil etme, derin öğrenme modelleriyle karşılaştırma ve farklı yaklaşımların etkinliğini değerlendirmek amaçlanmıştır. Bu bölümde kullanılan veri seti, uygulanan tahmin modelleri ve geliştirilen ConvLSTM hakkında ayrıntılı bilgiler sunulmuştur.


Veri Seti

Kullanılan veri seti, Hindistan Meteoroloji Departmanı ve Hindistan Yenilenebilir Enerji Ajansı (IREDA) tarafından sağlanan rüzgâr hızına ilişkin kamuya açık veri tabanlarından elde edilmiştir. Bu veri seti, Jaisalmer, Kochi, Mangalore, Puri ve Rameswaram şehirlerine ait 01.01.2010 - 21.02.2024 tarihleri arasındaki saatlik rüzgâr hızlarını içermektedir. Veriler, her bir şehir için 10 metre ve 100 metre yükseklikte ölçülen değerleri kapsamakta olup, bu yükseklikler enerji, meteoroloji ve çevresel analizlerde referans yükseklikler olarak kullanılmaktadır. Veri setinin güncelliği, 2024 yılı Şubat ayına kadar uzanan ölçümleri içermesiyle sağlanmıştır. Veriler, ilgili kurumların kalibrasyonlu meteorolojik istasyonları tarafından düzenli olarak ölçülmüş ve kalite kontrol süreçlerinden geçirilmiştir. Özellikle eksik veya hatalı veri noktaları, interpolasyon ve veri temizleme yöntemleriyle düzenlenmiştir. Ayrıca, veri setinin doğruluğunu artırmak amacıyla ek istatistiksel kontroller yapılmıştır. Veriler, Hindistan Meteoroloji Departmanı tarafından kullanılan otomatik ölçüm cihazları ve anemometreler yardımıyla toplanmıştır. Ölçümler düzenli olarak her saat alınmış ve çevresel koşullara göre standart bir protokolle işlenmiştir. Ayrıca, veri işleme sürecinde Python ile veri görselleştirme ve analitik

işlemler yapılmış ve çalışmada kullanılan metodoloji detaylı şekilde açıklanmıştır.

Veri seti tarih, sıcaklık, nem, çiy noktası, yağmur ve kar yağış durumu, bulutluluk, rüzgâr hızı ve yüzey basıncı gibi iklim değişkenlerini içermektedir [28]. Kullanılan veri setindeki özellikler (sıcaklık, nem, çiy noktası, yağış durumu, bulutluluk, yüzey basıncı vb.), rüzgâr hızını etkileyen meteorolojik parametreler arasından seçilmiştir. Bu seçim, literatürdeki benzer çalışmalar ve rüzgâr hızı ile bu değişkenler arasındaki doğrusal olmayan ilişkilerin kanıtlanmış olması temel alınarak yapılmıştır. Örneğin, yüzey basıncı farkları ve sıcaklık değişimleri, rüzgâr hızını belirlemede kritik faktörlerdir. Bu özellikler modelimize zengin bir giriş sağlamış ve tahmin doğruluğunu artırmıştır.

Veri setinden, rüzgâr hızının 10 metre ve 100 metre yüksekliklerdeki ölçümlerinin değerleri seçilmiştir. 10 metre yüksekliği, meteorolojide yüzey rüzgâr hızlarını raporlamak için yaygın olarak kullanılan bir referans yüksekliğidir. Bu yükseklik, çoğu yüzey engelinin (binalar, ağaçlar vb.) üzerinde olduğundan, yer seviyesindeki koşulları daha doğru bir şekilde yansıtır. 10 metre yüksekliği hava tahminleri, tarım ve kentsel planlamada kullanılmaktadır. 100 metre yüksekliği, özellikle rüzgâr enerjisi bağlamında büyük önem taşır. Rüzgâr hızları genellikle daha yüksek ve daha tutarlı olduğu için rüzgâr türbinleri genellikle bu yükseklikte veya yakınında yerleştirilir. 100 metre yüksekliği rüzgâr çiftliği planlaması ve havacılıkta kullanılmaktadır [3]. Şekil 1'de, python programlama dili ve spyder yazılımı kullanılarak görselleştirilen Ocak 2010 ile Şubat 2024 arasında Jaisalmer, Kochi, Mangalore, Puri ve Rameswaram şehirlerindeki 10 metre yüksekliğindeki rüzgâr hızlarının zamana göre değişimi görülmektedir.



Şekil 1. 10 metre yüksekliğindeki rüzgâr hızlarının zamana göre değişimi

Şekil 1'de, şehirlerin 10 metre yüksekliğinde ölçülen rüzgâr hızlarının zaman içindeki değişimleri görülmektedir. Jaisalmer, yıl boyunca belirgin mevsimsel dalgalanmalara sahiptir. Bölgedeki sıcak ve kuru hava koşulları nedeniyle özellikle yaz aylarında rüzgâr hızlarında artış gözlemlenebilir. Genel olarak, yıllık ortalama rüzgâr hızlarının yüksek olduğu görülmektedir. 10 metre yüksekliğindeki rüzgâr hızlarının 15 yıllık ortalaması Jaisalmer için 14,87, Kochi için 7,02, Mangalore için 9,73, Puri için 13,70 ve Rameswaram için 24.46'dır. Kochi'de mevsimsel dalgalanmalar belirgin olup, özellikle muson sezonunda rüzgâr hızlarında artışlar görülmektedir. Yıllık ortalama rüzgâr hızları, Jaisalmer'e kıyasla daha düşüktür. Mangalore'de de mevsimsel dalgalanmalar görülmektedir. Özellikle muson dönemlerinde rüzgâr hızları artar. Mangalore'nin yıllık ortalama rüzgâr hızları, Kochi'ye benzer şekilde orta düzeydedir ve kıyı iklimi ile uyumludur. Puri'de, özellikle Bengal Körfezi'ne yakın olması nedeniyle, muson sezonunda rüzgâr hızlarında belirgin artışlar gözlemlenebilir.

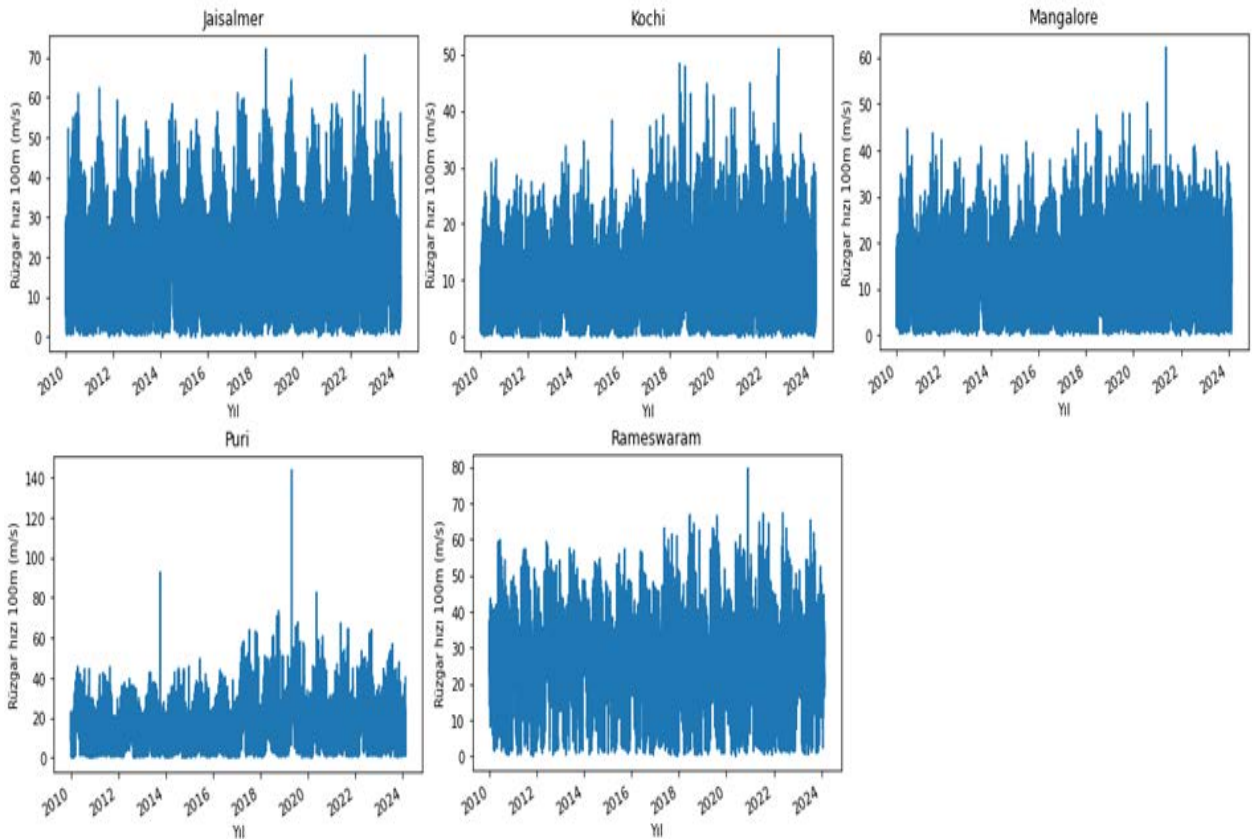
Rameswaram, yıl boyunca mevsimsel dalgalanmalar göstermektedir. Özellikle muson sezonunda rüzgâr hızlarında artışlar gözlenmektedir. Rameswaram'daki yıllık ortalama rüzgâr hızları genellikle orta düzeydedir ancak muson etkisiyle zaman zaman artış gösterebilir.

Şekil 2'de, python programlama dili ve spyder yazılımı kullanılarak görselleştirilen Ocak 2010 ile Şubat 2024 arasında Jaisalmer, Kochi, Mangalore, Puri ve

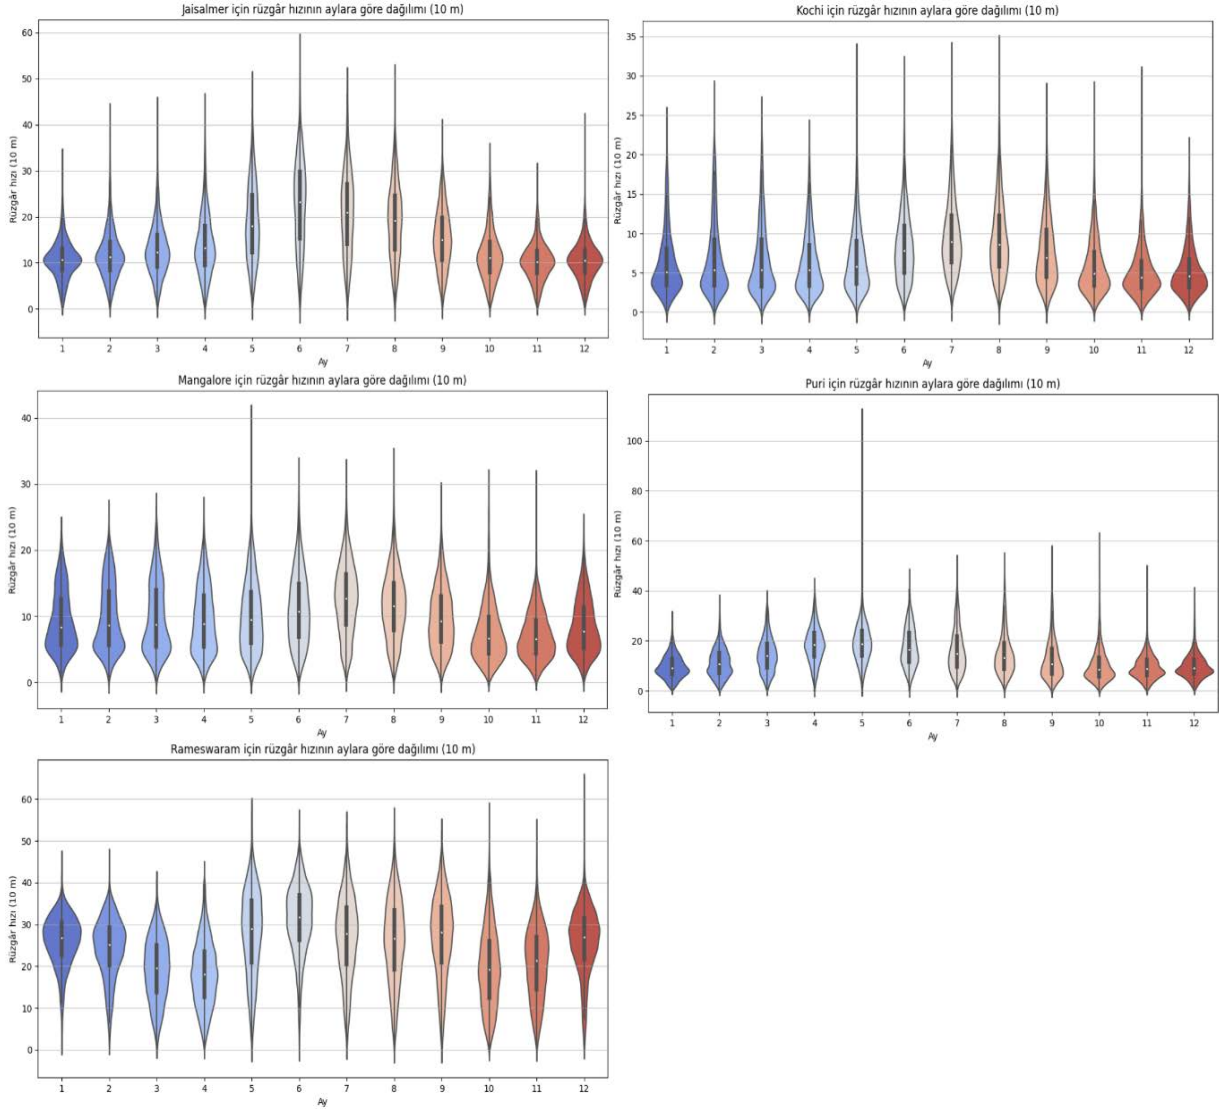
Rameswaram şehirlerindeki 100 metre yüksekliğindeki rüzgâr hızlarının zamana göre değişimi görülmektedir.

Şekil 2'de, şehirlerin 100 metre yüksekliğinde ölçülen rüzgâr hızlarının zaman içindeki değişimleri görülmektedir. Jaisalmer'de 100 metre yükseklikteki rüzgâr hızlarında belirgin mevsimsel dalgalanmalar gözlemlenebilir. Yıllık ortalama rüzgâr hızları oldukça yüksektir. 100 metre yüksekliğindeki rüzgâr hızlarının 15 yıllık ortalaması Jaisalmer için 20,90, Kochi için 10,68, Mangalore için 13,79, Puri için 18,94 ve Rameswaram için 27.52'dir. Jaisalmer'in çöl iklimi ve geniş açık alanları, bu yüksek hızların nedeni olarak görülebilir. Kochi'de mevsimsel rüzgâr hızları özellikle muson sezonunda artış göstermektedir. Kochi'nin yıllık ortalama rüzgâr hızları 100 metre yükseklikte daha düşüktür. Kıyı bölgesinde bulunan şehir, denizden gelen nemli hava akımları nedeniyle nispeten sabit ve orta hızda rüzgârlara sahiptir. Mangalore'de muson sezonunda rüzgâr hızlarında belirgin artışlar gözlemlenir. Puri'deki yıllık ortalama rüzgâr hızları muson ve siklon etkisiyle dalgalanabilir ve genellikle orta seviyelerde olabilir. Rameswaram'daki yıllık ortalama rüzgâr hızları 100 metre yükseklikte orta düzeydedir. Muson etkisiyle zaman zaman artışlar gözlenebilir.

Şekil 3'te şehirlerin 10 metre yüksekliğindeki rüzgâr hızlarının 15 yıllık periyot için aylık ortalamaları görülmektedir.



Şekil 2. 100 metre yüksekliğindeki rüzgâr hızlarının zamana göre değişimi



Şekil 3. Şehirlerin 10 metre yüksekliğindeki rüzgâr hızlarının aylara göre dağılımı

Şekil 4'te şehirlerin 100 metre yüksekliğindeki rüzgâr hızlarının 15 yıllık periyot için aylık ortalamaları görülmektedir.

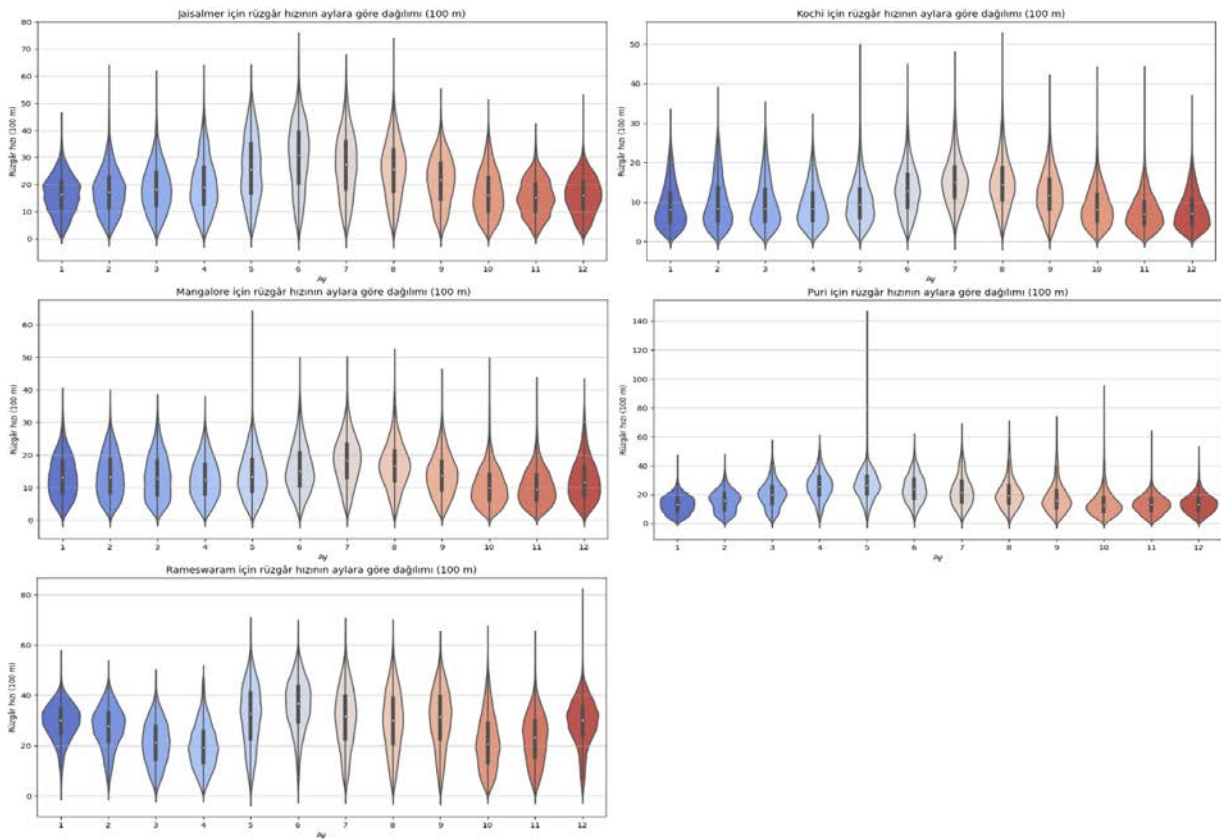
Şekil 3 ve Şekil 4'te görüldüğü gibi Jaisalmer'de kış aylarında, rüzgâr hızları genellikle düşüktür. Soğuk ve kuru hava hâkimdir. Bu dönemde rüzgâr hızları minimum seviyelerdedir. Sıcaklıkların artmasıyla rüzgâr hızları da yükselmektedir. Yaz aylarında rüzgâr hızları en yüksek seviyelere ulaşır. Bu dönem sıcak ve kuru hava koşullarının etkisindedir. Sonbaharda rüzgâr hızlarında düşüş görülmektedir. Eylül ayında yüksek olan rüzgâr hızları, Kasım ayına doğru azalmaktadır.

Kochi'de kış aylarında rüzgâr hızları genellikle düşüktür. Tropikal iklim etkisi ile rüzgâr hızları sabit ve hafiftir. Sıcaklıkların artmasıyla birlikte rüzgâr hızları da yavaş yavaş yükselmektedir. Yaz aylarında ve muson sezonunda rüzgâr hızlarında belirgin bir artış görülmektedir. Güneybatı musonlarının etkisiyle rüzgâr hızları en yüksek seviyelere ulaşmaktadır. Sonbaharda rüzgâr hızları düşmeye başlamaktadır.

Mangalore'da kışın rüzgâr hızları nispeten düşüktür. Tropikal iklimin etkisiyle rüzgâr hızları sabit kalmaktadır. Sıcaklıkların artmasıyla birlikte rüzgâr hızları da yükselmektedir. Yaz aylarında rüzgâr hızları artmaktadır. Sonbaharda rüzgâr hızları azalmaya başlamaktadır.

Puri'de kışın rüzgâr hızları nispeten düşüktür. Bengal Körfezi'nin etkisiyle rüzgâr hızları sabit kalmaktadır. İlkbaharda rüzgâr hızlarında artış gözlemlenmektedir. Sıcaklıkların artmasıyla rüzgâr hızları da yükselmektedir. Bengal Körfezi'nden gelen rüzgârların etkisiyle rüzgâr hızları en yüksek seviyelere ulaşmaktadır. Sonbaharda rüzgâr hızları azalmaya başlamaktadır.

Rameswaram'da kışın rüzgâr hızları genellikle düşüktür. Tropikal iklim etkisi ile rüzgâr hızları sabit ve hafiftir. İlkbaharda rüzgâr hızlarında artış gözlemlenmektedir. Yazın ve muson sezonunda rüzgâr hızlarında belirgin bir artış görülmektedir. Musonların etkisiyle rüzgâr hızları en yüksek seviyelere ulaşmaktadır. Sonbaharda rüzgâr hızları düşmeye başlamaktadır.



Şekil 4. Şehirlerin 100 metre yüksekliğindeki rüzgâr hızlarının aylara göre dağılımı

Tahmin Modelleri

RF bir topluluk öğrenme yaklaşımıdır. Rastgele öznitelik seçimine dayalı olarak oluşturulan ayrı bir sonlu grup karar ağacı tasarlamayı amaçlamaktadır. RF'ler, eğitimdeki farklılıklar nedeniyle güçlü genelleme kapasitelerine sahiptir ve ormandaki farklı karar ağaçlarını oluşturmak için kullanılan çift alt kümelerle sahiptir. Ancak sağlam ve etkili bir RF oluşturmak için karar ağaçlarının doğruluğunun ve çeşitliliğinin artırılması ile karar ağaçlarının sayısının azaltılması konularına dikkat edilmesi gerekmektedir [29].

Denetimli öğrenme algoritmalarından biri olan SVM, regresyon ve sınıflandırma sorunları için tasarlanmıştır. SVM'nin temel amacı, verileri en iyi şekilde ayıran hiper düzlemi bulmaktır. Bu hiper düzlem, farklı sınıflardaki veriler arasındaki en büyük marjini sağlar. Marjin, hiper düzlem ile en yakın veri noktaları arasındaki mesafeyi ifade eder. SVM algoritmasının, zaman serileri analizi, yüzlerin tespiti, bazı görüntülerin sınıflandırılması, metinlerin sınıflandırılması gibi uygulama alanlarında kullanılmaktadır [30].

CNN çok boyutlu girdilerin işlenmesinde kullanılan bir sinir ağıdır. Görüntü tanıma ve bilgisayarlı görmede kullanılan önemli araçlardan biri haline gelmiştir [31]. Geliştirilmelerinin nedeni 2 boyutlu görüntü verilerini tespit etmek olsa da tek değişkenli zaman serilerinin analizinde de etkin bir şekilde kullanılmaktadırlar.

Konvolüsyon, havuzlama ve tam bağlantılı katmanlar kullanılarak CNN oluşturulur [32].


LSTM bir tür tekrarlı sinir ağı modelidir. LSTM mimarisi, uzun vadeli bağımlılıkları sıralı bir şekilde öğrenebilen bellek hücreleri içerir [33]. LSTM ayrıca uzun vadeli bağımlılıklara sahip verileri analiz etmek ve anlamak için de kullanılır. Genellikle hava durumu tahminleri ve borsa fiyatları gibi zaman serisi verilerini analiz etmek için kullanılır [34].

ANFIS, bulanık sistemlerden öğrenebilmekte ve yapay sinir ağlarının geri yayılımı yoluyla sonuçlar çıkarabilmektedir. Öğrenme kuralları olarak da bilinen eğitim kuralları bu amaçla kullanılır. Özellikle basit sınıflandırma sorunlarının çözümünde faydalıdır. Bu sayede girdi vektörleri ile etkili bir şekilde geliştirilebilirler. Girdi ve çıktı arasındaki doğrusal olmayan ilişkiyi kavrayabilir, sorunları hızlı ve güvenilir bir şekilde çözebilirler. ANFIS'in temel özelliği, bilgiyi nöronlar arasındaki etkileşimlere dayalı olarak işlemeleridir [35].

Geliştirilen ConvLSTM Hibrit Modeli

Bu çalışmada kullanılan veri seti, saatlik olarak rüzgâr hızlarından oluşan bir zaman serisi veri setidir. Zaman serisi verilerinin, denetimli öğrenme modelleri tarafından işlenebilmesi için verilerin regresyon problemi yapısına dönüştürülmesi gereklidir. Bu amaçla Şekil 5'te

görüldüğü gibi kayan pencere kullanılarak zaman serisi verileri regresyon problemi yapısına dönüştürülmüştür.



Şekil 5. Kayan pencere yöntemi

Şekil 5'te örnek olarak boyutu 3 olan bir kayan pencerede görülmektedir. $t-3$, $t-2$ ve $t-1$ zamanındaki veriler kayan pencereye girdi olarak sunulmakta, t zamanındaki veri ise çıktı olarak alınmaktadır. Kayan pencere boyutunu belirlemek için yapılan deneyler, 9 boyutunda bir pencere için en düşük hata değerlerine ulaşıldığını göstermiştir. Tablo 1'de örnek olarak Jaisalmer için 10 metre yükseklikte ölçülen rüzgâr hızının tahmini için kayan pencere boyutunun belirlenmesine yönelik deneysel çalışmanın sonuçları sunulmuştur.

Tablo 2. Kayan pencere yöntemi

Pencere	RMSE	MAE	R ²
5	2.71	1.82	0.91
7	2.54	1.74	0.93
9	2.49	1.66	0.95
11	2.52	1.68	0.94

Tablo 2. Kayan pencere yöntemi

1.gözlem verisi	2.gözlem verisi	3.gözlem verisi	4.gözlem verisi	5.gözlem verisi	6.gözlem verisi	7.gözlem verisi	8.gözlem verisi	9.gözlem verisi	Çıktı verisi
7,20	6,98	6,69	6,69	5,35	6,13	6,98	6,92	6,48	5,44
6,98	6,69	6,69	5,35	6,13	6,98	6,92	6,48	5,44	5,09
6,69	6,69	5,35	6,13	6,98	6,92	6,48	5,44	5,09	6,83
6,69	5,35	6,13	6,98	6,92	6,48	5,44	5,09	6,83	7,62
5,35	6,13	6,98	6,92	6,48	5,44	5,09	6,83	7,62	8,89

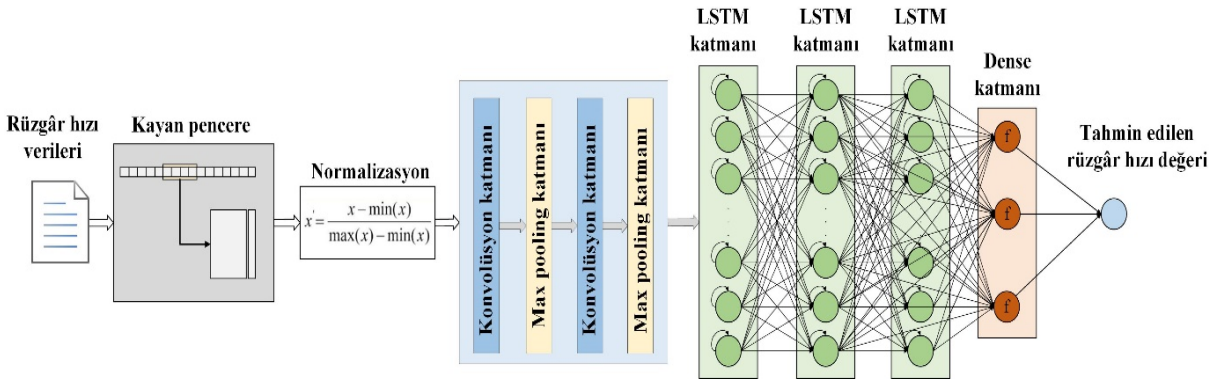
Regresyon problemi formatına dönüştürülen veri seti, min-max scaler kullanılarak ölçeklendirilmiştir. Veri setinin %33'ü test ve %67'si ise eğitim için kullanılmıştır. Bu oranlar yapılan deneysel çalışmalar neticesinde en düşük hata oranları elde edildiği için belirlenmiştir. Eğitim verilerinin %10'u ise model hiper-

Belirlenen 9 boyutundaki kayan pencere ilk 9 gözlem verisi girdi olarak sunulmuş ve 10. adımdaki gözlem verisi çıktı olacak şekilde denetimli öğrenme problemi yapısına dönüştürülmüştür. Her bir adımda kayan pencere bir gözlem adımı sağa kaydırılarak tüm gözlem verilerinin işlenmesi sağlanmıştır. Bu yöntem, geçmiş dokuz saati giriş olarak alıp onuncu saat için tahmin yapmayı sağlamaktadır. Kayan pencere boyutunun dokuz olarak belirlenmesi, yapılan deneylerde en düşük hata oranlarının elde edilmesini sağlamıştır. Ayrıca, veriler ölçeklendirme işlemi için Min-Max Scaler kullanılarak 0 ile 1 arasına normalize edilmiştir. Eğitim verilerinin %10'u, Grid Search yöntemi ile hiperparametre optimizasyonu için ayrılmıştır. Bu süreçler, modelin doğruluğunu artırmada kritik bir rol oynamıştır. Yapılan ön işleme adımları, ConvLSTM modelinin hem mekânsal hem de zamansal bağımlılıkları etkili bir şekilde öğrenmesini sağlamıştır. Özellikle, normalize edilen girişlerin ve kayan pencere yönteminin uygulanması, zaman serisi dinamiklerini daha hassas bir şekilde modellemeye olanak tanımıştır.

Tablo 2'de Jaisalmer şehrinin 10m rüzgâr hızı parametresi için kayan pencere yöntemine girdi olarak sunulan ve çıktı olarak elde edilecek olan gerçek değerler görülmektedir. Kullanılan veri seti 2010-01-01 00:00:00 tarih ve saatinden başlayarak 1 saat aralıklarla elde edilen ölçüm değerlerini göstermektedir. 1. Gözlem verisi 2010-01-01 00:00:00 tarih ve saatindeki rüzgâr hızını, 2. gözlem verisi ise 2010-01-01 01:00:00 tarih ve saatindeki rüzgâr hızını göstermektedir. 9. gözlem verisi 2010-01-01 08:00:00 tarih ve saatindeki rüzgâr hızını ve çıktı ise 2010-01-01 09:00:00 tarih ve saatindeki rüzgâr hızını göstermektedir.

parametrelerinin grid arama ile optimize edilmesi amacıyla kullanılmıştır.

ConvLSTM modeli, mekânsal ve zamansal verileri işlemek için CNN ve LSTM'in öne çıkan özelliklerini birleştiren hibrit bir modeldir. Geliştirilen ConvLSTM modelinin yapısı Şekil 6'da görülmektedir.



Şekil 6. Geliştirilen ConvLSTM modelinin mimarisi

Şekil 6’da görüldüğü gibi ConvLSTM giriş katmanı, konvolüsyon katmanları, pooling katmanları, LSTM katmanları, dense katmanı ve çıktı katmanından oluşmaktadır. Konvolüsyon katmanları, giriş verisinden mekânsal özelliklerin çıkarılmasını sağlamaktadır. Çıkarılan özellik haritalarına ReLU aktivasyon fonksiyonu uygulanmaktadır. Max pooling katmanları, özellik haritalarının boyutlarını azaltmak için kullanılmaktadır. LSTM katmanları, verideki zamana bağımlı uzun ve kısa vadeli bağımlılıkların belirlenmesini sağlamaktadır. LSTM katmanlarından elde edilen çıktılar dense katmanına gönderilmektedir ve nihai çıktı elde edilmektedir. ConvLSTM’de CNN katmanları, rüzgâr hızı verilerinin mekânsal özelliklerinin çıkarılmasından sorumludur. Çıkarılan özellikler, verinin zamansal dinamiklerini belirlemek için LSTM’e iletilmektedir. Bu sayede, ConvLSTM hem mekânsal hem de zamansal bağımlılıkları öğrenmektedir. ConvLSTM, CNN ve LSTM’nin etkili yönlerini birleştirerek daha yüksek bir tahmin doğruluğu sağlamaktadır. ConvLSTM’in hiper-parametreleri grid arama kullanılarak belirlenmiştir. Konvolüsyon katmanları, çekirdek boyutu 1 ve 64 filtreden oluşan 1D katmanlardır. Havuzlama katmanlarının çekirdek boyutu 1 ve havuzlama boyutu 2’dir. Ayrıca, her biri 64 nöron içeren 3 LSTM katmanı bulunmaktadır. LSTM’in epoch sayısı 100, batch size’ı 8, aktivasyon fonksiyonu ReLU, optimizier’i Adam ve kayıp fonksiyonu RMSE’dir.

ConvLSTM modelinde CNN katmanları, verinin mekânsal özelliklerini öğrenmek için kullanılır. Rüzgâr hızı gibi coğrafi verilerde mekânsal bağımlılıklar, özellikle farklı şehirlerin ve çevresel koşulların etkilerini anlamada kritik öneme sahiptir. Örneğin, bir şehirdeki rüzgâr hızı, o bölgedeki coğrafi faktörlere (dağlık alanlar, denize yakınlık, vb.) bağlı olarak değişir. CNN katmanları, bu tür mekânsal ilişkileri tespit edip öğrenerek, rüzgâr hızı tahminlerinde daha doğru sonuçlar elde edilmesini sağlar. LSTM katmanları, zaman serisi verilerindeki uzun vadeli bağımlılıkları öğrenir. Rüzgâr hızı gibi değişkenler, zaman içinde belli örüntüler gösterir ve geçmiş değerler, gelecekteki değerler üzerinde önemli bir etkiye sahiptir. LSTM, bu geçmiş bilgilere dayanarak, gelecekteki rüzgâr hızı tahminlerini yaparken, uzun vadeli bağımlılıkları etkili bir şekilde modelleyebilir. Bu, ConvLSTM modelinin zaman

indeki değişimlerin doğru şekilde yakalanmasına ve rüzgâr hızı tahminlerinin daha hassas olmasına olanak tanır.


Mekânsal ve zamansal bağımlılıkların birleştirilmesi, modelin doğruluğunu artırır çünkü geleneksel modeller sadece bir tür bağımlılığı (ya mekânsal ya da zamansal) öğrenebilirken, ConvLSTM her ikisini de aynı anda işleyerek daha derin ve kapsamlı bir öğrenme sağlar. Bu, rüzgâr hızı gibi dinamik ve karmaşık verilerin daha güvenilir ve doğru bir şekilde tahmin edilmesini mümkün kılar.

DENEYSEL SONUÇLAR

Bu çalışmada, Jaisalmer, Kochi, Mangalore, Puri ve Rameswaram’ın 10 metre ve 100 metre yükseklikte ölçülen rüzgâr hızlarının tahmin edilmesi amaçlanmıştır. Geliştirilen ConvLSTM modeli RF, SVM, ANFIS, CNN ve LSTM ile uygulamalı bir şekilde karşılaştırılmıştır. Tablo 3 ve Şekil 7’de Jaisalmer için deneysel sonuçlar görülmektedir. Tablo 3 ve Şekil 7’de görüldüğü gibi ConvLSTM 10 metre yükseklikte ölçülen rüzgâr hızının tahmininde 0,95 R², 100 metre yükseklikte ölçülen rüzgâr hızının tahmininde ise 0,95 R² ile karşılaştırılan modellerden daha başarılı olmuştur. ConvLSTM’in ardından sırasıyla LSTM, ANFIS, CNN, SVM ve RF başarılı olmuştur.

Tablo 3. Jaisalmer için deneysel sonuçlar

Model	Rüzgâr hızı 10 m			Rüzgâr hızı 100 m		
	RMS	MA	R ²	RMS	MA	R ²
RF	2,88	1,86	0,8	3,99	2,48	0,8
			5			5
SVM	2,85	1,87	0,8	3,87	2,51	0,8
			5			6
ANFIS	2,58	1,69	0,9	3,50	2,23	0,9
			4			4
CNN	2,70	1,80	0,8	3,67	2,36	0,8
			7			7
LSTM	2,56	1,69	0,9	3,48	2,23	0,9
			4			4
ConvLSTM	2,49	1,66	0,9	3,36	2,21	0,9
			5			5




Şekil 7. Jaisalmer için deneysel sonuçlar

Tablo 4 ve Şekil 8’de görüldüğü gibi ConvLSTM 10 metre yükseklikte ölçülen rüzgâr hızının tahmininde $0,90 R^2$, 100 metre yükseklikte ölçülen rüzgâr hızının

tahmininde ise $0,87 R^2$ ile karşılaştırılan modellerden daha başarılı olmuştur. ConvLSTM’in ardından sırasıyla LSTM, ANFIS, CNN, SVM ve RF başarılı olmuştur.

Tablo 4. Kochi şehri için deneysel sonuçlar

Model	Rüzgâr hızı 10 m			Rüzgâr hızı 100 m		
	RMSE	MAE	R^2	RMSE	MAE	R^2
RF	2,59	1,94	0,75	3,66	2,74	0,72
SVM	2,50	1,88	0,78	3,57	2,69	0,74
ANFIS	2,46	1,85	0,85	3,40	2,55	0,85
CNN	2,48	1,86	0,81	3,49	2,65	0,78
LSTM	1,46	1,84	0,85	3,48	2,64	0,85
ConvLSTM	1,25	1,71	0,90	3,38	2,58	0,87




Şekil 8. Kochi şehri için deneysel sonuçlar

Tablo 5 ve Şekil 9’da Mangalore için deneysel sonuçlar görülmektedir. Tablo 5 ve Şekil 9’da görüldüğü gibi ConvLSTM 10 metre yükseklikte ölçülen rüzgâr hızının tahmininde 0,88 R^2 , 100 metre yükseklikte ölçülen

rüzgâr hızının tahmininde ise 0,88 R^2 ile karşılaştırılan modellerden daha başarılı olmuştur. ConvLSTM’in ardından sırasıyla LSTM, ANFIS, CNN, SVM ve RF başarılı olmuştur

Tablo 5. Mangalore için deneysel sonuçlar

Model	Rüzgâr hızı 10 m			Rüzgâr hızı 100 m		
	RMSE	MAE	R^2	RMSE	MAE	R^2
RF	2,85	1,97	0,80	3,92	2,80	0,77
SVM	2,75	1,93	0,82	3,83	2,77	0,79
ANFIS	2,56	1,86	0,86	3,67	2,69	0,86
CNN	2,63	1,89	0,84	3,73	2,74	0,80
LSTM	2,54	1,85	0,86	2,66	2,65	0,86
ConvLSTM	2,41	1,80	0,88	2,44	2,31	0,88




Şekil 9. Mangalore şehri için deneysel sonuçlar

Tablo 6 ve Şekil 10’da görüldüğü gibi ConvLSTM 10 metre yükseklikte ölçülen rüzgâr hızının tahmininde 0,96 R^2 , 100 metre yükseklikte ölçülen rüzgâr hızının

tahmininde ise 0,97 R^2 ile karşılaştırılan modellerden daha başarılı olmuştur. ConvLSTM’in ardından sırasıyla LSTM, ANFIS, CNN, SVM ve RF başarılı olmuştur.

Tablo 6. Puri şehri için deneysel sonuçlar

Model	Rüzgâr hızı 10 m			Rüzgâr hızı 100 m		
	RMSE	MAE	R^2	RMSE	MAE	R^2
RF	2,75	1,88	0,83	3,51	2,42	0,85
SVM	2,70	1,89	0,84	3,46	2,45	0,85
ANFIS	2,40	1,67	0,95	3,02	2,08	0,95
CNN	2,58	1,81	0,85	3,35	2,36	0,86
LSTM	2,39	1,66	0,95	3,33	2,07	0,96
ConvLSTM	2,28	1,58	0,96	3,15	1,99	0,97



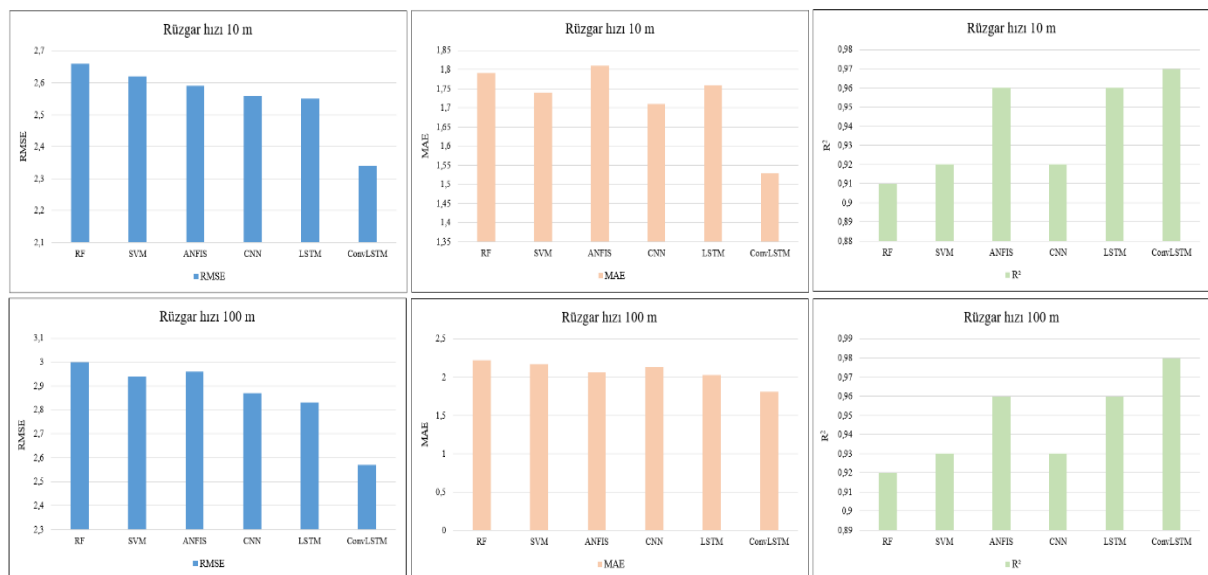
Şekil 10. Puri şehri için deneysel sonuçlar

Tablo 7 ve Şekil 11’de görüldüğü gibi ConvLSTM 10 metre yükseklikte ölçülen rüzgâr hızının tahmininde 0,97 R², 100 metre yükseklikte ölçülen rüzgâr hızının tahmininde ise 0,98 R² ile karşılaştırılan

modellerden daha başarılı olmuştur. ConvLSTM’in ardından sırasıyla LSTM, ANFIS, CNN, SVM ve RF başarılı olmuştur.

Tablo 7. Rameswaram için deneysel sonuçlar

Model	Rüzgâr hızı 10 m			Rüzgâr hızı 100 m		
	RMSE	MAE	R ²	RMSE	MAE	R ²
RF	2,66	1,79	0,91	3,00	2,22	0,92
SVM	2,62	1,74	0,92	2,94	2,17	0,93
ANFIS	2,59	1,81	0,96	2,96	2,06	0,96
CNN	2,56	1,71	0,92	2,87	2,13	0,93
LSTM	2,55	1,76	0,96	2,83	2,03	0,96
ConvLSTM	2,34	1,53	0,97	2,57	1,81	0,98



Şekil 11. Rameswaram için deneysel sonuçlar

ConvLSTM modeli RF, SVM, ANFIS, CNN ve LSTM ile kapsamlı bir şekilde karşılaştırılmıştır. Deneysel sonuçlar, ConvLSTM'in hem mekânsal hem de zamansal bağımlılıkları aynı anda işleyebilme yeteneği sayesinde diğer yöntemlerden üstün olduğunu göstermiştir. Özellikle, Jaisalmer ve Rameswaram şehirlerinde elde edilen 0,97 ve 0,98 gibi yüksek R² değerleri, diğer modellerin üzerinde bir başarı sunmaktadır. Ayrıca ConvLSTM, RMSE ve MAE değerlerinde en düşük hata oranlarına ulaşarak rüzgâr hızı tahmininde daha doğru ve güvenilir sonuçlar üretmiştir.

Deneysel sonuçlar, ConvLSTM'in ANFIS, LSTM, CNN, RF, SVM'den daha başarılı olduğunu göstermiştir. ConvLSTM, karşılaştırılan modellerin yetersiz kaldığı mekânsal ve zamansal bağımlılıkları birlikte işleyerek tahmin doğruluğunu artırır. Mekânsal ve zamansal verilerin dinamiklerini aynı anda işleyebilme kapasitesi, rüzgâr hızı gibi karmaşık değişkenlerin tahmininde etkinliği sağlar. ConvLSTM'in ANFIS'ten daha başarılı olması, ANFIS'in mekânsal ve zamansal verileri işleme yeteneğinin sınırlı olmasıyla açıklanabilir. ANFIS'in etkinliği yüksek boyuttaki karmaşık veri setlerinde sınırlıdır. ConvLSTM'in LSTM'den daha başarılı olması, ConvLSTM'in LSTM bileşeni yanında sahip olduğu CNN bileşenin etkisiyle yorumlanabilir. ConvLSTM bu sayede mekânsal ve zamansal verilerin dinamiklerini aynı anda yakalayarak daha doğru ve kapsamlı tahminler yapar. ConvLSTM'in CNN'den daha başarılı olması, ConvLSTM'in CNN'e ek olarak LSTM'nin zamansal bağımlılıkları öğrenme kapasitesini kullanması ile açıklanabilir. ConvLSTM'in RF ve SVM'den daha başarılı olması, ConvLSTM'in karmaşık örüntüleri daha iyi öğrenmesi ve modellenmesiyle açıklanabilir. RF ve SVM zaman serisi analizinde yeterince etkin değildir. ConvLSTM ve LSTM için t-istatistiği, p-değeri ve güven aralıkları her bir metrik için hesaplanarak Tablo 8'de sunulmuştur.

Tablo 8. ConvLSTM ve LSTM için t-istatistiği, p-değeri ve güven aralıkları

Test	RMSE	MAE	R ²
t-istatistiği	-5.24	-2.91	-2.58
p-değeri	0.0063	0.0436	0.0412
LSTM güven aralığı	(1.71, 2.89)	(1.65, 1.87)	(1.85, 1.98)
ConvLSTM Güven Aralığı	(1.52, 2.79)	(1.52, 1.79)	(1.88, 1.98)

Tablo 8'de görüldüğü gibi RMSE, MAE ve R² metrikleri açısından elde edilen sonuçlar, ConvLSTM ve LSTM modelleri arasındaki farkın istatistiksel olarak anlamlı olduğunu göstermektedir (p < 0.05).

TARTIŞMA

RF ve SVM modelleri, sınırlı mekânsal ve zamansal bağlamda statik özellikler arasında doğrudan ilişkiler kurar. Bu, zaman serisi verilerindeki dinamik değişimleri anlamada yetersiz kalmalarına neden olur. ConvLSTM ise mekânsal ve zamansal bağımlılıkları aynı anda

öğrenerek bu sınırlamayı aşar. ANFIS, bulanık mantık tabanlı çıkarımlar yapabilir ancak yüksek boyutlu, karmaşık zaman serisi verilerinde mekânsal veya zamansal özellikleri yeterince modelleyemez. ConvLSTM'in CNN ve LSTM bileşenleri, bu eksiklikleri tamamlamaktadır. CNN, mekânsal bağımlılıkları öğrenmede başarılıdır; LSTM ise zaman serisi verilerindeki uzun vadeli bağımlılıkları yakalamakta etkilidir. Ancak bu modeller, tek başına her iki bağımlılığı aynı anda işleyemez. ConvLSTM, bu iki yaklaşımı birleştirerek karmaşık ve dinamik verilerde daha yüksek doğruluk ve daha düşük hata oranları sunar. ConvLSTM'in CNN katmanları, rüzgâr hızına etki eden mekânsal özellikleri (örneğin coğrafi farklılıklar, yerel hava olayları) başarıyla öğrenir. LSTM katmanları, zaman serisi verilerindeki uzun vadeli değişimleri etkili bir şekilde modeller. ConvLSTM, bu iki yaklaşımı hibritleştirerek karmaşık verilerde daha kapsamlı bir modelleme sunar. Bu hibrit yapı sayesinde, düşük RMSE ve MAE değerleri ile yüksek R² performansına ulaşmıştır.

ConvLSTM'in sınırlılıkları veriye olan bağımlılık, verilerdeki karmaşıklık, donanım kapasitesi ve modelin genelleme kapasitesi açıklarından incelenebilir. ConvLSTM, büyük ve temiz veri setleriyle iyi performans gösterse de, veri kalitesi ve eksiklikleri modelin doğruluğunu etkileyebilir. Eksik veriler veya hatalı ölçümler, modelin tahminlerini olumsuz yönde etkileyebilir. Model, yüksek düzeyde gürültü içeren verilerde aşırı uyum yapabilir, bu da genel performansın düşmesine yol açabilir. Eğitim süresi ve kaynak tüketimi, büyük veri kümeleriyle çalışırken önemli bir zorluk oluşturabilir. Derin öğrenme modelleri, bazen genelleme yapma konusunda zorluk yaşayabilir ve belirli koşullarda aşırı uyum (overfitting) riski taşır. ConvLSTM, özellikle belirli şehirlerde veya spesifik iklim koşullarında eğitildiğinde, farklı coğrafi bölgelerdeki veriler üzerinde düşük performans gösterebilir. ConvLSTM modelinin hiperparametrelerinin yanlış seçilmesi, modelin başarısını olumsuz etkileyebilir.

SONUÇ

Rüzgâr hızı tahmini, güvenliği ve verimliliği sağlama açısından birçok uygulama alanında kritik öneme sahiptir. Rüzgâr hızı tahmini lojistik, tarım, nakliye, enerji üretimi, afet yönetimi ve çevresel izleme uygulamalarında faydaları maksimize ederek toplumsal ve ekonomik hayatın birçok yönünü olumlu yönde etkiler. Doğru tahminler, enerji verimliliğini artırmak, güvenliği sağlamak, ekonomik faydalar sunmak ve çevresel yönetimi iyileştirmek açısından kritik rol oynar. Örneğin, enerji sektöründe rüzgâr türbinlerinin en uygun performansını sağlamak, havacılıkta güvenli uçuşlar düzenlemek veya tarımda ürünleri korumak için rüzgâr hızının doğru bir şekilde tahmin edilmesi gereklidir. Yapay zekâ yöntemleri, rüzgâr hızının dinamiklerini etkili bir şekilde belirleyerek, tahminlerin doğruluğunu artırır. Yapay zekâ yöntemleri, verilerdeki karmaşık örüntüleri öğrenir ve geleneksel yöntemlere göre daha başarılı tahminler üretir. Bu sayede enerji üretiminden

afet yönetimine kadar geniş bir yelpazede toplumsal ve ekonomik hayatın birçok yönünü olumlu yönde etkileyerek verimliliği artırır ve riskleri azaltır.

Bu çalışmada, Hindistan'ın en yüksek rüzgâr hızına sahip şehirlerinden olan Jaisalmer, Kochi, Mangalore, Puri ve Rameswaram şehirlerinin rüzgâr hızlarının tahmin etmek amacıyla hibrit ConvLSTM modeli geliştirilmiştir. ConvLSTM, CNN ve LSTM'in etkin özelliklerini bir araya getirerek mekansal ve zamansal verileri işleyebilme yeteneğine sahiptir. CNN girdi verilerinden özellik çıkarmak için LSTM ise zaman serisi verilerindeki uzun vadeli bağımlılıkların modellenmesi için kullanılmıştır. Şehirlerin saatlik olarak tutulan, 10 metre ve 100 metre yüksekliklerdeki rüzgâr hızı ölçümlerinden oluşan yaklaşık 15 yıllık bir veri seti kullanılmıştır. ConvLSTM, RF, SVM, ANFIS, CNN ve LSTM ile uygulamalı olarak karşılaştırılmıştır. Deneysel sonuçlar, ConvLSTM'in her bir şehir ve rüzgâr hızı parametresinin neredeyse tamamında 0,9'un üzerinde R² değerine sahip olduğunu ve karşılaştırılan modellerden daha başarılı olduğunu göstermiştir.

ConvLSTM, zaman serisi verilerindeki uzun vadeli bağımlılıkları öğrenme kapasitesini CNN'in mekansal özellik çıkarma yeteneği ile birleştirerek, karmaşık ve dinamik verilerin tahmininde önemli avantajlar sunar. ConvLSTM'in bu başarısı, rüzgâr hızı gibi karmaşık ve çok boyutlu verilerin tahmininde de potansiyelini ortaya koymaktadır.

ConvLSTM'in mekansal ve zamansal bağımlılıkları birlikte işleyebilme kapasitesi, literatürde benzer çalışmalarda da kullanılmıştır. Ancak literatürde aynı veri setini ve tarih aralıklarını kullanarak yapılmış bir çalışma yoktur. ConvLSTM, CNN ve LSTM bileşenleri sayesinde, literatürdeki çalışmalarda da görüldüğü gibi mekansal ve zamansal özelliklerin etkili bir şekilde işlenmesini sağlamıştır. Elde edilen sonuçlar, bu çalışmadaki bulgularla tutarlıdır. Elde edilen yüksek R² değerleri, ConvLSTM'in karmaşık ve dinamik rüzgâr hızı verilerini etkili bir şekilde tahmin etme kapasitesini desteklemektedir. Bu sonuçlar, ConvLSTM'in zaman serisi ve mekansal veri tahminlerinde literatürdeki diğer derin öğrenme yöntemleriyle karşılaştırıldığında nasıl bir avantaja sahip olduğunu ortaya koymaktadır. Geliştirilen model yenilenebilir enerji, tarım, afet yönetimi, ulaşım ve kentleşme gibi potansiyel uygulama alanlarına sahiptir. Çalışmada geliştirilen ConvLSTM modelinin rüzgâr hızı tahmini, özellikle rüzgâr türbinlerinin verimliliğini artırmak için önemli bir araç olabilir. Doğru rüzgâr hızı tahminleri, rüzgâr santrallerinin daha etkin bir şekilde işletilmesini sağlar, enerji üretiminin optimize edilmesine yardımcı olur ve böylece enerji maliyetlerini düşürür. Ayrıca, rüzgâr enerjisinin şebekeye entegrasyonu için güvenilir tahminler sağlanabilir. Rüzgâr hızı tahminlerinin tarım sektöründe, özellikle açık hava tarımı ve sulama sistemlerinin yönetilmesinde kritik bir rolü vardır. Bu tür tahminler, mahsullerin rüzgârın etkisiyle zarar görmemesi için tarımsal planlamayı iyileştirebilir ve aynı zamanda sulama sistemlerinin daha verimli çalışmasını sağlayabilir. Rüzgâr hızı tahminleri, doğal afetler (örneğin, fırtına ve kasırga tahminleri) konusunda erken uyarı sistemlerinin

geliştirilmesinde de kullanılabilir. Rüzgâr hızı değişimlerini tahmin etmek, uçuş rotalarının ve deniz yollarının daha güvenli bir şekilde planlanmasına yardımcı olabilir. Yapıların rüzgâr yüklerini karşılayabilmesi için bu tür tahminler inşaat mühendisliği alanında karar verme süreçlerine dâhil edilebilir.

Gelecek çalışmalarda, veri kaynaklarının artırılması ve daha geniş bir coğrafi kapsama alanına sahip verilerin eklenmesi, modelin genelleme kapasitesini artırabilir. Özellikle farklı iklim bölgelerinden ve farklı yüksekliklerden alınan ölçümlerle modelin performansı daha kapsamlı bir şekilde değerlendirilebilir. ConvLSTM'in CNN ve LSTM bileşenlerinden oluşan hibrit yapısı oldukça etkili olsa da, dikkat mekanizmaları (attention mechanisms) veya Transformer tabanlı modeller gibi modern yaklaşımlar ile zenginleştirilmesi, tahmin doğruluğunu artırabilir.

KAYNAKÇA

- [1] Jaseena K.U., Koor B.C., Deterministic weather forecasting models based on intelligent predictors: A survey, *Journal of King Saud University-Computer and Information Sciences*. 34(6): 3393-3412, 2022.
- [2] Xu M., Yu L., Liang K., Vihma T., Bozkurt D., Hu X., Yang Q., Dominant role of vertical air flows in the unprecedented warming on the Antarctic Peninsula in February 2020, *Communications Earth and Environment*. 2(1), 2021.
- [3] Van Haaren R., Fthenakis V.. GIS-based wind farm site selection using spatial multi-criteria analysis (SMCA): Evaluating the case for New York State, *Renewable and sustainable energy reviews*. 15(7): 3332-3340, 2011.
- [4] Jing H., Li W., Su Y., Zhao W., Zhang J., Qiao M., Liu Q., Numerical study of wind characteristics at a long-span bridge site in mountain valley, *Physics of Fluids*. 36(3), 2024.
- [5] Young I.R., Kirezci E., Ribal A., The global wind resource observed by scatterometer, *Remote Sensing*. 12(18), 2020.
- [6] Amini M., Memari A.M., Review of literature on performance of coastal residential buildings under hurricane conditions and lessons learned, *Journal of performance of constructed facilities*. 34(6), 2020.
- [7] Ma L., Bocchini P., Christou V., Fragility models of electrical conductors in power transmission networks subjected to hurricanes, *Structural Safety*. 82, 2020.
- [8] Sibanda S., Workneh T.S., Potential causes of postharvest losses, low-cost cooling technology for fresh produce farmers in Sub-Saharan Africa, *African Journal of Agricultural Research*. 16(5): 553-566, 2020.
- [9] Brune S., Keller J.D., Wahl S., Evaluation of wind speed estimates in reanalyses for wind energy applications, *Advances in Science and Research*. 18: 115-126, 2021.
- [10] Gliksmann D., Averbeck P., Becker N., Gardiner B., Goldberg V., Grieger J., Franzke C.L., Wind and storm damage: From Meteorology to Impacts, *Natural Hazards and Earth System Sciences Discussions*. 1-47, 2022.
- [11] Neo E.X., Hasikin K., Lai K.W., Mokhtar M.I., Azizan M.M., Hizaddin H.F., Razak S.A., Artificial intelligence-assisted air quality monitoring for smart city management, *PeerJ Computer Science*. 9, 2023.
- [12] Dranka G.G., Ferreira P., Vaz A.I.F., Integrating supply and demand-side management in renewable-based energy systems, *Energy*. 232, 2021.
- [13] Rosenow J., Lindner M., Scheiderer J., Advanced flight planning and the benefit of in-flight aircraft trajectory optimization, *Sustainability*.; 13(3), 2021.
- [14] Gulpe I., A review on weather impact on aviation operations: Visibility, wind, precipitation, icing, *Journal of*

- Airline Operations and Aviation Management. 2(1): 1-44, 2023.
- [15] De Perez E.C., Berse K.B., Depante L.A.C., Easton-Calabria E., Evidente E.P.R., Ezike T., Van Sant C., Learning from the past in moving to the future: Invest in communication and response to weather early warnings to reduce death and damage, *Climate Risk Management*. 38, 2022.
- [16] Jovanovic N., Pereira L.S., Paredes P., Pôças I., Cantore V., Todorovic M., A review of strategies, methods and technologies to reduce non-beneficial consumptive water use on farms considering the FAO56 methods, *Agricultural water management*. 239, 2020.
- [17] Giovannini L., Ferrero E., Karl T., Rotach M.W., Staquet C., Trini Castelli S., Zardi D., Atmospheric pollutant dispersion over complex terrain: Challenges and needs for improving air quality measurements and modelling, *Atmosphere*. 11(6), 2020.
- [18] Malik P., Gehlot A., Singh R., Gupta L.R., Thakur A.K., A review on ANN based model for solar radiation and wind speed prediction with real-time data, *Archives of Computational Methods in Engineering*. 29(5): 3183-3201, 2022.
- [19] Aggarwal D., Sharma D., Saxena A.B., Role of AI in cyber security through Anomaly detection and Predictive analysis, *Journal of Informatics Education and Research*. 3(2), 2023.
- [20] Kosovic I.N., Mastelic T., Ivankovic D., Using Artificial Intelligence on environmental data from Internet of Things for estimating solar radiation: Comprehensive analysis, *Journal of cleaner production*. 266, 2020.
- [21] Dewitte S., Cornelis J.P., Müller R., Munteanu A., Artificial intelligence revolutionises weather forecast, climate monitoring and decadal prediction, *Remote Sensing*. 13(16), 2021.
- [22] Subbiah S.S., Paramasivan S.K., Arockiasamy K., Senthivel S., Thangavel M., Deep Learning for Wind Speed Forecasting Using Bi-LSTM with Selected Features, *Intelligent Automation and Soft Computing*. 35(3), 2023.
- [23] Chen P., Han D., Effective wind speed estimation study of the wind turbine based on deep learning, *Energy*. 247, 2022.
- [24] Chen X., Yu R., Ullah S., Wu D., Li Z., Li Q., Zhang Y., A novel loss function of deep learning in wind speed forecasting, *Energy*. 238, 2022.
- [25] Han Y., Mi L., Shen L., Cai C.S., Liu Y., Li K., Xu G., A short-term wind speed prediction method utilizing novel hybrid deep learning algorithms to correct numerical weather forecasting, *Applied Energy*. 312, 2022.
- [26] Khodayar M., Saffari M., Williams M., Jalali M.J., Interval deep learning architecture with rough pattern recognition and fuzzy inference for short-term wind speed forecasting, *Energy*. 254, 2022.
- [27] Hao Y., Yang W., Yin K., Novel wind speed forecasting model based on a deep learning combined strategy in urban energy systems, *Expert Systems with Applications*. 219, 2023.
- [28] Indian Cities Weather 2010-2024: Dive In!. <https://www.kaggle.com/datasets/mukeshdevrath007/indian-5000-cities-weather-data> (Erişim tarihi: 15.04.2024)
- [29] Karabadi N.E.I., Korba A.A., Assi A., Seridi H., Aridhi S., Dhifli W., Accuracy and diversity-aware multi-objective approach for random forest construction, *Expert Systems with Applications*. 225, 2023.
- [30] Bansal M., Goyal A., Choudhary A., A comparative analysis of K-nearest neighbor, genetic, support vector machine, decision tree, and long short term memory algorithms in machine learning, *Decision Analytics Journal*. 3, 2022.
- [31] Canbay, Y., Adsiz, S., Canbay, P., Privacy-Preserving Transfer Learning Framework for Kidney Disease Detection, *Applied Sciences*, 14(19), 8629, 2024.
- [32] Kaya, M., Bilge, H. Ş., Benzerlik Tabanlı Öğrenme Kullanarak Histopatolojik Görüntülerin Sınıflandırılması. *EMO Bilimsel Dergi*, 14(2): 49-58, 2024.
- [33] Utku, A., Hindistan'daki Turistik Şehirlerin İklim Değişkenlerinin Tahminine Yönelik Hibrit ConvGRU Modeli. *Mühendislik Bilimleri ve Araştırmaları Dergisi*, 6(2): 165-176, 2024.
- [34] Utku, A., Hybrid CNN-LSTM Model for Air Quality Prediction: A Case Study for Gurugram. *Journal of Soft Computing and Artificial Intelligence*, 5(1): 33-40, 2024.
- [35] Mohammadi B., Mehdizadeh S., Ahmadi F., Lien N.T.T., Linh N.T.T., Pham Q.B., Developing hybrid time series and artificial intelligence models for estimating air temperatures, *Stochastic Environmental Research and Risk Assessment*. 35: 1189-1204, 2021.