



Soil temperature forecasting based on time series analysis with transformer models

Muhammet Mücahit Enes Yurtsever¹ , Zeynep Hilal Kilimci^{1*} , Ayhan Küçükmanisa² 

¹Department of Information Systems Engineering, Faculty of Technology, Kocaeli University, İzmit, Kocaeli, 41001, Türkiye

²Department of Electronic and Communications Engineering, Faculty of Engineering, Kocaeli University İzmit, Kocaeli, 41001, Türkiye

Highlights:

- Presents the first systematic application of Transformer models for soil temperature prediction
- Compares Transformer architectures against tree-based and deep learning models
- Demonstrates that Transformer models consistently achieve lower error metrics across various forecasting horizons

Keywords:

- Soil temperature prediction
- Transformer models
- Time series forecasting
- Deep learning
- FLUXNET

Article Info:

Research Article

Received: 21.03.2025

Accepted: 19.01.2026

DOI:

10.17341/gazimmfd.1662870

Correspondence:

Author: Zeynep Hilal Kilimci
e-mail:
zeynep.kilimci@kocaeli.edu.tr
phone: +90 262 303 2242

Graphical/Tabular Abstract

A novel transformer-based framework is proposed for soil temperature forecasting using environmental time-series data from the FLUXNET network. The framework employs advanced transformer architectures-Vanilla Transformer, Informer, Autoformer, Reformer, and ETSformer-to capture long-range temporal dependencies in environmental data. To evaluate its effectiveness, the proposed approach is compared with traditional machine learning methods (Random Forest and XGBoost) and deep learning models (CNN and LSTM) across six FLUXNET stations representing diverse environmental conditions. The results demonstrate that transformer-based models achieve state-of-the-art prediction accuracy and maintain stable performance across different sites.

Table A. Performance comparison of transformer-based models for predicting soil temperature at 96,192,336, and 720 time-steps into the future

Methods	Method Details	Time Step (h)	NL - Loo	FR - Lbr	BE - Vie	IT - Col	FI - Hyy	CH - Lae
(Wang et al., 2021)	GRU & Auxiliary Network	24	-	-	-	-	-	1.028
(Hao et al., 2021)	EEMD-CNN	120	-	-	-	-	-	0.498
(Li et al., 2022)	Attention-based LSTM	168	0.352	0.811	1.119	2.947	3.268	-
Proposed Method	Reformer	192	0.158	0.251	0.258	0.174	0.204	0.297

Purpose: This study aims to develop a transformer-based framework for accurate soil temperature forecasting by exploiting advanced attention mechanisms capable of modeling long-range temporal dependencies in environmental time series.




Theory and Methods: Environmental time-series data from six FLUXNET stations are preprocessed to remove noise and extract temporal patterns from a 96-hour input sequence. Random Forest and XGBoost are used as machine learning baselines, while CNN and LSTM represent conventional deep learning approaches. Five transformer variants-Vanilla Transformer, Informer, Autoformer, Reformer, and ETSformer-are implemented to capture complex temporal dependencies. These architectures incorporate advanced attention mechanisms such as locality-sensitive hashing (Reformer) and exponential smoothing (ETSformer) to efficiently model long-term patterns. Model performance is evaluated using Mean Squared Error (MSE) and Mean Absolute Error (MAE) across multiple forecasting horizons (96, 192, 336, and 720 hours), (Table A). The input sequence length for these models is 96 timesteps, and the table shows the results for different prediction horizons across the six FLUXNET stations

Results: Experimental results show that transformer-based models consistently outperform both tree-based and conventional deep learning methods, particularly for longer prediction horizons. The models achieve significantly lower MAE values and demonstrate stable performance across all six FLUXNET stations, confirming their robustness under different environmental conditions.

Conclusion: The proposed transformer-based framework provides a scalable and accurate solution for soil temperature forecasting. By effectively capturing long-range dependencies in environmental time series, the approach surpasses traditional machine learning and deep learning models, offering a reliable tool for environmental monitoring, climate analysis, and agricultural decision support.



Transformatör modelleri ile zaman serisi analizi tabanlı toprak sıcaklığı tahmini

Muhammet Mücahit Enes Yurtsever¹ , Zeynep Hilal Kilimci^{1*} , Ayhan Küçükmanisa² 

¹Kocaeli Üniversitesi, Teknoloji Fakültesi, Bilişim Sistemleri Mühendisliği Bölümü, İzmit, Kocaeli, 41001, Türkiye

²Kocaeli Üniversitesi, Mühendislik Fakültesi, Elektronik Haberleşme Mühendisliği Bölümü, İzmit, Kocaeli, 41001, Türkiye

Ö N E Ç İ K A N L A R

- Toprak sıcaklığı tahmini için transformatör modellerinin ilk sistematik uygulamasını sunar
- Transformatör mimarilerini, ağaç tabanlı modeller ve derin öğrenme modelleri ile karşılaştırır
- Transformatör modellerinin, farklı tahmin sürelerinde daha düşük hata metrikleri sağladığını gösterir

Makale Bilgileri

Araştırma Makalesi

Geliş: 21.03.2025

Kabul: 19.01.2026

DOI:

10.17341/gazimmfd.1662870

Anahtar Kelimeler:

Derin öğrenme,
FLUXNET,
toprak sıcaklığı tahmini,
transformatör modeller,
zaman serisi kestirimi

ÖZ

Toprak sıcaklığı; buzulların enerji dengesi, kütle dengesi, ekolojik istikrar ve tarımsal verimlilik üzerinde belirleyici bir değişken olup, karmaşık ve doğrusal olmayan etkileşimler nedeniyle doğru biçimde tahmin edilmesi güçtür. Mevcut yöntemler bu karmaşıklıkları yeterince temsil edemediğinden, daha gelişmiş modellere ihtiyaç duyulmaktadır. Bu çalışma, toprak sıcaklığı tahmini için transformatör tabanlı yeni bir çerçeve önermektedir. Transformator mimarilerinin uzun vadeli bağımlılıkları ve zamansal örüntüleri yakalama konusundaki üstün yeteneklerinden yararlanılarak çevresel veriler üzerinde yüksek doğruluklu bir tahmin modeli geliştirilmiştir. Modelin geliştirilmesi ve değerlendirilmesi için altı farklı FLUXNET istasyonundan elde edilen veriler kullanılmıştır. Karşılaştırmalı analizler; ağaç tabanlı yöntemler, klasik derin öğrenme mimarileri ve beş gelişmiş transformator modeli (Vanilla Transformer, Informer, Autoformer, Reformer ve ETSformer) ile gerçekleştirilmiştir. Sonuçlar, transformator tabanlı modellerin tahmin doğruluğu bakımından geleneksel yaklaşımlara kıyasla belirgin üstünlük sağladığını göstermektedir. Ayrıca önerilen yöntemin farklı çevresel koşullarda tutarlı, sağlam ve geliştirilebilir performans sergilediği doğrulanmıştır. Bulgular, transformator modellerinin çevresel tahmin problemlerinde, özellikle toprak sıcaklığı öngörüsünde, yüksek potansiyele sahip olduğunu ortaya koymakta hem bilimsel anlayışa katkı sağlamak hem de ölçeklenebilir, güvenilir ve pratik uygulamalara uygun bir araç sunmaktadır.

Soil temperature forecasting based on time series analysis with transformer models

H I G H L I G H T S

- Presents the first systematic application of Transformer models for soil temperature prediction
- Compares Transformer architectures against tree-based and deep learning models
- Demonstrates that Transformer models consistently achieve lower error metrics across various forecasting horizons

Article Info

Research Article

Received: 21.03.2025

Accepted: 19.01.2026

DOI:

10.17341/gazimmfd.1662870

Keywords:

Deep learning,
FLUXNET,
soil temperature prediction,
transformer models,
time series forecasting

ABSTRACT

Soil temperature is a critical variable influencing glacier energy balance, mass balance, ecological stability, and agricultural productivity; however, its accurate prediction remains challenging due to complex and nonlinear interactions. Existing methods often fail to adequately capture these complexities, highlighting the need for more advanced modeling approaches. This study proposes a novel transformer-based framework for soil temperature forecasting. Leveraging the superior capability of transformer architectures to model long-term dependencies and temporal patterns, a high-accuracy predictive model is developed using environmental data. Data collected from six FLUXNET stations are employed for model development and evaluation. Comparative analyses are conducted against tree-based methods, conventional deep learning architectures, and five advanced transformer models (Vanilla Transformer, Informer, Autoformer, Reformer, and ETSformer). Experimental results demonstrate that transformer-based models achieve substantially higher predictive accuracy than traditional approaches. Moreover, the proposed method exhibits consistent, robust, and generalizable performance across diverse environmental conditions. These findings indicate that transformer models hold significant promise for environmental forecasting tasks, particularly for soil temperature prediction. The study contributes to advancing scientific understanding of soil temperature dynamics while providing a scalable, reliable, and practically applicable tool. Overall, the proposed approach addresses complex environmental prediction challenges and underscores the transformative potential of transformer-based methodologies for future research and applications.

*Sorumlu Yazar / Yazarlar / *Corresponding Author / Authors: enes.yurtsever@kocaeli.edu.tr, *zeynep.kilimci@kocaeli.edu.tr, ayhan.kucukmanisa@kocaeli.edu.tr / Tel: +90 262 303 2242

1. Giriş (Introduction)

Toprak sıcaklığının çevresel dinamikler bağlamındaki önemi, birçok ekolojik süreç üzerindeki karmaşık etkileriyle desteklenmekte olup, ekosistem yapısı ve işleyişinin temel belirleyicilerinden biri haline gelmektedir. Toprak sıcaklığının etkileri, biyotik ve abiyotik unsurların geniş bir yelpazesinde hissedilmekte ve biyokimyasal döngülerin oluşumunda, bitki fizyolojisinin şekillenmesinde ve genel çevresel dinamiklerin belirlenmesinde kritik bir rol oynamaktadır.

Toprak sıcaklığının önemi, biyokimyasal döngüleri yönlendirmedeki kritik rolünden kaynaklanmaktadır. Toprak sıcaklığı, mikrobiyal enzim kinetiği üzerinde belirgin bir etkiye sahip olup, organik madde ayrışma ve besin mineralizasyon hızlarını düzenlemektedir. Bu temel süreç, ekosistem besin maddesi mevcudiyetini ve döngü dinamiklerini belirleyerek birincil üretkenliği ve trofik etkileşimleri etkilemektedir. Adair vd. [1] tarafından belirtildiği gibi, sıcaklık ile yakından ilişkili olan mikrobiyal aktivite, toprak ekosistemlerinde besin döngüsünü ve kullanılabilirliğini düzenlemektedir. Toprak sıcaklığının besin dinamiklerindeki merkezi rolünü vurgulamaktadır.

Buna ek olarak, toprak sıcaklığı bitkilerin fizyolojik tepkilerini belirleyerek bitki örtüsü dinamikleri ve dağılım modelleri üzerinde etkili olmaktadır. Termal rejim, çimlenme, vejetatif büyüme ve çiçeklenme gibi fenolojik evreleri doğrudan düzenleyerek türlerin ekosisteme yerleşimini ve rekabetçi etkileşimlerini şekillendirmektedir. Bykova vd. [2] tarafından yapılan araştırma, sıcaklık rejimindeki sapmaların bitki fenolojisini nasıl etkilediğini, ekosistem içindeki senkronizasyonu bozarak tür bileşiminde değişimlere yol açabileceğini ortaya koymaktadır. Toprak sıcaklığının etkileri sadece karasal ekosistemlerle sınırlı kalmayıp sucul ekosistemlere de uzanmaktadır. Değişen toprak sıcaklığı rejimleri, çevredeki su kütlelerinde termal dalgalanmalar yaratarak sucul organizmaların fizyolojisini ve dağılımını etkilemektedir. Bu bağlantılı süreç, Fabris vd. [3] tarafından yapılan çalışmada açıkça görülmektedir. Çalışmada, toprak sıcaklığı kaynaklı termal değişimlerin akarsu sıcaklıklarını nasıl etkilediği ve bunun sucul türlerin metabolizma hızları ile yaşam alanı uygunluğuna nasıl yansıtıldığı incelenmiştir.

Bunun yanı sıra, toprak sıcaklığı karbon dinamikleri ve sera gazı emisyonları ile yakından ilişkilidir. Yükselen toprak sıcaklıkları, mikrobiyal solunum hızlarını artırarak atmosfere salınan karbon dioksit miktarını yükseltmektedir. Bu durum, iklim değişikliği sürecini şiddetlendirmekte ve küresel karbon döngüsüne katkıda bulunmaktadır. Bu bağlamda, Davidson vd. [4] tarafından yürütülen çalışmada, toprak sıcaklığı, mikrobiyal aktivite ve sera gazı emisyonları arasındaki karmaşık geri besleme mekanizmalarını ayrıntılı bir şekilde ortaya koymaktadır.

Toprak sıcaklığının ekosistem üzerindeki büyük etkileri göz önüne alındığında, toprak sıcaklığının doğru belirlenmesi önemli ve yaygın bir araştırma konusu haline gelmiştir. Toprak sıcaklığı, biyokimyasal döngülerin merkezinde yer almakta olup, besin döngüsünü ve ekosistem işleyişini yönlendiren mikrobiyal aktiviteleri düzenlemektedir. Besin dinamiklerini tam anlamıyla kavrayabilmek için toprak sıcaklığının toprak nemi, organik madde içeriği ve mikrobiyal topluluk yapısı gibi parametrelerle nasıl etkileşime girdiğinin anlaşılması gerekmektedir. Toprak sıcaklığının doğru ölçülmesi, bu karmaşık ilişkileri ortaya çıkararak araştırmacıların besin salınım hızlarını tahmin etmesine, besin yönetim stratejilerini optimize etmesine ve ekosistemlerin dayanıklılığını sağlamasına olanak tanımaktadır.

Bitki ekolojisi bağlamında, toprak sıcaklığı fenolojik geçişlerin ve tür dağılımlarının belirleyicisi konumundadır. Toprak sıcaklığının doğru

tahmin edilmesi, onun güneş radyasyonu, nem mevcudiyeti ve bitki örtüsü gibi faktörlerle nasıl etkileşim içinde olduğunu anlamaya yardımcı olur. Bu bulgular, ekolojistlerin bitki yaşam stratejilerindeki değişimleri öngörmesini sağlayarak türlerin sürekliliğini güvence altına alan, genetik çeşitliliği koruyan ve bozulan alanları eski haline getiren koruma stratejilerinin oluşturulmasına katkıda bulunur.

Ayrıca, kara ve su ekosistemleri arasındaki termal bağlantı, doğru toprak sıcaklığı tahminine dayanmaktadır. Toprak sıcaklığındaki dalgalanmaların çevredeki su kütlelerine nasıl yayıldığını anlamak, bilim insanlarına ekosistemler arası termal etkileşimleri bütüncül bir bakış açısıyla değerlendirme imkânı sunar. Bu bilgi, sucul habitatların korunması, türlerin termal değişimlere nasıl tepki vereceğinin öngörülmesi ve sucul besin ağlarını oluşturan karmaşık trofik ilişkilerin sürdürülebilirliğini sağlamak için kritik öneme sahiptir.

Daha geniş bir çerçevede değerlendirildiğinde, toprak sıcaklığı tahmini, sıcaklık değişimlerinin karbon dinamikleri üzerindeki etkisini ölçmek için vazgeçilmez bir araçtır. Hassas ölçümler, toprak sıcaklığı ile karbon döngüsünün temel taşı olan mikrobiyal aktivite arasındaki ilişkiyi açığa çıkarmaktadır. Küresel çabalar sera gazı emisyonlarını azaltmaya odaklanırken, toprak sıcaklığı tahmini karbon akışlarını izlemeyi, arazi yönetim stratejilerini optimize etmeyi ve sürdürülebilir, karbon-nötr bir geleceğe katkı sağlamayı mümkün kılmaktadır.

Toprak sıcaklığı, temel bir çevresel parametre olup, değişkenliğini belirleyen birçok karmaşık faktöre bağlıdır. Bu faktörler arasında mevsimsellik, güneş radyasyonu, hava sıcaklığı, toprak nemi, toprak bileşimi ve bitki örtüsü yer almaktadır. Bu faktörlere dayalı bilgiler ışığında, toprak sıcaklığı termokupullar, dirençli termometreler, toprak sıcaklık problemleri, kızılötesi termometreler ve uydu tabanlı sensörler gibi kaynaklardan sağlanan veriler kullanılarak ölçülebilmektedir. Öte yandan, son yıllarda makine öğrenmesi tabanlı yöntemler, toprak sıcaklığı tahmininde büyük bir popülerlik kazanmış olup, veri odaklı yaklaşımlar sunarak toprak sıcaklığı dinamiklerinin karmaşıklığını anlamaya, bilinçli kararlar alınmasına, çevresel sistemlere dair daha derin bir kavrayış geliştirilmesine ve tüm bu süreçlerin otomatikleştirilmesine olanak tanımaktadır. Bununla birlikte, makine öğrenmesi tabanlı yaklaşımların; finansal zaman serilerinin analizi, güneş ışınımı tahmini, endüstriyel ısı transferi süreçleri ve hidrolojik akım tahmini gibi farklı disiplinlerde de başarıyla uygulandığı literatürde açıkça görülmektedir [36–39].

Bu çalışmada, toprak sıcaklığının tahmini amacıyla transformatör modellerini kullanan öncü bir yöntem tanıtılmaktadır. Mevcut literatür çerçevesinde, transformatör modellerinin bu kapsamda kullanımı, toprak sıcaklığı tahminine yönelik ilk girişim olma özelliğini taşımaktadır. Yapılan deneysel çalışmalar, altı farklı FLUXNET istasyonunu kapsamakta olup, bu istasyonlardan elde edilen veriler beş farklı transformatör modeli (Vanilla Transformer, Informer, Autoformer, Reformer ve ETSformer) kullanılarak analiz edilmiştir. Önerilen çerçevenin etkinliğini vurgulamak amacıyla, elde edilen deneysel bulgular hem derin öğrenme metodolojileri hem de mevcut akademik çalışmalar ile karşılaştırılmıştır. Bu bulgular, transformatör modellerinin önemli bir değer taşıdığını doğrulamakla kalmayıp, aynı zamanda bu modellerin akademik alandaki katkıları önemli ölçüde artırma potansiyeline sahip olduğunu ortaya koymaktadır. Böylece, toprak sıcaklığı tahmini alanında çığır açan yeni bir paradigma oluşturulmaktadır.

Bu çalışmanın temel katkıları şu şekilde özetlenmiştir:

- Bu çalışma, çevresel modellemede kritik bir zorluğu ele alarak toprak sıcaklığının tahmin doğruluğunu artırmaya yönelik öncü bir transformatör tabanlı yaklaşım sunmaktadır.

- Toprak sıcaklığının modellenmesi için zaman serisi verilerine transformatör mimarilerinin ilk kez sistematik olarak uygulandığı bu çalışma, bu alanda yeni bir referans noktası oluşturmaktadır.
- Önerilen çerçevenin performansını değerlendirmek üzere kapsamlı deneysel karşılaştırmalar yapılmış; en son teknoloji transformatör modelleri, geleneksel ağaç tabanlı modeller ve ileri derin öğrenme teknikleriyle karşılaştırılmıştır. Bu karşılaştırmalar, önerilen yaklaşımın üstün performansını ve sağlamlığını ortaya koymaktadır.
- Önerilen model, çeşitli FLUXNET istasyonları ve zaman ölçeklerindeki değişimleri etkili şekilde yakalayan güçlü bir genelleme yeteneği sergilemekte, böylece gerçek dünya uygulamalarında güvenilirliği garanti altına almaktadır.
- Çalışma, mevcut metodolojilere kıyasla kayda değer bir iyileşme sağlayarak toprak sıcaklığı tahmininde en son teknoloji yaklaşımları geride bırakmakta ve bu alandaki literatüre önemli bir katkı sunmaktadır.

Makalenin organizasyonu şu şekildedir: Bölüm 2, toprak sıcaklığı tahmini ve ilgili konulara dair literatürü sunmaktadır. Bölüm 3, çalışmada kullanılan veri toplama aşamalarını, yöntemleri ve önerilen metodolojiyi tanıtmaktadır. Deneysel kurulum ve sonuçlar Bölüm 4'te verilmiştir. Bölüm 5 ise sonuçları özetlemekte, tartışmakta ve gelecek araştırma yönergelerini ortaya koymaktadır.

2. Literatür Çalışmaları (Related Works)

Bu bölüm, toprak sıcaklığı tahmini üzerine odaklanan literatür çalışmalarının bir özeti sunmaktadır. Toprak sıcaklığı tahminine odaklanan çalışmaların yanı sıra, toprak sıcaklığının kullanıldığı veya bahsedildiği birçok alandaki çalışmaları da incelemekteyiz. Bu alanlar arasında toprak nemi ve sulama yönetimi, bitki büyümesi ve verimliliği, tohum çimlenmesi ve fide gelişimi, toprak organizmaları ve mikroorganizmalar, toprak kimyası ve besinler, hastalıklar ve zararlılar, toprak erozyonu ve yüzey sıcaklığı, çevresel değişiklikler ve iklim etkileri gibi konular yer almaktadır.

Bir sistematik literatür taramasında [5] toplam 129 akademik makale, derin öğrenme (DL) uygulamalarının tarım alanındaki kullanımına odaklanarak incelenmiş ve bu çalışmalar beş farklı uygulama alanına ayrılmıştır: Mahsul verimi tahmini, bitki stresi tespiti, yabani ot ve zararlıların tanımlanması, hastalık tespiti ve akıllı tarım uygulamaları. "Akıllı tarım" şemsiyesi altında su kaynakları yönetimi, tohum incelemesi ve toprak kompozisyonunun kapsamlı analizi gibi alt kategoriler de ele alınmıştır. Mevcut akademik araştırma, DL yöntemlerinin tarımsal üretimi artırma ve ekonomik ilerlemeyi destekleme potansiyelini vurgulamaktadır. Çalışma, özellikle Evrişimli Sinir Ağları (CNN), Tekrarlayan Sinir Ağları (RNN), AlexNet ve ResNet gibi denetimli öğrenme ağlarının tarım sektöründe öne çıktığını ve ekonomik refahı artırmada etkili olduğunu ortaya koymaktadır. Bu araştırma, akıllı tarım uygulamalarını kolaylaştırmak ve sürdürülebilir bir tarım ortamı yaratmak için derin öğrenmenin potansiyelini tam olarak kullanmak amacıyla bu alanda sürekli akademik araştırmaların gerekliliğini savunmaktadır.

Bir başka sistematik literatür taraması, hiperspektral görüntüleme teknolojisi ve tarım uygulamalarında kullanılan ileri düzey DL ve makine öğrenmesi algoritmalarına odaklanarak gerçekleştirilmiştir [6]. Bu çalışma, önemli veri setlerini ve algoritmaları çıkarmak ve birleştirmek amacıyla yürütülmüştür. Araştırma, Hyperion hiperspektral, Landsat-8 ve Sentinel 2 çok bantlı veri setlerinin tarım uygulamalarında en yaygın şekilde kullanıldığını ortaya koymaktadır. En sık uygulanan makine öğrenmesi yöntemi ise destek vektör makineleri ve rastgele orman (RF) algoritmalarıdır. Ayrıca, mahsul sınıflandırma görevi, hiperspektral veri setleriyle başa çıkmadaki kanıtlanmış etkinliği nedeniyle, DL temelli CNN modeli tarafından

gerçekleştirilmektedir. Bu incelemenin, özellikle makine ve DL yöntemlerinin geçerli olduğu tarım uygulamaları bağlamında, hiperspektral uzaktan algılama alanındaki yeni araştırmacılar için büyük bir fayda sağlayacağı öngörülmektedir.

Zhang vd. çalışmalarında [7], toprak solunumunun (Rs) karasal ekosistemlerde sıcaklık ve yağış tedavilerine verdiği tepki, 178 sıcaklık tedavisi ve 134 yağış tedavisini kapsayan çalışmaların birleştirilmesiyle incelenmiştir. Sonuçlar, ısıma ve yağıştaki ortalama artışların sırasıyla Rs'yi %13,1 ve %33,1 oranında artırdığını göstermektedir. Ayrıca, yazarlar, Rs ile ilgili etki büyüklüklerinin pozitifliğinin, ortalama yıllık sıcaklık (MAT), ortalama yıllık yağış (MAP), yükseklik ve deney süresi (DUR) gibi çeşitli küresel değişkenlerde gözlemlenebildiğini bildirmektedir. Bu belirgin eğilimin, Rs'nin küresel iklim koşullarının geniş yelpazesine güçlü bir bağlılık gösterdiğine işaret ettiği vurgulanmaktadır. Bunun yanı sıra, diğer çevresel faktörlerin yağış ve sıcaklıkla etkileşiminin çarpıcı olduğu ve Rs üzerinde dolaylı bir değişikliğe neden olduğu ifade edilmektedir.

Saatlik toprak sıcaklığı tahmini için Seifi vd. [8], hibrit bir model sunmaktadır. Ayçiçeği optimizasyonu (SFO), Ateşböceği algoritması (FFA), Salp sürü algoritması (SSA) ve parçacık sürü optimizasyonu (PSO) optimizasyon algoritmaları, adaptif sinir bulanık arayüz sistemi (ANFIS), destek vektör makinesi (SVM), radyal tabanlı fonksiyon sinir ağı (RBFNN) ve çok katmanlı algılayıcı (MLP) makine öğrenmesi algoritmalarıyla birleştirilerek toprak sıcaklığı tahmininde daha iyi bir doğruluk elde edilmesi amaçlanmıştır. İran'da, 5, 10 ve 30 cm toprak derinliklerinde saatlik olarak deneyler yürütülmüştür. Yazarlara göre, hibrit meta-sezgisel modeller kullanıldığında, önerilen teknik toprak sıcaklığı tahmini için güvenilir ve doğru sonuçlar vermektedir.

Singhal vd. [9], Orta Himalaya bölgesinin toprak sıcaklığını tahmin etmek için bir Yapay Sinir Ağı (ANN) modeli kullanmaktadır. Çok katmanlı dokuz farklı ANN modeli, çeşitli derinliklerdeki toprak sıcaklıklarını tahmin etmek için oluşturulmuştur. Eşzamanlı ve önceki hava-toprak sıcaklığı verileri üzerinde yapılan deneyler, en iyi ANN varyasyonunu göstermiştir. Makale, önerilen ANN modelinin Orta Himalaya'nın buzul önü bölgeleri için sağlam tahmin sonuçları sağladığını belirtmektedir.

Bayatvarkeshi vd. [10], farklı iklim koşullarında hava sıcaklığı özelliklerini kullanarak toprak sıcaklığını tahmin etmeye odaklanmaktadır. Bu amaçla, dalgacık dönüşümüyle birleştirilen ANN ve ko-aktif nöro-bulanık çıkarım sistemleri (CANFIS) modelleri (sırasıyla WANN ve WCANFIS) kullanılmıştır. Önerilen yaklaşımın etkinliğini göstermek için, 2000-2010 yılları arasında İran'da 12 farklı lokasyonda 5, 10, 20, 30, 50 ve 100 cm toprak derinliklerinde toplanan verilerle deneyler yapılmıştır. Deneysel sonuçlar, hibrit WCANFIS modelinin toprak sıcaklığını tahmin etmede daha iyi bir tahmin yeteneğine sahip olduğunu ve 0,43 °C² RMSE skoru elde ettiğini göstermektedir.

Hindistan'ın yarı kurak bir bölgesinde günlük toprak sıcaklığını tahmin etmek için makine öğrenmesi algoritmalarını optimizasyon teknikleriyle birleştiren bir hibrit model sunulmaktadır [11]. SVM, MLP ve ANFIS teknikleri, slime mould algoritması (SMA), PSO ve benekli sırtlan optimizasyonu (SHO) algoritmalarıyla birleştirilmiştir. SVM ve SMA modellerinin birleştirilmesi, 5 cm, 15 cm ve 30 cm toprak derinliklerinde en iyi MAE skorlarını göstermektedir. Bir başka çalışmada [12], Türkiye'deki Giresun ve Bayburt istasyonlarının toprak sıcaklığını tahmin etmek için makine öğrenmesi algoritmalarının kullanımı önerilmiştir. Bayesian Ayrık Gaussian Process Regression (BT-GPR), Bayesian Ayrık Destek Vektör Regresyonu (BT-SVR) ve Uzun Kısa Süreli Bellek (LSTM)

teknikleri, beş buçuk yıllık günlük veri üzerinde modellenmiştir. Yazar, BT-GPR yaklaşımının 5 cm derinlikteki toprak sıcaklığını tahmin etmede 0,0525 °C RMSE skoruyla en iyi tahmin performansını sergilediği sonucuna varmıştır. Bir diğer çalışmada [13], toprak nemi ve sıcaklığını tahmin etmek için dikkat mekanizmalı uzun kısa vadeli bellek ağı modeli geliştirilmiştir. Önerilen model, RF, destek vektör regresyonu (SVR), elastik-net (ENET) ve orijinal LSTM teknikleriyle karşılaştırılarak 1 ve 7 günlük FLUXNET veri setleri üzerinde deneyler yapılmıştır. Deney sonuçları, önerilen LSTM modelinin literatürdeki çalışmalarla karşılaştırıldığında çoğunlukla üstün tahmin performansı sergilediğini göstermektedir. Bir başka çalışmada [14], 2018-2021 yılları arasında Çin'in Yangling istasyonundaki toprak sıcaklığını tahmin etmek için 1D-CNN-MLP sinir ağı çerçevesi tanıtılmaktadır. Önerilen modelin etkinliğini göstermek için MLP ve LSTM modellerinin performansıyla karşılaştırmalı bir analiz yapılmıştır. Elde edilen deneysel sonuçlara dayanarak, yazarlar 1D-CNN-MLP modelinin kullanımının alternatif tekniklere kıyasla daha üstün tahmin doğruluğu sağladığı kesin sonucuna varmışlardır. Bu bulgu, önerilen modelin belirli alandaki tahmine dayalı modelleme zorluklarını ele almadaki artan etkinliğini ve potansiyelini vurgulamaktadır.

Bir başka çalışmada [15], toprak sıcaklığını tahmin etmek için LSTM bellek ağlarını kullanarak DL yaklaşımının etkinliği gösterilmektedir. Yazarlar, 2013-2021 yılları arasında Bingöl civarında 50 cm toprak derinliğindeki toprak sıcaklığını tespit etmeye odaklanmıştır. Deney sonuçları, önerilen LSTM modelinin 1,25 °C RMSE skoru elde ettiğini göstermektedir. Diğer bir çalışma [16], toprak sıcaklığının sıralı kategorizasyonunu sağlayan yeni bir makine öğrenmesi temelli çerçeve önermektedir. En uygun algoritmayı bulmak için karar ağacı, naïve Bayes, k-en yakın komşular, destek vektör makineleri ve RF gibi beş farklı geleneksel makine öğrenmesi algoritması kullanılmıştır. Veri seti, 2011-2020 yılları arasında Amerika Birleşik Devletleri'nin üç eyaletinde 2, 4, 8, 20 ve 40 inç toprak derinliklerinden toplanmıştır. Çalışma, karar ağacı modelinin %90,95 doğruluk skoruyla en iyi sınıflandırma performansını sergilediği sonucuna varmıştır. Bir diğer çalışma [17], güneydoğu Kanada'daki kara-su arayüzünde toprak sıcaklığı ve su içeriğinin mekansal interpolasyonu bağlamında, radyal tabanlı fonksiyon sinir ağları ve DL tekniklerinin gücünden yararlanan bir metodoloji önermektedir. Deneysel çalışmalar, bu yöntemlerin ani geçişlerin olduğu bölgelerde bile toprak sıcaklığı verilerini etkili bir şekilde enterpole etme yeteneklerini göstermektedir. Sonuçlar, radyal tabanlı fonksiyon sinir ağları ve DL yaklaşımlarının coğrafi olarak karmaşık alanlarda mekansal interpolasyonla ilişkili zorlukları ele alma potansiyelini vurgulamaktadır. Bir başka çalışma [18], Sivas bölgesinde 5 cm, 50 cm ve 100 cm toprak derinliklerinde toprak sıcaklığı tahmini için makine öğrenmesi algoritmalarının performansına odaklanmaktadır. ANFIS ağı ile bulanık c-ortalama (ANFIS-FCM), izgara bölümlenme (ANFIS-GP), çıkarımsal kümeleme (ANFIS-SC), ileri beslemeli sinir ağı (FNN), Elman sinir ağı (ENN) ve LSTM sinir ağı yöntemleri kullanılarak kapsamlı deneyler yapılmıştır. Yazarlar, 5 cm toprak derinliğinde ENN, 50 cm toprak derinliğinde FNN ve 100 cm toprak derinliğinde ANFIS-GP'nin en iyi tahmin performansını sağladığını bildirmektedir.

Bir diğer çalışma [19], İzmir bölgesinde toprak sıcaklığını tahmin etmek için kendi kendine öğrenme adı verilen yeni bir model sunmaktadır. IoT cihazları tarafından saatlik özelleştirilmiş toprak verileri ve yaklaşık dokuz aylık meteorolojik veriler toplanmıştır. Yazarlar, önerilen tekniğin Extreme Gradient Boosting (XGBoost) tekniğiyle birleştirildiğinde, tüm toprak derinlikleri (10, 20, 30, 40 ve 50 cm) için 0,385 °C² ile 2,888 °C² arasında değişen MSE skorlarıyla en iyi performansı gösterdiğini bildirmektedir. Bir başka çalışmada [20] ise Ottawa bölgesinde toprak sıcaklığını tahmin etmek için geleneksel makine öğrenmesi algoritmalarından ileri düzey yapay

zeka tekniklerine kadar on üç yaklaşımı kapsayan kapsamlı bir karşılaştırma yapılmıştır. Deney sonuçları, DL yaklaşımının 0,980 R-kare ve %2,237 NRMSE ile en iyi tahmin performansını sergilediğini göstermektedir. Diğer bir çalışmada [21], Yazoo kilinde toprak sıcaklığını tahmin etmek için ANN temelli yeni bir yaklaşım sunmaktadır. Çalışma, Mississippi'nin Jackson metropol bölgesi içinde 25 millik yarıçapta bulunan altı enstrümanlı eğitim üzerinde odaklanılmaktadır. On yedi ay boyunca, eğitimlerin tepesinde 1,5 metre (5 feet) derinlikteki hacimsel nem içeriği, yağış, hava sıcaklığı ve toprak sıcaklığına ilişkin kapsamlı veriler toplanmıştır. Levenberg-Marquardt (LM) algoritmasının Tan-sigmoid transfer fonksiyonuyla birlikte kullanılması, önerilen yöntemin toprak sıcaklığını doğru bir şekilde tahmin etmedeki etkinliğini göstermektedir. Bu bulgular, ANN temelli yaklaşımların toprak sıcaklığı dinamiklerini anlama ve çevresel değerlendirmelere yardımcı olma potansiyelini vurgulamaktadır. Bir diğer çalışma [22], çoklu görünüm ve çoklu derinlikteki toprak sıcaklığını tahmin etmek için makine öğrenmesi ve zaman serisi tekniklerini kullanan yeni bir yaklaşım önermektedir. Önerilen çerçeve, önceki toprak verileri ve geçmiş meteorolojik veriler birleştirilerek modellenmiştir. Deney sonuçları, destek vektör regresyonu tekniğinin kullanımının, tahmin edilen toprak sıcaklığı değerlerinin gerçek değerlere yaklaşması açısından diğer yöntemlere kıyasla üstün performans sergilediğini göstermektedir.

Wang vd. [23], İsviçre'de toprak sıcaklığını tahmin etmek için yeni bir gömülü yaklaşım tasarlanmaktadır. Önerilen çerçeveyi uygulamak için, toprak sıcaklığı verilerinin küresel ve yerel özelliklerini toplamak üzere bir gated recurrent unit (GRU) modeli oluşturulmuştur. Laegern ve Fluehli istasyonlarından toplanan veriler, 5 cm, 10 cm ve 15 cm toprak derinliklerinde 6 saat, 12 saat ve 24 saatlik zaman noktalarını içermektedir. GRU modeline ek olarak, ANN, extreme learning machine model (ELM) ve LSTM yöntemleri, önerilen çerçevenin katkısını göstermek için modellenmiştir. Yazarlar, GRU modelinin kullanımının minimum RMSE, MAE ve MSE skorlarıyla en iyi tahmin performansını sağladığı sonucuna varmıştır. Abimbola vd. [24], Amerika Birleşik Devletleri genelinde günlük toprak sıcaklığı tahminini artırmak için bilgi destekli bir makine öğrenmesi yaklaşımı sunmaktadır. ANFIS yöntemi kullanılarak, 5, 10, 20, 50 ve 100 cm toprak derinliklerinde toprak sıcaklığı tahmin doğruluğunu artırmak için meteorolojik parametrelerin yeni bir dönüşümü kullanılmıştır. Her toprak derinliği için toprak sıcaklığını tahmin etmek üzere, meteorolojik özelliklerin dönüşümsüz (NT), otokorelasyon (AC), hareketli ortalama (MA) ve kombinasyon dönüşümleri (NT-ACMA) kullanılmıştır. Deney sonuçları, NT-ACMA modelinin genellikle her iki toprak dokusunda da 0,99 R-kare ile en iyi doğruluk skorunu sergilediğini göstermektedir.

Bu araştırma kapsamında, literatürdeki önceki çalışmalardan farklı olarak, transformatör modellerinin yeteneklerinden yararlanan yenilikçi bir çerçeve sunuyoruz. Bilgimiz dahilinde, bu çalışma, toprak sıcaklığı tahmini alanında transformatör modellerinin ilk kez kullanıldığı bir araştırma niteliği taşımaktadır. Önerilen modelin katkısını göstermek için, Hollanda, Fransa, Belçika, İtalya, Finlandiya ve İsviçre'deki altı farklı FLUXNET istasyonunda deneyler yapılmıştır. Ayrıca, adil bir karşılaştırma sağlamak için deney sonuçları, bağımsız DL teknikleri, ağaç temelli modeller ve literatür çalışmalarıyla karşılaştırılmıştır. Deney sonuçları, transformatör modellerinin kullanımının önemli ölçüde tahmin performansı sergilediğini ve bu nedenle yeni bir state-of-the-art (en iyi performans) belirlediğini göstermektedir.

3. Önerilen Çerçeve (Proposed Framework)

Doğal dil işleme (NLP) görevleri için tasarlanan transformatör modelleri, bilgisayarlı görü, zaman serisi tahmini ve çeşitli diğer

konularda da popülerdir. Bu popülerliğin temel nedenlerinden biri, transformatör modellerinin sıralı verilerde uzun süreli bağımlılıkları yakalayabilmesidir. Bu çalışmada, farklı zaman adımlarında toprak sıcaklığını tahmin etmek için DL, ağaç temelli modeller ve transformatör temelli modeller karşılaştırılmıştır. Elde edilen sonuçlara göre, transformatör temelli modeller, çok değişkenli ve çok adımlı zaman serisi verilerini tahmin etmede state-of-the-art sonuçlar elde etmiştir. Önerilen yöntemin genel mimarisi Şekil 1'de verilmiştir. Şekil 1'de, toprak sıcaklığını tahmin etmek için üç ayrı yol bulunmaktadır. LSTM ve CNN temelli modeller, ağaç temelli makine öğrenmesi modelleri ve önerilen transformatör temelli teknikler kullanılarak toprak sıcaklığı tahmini yapılmış ve bir performans karşılaştırması gerçekleştirilmiştir.

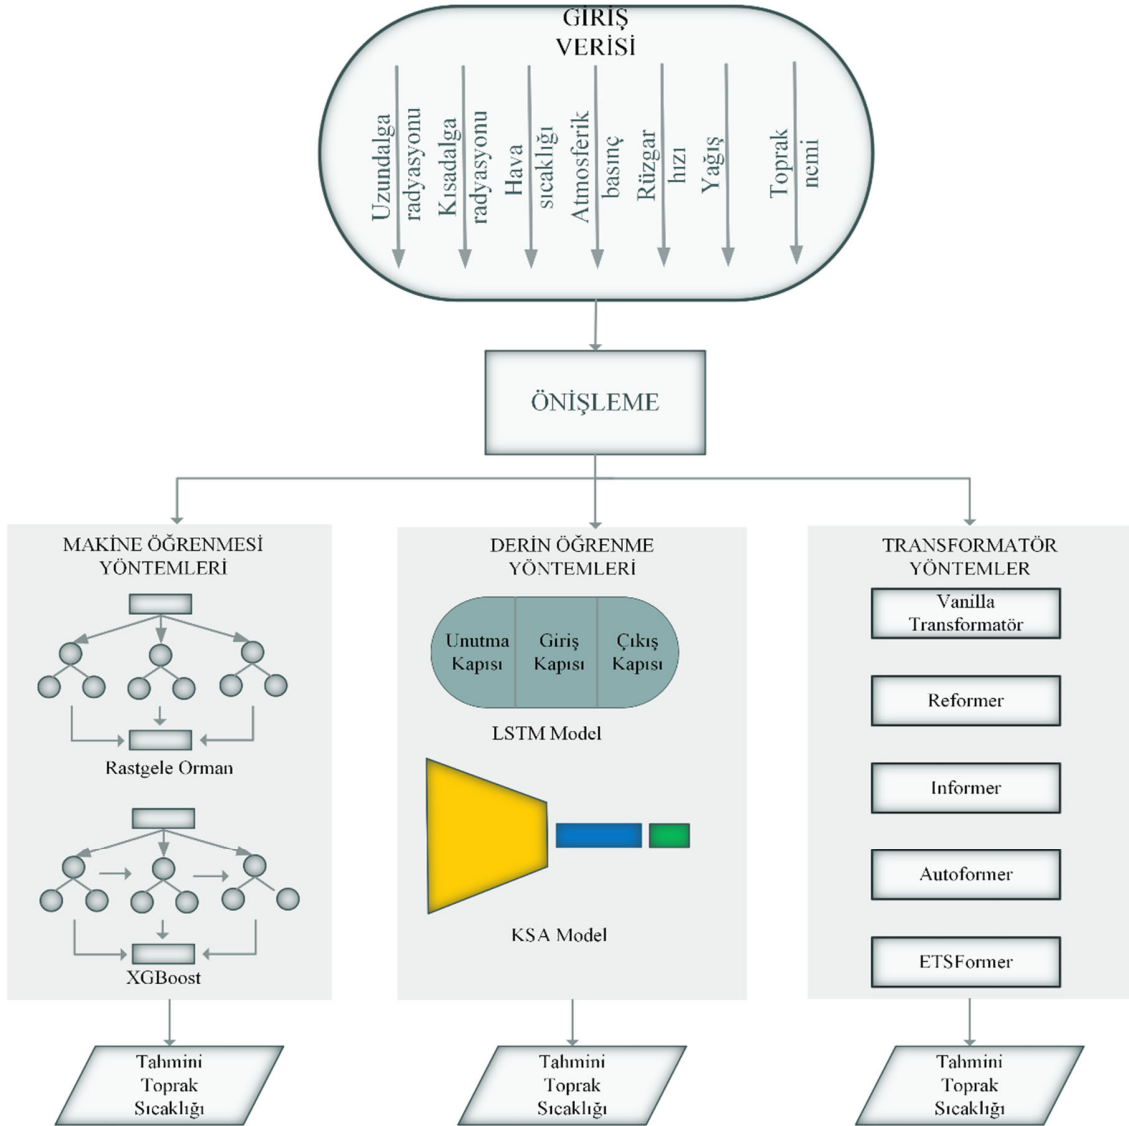
3.1. FLUXNET: Ön İşleme (Pre-processing)

FLUXNET [25], dünyanın çeşitli bölgelerindeki atmosferik değişkenlerin yanı sıra kara yüzeyi ile atmosfer arasındaki enerji, su ve karbondioksit alışverişine ilişkin gözlemleri içeren bir veri setidir. 50'den fazla ülkede 500'den fazla kule alanından toplanan verileri

içeren kapsamlı bir küresel veri setidir. FLUXNET verileri, Dünya'nın karbon ve su döngüleriyle ilgili çok çeşitli konuları incelemek için kullanılabilir:

- Farklı ekosistem türlerinin (ormanlar, çayırlar ve tarım arazileri gibi) küresel karbon döngüsündeki rolü.
- Kara yüzeyi ile atmosfer arasındaki su, enerji ve karbondioksit alışverişini etkileyen faktörler.
- Arazi kullanımı ve arazi örtüsü değişikliklerinin karbon ve su döngüleri üzerindeki etkileri.
- Ekosistemlerin sıcaklık, yağış ve atmosferik CO₂ konsantrasyonlarındaki değişiklikler gibi değişen iklim koşullarına verdiği tepkiler.

Araştırmacılar, politika yapıcılar ve diğer paydaşlar, Fluxnet2015 verilerini Dünya'nın karbon ve su döngülerini yönlendiren süreçleri daha iyi anlamak ve iklim değişikliği, arazi kullanımı ve ekosistem yönetimi gibi konularda karar verme süreçlerini bilgilendirmek için kullanabilir.



Şekil 1. Önerilen modelin mimarisi (Architecture of the proposed model)

Ön işleme aşamasının temel amacı, DL modellerinin performansını önemli ölçüde engelleyebilecek gürültülü verilerin belirlenmesi ve kaldırılmasıdır. Bu kritik adım, aykırı değerleri filtrelemek ve verinin bütünlüğünü ve güvenilirliğini sağlamak için tasarlanmış koşulların uygulanmasını içerir. Daha sonra, zaman serisi verileri analiz edilerek eğilim ve mevsimsellik gibi temel bileşenler belirlenir ve gözlemlenir. Bu çalışma kapsamında, odak noktamız altı farklı FLUXNET istasyonundan elde edilen verileri kullanarak DL modelleri ve transformatör temelli modeller oluşturmaktır. Bu istasyonlar Şekil 2'de gösterilmektedir. Bu özel istasyonların seçilmesi, kapsamlı bir analiz yapılmasını mümkün kılar. Bu istasyonlar, farklı coğrafi bölgeleri kapsar ve önerilen modellerin kapsamlı bir şekilde değerlendirilmesine olanak tanır. Bu yaklaşım, modellerin performansının farklı çevresel koşullar ve özellikler üzerinde geniş bir şekilde incelenmesini sağlayarak çalışmanın sağlamlığına katkıda bulunur.

FLUXNET veri seti, her istasyon için 2014 yılına kadar olan verileri içermektedir. Araştırmacılar bu veri setini saatlik, günlük, haftalık, aylık ve yıllık aralıklar gibi çeşitli zaman çözünürlüklerinde paylaşmıştır. Bu çalışmada, zaman serisi tahmini saatlik veriler üzerinde gerçekleştirilmiştir. Bu saatlik zaman serisi tahmini

yaklaşımı, verinin davranışını ve dalgalanmalarını daha detaylı ve ince bir şekilde inceleme olanağı sağlar. Önerilen DL, ağaç temelli ve transformatör temelli yöntemler, Tablo 1'de listelenen özellikleri girdi olarak kullanır. Seçilen özellikler için [26] çalışmasından esinlenmiştir. Tablo 1'de bu özellikler, analiz edilen bireysel istasyonlara özgü istatistiksel sonuçlarla ve metrik birimleriyle birlikte sunulmaktadır.

3.2. Tahminleme (Forecasting)

Bu çalışma, ağaç tabanlı, DL ve transformatör tabanlı modeller kullanarak toprak sıcaklığını tahmin etmeye odaklanmaktadır. Amaç, bu üç farklı yaklaşıma dayalı tahmin metodolojileri geliştirerek zaman içinde toprak sıcaklığını doğru bir şekilde öngörmektir. Bu yöntemlerin performansları karşılaştırılarak, toprak sıcaklığı dalgalanmaları için en doğru ve en etkili tahminleri sağlayan yaklaşımın belirlenmesi hedeflenmektedir.

Bu çalışmada öncelikle, zaman serisi görevlerindeki etkinliği bilinen Ağaç Tabanlı modeller, örneğin RF ve XGBoost, tahmin yapmak için uygulanmaktadır. Ardından, verideki daha karmaşık örüntüleri yakalamak amacıyla DL modelleri kullanılmaktadır. Son olarak,



Şekil 2. Bu çalışmada kullanılan FLUXNET veri istasyonlarının yakınlaştırılmış dünya haritası üzerindeki konumları (FLUXNET data sites used in this work on a zoomed world map)

Tablo 1. Bazı FLUXNET istasyonlarından kullanılan özelliklerin istatistiksel özeti (Statistical summary of the features used from selected FLUXNET stations)

İstasyonlar Özellikler	NL - Loo			FR - Lbr			IT - Col		
	Min	Max	Mean	Min	Max	Mean	Min	Max	Mean
Uzun dalga radyasyonu (W/m ²)	188,7	454,083	337,726	192,81	457,64	334,129	142,891	388,976	281,703
Kısa dalga radyasyonu (W/m ²)	0	1005	116,155	0	1017,46	146,771	0	1155,14	1155,14
Hava sıcaklığı (°C)	-14,86	34,82	10,103	-7,71	36,18	12,877	14,055	28,601	7,249
Atmosfer basıncı (kpa)	96,053	104,169	101,084	98,198	103,85	101,573	82,119	86,631	84,895
Rüzgar hızı (m/s)	0,024	9,377	2,352	0,039	12,813	3,114	0,025	6,94	1,625
Yağış (mm)	0	7,641	0,047	0	1,709	0,039	0	5,943	0,098
Toprak nemi (% hacimce)	0	25,1	8,6	17,711	94,447	38,396	11,324	31,511	5,407

zaman serisi tahmininde giderek daha fazla kullanılan transformatör tabanlı modeller uygulanmaktadır. Zaman karmaşıklığını azaltan dikkat mekanizmasını değiştirme işleminin tahmin performansına nasıl etki ettiğini gözlemlemek amacıyla beş farklı transformatör modeli test edilmektedir.

3.2.1. Ağaç Tabanlı Modeller (Tree-based models)

RF, eğitim sırasında birden fazla karar ağacı oluşturan ve bireysel ağaçların tahminlerinin ortalamasını alarak çıktı veren yaygın olarak kullanılan bir topluluk öğrenme yöntemidir. Hem sınıflandırma hem de regresyon görevlerini ele alabilme yeteneği ile bilinmekte olup, zaman serisi tahmini için de etkili bir modeldir. Model, her bir karar ağacını oluştururken rastgele özellik ve veri alt kümeleri seçerek aşırı öğrenmeyi (overfitting) azaltmaya yardımcı olur. Bu çalışmada, RF modeli 75 tahminci (estimator) ve maksimum 10 derinlik ile eğitilmiş olup, geri kalan parametreler Tablo 2'de belirtildiği şekilde ayarlanmıştır.

XGBoost, ölçeklenebilirliği ve doğruluğu ile bilinen güçlü bir ağaç tabanlı modeldir. Random Forest'tan farklı olarak, XGBoost ağaçları sıralı (ardışık) olarak inşa eder ve her yeni ağaç, bir öncekinin yaptığı hataları azaltmaya odaklanır. Bu yinelenmeli yaklaşım, modelin verideki karmaşık örüntüleri daha iyi yakalamasını sağlar. Bu çalışmada, XGBoost modeli 75 tahminci, maksimum 6 derinlik ile kullanılmış olup, subsample ve colsample_bytree gibi hiperparametreler 0,8 olarak ayarlanmıştır. Diğer hiperparametreler Tablo 2'de gösterildiği şekilde belirlenmiştir.

Tablo 2. Ağaç tabanlı modellerin eğitim parametreleri (Training parameters for tree-based models)

Parametreler	RF	XGBoost
Tahminleyici Sayısı	75	75
Maks. Derinlik	10	6
Subsample	-	0,8
Colsample Bytree	-	0,8

3.2.2. Derin Öğrenme Modelleri (Deep learning models)

Günümüzde, CNN'ler görüntü ve video işleme uygulamalarında yaygın olarak kullanılmaktadır. Daha derin katmanlı sinir ağlarının bir türü olarak değerlendirilebilen CNN'ler, geleneksel makine öğrenme yaklaşımlarında kullanılan özelliklerin çok ötesine geçen özellik çıkarma yetenekleriyle öne çıkmaktadır. CNN'lerin geliştirilmesinin arkasındaki motivasyon, komşu pikseller arasındaki yerel korelasyondan yararlanarak görüntü işlemede daha verimli bir yaklaşım oluşturmaktır. Geleneksel Yapay Sinir Ağları (ANN'ler) tüm giriş özelliklerini bağımsız olarak ele alırken, CNN'ler giriş verisine konvolüsyonel filtreler uygulayarak ağın parametrelerini daha verimli kullanmasını sağlamaktadır.


Mimari farklılıklar açısından bakıldığında, CNN'ler, tamamen bağlı katmanlar yerine konvolüsyonel katmanlar içererek basit ANN'lerden ayrılmaktadır. Konvolüsyonel katmanlar, öğrenilen filtrelerin giriş verisine uygulanmasını sağlayarak CNN'lerin temel bileşenlerinden birini oluşturmaktadır. Çekirdek (kernel) veya ağırlık (weight) olarak da adlandırılan bu filtreler, giriş verisi üzerinde kaydırmalı pencere mekanizması ile hareket eden kompakt matrislerdir. Bu filtreler, eleman bazlı çarpma ve ardından toplama işlemleri gerçekleştirilerek skaler çıktılar üretmektedir. Daha sonra, Düzleştirilmiş Doğrusal Birim (ReLU) gibi doğrusal olmayan bir aktivasyon fonksiyonu kullanılarak modele önemli bir doğrusal olmayan bileşen eklenmektedir. Önerilen CNN tabanlı yöntem, Şekil 3'te görsel olarak gösterilmektedir.

LSTM, RNN bir türü olarak, zaman serisi analizi, NLP ve ses işleme gibi ardışık verileri içeren alanlardaki karmaşıklıkları ele almak için tasarlanmış güçlü bir araçtır. Hochreiter ve Schmidhuber tarafından 1997 yılında geliştirilen LSTM ağları, çeşitli uygulama alanlarında hızla yaygın bir seçenek haline gelmiştir. LSTM ağlarının temel amacı, geleneksel RNN'lerde görülen kaybolan gradyan problemini çözmektir. Bu problem, ağın uzun vadeli ilişkileri öğrenmesini zorlaştırabilmektedir. LSTM ağları, zaman içinde seçici olarak veri saklayabilen veya silbilen yeni bir bellek hücresi türü kullanarak önceki zaman adımlarındaki önemli verilerin izlenmesini sağlamaktadır.


LSTM ağları ile basit ANN'ler ve CNN'ler gibi diğer sinir ağı türleri arasındaki temel fark, LSTM'lerin ardışık verileri işleyebilmesini sağlayan yinelenmeli bir yapıya sahip olmasıdır. LSTM ağları, bilgiyi işleme konusunda devrim yaratan ve üç temel kapıya dayanan öncü bir mekanizma kullanmaktadır: giriş kapısı (input gate), unutma kapısı (forget gate) ve çıkış kapısı (output gate). Bu kapılar, bellekte hangi verilerin saklanıp hangi verilerin silineceğini yöneterek, bilgiyi seçici bir şekilde saklama ve silme sürecini kontrol etmektedir. Böylece, ağ benzersiz bir uyarlabilirlik kazanarak uzun vadeli bağıntıları daha etkin bir şekilde öğrenebilmektedir. Eğitim sürecinde, LSTM ağı, giriş, unutma ve çıkış kapılarının yanı sıra aday bellek hücresi değerinin parametrelerini ayarlayarak zaman içinde hangi bilgilerin saklanacağını veya silineceğini öğrenmektedir. Bu sayede ağ, önceki zaman adımlarındaki önemli bilgileri takip edebilir ve bu belleği kullanarak gelecekteki zaman adımlarını tahmin edebilir. Önerilen LSTM tabanlı yöntem, Şekil 4'te sunulmaktadır.

3.2.3. Transformatör (Transformer)

Transformatör kavramı, Vaswani vd.aların 2017 yılındaki öncü çalışmasında [27] sunulduğu şekliyle, DL alanında önemli bir mimariyi temsil eder. Özellikle sıralı verilerin analizi için tasarlanan transformatörler, NLP ve zaman serisi gibi alanlarda olağanüstü bir yetenek sergiler. Transformatörler, temelde iki temel bileşenden oluşur: bir kodlayıcı (encoder) ve bir kod çözücü (decoder).



Şekil 3. Önerilen CNN modelinin mimarisi (The architecture of the proposed CNN model)



Şekil 4. Önerilen LSTM modelinin mimarisini (The architecture of the proposed LSTM model)

Kodlayıcı, girdi dizisini işlemekle görevliken, kod çözücü karşılık gelen çıktı dizisini üretmekten sorumludur. Dikkat çekici olan, öz-dikkat (self-attention) mekanizmasıdır. Bu yenilikçi mekanizma, modelin girdi dizisinin farklı bölümlerine eleman bazında işlem yaparken seçici bir şekilde odaklanmasını sağlar. Sonuç olarak, transformatörler girdi dizisindeki uzun menzilli bağımlılıkları yakalama konusunda geleneksel RNN'leri geride bırakır. Makalede önerilen ölçeklenmiş nokta çarpımı dikkat mekanizması (scaled-dot product attention) Eş. 1'de verilmiştir.

$$Attention(Q, K, V) = softmax\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (1)$$

Burada Q (Query), K (Key) ve V (Value) matrisleri sırasıyla sorgu, anahtar ve değer vektörlerini temsil etmektedir. QK^T ifadesi, sorgular ile anahtarlar arasındaki benzerliği ölçerken, T üst simgesi matrisin transpozunu ifade etmektedir. d_k ise anahtar vektörlerinin boyutunu göstermekte olup, ölçekleme amacıyla kullanılmaktadır. Softmax fonksiyonu, elde edilen benzerlik skorlarını normalize ederek dikkat ağırlıklarının hesaplanmasını sağlamaktadır.

Eş. 1'de hesaplanan dikkat mekanizması daha sonra birden fazla kez istifleterek Çoklu-Kafa Dikkati (Multi-Head Attention) oluşturulmaktadır. Ancak, ölçeklenmiş nokta çarpımı dikkat mekanizmasının bir dezavantajı, hesaplama karmaşıklığının $O(L^2)$ olmasıdır. Burada L , dizinin uzunluğunu ifade eder ve bu durum, dönüştürücü (transformer) modellerinin eğitilmesini hesaplama açısından maliyetli hale getirmektedir. Buradaki $O(L^2)$ ifadesi, öz-dikkat mekanizmasının dizi uzunluğu L cinsinden hesaplama karmaşıklığını ifade eden Big-O gösterimidir. Bu gösterimde kullanılan O sembolü, sorgu matrisi Q ile ilişkili olmayıp, algoritmik zaman/mekân karmaşıklığını tanımlamak amacıyla kullanılmaktadır. Bu çalışmada, orijinal makalede önerilen varsayılan parametreler kullanılarak farklı zaman adımları için altı farklı FLUXNET istasyonu veri kümesi üzerinde vanilya (standart) transformatör modeli eğitilmiştir.

3.2.4. Reformer: Verimli Transformatör (Efficient Transformer)

Büyük Transformatör modelleri, bir dizi görevde state-of-the-art (en iyi performans) sonuçlar elde eder, ancak bu modellerin eğitimi, özellikle uzun diziler söz konusu olduğunda oldukça maliyetli olabilir. Reformer modelinin yazarları [28], transformatör modellerinin verimliliğini artırmak için iki yeni yöntem sunmaktadır. İlk olarak, ölçeklendirilmiş nokta çarpımı dikkat mekanizmasını, yerel-duyarlı karma (locality-sensitive hashing, LSH) ile değiştirerek hesaplama karmaşıklığını $O(L^2)$ 'den $O(L \log L)$ 'ye düşürmüşlerdir. İkinci önemli katkı ise geri dönüşümlü (reversible) katmanların kullanılmasıdır. Bu yöntem, ilk olarak Gomez vd. [29] tarafından tanıtılmıştır ve model boyunca yalnızca tek bir aktivasyon kopyasının saklanması sağlayarak N faktörünü ortadan kaldırır. Burada N , modeldeki katman sayısını ifade etmektedir. Klasik

transformatörlerde bellek kullanımı katman sayısı ile doğrusal olarak artarken, Reformer'da kullanılan geri dönüşümlü katmanlar sayesinde ara aktivasyonlar yeniden hesaplanabilmekte ve bellek maliyetindeki N faktörü ortadan kaldırılmaktadır.

64,000 kelimelik bir dizinin model tarafından işlendiği bir durum ele alındığında, LSH dikkati, bu diziyi benzerliğe göre sıralayarak en benzer anahtarlarla dikkat hesaplaması yapmaktadır. Bu yöntem, hesaplama karmaşıklığını azaltmaktadır.

Ölçeklenmiş nokta çarpımı dikkat mekanizmasında (1) numaralı denklemde gösterilen QK^T matris çarpımı, $O(L^2)$ karmaşıklığının ana sebebidir. Reformer'in temel fikri, tüm sorgular Q ile tüm anahtarlar K arasındaki çarpımı hesaplamak yerine, her bir sorguyu (boyutu $1 \times d_k$ olan) ayrı ayrı indeksleyerek bu $O(L^2)$ karmaşıklığını önlemektir. Reformer'da önerilen LSH dikkati, Eş. 2'de verilmiştir.

$$Attention(Q, K, V) = softmax\left(\frac{qik^T}{\sqrt{d_k}}\right)V \quad (2)$$

RevNets, ağ yapısına yönelik yenilikçi bir yaklaşım sunarak geleneksel geri yayılım yöntemlerinden farklı bir mekanizma getirir. RevNets bağlamında, katmanlar kademeli olarak tersine çevrilir, bu da geri yayılımın, ağıın ara değerlerine erişmeye gerek kalmadan, çıktudan girdiye doğru geçmesine olanak tanır. RevNets'in temel özelliği, her biri birer giriş ve çıkış çiftleri üzerinde işlem yapan tersinir katmanların işlemidir. Bu giriş ve çıkışlar, $(x_1, x_2) \rightarrow (y_1, y_2)$ şeklinde gösterilir. Bu tersinir katmanların davranışı, aşağıdaki denklemlerle doğru bir şekilde tanımlanabilir. Yazarlar, RevNet kavramını transformatör modellerine uygulamak için dikkat (attention) ve ileri besleme (Feed-forward) katmanlarını birleştirmiştir. Bu bağlamda F, Eş. 3'te dikkat katmanı olarak yer alırken, G ise ileri besleme katmanı olarak tanımlanmıştır. Bu fonksiyonların yerine konmasıyla elde edilen özelleştirilmiş yapı, Eş. 4'te gösterilmektedir.

$$y_1 = x_1 + F(x_2) \quad y_2 = x_2 + G(y_1) \quad (3)$$

$$Y_1 = X_1 + Attention(X_2) \quad Y_2 = X_2 + FeedForward(Y_1) \quad (4)$$

3.2.5. Informer: Verimli Transformatörün Ötesi (Informer: Beyond Efficient Transformer)

Zhou vd. [30] tarafından sunulan Informer modeli, uzun dizileri verimli bir şekilde işleyebilen ve zaman serisi tahmini için tasarlanmış "Informer" adlı yeni bir transformatör temelli mimari önermektedir. Uzun dizi zaman serisi tahmini (LSTF) görevleri, Transformatör modelleri kullanılarak gerçekleştirilemez çünkü çeşitli sorunlar ortaya çıkar. Önerilen Informer modeli, LSTF görevlerinde transformatör temelli modellerin kullanımına önemli katkılarda bulunur.

Informer, zaman serisi verilerindeki hem yerel hem de küresel bağımlılıkları yakalamak için ProbSparse Öz-Dikkat (ProbSparse Self-Attention, PSA) mekanizması ile Yerel-Küresel (Local-Global, LG) yapısını birleştiren bir hibrit dikkat mekanizması sunar. Bu mekanizma, modelin uzun dizileri verimli bir şekilde işlerken dizinin önemli kısımlarına odaklanmasını sağlar.

Informer'de önerilen üretici stil kodlayıcı, uzun zaman serisi dizileri için tahminleri ardışık bir şekilde değil, tek bir ileri işlemde yapmaktadır. Bu, uzun diziler için tahmin yaparken çıkarım hızını önemli ölçüde artırır. Her bir anahtar, ProbSparse Self-attention yardımıyla yalnızca baskın sorgulara dikkat edebilir. Eş. 5'te Q matrisi, q ile aynı boyutlara sahiptir ve yalnızca Top- u sorguları, $M(q, K)$ seyrekliğe dayalı ölçümüne göre seyrek şekilde doldurulmuştur. ProbSparse dikkat mekanizması sayesinde, tıpkı Reformer'da olduğu gibi, Informer transformatör modeli $O(L \log L)$ karmaşıklığına ulaşmaktadır.

$$A(Q, K, V) = \text{Softmax}\left(\frac{QK^T}{\sqrt{d}}\right)V \quad (5)$$

Eş. 5'te Q matrisi, q ile aynı boyutlara sahiptir ve yalnızca Top- u sorguları, $M(q, K)$ seyrekliğe dayalı ölçümüne göre seyrek şekilde doldurulmuştur. ProbSparse dikkat mekanizması sayesinde, tıpkı Reformer'da olduğu gibi, Informer transformatör modeli $O(L \log L)$ karmaşıklığına ulaşmaktadır. Eş. 5'te Q , sorgu vektörlerini; K , anahtar vektörlerini; V , değer vektörlerini temsil etmektedir. Burada q , Q matrisi içerisindeki tekil bir sorgu vektörünü ifade etmektedir. ProbSparse self-attention mekanizmasında Top- u , tüm sorgular yerine yalnızca en yüksek önem skoruna sahip u adet baskın sorgunun seçilmesini ifade etmektedir. Bu seçim işlemi, sorgu ile anahtarlar arasındaki bilgi yoğunluğunu ölçen $M(q, K)$ fonksiyonu aracılığıyla gerçekleştirilmektedir. $M(q, K)$, sorgu q ile tüm anahtarlar K arasındaki dikkat dağılımının seyrekliğini ölçen bir önem metriğidir ve bu metrik sayesinde yalnızca bilgi açısından en anlamlı sorgular dikkat hesaplamasına dahil edilmektedir. Bu yaklaşım, hesaplama karmaşıklığını klasik self-attention yapısındaki $O(L^2)$ seviyesinden $O(L \log L)$ seviyesine düşürmektedir.

3.2.6. Autoformer: Ayrıştırma Tabanlı Transformatör (Autoformer: Decomposition Transformers)

Zaman serisi tahmini, enerji tüketimi, trafik, ekonomi planlaması, hava durumu ve hastalık yayılımı tahmini gibi alanlarda yaygın bir şekilde kullanılmaktadır. Gerçek dünya senaryolarında, geleceği daha uzun bir süre önceden tahmin etme ihtiyacı acildir, çünkü bu, etkili uzun vadeli planlama ve erken uyarı sistemleri için hayati öneme sahiptir. Bu nedenle, araştırma makalesi, önemli bir uzunluğa sahip genişletilmiş bir zaman serisinin tahminini içeren uzun vadeli zaman serisi tahmini problemini incelemeye odaklanmaktadır.

Uzun vadeli tahmin görevini, özellikle zorlu bir hale gelir. İlk olarak, uzatılmış zaman serilerinden doğrudan zamansal bağımlılıkları belirlemek güvenilmezdir, çünkü bu bağımlılıklar iç içe geçmiş zamansal desenler tarafından gizlenmiş olabilir. İkinci olarak, geleneksel Transformatör modelleri, öz-dikkat mekanizmaları nedeniyle uzun vadeli tahminlerde dizi uzunluğunun karesel karmaşıklığından dolayı hesaplama açısından maliyetli hale gelir.

Araştırmacılar, önceki transformatör temelli tahmin modellerinin [28, 30] seyrek öz-dikkat mekanizmaları sunarak hesaplama maliyetini düşürdüğünü, ancak bu modellerin hâlâ noktasal temsil toplamayı kullandığını belirtmiştir. Verimliliği artırmayı hedeflerken, seyrek noktasal bağlantıların varlığı nedeniyle bilgi kullanımı zarar görebilir.

Yukarıda bahsedilen sorunlardan yola çıkarak, araştırmacılar uzun vadeli zaman serisi tahmini için Autoformer adlı yeni bir çözüm sunmuştur. Bu çözüm, geleneksel transformatörlerin yerini alır. Autoformer, artık (residual) ve kodlayıcı-kod çözücü yapısını korurken, Transformer'ın aksine bir ayrıştırma (decomposition) tahmin mimarisi benimser. Autoformer, stokastik süreç teorisinden [31, 32] ilham alır ve öz-dikkat mekanizması yerine bir AC mekanizması içerir. Bu mekanizma, seri periyodikliğinden yararlanarak alt seri benzerliğini tespit eder ve temel periyotlardan ilgili alt serileri toplar. Bu seri temelli mekanizmayı benimseyerek, Autoformer, uzunluk- L serileri için hesaplama karmaşıklığını $O(L \log L)$ 'ye düşürür ve noktasal temsil toplamayı alt seri düzeyine genişleterek bilgi tüketimi darboğazını ortadan kaldırır. Altı metrik üzerinde Autoformer, en yüksek doğruluk seviyesini elde eder.

3.2.7. ETSFormer: Üstel Düzgünleştirme Tabanlı Transformatör (ETSFormer: Exponential Smoothing Transformers)

Woo vd. [33], zaman serisi tahmini performansını artırmak için iki çerçeveyi birleştiren ETSformer adlı yeni bir zaman serisi tahmin modeli geliştirmiştir. ETSformer, mevsimsel-eğilim ayrıştırma ve

üstel düzleştirme (exponential smoothing) gibi klasik yöntemlerle mevcut transformatörleri birleştirerek yenilikçi üstel düzleştirme ve frekans dikkati (frequency attention) tekniklerini sunar. ETSformer'in ilham kaynağı, zaman serisi tahmininde kullanılan klasik üstel düzleştirme teknikleridir. Orijinal transformatörlerdeki öz-dikkat mekanizması yerine, hem doğruluğu hem de verimliliği artıran üstel düzleştirme dikkati (Exponential Smoothing Attention, ESA) ve frekans dikkati (Frequency Attention, FA) yöntemlerini kullanır. Sonuç olarak, ETSformer zaman serisi tahmininde state-of-the-art (en iyi performans) sonuçlar elde eder.

Araştırmacılar, üstel düzleştirme için Holt-Winters yöntemini [34] kullanmıştır. Bu yöntem, Eş. 6'da verilmiştir.

$$\begin{aligned} \text{Seviye: } e_t &= \alpha(x_t - s_{t-p}) + (1 - \alpha)(e_{t-1} + b_{t-1}) \\ \text{Büyüme: } b_t &= \beta(e_t - e_{t-1}) + (1 - \beta)b_{t-1} \\ \text{Mevsimsellik: } s_t &= \gamma(x_t - e_t) + (1 - \gamma)s_{t-p} \\ \text{Tahminleme: } \hat{x}_{t+h|t} &= e_t + hb_t + s_{t+h-p} \end{aligned} \quad (6)$$

Eş. 6'da kullanılan Holt-Winters üstel düzleştirme bileşenleri, zaman serisinin seviye (level), büyüme/eğilim (trend) ve mevsimsellik (seasonality) yapılarını ayrı ayrı modellemeyi amaçlamaktadır. Bu kapsamda, denklemlerde yer alan semboller aşağıda açıklanmaktadır:

- x_t : Zaman serisinin t tanındaki gözlenen gerçek değerini ifade etmektedir.
- e_t : t tanındaki seviye bileşenini temsil etmektedir.
- b_t : t tanındaki büyüme/eğilim bileşenini göstermektedir.
- s_t : t tanındaki mevsimsel bileşeni ifade etmektedir.
- α, β, γ : Sırasıyla seviye, eğilim ve mevsimsellik bileşenleri için kullanılan, $[0, 1]$ aralığında tanımlı üstel düzleştirme katsayılarıdır. Bu katsayılar, geçmiş bilgilerin mevcut tahmine ne ölçüde etki edeceğini belirlemektedir.
- p : Zaman serisinin mevsimsellik periyodunu ifade etmektedir.
- h : İleriye dönük tahmin ufkunu göstermektedir.
- $\hat{x}_{t+h|t}$: t zamanına kadar olan bilgiler kullanılarak $t + h$ an için üretilen tahmin değerini temsil etmektedir.

Bu denklemler, tahminin, son tahmin edilen e_t seviyesinden oluştuğunu ve bunun, son büyüme faktörü b_t ile h katı kadar artırıldığını, ayrıca son mevcut mevsimsel faktör s_{t+h-p} 'nin eklendiğini göstermektedir. Bu yapı sayesinde, tahmin değeri; son seviye bileşeni e_t , eğilim bileşeni b_t ve ilgili mevsimsel bileşen s_{t+h-p} birlikte kullanılarak oluşturulmaktadır. Böylece model, zaman serisinin uzun dönemli eğilimini ve periyodik dalgalanmalarını eş zamanlı olarak yakalayabilmektedir.

Önerilen mimarinin her katmanında, encoder bileşeni, sağlanan geri dönük pencereyi kullanarak büyüme ve mevsimsellik ile ilişkilendirilmiş gizli bileşenleri iteratif olarak çıkaracak şekilde özel olarak tasarlanmıştır. Benzer şekilde, level bileşeni, eş. 6'da temsil edilen klasik seviye düzeltme tekniğine benzer bir teknik kullanılarak çıkarılmaktadır. Bu çıkarılan bileşenler daha sonra decoder modülüne aktarılır, burada h adım ileriye yönelik nihai tahmini oluşturacak şekilde birleşir. Bu tahmin, seviye, büyüme ve mevsimsellik için bireysel tahminlerin birleştirilmesiyle sentezlenir, bu da Eş. 7'deki ifadelerde kesin bir şekilde tanımlanmıştır:

$$\hat{X}_{t:t+H} = E_{t:t+H} + \text{Linear} \left(\sum_{n=1}^N \left(B_{t:t+H}^{(n)} + S_{t:t+H}^{(n)} \right) \right) \quad (7)$$

Eş. 7'deki $E_{t:t+H} \in R^{H \times m}$ ve $B_{t:t+H}^{(n)}, S_{t:t+H}^{(n)} \in R^{H \times d}$ matrisleri, tahmin ufkunda her zaman adımı için seviye tahminleri ile büyüme ve mevsimsellik gizli temsillerini temsil etmektedir. Toplamda N encoder yığını bulunmaktadır ve " n " endeksi yığın indeksini

belirtmektedir. Büyüme ve mevsimsellik temsillerini gizli alandan gözlem alanına projekte etmek için, $Linear(\cdot): R^d \rightarrow R^m$ her zaman adımı boyunca eleman bazlı bir işlem gerçekleştirmektedir.

4. Deneysel Sonuçları (Experiment Results)

Bu çalışma, önerilen yöntemleri karşılaştırmak ve değerlendirmek amacıyla toprak sıcaklığı verilerini içeren yaygın olarak bilinen FLUXNET verisetini kullanmaktadır. Deneysel, zaman serisi tahminleri saatlik veriler üzerinde yapılmıştır. Her bir altı FLUXNET istasyonu için veri kümesi bölümü ve istatistiksel bilgiler Tablo 3'te verilmiştir. Önerilen yöntemlerin performansı, Eş. 8'de ve Eş. 9'da verilen yaygın metrikler kullanılarak ölçülmektedir. Mean Absolute Error (MAE), L1 kaybı olarak da bilinen, gerçek ve tahmin edilen değerler arasındaki ortalama mutlak hatadır. Mean Squared Error (MSE), L2 kaybı olarak da bilinen, gerçek ve tahmin edilen değerler arasındaki ortalama kareli hatadır. Hem MAE hem de MSE hesaplamalarının kullanılması, modelin performansı hakkında veri kümesi genelinde fikir verir. Kareli hata ile mutlak hata arasındaki ana fark, kareli hatanın, hataları yalnızca farkı hesaplamak yerine kare olarak daha büyük hataları daha şiddetli şekilde cezalandırmasıdır. Bu işlemdeki farklılık, kareli hatanın daha büyük sapmalara duyarlılığını artırır.

$$MSE = \frac{1}{n} \sum_{i=1}^n (T_{real} - T_{pre})^2 \quad (8)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |T_{real} - T_{pre}| \quad (9)$$

Tablo 2 ve Tablo 4, bu çalışmada kullanılan üç farklı model için kullanılan eğitim parametrelerinin bir özetini sunmaktadır. Bu parametreler, her bir modelin kendi kategorisindeki modelleri

arasında tutarlılığı ve karşılaştırılabilirliği sağlamak amacıyla tüm modellerde aynıdır. Bu tablolarda yer alan optimal parametreleri belirlemek için grid search hiperparametre ayarlama yaklaşımı uygulanmıştır. Farklı hiperparametre kombinasyonları değerlendirilmiş ve en iyi sonuçları veren konfigürasyon belirlenmiştir. Hiperparametreler için belirlenen arama aralıkları Tablo 5'te verilmiştir. Transformatör modeller için beş farklı modelin de parametreleri, orijinal çalışma ile aynı tutulmuştur.

Ağaç tabanlı modellerin değerlendirme sonuçları Tablo 5'te sunulmaktadır. Bu tablo, toprak sıcaklığını tahmin etmek için kullanılan iki ağaç tabanlı modelin, Random Forest ve XGBoost'un, altı farklı istasyonda (NL - Loo, FR - Lbr, BE - Vie, IT - Col, FI - Hyy, ve CH - Lae) çeşitli tahmin uzunlukları için değerlendirme sonuçlarını göstermektedir: 96, 192, 336 ve 720 zaman adımı. Bu zaman adımları, sırasıyla 96, 192, 336 ve 720 saat sonrasına kadar toprak sıcaklığını tahmin etmeyi ifade etmektedir. Girdi uzunluğu sabit olup 96 zaman adımında tutulmuştur, yani modeller tahminlerini yapmak için önceki 96 saatin verilerine dayanır.

Random Forest için, MSE ve MAE değerleri genellikle daha uzun tahmin ufuklarında artış göstermektedir, bu da tahmin süresi uzadıkça doğruluğun kademeli olarak düştüğünü göstermektedir. Örneğin, NL - Loo'da, MSE 96 adımda 0,622 °C'den 336 adımda 0,637 °C'ye yükselmekte, ancak 720 adımda 0,598'e hafifçe azalmaktadır. FR - Lbr ve IT - Col gibi diğer istasyonlarda da benzer bir desen gözlemlenmektedir; model, nispeten düşük hata değerlerini korumakta (örneğin, FR - Lbr'de 96 adımda MSE = 0,234 °C²), ancak daha uzun ufuklarla zorluk yaşamaktadır, örneğin IT - Col'de 720 adımda 0,744 °C MAE değerleri de tutarlı bir performans sergileyerek, farklı zaman adımları ve istasyonlarda 0,344 °C ile 0,774 °C arasında değişmektedir.

Tablo 3. Altı Fluxnet sahasına ait veri kümesi bölümü ve istatistiksel bilgiler (Dataset division and statistical information for six flux sites)

İstasyon	Saatlik Gözlem Sayısı	Eğitim Verisi Kapsamı (%70)	Doğrulama Verileri Kapsamı (%10)	Test Verileri Kapsamı (%10)
NL - Loo	177,551	2000-01-01	2010-07-02	2012-01-01
		2010-07-02	2012-01-01	2014-12-31
BE - Vie	131,495	2000-01-01	2010-07-02	2012-01-01
		2010-07-02	2012-01-01	2014-12-31
FR - Lbr	35,063	2005-01-01	2007-10-20	2008-03-14
		2007-10-20	2008-03-14	2008-12-31
FI - Hyy	46,055	2009-09-30	2013-06-04	2013-12-13
		2013-06-04	2013-12-13	2014-12-31
IT - Col	43,841	2009-12-30	2013-07-01	2013-12-31
		2013-07-01	2013-12-31	2014-12-31
CH - Lae	81,851	2005-08-30	2012-03-13	2013-02-17
		2012-03-13	2013-02-17	2014-12-31

Tablo 4. DL ve transformatör modeller için eğitim parametreleri (Training parameters for both deep learning and transformer models)

Parametreler	DL Modelleri	Transformatör Modeller
Learning Rate	0,01	0.0001
Epoch	20	5
Batch	32	32
Optimizasyon Alg.	Adam	GELU

Tablo 5. DL modelleri için belirlenen hiperparametre arama uzayı (Hyperparameter search space determined for deep learning models)

Hiperparametre	Değer Aralığı	Seçilen Değer
Öğrenme Oranı (Learning Rate)	[0.001, 0.01, 0.1]	0.01
Epoch Sayısı	[10, 20, 50]	20
Batch Boyutu	[16, 32, 64]	32
Optimizasyon Algoritması	[Adam, SGD, RMSprop]	Adam

Tablo 6. RF ve XGBoost modelleri için farklı tahmin ufuklarında toprak sıcaklığı tahmin performansı (Soil temperature forecasting performance of RF and XGBoost across different prediction horizons)

Yöntem	Metrik	NL - Loo				FR - Lbr				BE - Vie				IT - Col			
		96	192	336	720	96	192	336	720	96	192	336	720	96	192	336	720
RF	MSE (°C ²)	0,622	0,603	0,637	0,598	0,234	0,253	0,275	0,321	0,464	0,525	0,616	0,673	0,332	0,424	0,541	0,744
	MAE (°C)	0,55	0,54	0,546	0,534	0,348	0,352	0,356	0,386	0,49	0,52	0,561	0,59	0,344	0,396	0,469	0,544
XGB	MSE (°C ²)	1,169	1,168	1,199	1,096	0,343	0,37	0,399	0,436	0,914	1,072	1,16	0,961	0,469	0,612	0,813	1,025
	MAE (°C)	0,815	0,815	0,828	0,795	0,447	0,463	0,481	0,502	0,746	0,806	0,84	0,768	0,469	0,539	0,633	0,706

Tablo 7. CNN ve LSTM modelleri için farklı tahmin ufuklarında toprak sıcaklığı tahmin performansı (Soil temperature forecasting performance of CNN and LSTM models across different prediction horizons)

Yöntem	Metrik	NL - Loo				FR - Lbr				BE - Vie				IT - Col			
		96	192	336	720	96	192	336	720	96	192	336	720	96	192	336	720
LSTM	MSE (°C ²)	4,006	4,685	20,459	5,636	4,03	4,116	4,574	5,85	2,388	3,015	3,571	3,892	4,517	4,656	6,338	7,171
	MAE (°C)	1,517	1,68	3,944	1,887	1,519	1,565	1,682	1,933	1,215	1,322	1,45	1,543	1,495	1,542	1,898	1,997
CNN	MSE (°C ²)	1,825	1,914	2,149	2,127	1,746	1,966	2,206	2,169	1,673	1,768	1,843	1,857	2,135	2,078	2,168	2,56
	MAE (°C)	1,342	1,464	1,646	1,673	1,321	1,496	1,741	1,699	1,285	1,374	1,425	1,448	1,563	1,616	1,767	2,026

Tablo 8. Farklı tahmin ufuklarında transformatör tabanlı modellerin toprak sıcaklığı tahmin performansı (Soil temperature forecasting performance of transformer-based models across different prediction horizons)

Yöntem	Metrik	NL - Loo				FR - Lbr				BE - Vie				IT - Col			
		96	192	336	720	96	192	336	720	96	192	336	720	96	192	336	720
Transformer	MSE (°C ²)	0,004	0,039	0,061	0,102	0,066	0,104	0,122	0,142	0,061	0,104	0,129	0,149	0,043	0,083	0,101	0,139
	MAE (°C)	0,047	0,15	0,187	0,24	0,2	0,256	0,273	0,296	0,184	0,248	0,28	0,305	0,137	0,197	0,211	0,268
Informer	MSE (°C ²)	0,02	0,036	0,062	0,09	0,068	0,098	0,132	0,172	0,059	0,104	0,123	0,152	0,047	0,092	0,119	0,113
	MAE (°C)	0,107	0,142	0,188	0,23	0,203	0,25	0,288	0,327	0,184	0,25	0,274	0,312	0,143	0,199	0,233	0,249
Autoformer	MSE (°C ²)	0,015	0,048	0,078	0,166	0,076	0,091	0,118	0,161	0,079	0,108	0,146	0,237	0,058	0,099	0,109	0,153
	MAE (°C)	0,091	0,166	0,212	0,313	0,218	0,23	0,269	0,317	0,206	0,25	0,296	0,38	0,174	0,235	0,248	0,304
Reformer	MSE (°C ²)	0,028	0,044	0,075	0,116	0,068	0,094	0,117	0,107	0,069	0,108	0,118	0,133	0,047	0,063	0,071	0,076
	MAE (°C)	0,128	0,158	0,213	0,269	0,208	0,251	0,279	0,269	0,201	0,258	0,274	0,295	0,145	0,174	0,189	0,206
ETSformer	MSE (°C ²)	0,023	0,049	0,085	0,189	0,086	0,111	0,131	0,193	0,062	0,106	0,149	0,257	0,062	0,097	0,128	0,186
	MAE (°C)	0,118	0,168	0,22	0,338	0,229	0,259	0,283	0,347	0,199	0,248	0,298	0,398	0,189	0,234	0,271	0,337

Buna karşılık, XGBoost, çoğu tahmin uzunluğu ve istasyon için Random Forest'tan daha yüksek MSE ve MAE değerleri sergileyerek, bu görevde daha düşük performans göstermektedir. Örneğin, NL - Loo'da, MSE 96 adımda 1.169 °C²'de başlamakta ve tüm ufuklar boyunca 1.0°C²'nin üzerinde kalmaktadır. Ayrıca, FR - Lbr'de, MSE 96 adımda 0.343'ten 720 adımda 0.436'ya yükselmektedir. BE - Vie gibi diğer istasyonlarda da benzer eğilimler gözlemlenmektedir, burada MSE 336 adımda 1.160 °C²'a ulaşmaktadır. XGBoost'teki MAE değerleri de tahmin uzunluğu ile artmakta, ancak bu fark, Random Forest'a kıyasla daha belirgin hale gelmektedir. Örneğin, CH - Lae'de, MAE artışı 1.030'dan 1.041'e (°C) kadar devam etmektedir. Genel olarak, RF, çoğu senaryoda, özellikle 96 ve 192 adım gibi daha kısa tahmin uzunluklarında XGBoost'u sürekli olarak geride

bırakmaktadır. Ancak, her iki model de tahmin süresi uzadıkça zorluklar yaşamaktadır, bu da ağaç tabanlı modellerle uzun vadeli toprak sıcaklığı tahminindeki sınırlamaları göstermektedir.

Benzer şekilde, derin öğrenmeye dayalı yöntemlerin değerlendirme sonuçları Tablo 7'de verilmiş olup, transformatör tabanlı yöntemlerin değerlendirme sonuçları ise Tablo 8'de sunulmuştur. Tablo 6, 7 ve 8'de verilen sonuçlar, Tablo 3'teki dağılım kullanılarak altı farklı istasyon için elde edilmiştir. Bu tablolar boyunca her model, 96, 192, 336 ve 720 zaman adımları dahil olmak üzere çeşitli zaman dilimlerinde tahmin yeteneği açısından değerlendirilmiştir. Bu zaman adımları, modelin gelecekteki tahmin süresini belirtir. Örneğin, 96 zaman adımı, takip eden 96 saatlik bir tahmin ufukunu ifade eder. Bu

Tablo 9. Önerilen yöntem ve literatürün karşılaştırılması (Comparison of proposed method and literature)

Çalışmalar	Metot Detayları	Zaman Adımı (Saat)	Fluxnet Stations					
			NL - Loo	FR - Lbr	BE - Vie	IT - Col	FI - Hyy	CH- Lac
[23]	GRU & Auxiliary Network	24	-	-	-	-	-	1,0287
[35]	EEMD-CNN	120	-	-	-	-	-	0,498
[13]	Attention-based LSTM	168	0,352	0,811	1,119	2,947	3,268	-
Önerilen yöntem	Reformer	192	0,158	0,251	0,258	0,174	0,204	0,297

değerlendirme tablolarında, daha düşük değerler üstün performansı gösterir ve kalın yazı tipiyle vurgulanmıştır. Reformer yöntemi, 6 şehir ve 4 zaman adımı yapılan 20 testin 11'inde diğer yöntemlerden daha başarılı olmuştur. Transformatör yöntemleri genellikle sonuçlar açısından DL yöntemlerini geride bırakmaktadır. Özellikle dikkat çekici olan ise Reformer yönteminin CNN yaklaşımıyla elde edilen sonuçlarla karşılaştırıldığında yaklaşık 50 kat daha iyi sonuçlar elde etmesidir.

Tablo 9, mevcut literatürde özetlenen güncel toprak sıcaklığı tahmin yöntemleri ile önerilen yaklaşım arasında, MAE metriği kullanılarak kapsamlı bir karşılaştırma sunmaktadır. Bu karşılaştırma, Fluxnet veri seti üzerinde gerçekleştirilmiştir. Tablo 9'da karşılaştırılan yöntemler DL temelli yaklaşımlardır. Bu yöntemlerin sonuçları orijinal makalelerinden alınmıştır. Tablo 9'da sunulan tahmin değerleri, 5 cm toprak derinliği için türetilmiştir. Kısa vadeli zaman adımlarını tahmin etmek nispeten daha az zorlu olduğundan, tablodaki tüm yöntemler için en uzun tahmin aralıkları kullanılmıştır. Özellikle belirtmek gerekir ki, [23] ve [35] yöntemlerinin sonuçları sınırlı sayıda istasyonun verilerine dayanmaktadır. Bu, performans değerlendirmelerinin bu özel istasyonların koşullarıyla sınırlı olduğu ve daha geniş senaryolardaki performanslarını doğru bir şekilde yansıtmayabileceği anlamına gelir. Tablo 8'de görüldüğü gibi, önerilen Reformer yöntemi, diğer yöntemlere kıyasla tutarlı bir şekilde daha düşük MAE değerleri sergilemektedir. Bu tutarlı eğilim, Reformer yaklaşımının toprak sıcaklığı tahmininde üstün bir tahmin doğruluğu gösterdiğini ve bu alanda dikkate değer bir ilerleme sağladığını ima etmektedir. Ayrıca, Reformer yönteminin, ikinci en iyi yöntem olan [13]'e kıyasla neredeyse iki kat daha iyi sonuçlar gösterdiği vurgulanmalıdır. Bu durum, mevcut yaklaşımlara kıyasla tahmin hatalarını önemli ölçüde azaltma kapasitesine sahip olduğunu göstermektedir.

Çalışma kapsamında en iyi model olarak seçilen Reformer modelinin tahmin sürecinde kullandığı özelliklerin önem derecelerini belirlemek amacıyla SHapley Additive exPlanations (SHAP) analizi uygulanmıştır. SHAP, oyun teorisine dayalı Shapley değerleri kullanarak model çıktılarını açıklamaktadır. Analizde 200 test örneği kullanılmış ve 100 arka plan örneği ile karşılaştırma yapılmıştır. SHAP değerleri, her bir özelliğin model tahminlerine olan katkısını sayısal olarak ifade etmektedir.

SHAP analizi sonucunda elde edilen özellik önem sıralaması Tablo 10'da verilmiştir. Analiz sonuçlarına göre, en önemli üç özellik toplam model kararının %42,30'unu oluşturmaktadır. Hava sıcaklığı, toprak sıcaklığı tahmininde en etkili özellik olarak belirlenmiştir. Atmosfer basıncı ve yağış sırasıyla ikinci ve üçüncü sırada yer almaktadır. Özellik önem dağılımının görece dengeli olduğu gözlemlenmiştir. En yüksek öneme sahip özellik ile en düşük öneme sahip özellik arasındaki fark %4,66'dır. Bu durum, modelin tahmin sürecinde tüm özellikleri belirli bir oranda dikkate aldığını göstermektedir. Radyasyon bileşenleri (uzun dalga ve kısa dalga) orta düzeyde öneme sahiptir ve sırasıyla %12,67 ve %10,61 katkı sağlamaktadır. Toprak nemi %12,60 ile beşinci sırada yer alırken, hedef değişken olan toprak sıcaklığının geçmiş değerleri %11,49

önem derecesine sahiptir. Rüzgâr hızı, %10,32 ile en düşük önem derecesine sahip özellik olarak belirlenmiş ancak bu değer diğer özelliklerle karşılaştırıldığında önemli bir farklılık göstermemektedir. SHAP analizi, Reformer modelinin toprak sıcaklığı tahmininde meteorolojik özellikleri dengeli bir şekilde kullandığını ortaya koymuştur. Hava sıcaklığı, atmosfer basıncı ve yağış en kritik özellikler olarak öne çıkmakta, ancak tüm özelliklerin model performansına anlamlı katkıları bulunmaktadır. Bu bulgular, çok değişkenli yaklaşımın toprak sıcaklığı tahmini için uygun olduğunu desteklemektedir.

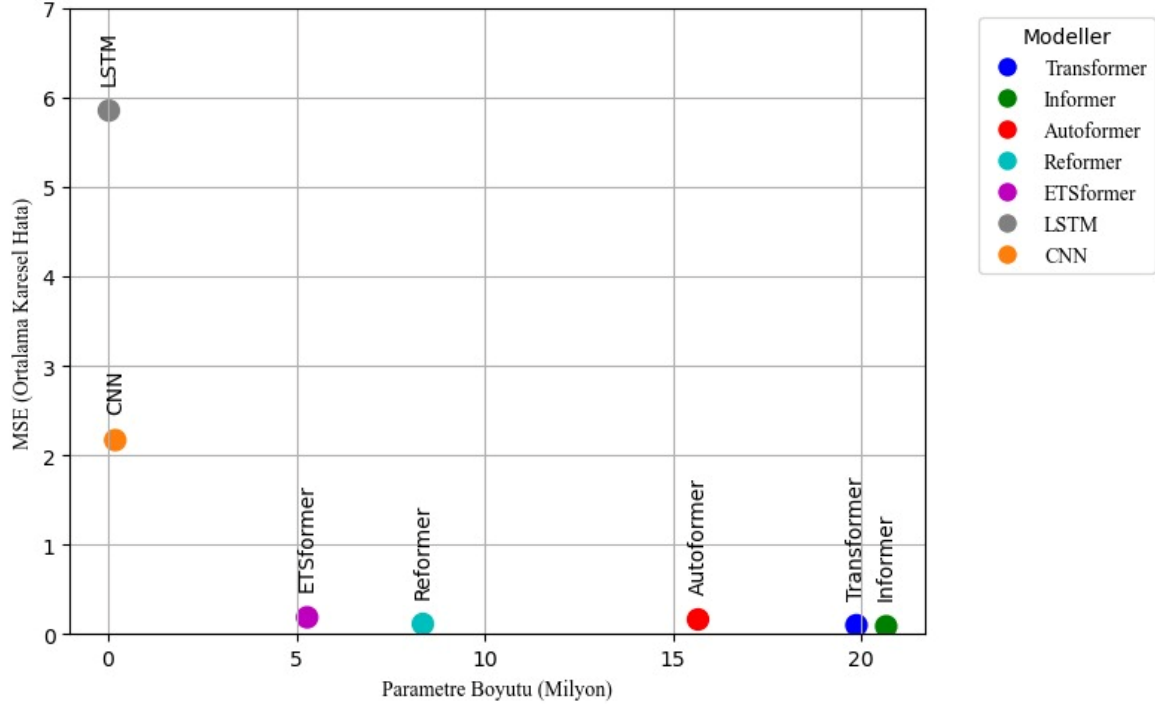
Tablo 10. SHAP Analizine göre her bir özelliğin önem derecesi (The importance level of each feature according to SHAP Analysis)

Özellik	Önem Derecesi
Hava Sıcaklığı (TA_F_MDS)	%14,97
Atmosfer Basıncı (PA_ERA)	%14,26
Yağış (P_ERA)	%13,00
Uzun Dalga Radyasyonu (LW_IN_F_MDS)	%12,66
Toprak Nemi (SWC_F_MDS_1)	%12,60
Toprak Sıcaklığı (TS_F_MDS_1)	%11,49
Kısa Dalga Radyasyonu (SW_IN_F_MDS)	%10,61
Rüzgâr Hızı (WS_ERA)	%10,32

Şekil 5, parametre boyutu (milyon) ve MSE açısından Transformatör tabanlı modeller ile geleneksel DL modellerinin karşılaştırmalı bir analizini sunmaktadır. 'FR - Lbr' istasyonundan elde edilen bu sonuçlar, 720 zaman adımıyla yapılan tahmin uzunluğu için model boyutu ile performans arasındaki dengeli bir şekilde vurgulanmaktadır. Grafik, geleneksel DL modelleri olan LSTM ve CNN'nin nispeten daha küçük parametre boyutlarına sahip olmalarına rağmen, Transformatör tabanlı modellere kıyasla önemli ölçüde daha yüksek MSE değerleri sergilediğini göstermektedir. Özellikle, yalnızca 0.019 milyon parametreye sahip olan LSTM, en yüksek MSE'yi (5,850 °C²) üretirken tahmin gereksinimlerini etkili bir şekilde karşılayamadığını ortaya koymaktadır. 0,189 milyon parametreye sahip olan CNN ise biraz daha iyi performans gösterse de hâlâ yüksek bir MSE (2,169 °C²) üretmektedir. Buna karşın, Transformer ve Informer gibi Transformatör tabanlı modeller, önemli ölçüde daha büyük parametre boyutlarına sahip olmalarına rağmen çok daha düşük MSE değerleri ile üstün performans sergilemektedir. Bu durum, karmaşık zaman serisi tahmin görevlerini ele almada Transformatör mimarilerinin avantajını vurgulamaktadır. Sonuç olarak bu bulgular, daha küçük modellerin hesaplama verimliliği sağlamasına karşın, Transformatör modellerinin daha iyi doğruluk elde ettiğini ve hassas tahminler gerektiren görevler için çok daha uygun olduğunu göstermektedir.

4.1. Zaman Serisi Tahmin Modellerinin İstatistiksel Karşılaştırması (Statistical Comparison of Time Series Forecasting Models)

Çalışmada beş farklı transformatör tabanlı zaman serisi tahmin modelinin performansları istatistiksel olarak karşılaştırılmıştır. Modeller, dört FLUXNET istasyonundan (BE, CH, FI, FR) elde



Şekil 5. FR - Lbr istasyonunda 720 zaman adımli tahmin için modellerin parametre boyutu ve MSE açısından karşılaştırması (Comparison of the models in terms of parameter size and MSE for the 720-time-step forecast at the FR-Lbr station)

Tablo 11. Modellerin istasyonlara göre MSE değerleri ($^{\circ}C^2$) ve tanımlayıcı istatistikleri (MSE values and descriptive statistics of the models according to stations)

Model	BE	CH	FI	FR	Ortalama	Std. Sapma
Informer	0.036	0.098	0.104	0.092	0.0825	0.0314
Autoformer	0.048	0.091	0.108	0.099	0.0865	0.0266
Reformer	0.044	0.094	0.108	0.063	0.0773	0.0291
Transformer	0.039	0.104	0.104	0.083	0.0825	0.0306
ETSformer	0.049	0.111	0.106	0.097	0.0907	0.0284

edilen toprak sıcaklığı tahmin verileri üzerinde 192 adımlık tahmin uzunluğu için test edilmiştir. İstatistiksel anlamlılık analizleri, Friedman testi ve Wilcoxon işaretli sıralar testi kullanılarak gerçekleştirilmiştir.

Çalışmada kullanılan MSE değerleri Tablo 11'de sunulmuştur. Her model, dört farklı istasyon için ayrı ayrı eğitilmiş ve test edilmiştir. Tablo 11'de görüldüğü üzere, Reformer modeli en düşük ortalama MSE değerine (0,0773) sahip olurken, ETSformer en yüksek ortalama MSE değerini (0,0907) göstermiştir. Standart sapma değerleri incelendiğinde, tüm modellerin istasyonlar arası varyasyonunun benzer düzeylerde olduğu gözlemlenmiştir.

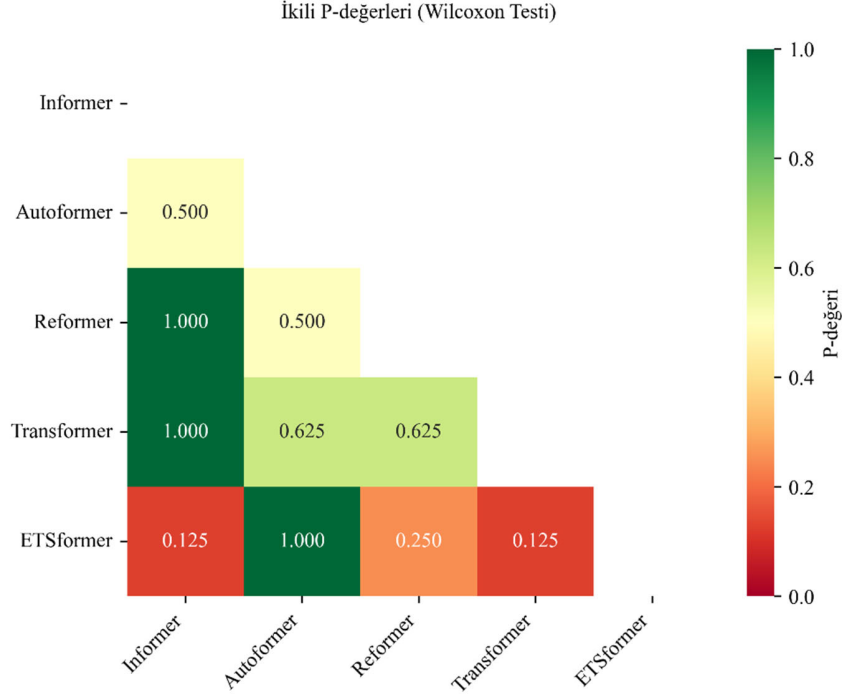
Beş model arasında genel bir performans farkının olup olmadığını test etmek amacıyla parametrik olmayan Friedman testi uygulanmıştır. İkili karşılaştırmalar için Wilcoxon işaretli sıralar testi kullanılmıştır. Çoklu karşılaştırma problemini kontrol altına almak üzere Bonferroni düzeltmesi uygulanmış ve anlamlılık düzeyi $\alpha = 0,05/10 = 0,005$ olarak belirlenmiştir.

Friedman testi sonuçları, beş model arasında istatistiksel olarak anlamlı bir performans farkı olmadığını göstermiştir: $\chi^2(4) = 5,333$, $p = 0,255$. Bu sonuç, gözlemlenen MSE farklarının rastgele varyasyondan kaynaklanabileceğini ve modeller arasında sistematik bir üstünlük bulunmadığını işaret etmektedir. Wilcoxon işaretli sıralar

testi ile gerçekleştirilen ikili karşılaştırma sonuçları Şekil 6'da sunulmuştur. Bonferroni düzeltmesi ($\alpha = 0,005$) uygulandığında hiçbir ikili karşılaştırma istatistiksel anlamlılık düzeyine ulaşmamıştır. En düşük p-değeri, Informer-ETSformer ($p = 0,125$) ve Transformer-ETSformer ($p = 0,125$) karşılaştırmalarında gözlemlenmiş olup, bu değerler bile düzeltilmiş anlamlılık eşiğinin oldukça üzerindedir.

Şekil 6'da sunulan p-değeri ısı haritası, tüm ikili karşılaştırmaların yeşil tonlarda gösterildiğini ortaya koymaktadır; bu durum, hiçbir model çiftinin istatistiksel olarak anlamlı bir fark göstermediğinin görsel bir kanıtıdır. Matrisin simetrik yapısı, test sonuçlarının tutarlılığını doğrulamaktadır.

Tablo 12'de, beş zaman serisi tahmin modelinin dikkat mekanizması özellikleri, ortalama eğitim süreleri ve ortalama MSE değerleri sunulmuştur. Tablo 12'de görüldüğü üzere, Reformer modeli en düşük ortalama MSE değerini (0,0773 $^{\circ}C^2$) elde etmesine rağmen, orta düzeyde bir eğitim süresi (16,4 dakika) gerektirmiştir. Informer modeli ise en hızlı eğitim süresini (13,2 dakika) sağlarken, Reformer'a göre %6,7 daha yüksek MSE değeri göstermiştir. Dikkat çekici şekilde, $O(L^2)$ karmaşıklığa sahip Transformer modeli, modern GPU optimizasyonları sayesinde Informer'a yakın bir eğitim süresi (13,9 dakika) sergilemiş ve benzer MSE performansı (0,0825 $^{\circ}C^2$) göstermiştir.



Şekil 6. Wilcoxon işaretli sıralar testi ile gerçekleştirilen ikili karşılaştırma sonuçları (Pairwise comparison results performed with Wilcoxon signed-rank test)

Tablo 12. Modellerin dikkat mekanizması, eğitim süresi ve MSE performansı karşılaştırması (Comparison of models' attention mechanism, training time, and MSE performance)

Model	Dikkat Mekanizması	Karmaşıklık	Ortalama Eğitim Süresi (dakika)	Ortalama MSE ($^{\circ}\text{C}^2$)
Informer	ProbSparse Attention	$O(L \log L)$	13,2	0,0825
Autoformer	Auto-correlation	$O(L \log L)$	18,1	0,0865
Reformer	LSH Attention	$O(L \log L)$	16,4	0,0773
Transformer	Full Attention	$O(L^2)$	13,9	0,0825
ETSformer	Exponential Smoothing	$O(L \log L)$	15,2	0,0907

Autoformer modelinin $O(L \log L)$ teorik karmaşıklığa sahip olmasına rağmen en uzun eğitim süresini (18,1 dakika) gerektirmesi, oto-korelasyon hesaplamaları için kullanılan FFT işlemlerinin ve her katmanda uygulanan seri ayrıştırma (series decomposition) mekanizmasının pratik hesaplama yükünü artırdığını göstermektedir. ETSformer modeli, üstel düzeltme tabanlı dikkat mekanizması kullanmasına rağmen en yüksek ortalama MSE değerini (0,0907 $^{\circ}\text{C}^2$) göstermiş, bu durum klasik zaman serisi yöntemlerinden ilham alan bu yaklaşımın DL tabanlı dikkat mekanizmalarına göre daha az etkili olabileceğini düşündürmüştür.

5. Sonuçlar (Conclusions)

Transformatör modellerinin toprak sıcaklığı tahmini için kullanımı, yeni bir son teknoloji oluşturmada ve bu modellerin etkinliğini vurgulamakta, geleneksel yöntemlere göre belirgin avantajlar sunmaktadır. Bu yaklaşımın başlıca gücü, toprak sıcaklığı verilerindeki karmaşık zamansal bağımlılıkları yakalayabilme yeteneğidir. Bu, geleneksel ağaç tabanlı ve DL modellerine kıyasla daha doğru uzun vadeli tahminler elde edilmesini sağlamaktadır. Bu özellik, toprak sıcaklığının ekolojik süreçler ve kaynak yönetimi kararlarını etkileyen önemli bir faktör olması nedeniyle ekolojik ve çevresel izleme için kritik öneme sahiptir. Transformatör modelleri, dikkat mekanizmaları sayesinde uzun vadeli bağımlılıkları yönetme konusunda mükemmeldir, bu da onları toprak sıcaklığı gibi zamansal

veriler için son derece uygun hale getirir. Bu modellerle elde edilen iyileştirilmiş doğruluk, toprak sıcaklığındaki ince değişiklikleri anlamaya yardımcı olur ve ekolojik dinamikleri takip etmek için önemlidir.

Birden fazla FLUXNET istasyonu kullanarak yapılan bu çalışma, transformatör modellerinin farklı çevresel koşullara uyum sağlama yeteneğini göstermektedir. Bu modellerin dayanıklılığı, geleneksel modellere göre farklı ortamlarda yeniden ayar yapma ihtiyacını azaltarak daha güvenilir hale getirir. Transformatör tabanlı yöntemler, emek yoğun manuel tahmin yöntemlerine duyulan ihtiyacı en aza indirir. Otomasyonu sayesinde toprak sıcaklığı tahmini sürecini kolaylaştırır, araştırmacılara ve uygulayıcılara daha verimli bir araç sunarak kaynakları daha ileri düzey ekolojik çalışmalar ve karar alma süreçlerine yönlendirir.

Bu tahmin yeteneği, tarım, ormancılık ve koruma gibi alanlarda önemli faydalar sağlar. Doğru toprak sıcaklığı tahminleri, ekosistem yönetimi, kaynak tahsisi ve biyoçeşitliliğin korunmasında, ekim takvimleri, sulama ihtiyaçları ve koruma çabaları gibi kararları bilgilendirir. Bu yaklaşım aynı zamanda aşırı sıcaklık olayları için erken uyarı sistemlerinin potansiyel geliştirilmesine olanak tanır. Bu, ekologlar, çiftçiler ve politika yapımcılar için büyük bir avantaj sağlayarak, mahsul hasarı, toprak bozulması ve diğer sıcaklık duyarlı ekolojik etkilerle ilgili risklerin azaltılmasına yardımcı olur.

Gelecek çalışmalarda, farklı iklim bölgelerini ve çeşitli toprak tiplerini temsil eden ek veri setlerinin modele dâhil edilmesi planlanmaktadır. Bu tür bir genişletme, önerilen transformatör tabanlı yaklaşımın farklı çevresel koşullar altındaki genelleme kapasitesinin daha kapsamlı biçimde değerlendirilmesine olanak sağlayacaktır. Özellikle farklı iklim rejimlerine sahip bölgelerden elde edilecek uzun dönemli toprak sıcaklığı verilerinin kullanılması, modelin mekânsal ve çevresel çeşitlilik karşısındaki dayanıklılığını artırarak daha genellenabilir ve güvenilir tahminler üretilmesine katkı sağlayabilir.

Kaynaklar (References)

- Adair E. C., Parton W. J., Del Grosso S. J., Silver W. L., Harmon M. E., Hall S. A., Burke I. C., Hart S. C., Simple three-pool model accurately describes patterns of long-term litter decomposition in diverse climates, *Global Change Biology*, 14 (11), 2636–2660, 2008.
- Bykova O., Chuine I., Morin X., Higgins S. I., Temperature dependence of the reproduction niche and its relevance for plant species distributions, *Journal of Biogeography*, 39 (12), 2191–2200, 2012.
- Fabris L., Buddendorf W. B., Soulsby C., Assessing the seasonal effect of flow regimes on availability of Atlantic salmon fry habitat in an upland Scottish stream, *Science of The Total Environment*, 696, 133857, 2019.
- Davidson E. A., Janssens I. A., Temperature sensitivity of soil carbon decomposition and feedbacks to climate change, *Nature*, 440 (7081), 165–173, 2006.
- Attri I., Awasthi L. K., Sharma T. P., Rathee P., A review of deep learning techniques used in agriculture, *Ecological Informatics*, 102217, 2023.
- Khan A., Vibhute A. D., Mali S., Patil C. H., A systematic review on hyperspectral imaging technology with a machine and deep learning methodology for agricultural applications, *Ecological Informatics*, 69, 101678, 2022.
- Zhang Z., Li Y., Williams R. A., Chen Y., Peng R., Liu X., Qi Y., Wang Z., Responses of soil respiration and its sensitivities to temperature and precipitation: A meta-analysis, *Ecological Informatics*, 102057, 2023.
- Seifi A., Ehteram M., Nayebloei F., Soroush F., Gharabaghi B., Torabi Haghighi A., GLUE uncertainty analysis of hybrid models for predicting hourly soil temperature and application wavelet coherence analysis for correlation with meteorological variables, *Soft Computing*, 25, 10723–10748, 2021.
- Singhal M., Gairola A. C., Singh N., Artificial neural network-assisted glacier forefield soil temperature retrieval from temperature measurements, *Theoretical and Applied Climatology*, 143, 1157–1166, 2021.
- Bayatvarkeshi M., Bhagat S. K., Mohammadi K., Kisi O., Farahani M., Hasani A., Deo R., Yaseen Z. M., Modeling soil temperature using air temperature features in diverse climatic conditions with complementary machine learning models, *Computers and Electronics in Agriculture*, 185, 106158, 2021.
- Malik A., Tikhamarine Y., Sihag P., Shahid S., Jamei M., Karbasi M., Predicting daily soil temperature at multiple depths using hybrid machine learning models for a semi-arid region in Punjab, India, *Environmental Science and Pollution Research*, 29 (47), 71270–71289, 2022.
- Guleryuz D., Estimation of soil temperatures with machine learning algorithms—Giresun and Bayburt stations in Turkey, *Theoretical and Applied Climatology*, 147 (1-2), 109–125, 2022.
- Li Q., Zhu Y., Shangguan W., Wang X., Li L., Yu F., An attention-aware LSTM model for soil moisture and soil temperature prediction, *Geoderma*, 409, 115651, 2022.
- Wang Y., Zhuang D., Xu J., Wang Y., Soil Temperature Prediction Based on 1D-CNN-MLP Neural Network Model, *Journal of the ASABE*, 0, 2023.
- Orhan İ., Özkan İ., Öztaş T., Yüksel A., Soil Temperature Prediction with Long Short Term Memory (LSTM), *Türk Tarım ve Doğa Bilimleri Dergisi*, 9 (3), 779–785, 2022.
- Küçük C., Birant D., Taşer P. Y., A Novel Machine Learning Approach: Soil Temperature Ordinal Classification (STOC), *Journal of Agricultural Sciences*, 28 (4), 635–649, 2022.
- Imanian H., Shirkhani H., Mohammadian A., Hiedra Cobo J., Payeur P., Spatial Interpolation of Soil Temperature and Water Content in the Land-Water Interface Using Artificial Intelligence, *Water*, 15 (3), 473, 2023.
- Bilgili M., Şaban Ü., Şekertekin A., Gürlek C., Machine Learning Approaches for One-Day Ahead Soil Temperature Forecasting, *Journal of Agricultural Sciences*, 29 (1), 221–238, 2023.
- Tüysüzöğlü G., Birant D., Kıranoğlu V., Soil Temperature Prediction via Self-Training: Izmir Case, *Journal of Agricultural Sciences*, 28 (1), 47–62, 2022.
- Imanian H., Hiedra Cobo J., Payeur P., Shirkhani H., Mohammadian A., A Comprehensive Study of Artificial Intelligence Applications for Soil Temperature Prediction in Ordinary Climate Conditions and Extremely Hot Events, *Sustainability*, 14 (13), 8065, 2022.
- Khan M. S., Ivoke J., Nobahar M., Amiri F., Artificial Neural Network (ANN) based Soil Temperature model of Highly Plastic Clay, *Geomechanics and Geoengineering*, 17 (4), 1230–1246, 2022.
- Tuysuzoglu G., Birant D., Kıranoğlu V., Multi-view multi-depth soil temperature prediction (MV-MD-STP): a new approach using machine learning and time series methods, *International Journal of Intelligent Engineering Informatics*, 10 (1), 74–104, 2022.
- Wang X., Li W., Li Q., A new embedded estimation model for soil temperature prediction, *Scientific Programming*, 2021, 1–16, 2021.
- Abimbola O. P., Meyer G. E., Mittelstet A. R., Rudnick D. R., Franz T. E., Knowledge-guided machine learning for improving daily soil temperature prediction across the United States, *Vadose Zone Journal*, 20 (5), e20151, 2021.
- Pastorello G., Trotta C., Canfora E., Chu H., Christianson D., Cheah Y.-W., ..., Amiro B., The FLUXNET2015 dataset and the ONEFlux processing pipeline for eddy covariance data, *Scientific Data*, 7 (1), 1–27, 2020.
- Li Q., Zhu Y., Shangguan W., Wang X., Li L., Yu F., An attention-aware LSTM model for soil moisture and soil temperature prediction, *Geoderma*, 409, 115651, 2022.
- Vaswani A., Shazeer N., Parmar N., Uszkoreit J., Jones L., Gomez A. N., Kaiser Ł., Polosukhin I., Attention is all you need, *Advances in Neural Information Processing Systems*, 30, 2017.
- Kitaev N., Kaiser Ł., Levskaya A., Reformer: The efficient transformer, *arXiv preprint arXiv:2001.04451*, 2020.
- Gomez A. N., Ren M., Urtasun R., Grosse R. B., The reversible residual network: Backpropagation without storing activations, *Advances in Neural Information Processing Systems*, 30, 2017.
- Zhou H., Zhang S., Peng J., Zhang S., Li J., Xiong H., Zhang W., Informer: Beyond efficient transformer for long sequence time-series forecasting, *Proceedings of the AAAI Conference on Artificial Intelligence*, 35 (12), 11106–11115, 2021.
- Chatfield C., *The analysis of time series: An introduction*, Chapman and Hall/CRC, 2003.
- Papoulis A., Unnikrishna Pillai S., *Probability, random variables and stochastic processes*, McGraw-Hill, 2002.
- Woo G., Liu C., Sahoo D., Kumar A., Hoi S., Etsformer: Exponential smoothing transformers for time-series forecasting, *arXiv preprint arXiv:2202.01381*, 2022.
- Holt C. C., Forecasting seasonals and trends by exponentially weighted moving averages, *International Journal of Forecasting*, 20 (1), 5–10, 2004.
- Hao H., Yu F., Li Q., Soil temperature prediction using convolutional neural network based on ensemble empirical mode decomposition, *IEEE Access*, 9, 4084–4096, 2021.
- Özdoğan İ., Boran F. E., Yıldız O., Fuzzy linguistic summarization of time series with interval type-2 fuzzy c-means: BIST100 sample stock application, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 40 (3), 1659-1672, 2025.
- Arseven B., Çınar S. M., Solar radiation prediction with extraterrestrial radiation supported multivariate Ridge and Lasso regression methods, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 40 (3), 1745-1756, 2025.
- Nalkıran M., Altuntaş S., Prediction of heat transfer value using an internet of things and machine learning-based approach in the automotive industry, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 40 (2), 937-950, 2025.
- Akbulut U., Çifçi M. A., İşler B., Aslan Z., Comparison of different techniques in river flow prediction using machine learning methods, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 40 (1), 467-486, 2025.