

LSTM ve Hibrit CNN–LSTM Derin Öğrenme Yaklaşımları ile Isparta İli İçin Zaman Serisi Tabanlı Sıcaklık Tahmini

Time Series–Based Temperature Forecasting for Isparta Province Using LSTM and Hybrid CNN–LSTM Deep Learning Approaches

Erdem ÇOBAN^{1*} 

^{1*}Haliç Üniversitesi, Mimarlık Fakültesi, Mimarlık Bölümü, İstanbul, Türkiye.

*Sorumlu Yazar:
erdemcoban@halic.edu.tr

Geliş/Received: 10.08.2025;
Kabul/Accepted: 15.11.2025

Atıf/Citation: Çoban, E. (2025). LSTM ve Hibrit CNN–LSTM Derin Öğrenme Yaklaşımları ile Isparta İli İçin Zaman Serisi Tabanlı Sıcaklık Tahmini. *UMBD*, 8(3), 104-117

Öz

Günlük hava sıcaklığı, tarım, enerji, sağlık ve su yönetimi gibi pek çok sektörü doğrudan etkileyen kritik bir meteorolojik parametredir. Küresel iklim değişikliğiyle birlikte sıcaklık rejimlerindeki dalgalanmalar ve uzun vadeli artışlar, bölgesel tahmin modellerinin geliştirilmesini daha da önemli hale getirmiştir. Bu çalışmada, Isparta ili için günlük hava sıcaklığı tahmini amacıyla dört farklı modelin (XGBoost, LSTM, CNN ve CNN–LSTM) karşılaştırmalı analizi gerçekleştirilmiştir. Geçmiş yıllara ait günlük sıcaklık verileri kullanılarak yapılan tahminlerde, modeller hem eğitim hem de test setleri üzerinde MAE, MSE, R², NSE ve Willmott d gibi istatistiksel ölçütlerle değerlendirilmiştir. Elde edilen sonuçlar, test verisi üzerinde LSTM modelinin en yüksek doğruluğu sunduğunu göstermiştir (MAE 1,139, MSE 2,334, R² 0,966, NSE 0,965, Willmott d 0,991). CNN–LSTM modeli ise LSTM'e çok yakın değerlerle (MAE 1,236, MSE 2,661, R² 0,962, NSE 0,960, Willmott d 0,990) istikrarlı bir alternatif olarak öne çıkmıştır. CNN modeli rekabetçi performans sergilemiş (MAE 1,228, MSE 2,688, R² 0,961, NSE 0,960, Willmott d 0,989), XGBoost modeli ise diğer modellere kıyasla daha zayıf kalmıştır (MAE 2,526, MSE 10,63, R² 0,855, NSE 0,843, Willmott d 0,960). Genel olarak, LSTM modeli uzun vadeli bağımlılıkları yakalama başarısıyla öne çıkarken, CNN–LSTM modeli kısa dönemli örüntüleri de dikkate alarak güvenilir ve kararlı bir tahmin yaklaşımı sunmuştur. Bu bulgular, derin öğrenme modellerinin yerel ölçekli sıcaklık tahminlerinde karar vericilere daha doğru öngörüler sağlayabileceğini ortaya koymaktadır.

Anahtar Kelimeler: CNN, Derin öğrenme, LSTM, Sıcaklık tahmini, XGBoost, Zaman serisi

Abstract

Temperature and its variations play a crucial role in agriculture, energy consumption, and urban planning. Accurately forecasting air temperature is essential for sustainable resource management and climate adaptation strategies. In this study, four different models—XGBoost, LSTM, CNN, and the hybrid CNN–LSTM—were applied for daily temperature prediction in Isparta, a region sensitive to climatic fluctuations. The performance of the models was evaluated using statistical metrics including MAE, MSE, R², NSE, and Willmott's d. The results show that the LSTM model achieved the highest accuracy on the test data, with a mean absolute error of 1.14 °C, mean squared error of 2.33, coefficient of determination of 0.966, Nash–Sutcliffe efficiency of 0.965, and Willmott's d index of 0.991. The CNN–LSTM model provided very close results, with a mean absolute error of 1.23 °C, mean squared error of 2.66, coefficient of determination of 0.962, Nash–Sutcliffe efficiency of 0.960, and Willmott's d index of 0.990, demonstrating a stable predictive ability. The CNN model also produced competitive results, while the XGBoost algorithm showed weaker performance with higher error values and lower generalization capability. These findings highlight that LSTM is most effective in capturing long-term dependencies, whereas the CNN–LSTM hybrid offers a robust alternative capable of modeling both short-term patterns and long-term dynamics. Thus, both models can be considered valuable tools for local meteorological forecasting and climate-aware decision-making.

Keywords: CNN, Deep learning, LSTM, Temperature forecasting, XGBoost, Time series

1. Giriş

İklim değişikliği ve küresel ısınma, günümüzde insanlık için en büyük çevresel sorunlardan biri hâline gelmiştir. Aşırı hava olaylarının sıklığı ve şiddetinde gözlenen artış, uzun süreli kuraklıklar ve beklenmedik sıcaklık dalgalanmaları gibi etkiler, özellikle tarım ve doğaya bağlı ekonomiler üzerinde ciddi tehditler oluşturmaktadır (Astsatryan vd., 2021). Bu nedenle, hava sıcaklığının doğru ve zamanında tahmin edilmesi; tarımsal verimlilik, enerji yönetimi, halk sağlığı ve doğal afet risklerinin azaltılması gibi birçok alanda kritik bir rol oynamaktadır (Buratto vd., 2024). Sıcaklık verilerinin yanı sıra diğer hidrometeorolojik parametrelerdeki uzun dönemli trendlerin belirlenmesi ve geleceğe yönelik tahminlerinin yapılması, su kaynakları yönetimi, çevresel risk azaltımı ve iklim uyum stratejilerinin geliştirilmesi açısından büyük önem taşımaktadır (Aksay vd., 2025; Kalkınç vd., 2023). Yapay zekâ tabanlı yöntemlerin hidro-meteoroloji alanındaki muhtelif veri kümelerinde kullanımının önemi, son yıllarda yapılan çalışmalarla giderek daha fazla ortaya konmaktadır. Çoban (2024), mevsimsel akım verileriyle yaz aylarındaki debileri tahmin etmek amacıyla Rastgele Orman ve AdaBoost algoritmalarını uygulamış; çalışmada elde edilen yüksek doğruluk, kuraklık riskine karşı su kaynaklarının planlanmasında bu tür makine öğrenmesi modellerinin etkinliğini göstermiştir. Benzer şekilde, Saplıoğlu ve Çimen (2010), eksik yağış verilerinin tahmini için Yapay Sinir Ağları modelini kullanarak klasik yöntemlere kıyasla daha isabetli sonuçlara ulaşmış ve yağış gibi hidrolojik parametrelerin doğru tahmininin, su yapılarının tasarımı ve yönetimi açısından kritik olduğunu vurgulamıştır. Türkiye'nin güneybatısında yer alan Isparta ili, Akdeniz ile karasal iklim arasında geçiş özelliği gösteren, tarım temelli üretim faaliyetlerinin yoğun olduğu bir bölgedir. Elma, lavanta ve gül yetiştiriciliği gibi ekonomik faaliyetler, mevsimsel sıcaklık değişimlerinden doğrudan etkilenmektedir. Bahar aylarında meydana gelen don olayları ya da yaz aylarında yaşanan sıcak hava dalgaları, ürün rekoltesi ve sulama ihtiyacını doğrudan etkilemektedir. Bu durum, Isparta gibi iklim değişimine hassas bölgelerde yerel düzeyde güvenilir sıcaklık tahmin modellerine olan ihtiyacı ortaya koymaktadır. Geleneksel istatistiksel ve fiziksel modeller, sıcaklık zaman serilerinde bulunan doğrusal olmayan ilişkileri ve uzun dönemli bağımlılıkları yakalamada sınırlı kalabilmektedir. Buna karşılık, yapay zekâ ve makine öğrenmesi tabanlı yöntemler; büyük veri kümelerinden anlamlı örüntüleri öğrenebilme ve karmaşık iklim sistemlerini modelleyebilme yetenekleri sayesinde son yıllarda dikkat çekici başarılar elde etmiştir. Özellikle Derin Öğrenme yaklaşımlarında öne çıkan Evrişimli Sinir Ağları (CNN) kısa dönemli örüntüleri çıkarırken; Uzun Kısa Süreli Bellek (LSTM) ağları, zaman serilerindeki uzun vadeli bağıntıları modelleyebilmektedir (Karevan ve Suykens, 2020). Bu iki yapının birleşimi olan CNN–LSTM hibrit modelleri, hem yerel sıcaklık değişimlerini hem de mevsimsel eğilimleri aynı anda yakalayarak yüksek doğrulukta tahminler sunabilmektedir (Utku, 2024; Hou vd., 2022; Gao vd., 2023; Alizamir, 2025). Bunun yanında, Hou vd., (2022) tarafından Yinchuan meteoroloji istasyonunda gerçekleştirilen çalışmada, CNN–LSTM modeli saatlik sıcaklık tahmininde CNN ve LSTM tekil modellerine kıyasla daha yüksek doğruluk sağlamış (test aşamasında MAE=1,02, RMSE=1,97) ve uzun zaman serilerinde güvenilir öngörüler sunmuştur. Bu kapsamda Kim ve Cho (2019) tarafından geliştirilen CNN-LSTM tabanlı model, zamansal ve mekânsal özellikleri birlikte işleyerek bireysel enerji tüketimini başarıyla tahmin etmiştir. Öte yandan, güçlü makine öğrenmesi algoritmalarından biri olan Extreme Gradient Boosting (XGBoost), sıcaklık tahmini gibi çevresel uygulamalarda ve farklı disiplinlerde yüksek doğruluk sağlayan tahmin uygulamalarıyla öne çıkmaktadır. Fang vd. (2022) tarafından yapılan bir çalışmada XGBoost modeli, ABD’de COVID-19 vaka tahmini için ARIMA modeliyle karşılaştırılmış ve hata metriklerinde (MAE, RMSE, MAPE) daha iyi sonuçlar vermiştir. Benzer şekilde, inşaat mühendisliği alanında da XGBoost, prefabrik beton binaların yatırım maliyet tahmininde başarılı şekilde uygulanmış, klasik makine öğrenmesi yöntemlerine göre daha güçlü genelleme ve yorumlanabilirlik sağlamıştır (Yan vd., 2022).

Bu çalışmada, ERA5 yeniden analiz verileri kullanılarak Isparta ili merkez istasyonuna ait günlük hava sıcaklıkları, CNN–LSTM derin öğrenme modeli ve XGBoost regresyon algoritması ile tahmin edilmiştir. Çalışmanın temel amacı, her iki modelin tahmin doğruluğunu karşılaştırmak ve değerlendirme metrikleri (MAE, MSE, R^2) üzerinden performanslarını analiz etmektir. Elde edilen bulguların, iklim değişimine duyarlı


bölgelerde tarımsal planlama, enerji yönetimi ve erken uyarı sistemleri gibi uygulamalara katkı sağlaması beklenmektedir.

2. Materyal ve Yöntem

2.1. Çalışma alanı ve veri

Bu çalışma, Türkiye'nin güneybatısında yer alan Isparta ili merkez yerleşimine odaklanmaktadır. Akdeniz iklimi ile karasal iklim arasında bir geçiş kuşağında bulunan Isparta, yazları sıcak ve kurak, kışları ise soğuk ve yağışlı bir iklim yapısına sahiptir. Yaklaşık 1050 metre rakıma sahip olan şehir merkezi, çevresindeki göllerin etkisiyle belirgin bir mikroklimatik çeşitliliğe sahiptir. Denizden uzak konumu, yüksekliği ve topoğrafik özellikleri nedeniyle, bölgedeki hava sıcaklıkları mevsimsel olarak büyük farklılıklar gösterebilmektedir. Isparta, kıyı bölgesi olmamakla birlikte ekolojik ve tarımsal açıdan Türkiye'nin önemli üretim merkezlerinden biridir. Özellikle elma, gül ve lavanta yetiştiriciliği, ilin ekonomik yapısında temel rol oynamaktadır. Ancak son yıllarda, mevsim geçişlerinde yaşanan erken ve geç don olayları, uzayan yaz kuraklıkları ve ani sıcaklık dalgalanmaları, tarımsal verimliliği ve su kaynaklarını olumsuz yönde etkilemektedir. Bu iklimsel stres faktörleri, hem doğal ekosistemleri hem de kırsal yaşamı tehdit ederken, aynı zamanda mevsimsel dengeye bağlı sektörlerin sürdürülebilirliğini de riske atmaktadır. Bu bağlamda, Isparta gibi iklim değişimine duyarlı iç bölgelerde, yerel ölçekli ve yüksek doğrulukta sıcaklık tahminleri üretebilen modellerin geliştirilmesi büyük önem taşımaktadır. Bu çalışma, özellikle tarımsal planlama, sulama yönetimi, don riskinin azaltılması ve bölgesel iklim uyum stratejilerinin desteklenmesine katkı sağlamayı amaçlamaktadır. Bu amaç doğrultusunda, derin öğrenme (CNN-LSTM) ve topluluk öğrenmesi (XGboost) yaklaşımlarına dayalı veri odaklı bir sıcaklık tahmin modeli önerilmiştir.

Bu çalışmada, Türkiye'nin güneybatısında yer alan Isparta ili merkez noktasına ait günlük hava sıcaklığı verileri kullanılarak, veri odaklı bir sıcaklık tahmin modeli geliştirilmiş ve değerlendirilmiştir. Çalışma alanı, yaklaşık 37,7648°K enlem ve 30,5566°D boylam koordinatlarında konumlanan Isparta şehir merkezini kapsamaktadır. Kullanılan veri seti, Ocak 2015 ile Aralık 2024 tarihleri arasındaki dönemi içermekte olup, toplam 3643 günlük gözlem içermektedir. Sıcaklık verileri, Avrupa Orta Vadedi Hava Tahminleri Merkezi (ECMWF) tarafından sağlanan ERA5 yeniden analiz veri setinden elde edilmiştir. ERA5 veri kümesi, küresel kapsama sahip olup, atmosfer, kara yüzeyi ve okyanus parametrelerine ilişkin saatlik çözünürlükte (~31 km) yüksek kaliteli veriler sunmaktadır. Bu çalışmada kullanılan sıcaklık değişkeni, yüzeyden yaklaşık 2 metre yükseklikte ölçülen günlük ortalama hava sıcaklığı (T2m) değerlerini temsil etmektedir. Isparta merkezine en yakın grid hücresi temel alınarak elde edilen bu veriler, modelin eğitilmesi ve test edilmesi amacıyla ön işleme tabi tutulmuştur. ERA5 verisinin yüksek zamansal ve mekânsal çözünürlüğü sayesinde, Isparta gibi topoğrafik çeşitliliğe sahip bir iç bölgede bile yerel sıcaklık desenlerinin güvenilir bir şekilde modellenmesi mümkün olmaktadır. Bu bağlamda, ERA5 yeniden analiz verileri, hem gözlemsel boşlukların giderilmesi hem de uzun dönemli tahmin modellerinin geliştirilmesi açısından önemli bir kaynak sunmaktadır. Ancak Isparta ili için yerel meteoroloji istasyonu verileri mevcut olmadığından, ERA5 verilerinin doğrudan istasyon ölçümleriyle doğrulaması yapılamamıştır. Bu husus çalışmanın bir sınırlılığı olarak değerlendirilmiştir. Bununla birlikte, Türkiye'nin farklı bölgelerinde yapılan çalışmalar ERA5 verilerinin yerel gözlemlerle yüksek uyum gösterdiğini ortaya koymaktadır (Yılmaz, 2023; Mutlu, 2025). Gelecekte yapılacak araştırmalarda, ERA5 verilerinin yerel istasyon gözlemleriyle karşılaştırılması, model performanslarının daha sağlam bir şekilde değerlendirilmesine katkı sağlayacaktır. Isparta iline ait günlük sıcaklık değerlerinin yıllık değişim eğilimleri Şekil 1'de zaman serisi olarak sunulmaktadır.



Şekil 1. Isparta ili günlük sıcaklıklarının zaman serisi

Tablo 1. Isparta ili merkezine ait günlük 2 metre hava sıcaklığı verilerinin tanımlayıcı istatistikleri

Isparta ili günlük sıcaklık	
Veri Sayısı	3643
Ortalama	21,93
Asgari	1,67
25%	14,02
50%	23,08
75%	29,62
Azami	38,99
Standart Sapma	8,47

Bu çalışmada, yüzeyden yaklaşık 2 metre yükseklikteki hava sıcaklığını (T2m) temsil eden günlük veriler kullanılmıştır. T2m, iklim ve hava durumu çalışmalarında yaygın olarak kullanılan, güvenilir bir atmosferik parametredir. Isparta merkezine ait sıcaklık verileri, ERA5 yeniden analiz veri setinden elde edilmiş olup, uzun dönemli analiz ve tahmin modelleri için uygun yapısıyla dikkat çekmektedir. Isparta, kıyı bölgesi olmamakla birlikte, rakımı yüksek, topoğrafyası karmaşık ve kara içi iklim etkilerine açık bir yerleşim alanıdır. Bu özellikleri sayesinde, sıcaklık tahmin modellerinin mekânsal genelleme yeteneklerini test etmek için elverişli bir örnek teşkil etmektedir. Ayrıca, don olayları, ani sıcaklık değişimleri ve kurak yaz dönemleri gibi iklimsel risklere açık yapısıyla, derin öğrenme temelli melez tahmin modellerinin dayanıklılık ve uyarlanabilirlik düzeylerinin test edilmesi açısından kritik öneme sahiptir. Isparta ili merkezine ait günlük 2 metre hava sıcaklığı verilerinin temel tanımlayıcı istatistikleri Tablo 1’de sunulmaktadır. Toplam 3643 gözlem içeren bu veri setinde sıcaklık değerleri 1,67 °C ile 38,99 °C arasında değişmekte olup, ortalama sıcaklık 21,93 °C ve standart sapma 8,47 °C olarak hesaplanmıştır.

2.1.1. Veri ayrımı

Çalışmada zaman serisi tahminine uygun şekilde kronolojik veri ayrımı yapılmıştır. Toplam 3643 günlük sıcaklık gözleminin ilk %80’i (2015–2022 dönemi) eğitim verisi, son %20’si (2023–2024 dönemi) test verisi olarak kullanılmıştır. Veri karıştırma (shuffle) uygulanmamış, böylece zaman bağımlılığı korunmuştur. Ayrıca her tahmin için önceki 10 günün sıcaklık değerleri girdi penceresi olarak modele sunulmuştur.

2.1.2. Min-Maks Normalizasyonu

Zaman serisi tahmininde modelin başarısını artırmak ve veri ölçeklenmesini standart hale getirmek için Min-Maks normalizasyonu yaygın olarak kullanılmaktadır (Henderi, 2021). Min-maks normalizasyonu, verileri

belirlenen bir aralığa (genellikle [0,1] veya [-1,1]) ölçekleyerek modelin daha stabil ve hızlı öğrenmesini sağlar. Normalizasyon işlemi denklem 1'deki gibi gerçekleştirilmektedir:

$$X_N = \frac{x - x_{min}}{x_{maks} - x_{min}} \quad (1)$$

Bu işlem, özellikler arasındaki ölçek farklılıklarını ortadan kaldırarak, modelin daha dengeli ve etkili bir öğrenme süreci geçirmesine katkı sağlar. Bu çalışmada kullanılan CNN-LSTM ve XGBoost modellerinde, sıcaklık verileri Min-Maks normalizasyonu yöntemiyle [0,1] aralığına ölçeklendirilmiştir. Bu sayede, farklı değer aralıklarına sahip veri noktalarının model tarafından öğrenilmesi kolaylaşmış ve eğitim sürecindeki ağırlık güncellemeleri daha kararlı hâle getirilmiştir. Normalizasyon işlemi, özellikle derin öğrenme modellerinde eğitimin verimli gerçekleşmesi açısından yaygın ve etkili bir ön işleme tekniğidir.

2.2. Makine öğrenmesi algoritmaları

2.2.1. XGBoost

Extreme Gradient Boosting, gradyan artırma çerçevesine dayanan ve karar ağaçları kullanan yüksek performanslı bir makine öğrenmesi algoritmasıdır (Chen ve Guestrin, 2016). Bu algoritma, iteratif olarak hatalı tahmin edilen örneklere daha fazla ağırlık vererek modeli geliştirmeyi amaçlar ve özellikle zaman serisi gibi karmaşık veri yapılarında etkili tahminler gerçekleştirebilir (Brownlee, 2019). Diğer geleneksel yöntemlere göre avantajı, hem hesaplama açısından verimli olması hem de L1 ve L2 düzenleme yöntemlerini kullanarak aşırı öğrenmeyi sınırlayabilmesidir (Nielsen, 2016). XGBoost, paralelleştirilebilir yapısı ve eksik veri işleyebilme kapasitesi sayesinde büyük veri setlerinde yaygın olarak tercih edilmektedir (Brownlee, 2019). Bu çalışmada, XGBoost algoritması günlük sıcaklık tahmininde kullanılmış ve elde edilen performans sonuçları CNN, LSTM ve CNN-LSTM hibrit modelleriyle karşılaştırılmıştır. XGBoost, eğitim verisi üzerinde yüksek doğruluk sağlamasına rağmen, test aşamasında genelleme gücü bakımından daha düşük performans göstermiştir. Bu durum, algoritmanın deterministik yapısının zamansal bağımlılıkları öğrenmede sınırlı kalabileceğine işaret etmektedir (Zhang vd., 2022).

2.2.2. CNN

CNN (Convolutional Neural Networks), giriş verisinden özellik hiyerarşilerini otomatik ve uyarlanabilir biçimde öğrenmek üzere geliştirilmiş derin öğrenme mimarileridir (LeCun vd., 1998). Görüntü işleme alanında yaygın olarak kullanılmakla birlikte, zaman serisi verilerinde kısa vadeli örüntülerin ve yerel ilişkilerin çıkarılması için de etkili şekilde kullanılmaktadır (Oord vd., 2016). Zaman serisi tahmini bağlamında CNN'ler, kayan pencere (sliding window) yaklaşımı ile ardışık veri noktaları arasındaki geçici ilişkileri öğrenebilir. Her evrişim katmanı, giriş dizisi üzerinde kayan filtreler (kernels) uygulayarak özellik haritaları (feature maps) oluşturur. Bu işlem, verinin yerel örüntülerini algılayarak daha üst düzey soyutlamaların öğrenilmesini sağlar. Bu yapı sayesinde CNN'ler, kısa vadeli sıcaklık dalgalanmaları gibi kısa süreli iklimsel değişimleri modellemek için uygundur. Matematiksel olarak, bir boyutlu evrişim işlemi aşağıdaki şekilde tanımlanabilir:

$$y_i = (x * w)_i = \sum_{j=0}^{k-1} w_j \cdot x_{i+j} \quad (2)$$

Burada x giriş zaman serisini, w ise boyutu k olan evrişim filtresini temsil eder. y_i , evrişim sonucunda elde edilen çıkış değeridir.

2.2.3. LSTM

LSTM (Long Short-Term Memory), ardışık verilerdeki uzun vadeli bağıntıları öğrenmek üzere geliştirilmiş bir tür Tekrarlayan Sinir Ağı'dır (Hochreiter ve Schmidhuber, 1997; Nelson vd., 2017). Geleneksel RNN'lerde sıkça rastlanan gradyan sönümlenmesi (vanishing gradient) problemini aşmak amacıyla geliştirilen LSTM, içerdiği hafıza hücresi (cell state) ve kapı mekanizmaları (unutma, giriş ve çıkış kapıları) sayesinde bilgiyi uzun zaman aralıklarında koruyabilir, gerektiğinde silebilir ya da güncelleyebilir (Olah, 2015). Bu yapısıyla LSTM, özellikle zaman serisi tahmininde, iklimsel olayların ya da sıcaklık gibi çevresel değişkenlerin modellenmesinde sıklıkla tercih edilmektedir. LSTM hücresindeki işlemler aşağıdaki adımlar ile tanımlanır:

$$f_t = \sigma(W_f x_t + U_f h_{t-1} + b_f) \quad (\text{unutma kapısı}) \quad (3)$$

$$i_t = \sigma(W_i x_t + U_i h_{t-1} + b_i) \quad (\text{giriş kapısı}) \quad (4)$$

$$\hat{c}_t = \tanh(W_c x_t + U_c h_{t-1} + b_c) \quad (\text{aday hücre durumu}) \quad (5)$$

$$c_t = f_t \odot c_{t-1} + i_t \odot \hat{c}_t \quad (\text{yeni hücre durumu}) \quad (6)$$


$$o_t = \sigma(W_o x_t + U_o h_{t-1} + b_o) \quad (\text{çıkış kapısı}) \quad (7)$$

$$h_t = o_t \odot \tanh(c_t) \quad (\text{yeni gizli durum}) \quad (8)$$

Burada, σ sigmoid aktivasyon fonksiyonunu, $\tanh$ hiperbolik tanjant fonksiyonunu, $\odot$ ise eleman bazında çarpımı ifade eder. x_t giriş, h_{t-1} önceki gizli durum, c_{t-1} ise önceki hücre durumudur.

2.2.4. CNN-LSTM hibrit model mimarisi

Bu çalışmada, günlük hava sıcaklığı tahminleri için CNN ve LSTM ağlarının birleşiminden oluşan hibrit bir derin öğrenme modeli geliştirilmiştir. Modelde, giriş verileri öncelikle CNN katmanlarına aktarılmakta; burada zaman serisinin kısa dönemli dalgalanmaları ve yerel desenleri, konvolüsyon filtreleri ve havuzlama (pooling) işlemleri yardımıyla çıkarılmaktadır. CNN'den elde edilen öznitelik haritaları daha sonra LSTM katmanına beslenmekte, bu aşamada ardışık bellek hücreleri aracılığıyla zaman içerisindeki uzun vadeli bağımlılıklar ve mevsimsel eğilimler öğrenilmektedir. Böylece CNN katmanları öznitelik çıkarımı ve boyut indirgeme görevini üstlenirken, LSTM katmanları bu öznitelikleri zamansal bağlamda işleyerek daha anlamlı hale getirmektedir. Nihai aşamada, yoğun (Dense) katman aracılığıyla işlenen çıktılar regresyon katmanına iletilmekte ve bir sonraki günün sıcaklık değeri tahmin edilmektedir. Bu bütünleşik mimari, tek başına CNN veya yalnızca LSTM kullanımına kıyasla daha yüksek doğruluk sağlamış; hem kısa vadeli anomalileri hem de uzun vadeli iklimsel desenleri birlikte öğrenerek üstün tahmin performansı ortaya koymuştur (Şekil 3). Bu çalışmada kullanılan CNN-LSTM hibrit modeli, giriş verilerinin ilk olarak evrişimsel katmanlarda kısa dönemli örüntülerin çıkarılması ve ardından LSTM katmanlarında zamansal bağımlılıkların öğrenilmesi prensibine dayanmaktadır. Modelin mimari yapısı ve veri akışı adımları Şekil 2'de gösterilmektedir.



Şekil 2. CNN-LSTM hibrit modeli akış diyagramı

2.2.5. Model mimarileri ve hiperparametreler

Çalışmada kullanılan modellerin mimari yapıları ve temel hiperparametre ayarları Tablo 2’de sunulmuştur. Tüm derin öğrenme tabanlı modellerde kayıp fonksiyonu olarak Ortalama Kare Hata (MSE) ve eniyileştirici olarak Adam algoritması tercih edilmiştir. Eğitim sürecinde epoch sayısı 50, batch size değeri ise 32 olarak belirlenmiştir. CNN katmanlarında 64 filtre ve 3 çekirdek boyutu kullanılırken, LSTM katmanlarında 50 bellek hücresi ile çalışılmıştır. CNN–LSTM hibrit mimarisinde ise CNN katmanlarıyla çıkarılan kısa vadeli örüntüler, LSTM katmanları aracılığıyla zamansal bağımlılıkların öğrenilmesine aktarılmıştır. XGBoost algoritması için 100 ağaç, 0,1 öğrenme oranı ve sabit bir random_state parametresi kullanılmıştır.

Tablo 2. Çalışmada kullanılan modellerin mimarileri ve hiperparametreleri

Model	Girdi Penceresi	Katmanlar / Birimler	Aktivasyon	Diğer
LSTM	10 gün	LSTM 50 → Dense 1	tanh / —	Adam (varsayılan), kayıp: MSE; epoch: 50; batch: 32
CNN	10 gün	Conv1D 64, kernel 3 → MaxPool 2 → Flatten → Dense 50 → Dense 1	ReLU / ReLU / —	Adam (varsayılan), kayıp: MSE; epoch: 50; batch: 32
CNN–LSTM	10 gün	Conv1D 64, kernel 3 → MaxPool 2 → LSTM 50 → Dense 1	ReLU / tanh / —	Adam (varsayılan), kayıp: MSE; epoch: 50; batch: 32
XGBoost	—	Ağaç-tabanlı	—	n_estimators: 100; learning_rate: 0.1; random_state: 42

2.3. Değerlendirme metrikleri

Bu çalışmada, geliştirilen tahmin modellerinin başarımını değerlendirmek amacıyla beş temel ölçüt kullanılmıştır: Ortalama Mutlak Hata (MAE), Ortalama Kare Hata (MSE), Belirleme Katsayısı (R^2), Nash–Sutcliffe Verimlilik Katsayısı (NSE) ve Willmott d İndeksi (d). Bu metrikler, model performansını farklı açılardan analiz ederek daha bütüncül bir değerlendirme yapılmasına olanak tanımaktadır. MAE, tahmin edilen değerler ile gözlenen değerler arasındaki ortalama mutlak farkı ifade ederken; MSE, hata karelerine ağırlık vererek büyük sapmaları daha hassas biçimde yansıtır. R^2 metriği, modelin varyansı ne ölçüde açıkladığını göstererek genel uyum hakkında bilgi sunar. Bunlara ek olarak, NSE metriği modelin tahmin gücünü gözlem ortalamasına kıyasla ölçerken, d indeksi ise tahmin ve gözlem değerleri arasındaki bağıl uyumu değerlendirir. Bu iki ek metrik, özellikle hidrolojik ve iklimsel zaman serilerinin değerlendirilmesinde yaygın olarak kullanılmakta ve modelin uç değerler ile genel eğilimleri ne kadar iyi yansıttığını daha detaylı biçimde ortaya koymaktadır. Bu kapsamlı değerlendirme çerçevesi sayesinde, hem klasik hem de hibrit derin öğrenme temelli modellerin farklı yönlerden performansları karşılaştırmalı olarak analiz edilmiştir.

2.3.1. MSE- (Mean Squared Error)

Gerçek ve tahmin edilen değerler arasındaki farkların karelerinin ortalamasıdır. MSE, hataların büyüklüğünü dikkate alır ve büyük hataları daha fazla cezalandırır. MSE, modelin büyük hataları ne kadar iyi önlediğini vurgular. Küçük hataları görmezden gelmez. Çünkü hataların kareleri alınır, MSE, uç değerleri (outliers) daha fazla vurgular ve dolayısıyla duyarlı bir ölçü olabilir.

$$MSE = \frac{1}{N} \sum_{j=1}^N (y_j - \hat{y}_j)^2 \quad (9)$$

2.3.2. MAE- (Mean Absolute Error)

MAE, bir modelin tahmin performansını değerlendirmek için yaygın olarak kullanılan ve sezgisel olarak anlaşılabilir bir ölçüttür. Gözlemlenen değerler (y_j) ile tahmin edilen değerler ($\hat{y}_j$) arasındaki mutlak farkların aritmetik ortalamasını ifade eder. MAE, tüm hataları eşit olarak değerlendirir ve tahmin edilen değişkenle aynı

birimde ifade edilir; bu da tahmin hatalarının fiziksel olarak doğrudan yorumlanmasına olanak tanır (Denklem 12).

$$MAE = \frac{1}{N} \sum_{j=1}^N \left[\frac{y_j - \hat{y}_j}{y_j} \right] \quad (10)$$

2.3.3. R²- (Determination Coefficient)

Modelin bağımlı değişkenin varyansını ne kadar açıkladığını ölçer. Yani, modelin veriyi ne kadar iyi açıklayabildiğini gösterir. R² değeri, modelin ne kadar iyi bir tahmin yaptığını anlamamıza yardımcı olur. R² değeri 1'e yaklaştıkça model, hedef değişkenin varyansını daha fazla açıklıyor demektir. 0,0 değeri, modelin veriyi hiç açıklamadığını, 1,0 değeri ise veriyi tamamen açıkladığını gösterir. Kolayca yorumlanabilir ve genellikle bir modelin başarısını hızlıca gösterebilir. R²'nin yüksek olması, her zaman daha iyi bir model olduğu anlamına gelmez. Özellikle aşırı karmaşık modellerde, R² değeri yüksek olsa da, model aşırı uyum sağlamış (overfitting) olabilir.

$$R^2 = 1 - \frac{\sum_{j=1}^N (y_j - \hat{y}_j)^2}{\sum_{j=1}^N (y_j - \bar{y})^2} \quad (11)$$

2.3.4. MAPE – (Mean Absolute Percentage Error)

Gerçek ve tahmin edilen değerler arasındaki mutlak yüzde farklarının ortalamasını ifade eder. MAPE, genellikle iş dünyasında tahmin doğruluğunu ölçmek için yaygın olarak kullanılır. MAPE, birimlerden bağımsızdır ve her hata yüzdesini dikkate alır, bu da farklı veriler arasında karşılaştırma yapmayı kolaylaştırır. Gerçek değerlerin sıfır olduğu durumlarda hata sonsuza gider, bu yüzden sıfır içeren veri setlerinde dikkatle kullanılmalıdır.

$$MAPE = \frac{100\%}{N} \sum_{j=1}^N \left| \frac{y_j - \hat{y}_j}{y_j} \right| \quad (12)$$

2.3.5. NSE (Nash–Sutcliffe Verimlilik Katsayısı)

NSE, model tahminlerinin gözlenen değerlere göre başarımını ölçen ve özellikle hidrolojik ve meteorolojik modelleme çalışmalarında sıkça tercih edilen bir metriktir. NSE, modelin gözlem ortalamasına kıyasla ne derece başarılı tahminler yaptığını gösterir. Denklem (13) ile tanımlanır:

$$NSE = 1 - \frac{\sum_{j=1}^N (y_j - \hat{y}_j)^2}{\sum_{j=1}^N (y_j - \bar{y})^2} \quad (13)$$

Burada y_j gözlenen değerleri, $\hat{y}_j$ model tahminlerini ve $\bar{y}$ ise gözlem ortalamasını temsil etmektedir. NSE değeri 1'e yaklaştıkça modelin başarımı artmakta, 0 veya negatif değerlere yaklaştıkça başarımları azalmaktadır.

2.3.6. Willmott'un d İndeksi (d-statistic)

Willmott'un d İndeksi, modelin tahminleri ile gözlenen değerler arasındaki bağıl uyumu değerlendiren performans göstergesidir. Korelasyona dayalı metriklerin bazı sınırlamalarını aşmak amacıyla geliştirilmiş olan bu indeks, özellikle büyük sapmaların değerlendirilmesinde dengeli sonuçlar verir. Denklem (14) ile tanımlanır:

$$\text{Willmott'un d İndeksi} = 1 - \frac{\sum_{j=1}^N (y_j - \hat{y}_j)^2}{\sum_{j=1}^N (|\hat{y}_j - \bar{y}| + |y_j - \bar{y}|)^2} \quad (14)$$

Bu denklemde, yine y_j , $\hat{y}_j$, $\bar{y}$ sırasıyla gözlenen değer, tahmin edilen değer ve gözlem ortalamasını ifade eder. d değeri 1'e yaklaştıkça modelin tahmin başarısı artar; 0 değeri ise modelin başarısız olduğunu gösterir.

3. Bulgular ve Tartışma


Bu çalışmada, Isparta ili için geliştirilen CNN-LSTM hibrit modelin performansı; MAE, MSE, R^2 , NSE ve Willmott d indeksi gibi değerlendirme ölçütleri ile analiz edilmiştir. Elde edilen sonuçlar, CNN-LSTM modelinin tek başına kullanılan CNN ve LSTM modellerine kıyasla hata değerlerini azaltırken doğruluk metriklerini artırdığını göstermektedir. Bu durum, konvolüsyonel yapının yerel örüntüleri yakalama kabiliyeti ile LSTM'nin zamansal bağımlılıkları modellemesinin birleşiminin sıcaklık tahmini için güçlü bir sinerji oluşturduğunu göstermektedir. Elde edilen bulgulara göre, CNN-LSTM hibrit modeli, Isparta için günlük sıcaklık tahmininde hem hata ölçütleri açısından en düşük (MAE, MSE) değerlere hem de en yüksek doğruluk katsayılarına (R^2 , NSE, d) ulaşmıştır. Karşılaştırılan tüm modeller arasında genel başarı açısından en tutarlı ve güvenilir sonuçları CNN-LSTM modeli sağlamıştır. Bu bulgular, önerilen yaklaşımın geleneksel makine öğrenmesi yöntemlerinden olan XGBoost algoritmasına kıyasla da daha iyi bir performans sergilediğini ortaya koymaktadır. Tablo 3, günlük hava sıcaklığı tahmini amacıyla Isparta ili için uygulanan dört farklı modelin (XGBoost, LSTM, CNN ve CNN-LSTM) performans metriklerini sunmaktadır. Modeller hem eğitim hem de test veri setleri için MAE, MSE, R^2 , NSE ve Willmott d indeksi gibi standart doğruluk metrikleriyle değerlendirilmiştir. Özellikle LSTM modeli, her iki veri setinde de en düşük MAE ve MSE değerlerini, en yüksek R^2 , NSE ve Willmott d skorlarını elde ederek, tüm modeller arasında en yüksek öngörü başarımını göstermiştir.

Tablo 3. Hava sıcaklığı için modellerin tahmin performansı


	Model	MAE	MSE	R^2	NSE	Willmott d
Eğitim	XGBoost	1,333	3,060	0,831	0,958	0,989
	LSTM	1,249	2,814	0,863	0,961	0,990
	CNN	1,510	3,872	0,867	0,946	0,986
	CNN-LSTM	1,502	3,669	0,956	0,949	0,986
Test	XGBoost	2,526	10,63	0,855	0,843	0,960
	LSTM	1,139	2,334	0,966	0,965	0,991
	CNN	1,228	2,688	0,961	0,960	0,989
	CNN-LSTM	1,236	2,661	0,962	0,960	0,990

Eğitim setinde en iyi performans görece düşük hata değerleriyle LSTM modeli tarafından elde edilmiştir; ortalama mutlak hata 1,249, ortalama karesel hata 2,814 ve determinasyon katsayısı 0,863 olarak hesaplanmıştır. CNN-LSTM hibrit modeli ise eğitim aşamasında 1,502 ortalama mutlak hata ve 3,669 ortalama karesel hata ile LSTM'e yakın, ancak determinasyon katsayısı açısından (0,956) daha yüksek bir değer sunmuştur. CNN modeli 1,510 ortalama mutlak hata ve 3,872 ortalama karesel hata ile biraz daha düşük bir performans göstermiştir. XGBoost modeli ise eğitimde 1,333 ortalama mutlak hata ve 3,060 ortalama karesel hata üretmiş, fakat determinasyon katsayısı 0.831 ile diğer modellere kıyasla daha düşük bir başarı sergilemiştir. Test setinde ise en başarılı sonuç LSTM modeli tarafından elde edilmiştir. Modelin ortalama mutlak hatası 1,139, ortalama karesel hatası 2,334 ve determinasyon katsayısı 0,966 olarak bulunmuştur. CNN-LSTM hibrit modelinin test sonuçları LSTM'e oldukça yakın olup, ortalama mutlak hata 1,236, ortalama karesel hata 2,661 ve determinasyon katsayısı 0,962 düzeyinde gerçekleşmiştir. CNN modeli de güçlü bir performans sergilemiş, test setinde 1,228 ortalama mutlak hata, 2,688 ortalama karesel hata ve 0,961 determinasyon katsayısı ile rekabetçi sonuçlar ortaya koymuştur. Buna karşılık, XGBoost modeli test aşamasında daha yüksek hata değerleri (ortalama mutlak hata 2,526, ortalama karesel hata 10,63) ve daha düşük determinasyon katsayısı (0,855) ile diğer modellere kıyasla zayıf kalmıştır. Genel olarak, test verileri üzerinde en yüksek doğruluk LSTM modeli tarafından sağlanırken, CNN-LSTM hibrit modeli oldukça yakın sonuçlarıyla istikrarlı bir alternatif olarak öne çıkmıştır. CNN modeli dengeli bir performans ortaya koyarken,


XGBoost'un test aşamasındaki görece düşük başarısı, klasik makine öğrenmesi yöntemlerinin derin öğrenme yaklaşımlarına göre sınırlı kaldığını göstermektedir.



Şekil 3. Farklı modeller kullanılarak test ve eğitim setleri boyunca **İsparta veri setine** ait gerçek ve tahmin edilen sıcaklık değerlerinin karşılaştırıldığı saçılım grafikleri



Şekil 4. Isparta ili gözlemlenen ve tahmin edilen yüzey sıcaklıklarının zamansal karşılaştırması



Şekil 5. Isparta iline ait 2020 yılı sıcaklık tahminleri; gerçek ölçümler ile XGBoost, LSTM, CNN ve CNN-LSTM modellerinin karşılaştırması

Şekil 4’te, 2015–2025 yılları arasında Isparta bölgesi için tahmin edilen günlük yüzey sıcaklığı değerleri ile gözlemlenen gerçek değerler karşılaştırılmaktadır. Şekil 5’te ise tüm modellerin tahmin performansları, gerçek değerlerle karşılaştırmalı olarak tek bir grafikte sunulmaktadır. XGBoost, LSTM, CNN ve CNN-LSTM modelleri tarafından yapılan tahminler, mevsimsel dalgalanmaları başarılı bir şekilde yansıtmaktadır. Özellikle yaz ve kış mevsimlerindeki sıcaklık uçlarında bile modellerin genel eğilimi yakalayabildiği görülmektedir. CNN-LSTM hibrit modeli, gerek yaz aylarındaki zirveler gerekse kış aylarındaki minimum değerlerde, gözlemlenen sıcaklıklarla oldukça yakın sonuçlar vererek en yüksek örtüşmeyi sağlamıştır. Bu durum, modelin Isparta bölgesine özgü zamansal sıcaklık desenlerini etkili biçimde yakalayabildiğini göstermektedir.

4. Sonuç

Bu çalışmada, Isparta ili için günlük hava sıcaklığı tahmininde XGBoost, LSTM, CNN ve CNN-LSTM modelleri karşılaştırılmış ve performansları MAE, MSE, R^2 , NSE ve Willmott d gibi metrikler üzerinden değerlendirilmiştir. Bulgular, test verileri üzerinde LSTM modelinin en başarılı performansı sergilediğini göstermiştir. LSTM modeli yaklaşık 1,14 MAE, 2,33 MSE ve 0,97’ye yakın R^2 değeriyle yüksek doğruluk sağlamıştır. CNN-LSTM hibrit modeli ise LSTM’e oldukça yakın sonuçlar üretmiş; 1,24 civarında MAE, 2,66 civarında MSE ve 0,96 düzeyinde R^2 değeriyle dengeli ve güvenilir bir alternatif olarak öne çıkmıştır. CNN modeli de rekabetçi performans göstermiş, ancak hata değerleri bakımından LSTM ve CNN-LSTM’in gerisinde kalmıştır. XGBoost modeli ise eğitim aşamasında kabul edilebilir sonuçlar elde etmesine rağmen test setinde yaklaşık 2,5 MAE ve 10,6 MSE değerleri ile düşük genelleme başarısı sergilemiştir. NSE ve Willmott d metriklerinin 0,96–0,99 aralığında yüksek değerler alması, özellikle LSTM ve CNN-LSTM modellerinin hem ortalama eğilimi hem de uç değerleri doğru biçimde yakalayabildiğini ortaya koymuştur. Genel olarak, LSTM modeli uzun vadeli bağımlılıkları modellemede öne çıkarken, CNN-LSTM modeli kısa dönemli örüntüleri de dikkate alarak karar destek sistemlerinde pratik ve güvenilir bir çözüm sunmaktadır. Bu nedenle, Isparta ili gibi iklimsel değişkenliğin kritik olduğu bölgelerde hibrit derin öğrenme yaklaşımlarının tarım, enerji ve afet yönetimi uygulamalarında etkili bir şekilde kullanılabileceği sonucuna varılmıştır.

Kaynakça

- Aksay, E., Çoban, E., & Güçlü, Y. S. (2025). Normalized innovative trend analysis model and Mann-Kendall test for solar data. *Modeling Earth Systems and Environment*, 11(5), Article 347. <https://doi.org/10.1007/s40808-025-02550-5>
- Alizamir, M. (2025). Daily soil temperature prediction using hybrid deep learning and SHAP for sustainable soil management. *International Journal of Green Energy*. Advance online publication. <https://doi.org/10.1080/19942060.2025.2541686>
- Astsatryan, H., Hakobyan, G., Harutyunyan, A., Poghosyan, M., & Kostanyan, H. (2021). Air temperature prediction using artificial neural networks for the Ararat Valley. *Earth Science Informatics*, 14, 2359–2372. <https://doi.org/10.1007/s12145-021-00583-9>
- Brownlee, J. (2019). *XGBoost With Python: Gradient Boosted Trees with XGBoost and scikit-learn*. Machine Learning Mastery.
- Beloiev, H. I., Saitov, S. R., Filimonova, A. A., Chichirova, N. D., Babikov, O. E., & Iliev, I. K. (2025). Short-Term Electrical Load Forecasting Based on XGBoost Model. *Energies*, 18(19), 5144. <https://doi.org/10.3390/en18195144>
- Buratto, W. G., Muniz, R. N., Nied, A., Barros, C. F. D. O., Cardoso, R., & Gonzalez, G. V. (2024). Wavelet CNN-LSTM time series forecasting of electricity power generation considering biomass thermal systems. *IET Generation, Transmission & Distribution*, 18(21), 3437–3451. <https://doi.org/10.1049/gtd2.13292>
- Chen, T., & Guestrin, C. (2016, August). Xgboost: A scalable tree boosting system. In *Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining* (pp. 785–794). <https://doi.org/10.1145/2939672.2939785>

- Cifuentes, J., Marulanda, G., Bello, A., & Reneses, J. (2020). Air temperature forecasting using machine learning techniques: a review. *Energies*, 13(16), 4215. <https://doi.org/10.3390/en13164215>
- Çoban, E. (2024). Makine öğrenmesi algoritmaları ile yaz sezonu ortalama akım değerlerinin tahmini. *Journal of Innovations in Civil Engineering and Technology*, 6(2), 73–81. <https://doi.org/10.60093/jiciviltech.1497771>
- Fang, Z., Yang, S., Lv, C., An, S., & Wu, W. (2022). Application of a data-driven XGBoost model for the prediction of COVID-19 in the USA: A time-series study. *BMJ Open*, 12(2), e056685. <https://doi.org/10.1136/bmjopen-2021-056685>
- Gao, P., Li, D., Liu, Z., Li, W., & Yang, X. (2023). NDVI prediction based on time series decomposition and CNN–LSTM combination. *Water Resources Management*, 37, 1089–1106. <https://doi.org/10.1007/s11269-022-03419-3>
- Henderi, H., Wahyuningsih, T., & Rahwanto, E. (2021). Comparison of Min-Max normalization and Z-Score Normalization in the K-nearest neighbor (kNN) Algorithm to Test the Accuracy of Types of Breast Cancer. *Indonesian Journal of Information and Information Systems*, 4(1), 1–6. <https://doi.org/10.47738/ijis.v4i1.73>
- Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8), 1735–1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- Hou, J., Li, L., Wang, R., & Wang, Z. (2022). Hourly temperature prediction using CNN–LSTM. *Geomatics, Natural Hazards and Risk*, 13(1), 1138–1157. <https://doi.org/10.1080/19475705.2022.2102942>
- Hou, W., Zhang, X., & Wang, Y. (2022). Hourly air temperature prediction using CNN–LSTM hybrid deep learning model: A case study in Yinchuan, China. *Atmosphere*, 13(8), 1269. <https://doi.org/10.1080/19475705.2022.2102942>
- Kalkınç, H. Y., Çoban, E., & Güçlü, Y. S. (2025). *Wilcoxon testi ve saçılma diyagramı kullanılarak hidrometeorolojik verilerin trend analizi*. *Turkish Journal of Civil Engineering*, 36(5), 1-31. <https://doi.org/10.18400/tjce.1630037>
- Karevan, Z., & Suykens, J. A. K. (2020). Transductive LSTM for time-series prediction: An application to weather forecasting. *Neural Networks*, 125, 1–9. <https://doi.org/10.1016/j.neunet.2019.12.030>
- Kim, T. Y., & Cho, S. (2019). Predicting residential energy consumption using CNN-LSTM neural networks. *Energy*, 182, 72–81. <https://doi.org/10.1016/j.energy.2019.05.230>
- LeCun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278–2324. <https://doi.org/10.1109/5.726791>
- Mutlu, A. Comparative evaluation of NASA, ERA5, and observational data for accuracy and reliability. *Theor Appl Climatol* 156, 367 (2025). <https://doi.org/10.1007/s00704-025-05605-w>
- Nelson, D. M. Q., Pereira, A. M., & de Oliveira, R. A. (2017). Stock market's price movement prediction with LSTM neural networks. In *2017 International Joint Conference on Neural Networks (IJCNN)* (pp. 1419–1426). <https://doi.org/10.1109/IJCNN.2017.7966019>
- Nielsen, D. (2016). Tree boosting with XGBoost: Why does XGBoost win “every” machine learning competition? *Master’s thesis, NTNU*. <http://hdl.handle.net/11250/2433761>
- Oord, A. V. D., Dieleman, S., Zen, H., Simonyan, K., Vinyals, O., Graves, A., ... & Kavukcuoglu, K. (2016). WaveNet: A generative model for raw audio. *arXiv preprint arXiv:1609.03499*. <https://arxiv.org/abs/1609.03499>
- Saplıoğlu, K., & Çimen, M. (2010). Yapay sinir ağlarını kullanarak günlük yağış miktarının tahmini. *Mühendislik Bilimleri ve Tasarım Dergisi*, 1(1), 14–21.
- Utku, A. (2024). CNN–LSTM hibrit modeli ile Bingöl ve Tunceli için hava sıcaklığı tahmini. *International Journal of Pure and Applied Sciences*, 10(2), 550–562. <https://doi.org/10.29132/ijpas.1548698>

- Xiao, C., Liu, X., & Zeng, Z. (2019). Sea surface temperature prediction using LSTM-AdaBoost combination with time series satellite data. *Remote Sensing of Environment*, 233, 111358. <https://doi.org/10.1016/j.rse.2019.111358>
- Yan, H., He, Z., Gao, C., Xie, M., Sheng, H., & Chen, H. (2022). Investment estimation of prefabricated concrete buildings based on XGBoost machine learning algorithm. *Advanced Engineering Informatics*, 54, 101789. <https://doi.org/10.1016/j.aei.2022.101789>
- Yilmaz, M. (2023). Accuracy assessment of temperature trends from ERA5 and ERA5-Land. *Science of The Total Environment*, 856, 159182. <https://doi.org/10.1016/j.scitotenv.2022.159182>
- Yu, Y., Si, X., Hu, C., & Zhang, J. (2019). A review of recurrent neural networks: LSTM cells and network architectures. *Neural computation*, 31(7), 1235-1270. https://doi.org/10.1162/neco_a_01199
- Zhang, P., Jia, Y., & Shang, Y. (2022). Research and application of XGBoost in imbalanced data. *International Journal of Distributed Sensor Networks*, 18(6), 15501329221106935. <https://doi.org/10.1177/15501329221106935>