



## Geomatik

<https://dergipark.org.tr/tr/pub/geomatik>

e-ISSN 2564-6761



### Yinelemeli sinir ağlarıyla GNSS verilerinde birleştirilmiş ve bireysel model karşılaştırılması

Merve Şimşek<sup>\*1</sup>, Murat Taşkıran<sup>2</sup>, Uğur Doğan<sup>1</sup>

<sup>1</sup>Yıldız Teknik Üniversitesi, İnşaat Fakültesi, Harita Mühendisliği Bölümü, İstanbul, Türkiye, [mrve.smsek@gmail.com](mailto:mrve.smsek@gmail.com), [dogan@yildiz.edu.tr](mailto:dogan@yildiz.edu.tr)

<sup>2</sup>Yıldız Teknik Üniversitesi, Elektrik-Elektronik Fakültesi, Elektronik ve Haberleşme Mühendisliği Bölümü, İstanbul, Türkiye, [mrttskrn@yildiz.edu.tr](mailto:mrttskrn@yildiz.edu.tr)

Kaynak Göster: Şimşek, M., Taşkıran, M., & Doğan, U. (2025). Yinelemeli sinir ağlarıyla GNSS verilerinde birleştirilmiş ve bireysel model karşılaştırılması. *Geomatik*, 10 (1), 65-74

DOI: 10.29128/geomatik.1530761

#### Anahtar Kelimeler

GNSS  
Zaman Serisi Kestirimi  
Derin Öğrenme  
Yinelemeli Sinir Ağları

#### Araştırma Makalesi

Geliş: 09.08.2024  
Reviz: 18.09.2024  
Kabul: 20.09.2024  
Çevrim İçi Yayınlanma:  
01.03.2025



#### Öz

Bu çalışmada, derin öğrenme algoritmalarından olan Uzun Kısa Süreli Bellek (LSTM) ve Geçitli Tekrarlayan Birim (GRU) ile GNSS istasyon verilerinin Kuzey, Doğu ve Düşey bileşenleri için ileriye dönük ayrı ayrı kestirimler yapılarak, istasyon bazında eğitilen modeller ve tüm istasyon verilerinin birlikte eğitildiği tek model performansları karşılaştırılarak model yönetiminin performanslar üzerine etkisi incelenmiştir. Her bir GNSS istasyonu için ayrı modellerin kullanıldığı Senaryo I ve toplu verilerle tek bir birleşik modelin kullanıldığı Senaryo II için model performansı, ortalama karekök hata (RMSE), ortalama mutlak hata (MAE) ve belirleme katsayısı ( $R^2$ ) kullanılarak Doğu, Kuzey ve Düşey bileşenler için değerlendirilmiştir. GRU algoritmasıyla Doğu bileşen için ortalama RMSE değeri Senaryo I ve II için sırayla 1.68 ve 1.67 mm, MAE değeri 1.24 ve 1.27 mm; Kuzey bileşen için RMSE değeri 1.70 ve 1.72 ve MAE değeri 1.32 ve 1.33 mm, Düşey bileşen için RMSE 4.50 ve 4.43 mm ve MAE 3.58 ve 3.50 mm'dir. Bulgular tek model yaklaşımının model yönetimini basitleştirilerek özellikle daha homojen veri özelliklerine sahip bölgelerde, ayrı ayrı eğitilmiş modellerle karşılaştırılabilir doğruluk elde edebileceğini göstermektedir.

### Comparison of combined and individual model in GNSS data with recurrent neural networks

#### Keywords

GNSS  
Time Series Forecasting  
Deep Learning  
DEM  
Recurrent Neural Network

#### Research Article

Received: 09.08.2024  
Revised: 18.09.2024  
Accepted: 20.09.2024  
Online Published:  
01.03.2025

#### Abstract

In this study, the effect of model management on performance is analysed by comparing the performance of station-based models and the single model trained with all station data using the Long Short Term Memory (LSTM) and Gated Recurrent Unit (GRU) deep learning algorithms for the North, East and Vertical components of GNSS station data. For Scenario I, where separate models are used for each GNSS station, and Scenario II, where a single combined model is used with aggregated data, model performance is evaluated for the East, North and Vertical components using Root Mean Square Error (RMSE), Mean Absolute Error (MAE) and Coefficient of Determination ( $R^2$ ). With the GRU algorithm, the average RMSE for the East component is 1.68 and 1.67 mm and the MAE is 1.24 and 1.27 mm for scenarios I and II respectively; for the North component the RMSE is 1.70 and 1.72 and the MAE is 1.32 and 1.33 mm; for the Vertical component the RMSE is 4.50 and 4.43 mm and the MAE is 3.58 and 3.50 mm. The results show that the single model approach can simplify model management and achieve comparable accuracy to separately trained models, especially in regions with more homogeneous data characteristics.

## 1. Giriş

Küresel Navigasyon Uydu Sistemi (GNSS), modern dünyanın temel yapı taşlarından biri haline gelmiştir. Son yıllarda, GNSS teknolojisi, sadece navigasyon ve konumlandırma alanlarında değil, aynı zamanda jeodezik ve jeofiziksel araştırmalar gibi daha geniş bir yelpazede kullanılmaya başlanmıştır (Li ve ark., 2021). Bu teknoloji, yer yüzeyinin ve yer kabuğunun hareketlerinin hassas ölçümlerini sağlayarak, deprem öncesi aktivite izleme, volkanik hareketlerin takibi ve iklim değişikliklerinin etkilerinin anlaşılması gibi kritik alanlarda önemli roller üstlenmektedir. GNSS verilerinin bu geniş spektrumda kullanımı, doğal afetlerin erken tespiti ve zararlarının azaltılması açısından büyük önem taşımaktadır. GNSS, yer hareketini çok yüksek frekansta ve mekansal hassasiyetle gerçek zamanlı olarak ölçer (Li ve ark., 2015; Mufundirwa ve ark., 2010). Uzun dönem veri toplanmış GNSS koordinat zaman serileri jeodezi ve jeodinamik araştırmalar için değerli bilgiler sağlamaktadır (Geoffrey ve Lavallée., 2002; Ohta ve ark., 2012; Deng ve ark., 2017). Bu veriler yalnızca uzun vadeli değişim eğilimini yansıtmakla kalmaz, aynı zamanda jeofiziksel etkilerin neden olduğu doğrusal olmayan değişiklikleri de temsil etmektedir. GNSS koordinat zaman serileri, levha hareketlerinin izlenmesinde (Bevis ve ark., 2005; Montillet ve ark., 2015; Şimşek ve ark., 2019), baraj veya köprü deformasyonunun izlenmesinde (Meng ve ark., 2004; Yi ve ark., 2013; Yu ve ark., 2014; Xi ve ark., 2018; Chen ve ark., 2018) ve küresel veya bölgesel referans sistemlerinin oluşturulmasında önemli bir rol oynamaktadır (Altamimi ve ark., 2016; Yurdakul ve Kalaycı, 2022).

Jeodezi ve jeofizik alanlarında, GNSS verilerinin analizi Dünya'nın dinamiklerini anlamak için hayati öneme sahiptir. Bu sistemlerin performansını daha da iyileştirmek ve daha derinlemesine analizler yapabilmek için Makine Öğrenimi (ML) ve Derin Öğrenme (DL) tekniklerinin kullanılması giderek daha fazla önem kazanmaktadır. Bu teknikler, geleneksel analiz yöntemlerinin ötesine geçerek, verilerin dağılımı için açık bir formül üretmek yerine, veri özellikleri arasındaki karmaşık ilişkileri öğrenmeye ve bu bilgileri tahmin, sınıflandırma, kümeleme ve anomali tespiti gibi çeşitli uygulamalarda kullanmaya olanak tanımaktadır. Özellikle, Derin Öğrenme ve yapay sinir ağları, büyük ve karmaşık GNSS veri kümelerindeki gizli örüntüleri ve ilişkileri ortaya çıkarmak için idealdir. Bu teknolojiler, zaman serilerinin yapısal özelliklerini ve uzun vadeli eğilimlerini anlamakta son derece etkilidir.

Makine öğrenmesi ve derin öğrenme gibi veri odaklı öğrenme tekniklerin zaman serilerini modellediği ve tahmin ettiği çalışmalar yapılmıştır. Yapay sinir ağı (YSA) (Lian ve ark., 2015; Serwa ve ark., 2024), rastgele orman (Hu ve ark., 2021), destek vektör makinesi (SVM) (Miao ve ark., 2018), aşırı öğrenme makinesi (ELM) (Liao ve ark., 2020) ve LSTM ağları (Yang ve ark., 2019) zaman serisi tahmininde geniş çapta çalışılmıştır. Xing ve arkadaşları, heyelan deformasyonunun izlenmesinde, Dashuitian'da yapılan deneylerde varyasyonel mod ayrışımına (VMD) ve LSTM ve EMD-LSTM açısından daha yüksek tahmin doğruluğuna sahip bir yığın LSTM'e dayanan bir model önermiştir (Xing ve ark., 2019a). Xing

ve arkadaşları heyelan yer değiştirmesini tahmin etmek için çift hareketli ortalama (DMA) yöntemi ile LSTM'yi birleştirmiş ve yüksek kaliteli güven aralıkları elde etmiştir (Xing ve ark., 2019b). Wang ve arkadaşları, Uyarlanabilir Gürültülü Komple Topluluk Ampirik Mod Ayrışımına (CEEMDAN-AMLSTM) dayalı bir dikkat mekanizması LSTM modeli geliştirmiş ve heyelan yer değiştirme tahmini için geçerliliğini doğrulamıştır (Wang ve ark., 2021). Yang ve arkadaşları (2019), Three Gorges Rezervuar Alanındaki heyelanların periyodik yer değiştirmesini tahmin etmek için bir LSTM modeli kullanmış ve LSTM yönteminin, tarihsel bilgilerin tam olarak kullanılması nedeniyle heyelanların dinamik özelliklerini statik bir modelden daha iyi simüle edebildiğini bulmuşlardır (Yang ve ark., 2019).

Zhu ve arkadaşları (2022), heyelan yer değiştirmesini tahmin etmek için hibrit bir makine öğrenme yaklaşımı sunmaktadır. Değişken Modal Ayrıştırma (VMD) ile yer değiştirme eğilim ve periyodik bileşenlere ayrılmıştır. Periyodik bileşen için ise Aşırı Öğrenme Makinesi (ELM) kullanılmıştır. ELM modelini optimize etmek için Parçacık Sürü Optimizasyonu (PSO) uygulanmıştır. Üç Boğaz Barajı alanında test edilen model, LSSVM ve CNN-GRU gibi diğer yöntemlerle karşılaştırıldığında RMSE, MAE, MAPE ve  $R^2$  değerleri açısından üstün performans göstermiştir. DES-PSO-ELM modelinin RMSE, MAE, MAPE ve  $R^2$  değerleri sırasıyla 1.295 mm, 0.998 mm, %0.008 ve 0.999 olarak bulunmuştur.

Jiang ve arkadaşları (2023), baraj gölü yer kaymalarını tahmin etmek için Çoklu Ölçekli Tepki Analizi (JTFA) ve GRU tabanlı bir derin öğrenme modeli önermektedir. GNSS verileri, yıllık yağış miktarı ve rezervuar su seviyesi verilerini kullanarak, yer kaymasının doğrusal olmayan doğasını modellemeyi amaçlamışlardır. Çalışmanın bulguları, yer kaymalarının belirgin bir 12 aylık döngüsü olduğunu ve GRU modelinin yüksek bir başarı oranı (RMSE: 12.301 mm,  $R^2$ : 0.979) elde ettiğini göstermektedir.

Huang ve arkadaşları (2022), Muyubao heyelanının yer değiştirmesini tahmin etmek için Temporal Convolutional Network (TCN) ve Salp Swarm Algorithm (SSA) algoritmasını birleştiren bir hibrit model önermektedir. Trend bileşeni için polinom fonksiyonları, periyodik bileşenin tahmininde ise SSA ile optimize edilmiş TCN modeli kullanılmıştır. TCN modelinin RMSE değeri 6.37 mm, MAPE değeri %1.49 olarak ölçülmüştür. SVM modeliyle karşılaştırıldığında, ortalama iyileşme oranı %8.99 ile %66.69 arasında değişmektedir. Bu sonuçlar, TCN'nin RNN ve CNN özelliklerini birleştirerek yüksek performans sağladığını göstermektedir.

Yang ve arkadaşlarının 2024'te yaptığı çalışma, Çin'in Zhejiang Eyaleti'ndeki Wenzhou Belt Otoyolu'ndaki bir heyelana odaklanmakta ve grafik derin öğrenme ile GNSS konumlandırmasına dayalı yeni çok değişkenli heyelan yer değiştirme tahmin yöntemi önermektedir. Bu yöntem, GNSS yer değiştirme verileri, yağış, yeraltı su seviyesi ve toprak nem içeriği gibi zaman serisi verilerini birleştirerek yer kayması tahminlerinde üstün sonuçlar göstermiştir. GTS modeli, SVM, XGBoost ve LSTM gibi mevcut yöntemlerden daha iyi performans sergilemiş ve mekansal ve zamansal bağımlılıkları bir araya getirerek tahmin yeteneğini artırmıştır.

Port Kembla ve Milner Bay lokasyonları için deniz seviyesi yükselmesini tahmin etmek amacıyla karma bir derin öğrenme modeli olan SVM-D-CNN-BiLSTM'yi kullanmışlardır. Port Kembla için yıllık ortalama deniz seviyesi yükselmesinin yaklaşık olarak 4,5 mm/yıl, Milner Bay için ise yaklaşık 2,75 mm/yıl olacağı tahmin edilmiştir. Bu projeksiyonlar, gelecekte alınacak önlemler ve politikalar için kritik öneme sahiptir. Sonuç olarak, [Raj ve Brown'un \(2023\)](#) çalışması, deniz seviyesi yükselmesi tahminleri için oldukça karmaşık bir derin öğrenme modeli kullanarak yüksek derecede doğru ve güvenilir sonuçlar elde etmeyi başarmıştır ([Raj, N. ve Brown, J., 2023](#)).

[Jiang ve ark. \(2024\)](#), GNSS koordinat zaman serilerinin tahmini için Transformer çerçevesine dayanan yeni bir derin kendine dikkat sinir ağı (DSANN) önermişlerdir. Yaptıkları deneylerde, DSANN modelinin LSTM ve En Küçük Kareler (LS) yöntemlerine göre daha düşük RMSE ve MAE değerleri elde ettiğini ve eksik veri oranı %20'ye kadar olan durumlarda bile yüksek tahmin doğruluğunu koruduğunu göstermişlerdir. Benzer şekilde, [Xie ve ark. \(2024\)](#), GNSS verileriyle deformasyon izleme için CNN ve GRU modellerini birleştiren bir yöntem sunmuşlardır. Önerilen CNN-GRU modeli, geleneksel Genişletilmiş Kalman Filtresi (EKF) yöntemine göre yaklaşık %45 daha iyi performans sergilemiş ve deformasyon tahmininde daha yüksek doğruluk ve güvenilirlik sağlamıştır. Bu çalışmalar, derin öğrenme modellerinin GNSS zaman serilerinin tahmininde etkin bir şekilde kullanılabileceğini göstermektedir.

Bu çalışmada da derin öğrenme algoritmalarından olan GRU ve LSTM ile Türkiye'nin İç Anadolu Bölgesinde bulunan TUSAGA-Aktif ağına ait 6 GNSS istasyon verilerinin Kuzey, Doğu ve Düşey bileşenleri için ileriye dönük ayrı ayrı kestirimler yapılmıştır. İstasyon bazında eğitilen modeller ve tüm istasyon verilerinin birlikte eğitildiği tek model performansları karşılaştırılarak model yönetimin performansları üzerine etkisi analiz edilmiştir.

İlerleyen bölümlerde; [Bölüm 2](#)'de kullanılan veriler, yöntemlerin ve işlem adımlarının, model algoritmalarının açıklaması verilmiştir. [Bölüm 3](#)'te, bulgular verilmiş ve karşılaştırmalı analizleri yapılmış; [Bölüm 4](#)'te sonuçlar tartışılmış ve öneriler sunulmuştur.

## 2. Yöntem

Bu araştırmanın verisi Nevada Jeodezi Laboratuvarı tarafından sağlanan günlük Hassas Nokta Konumlandırma (PPP) çözümlerinden elde edilmiştir. Bu çalışmada kullanılan GNSS istasyonları, bölgenin önemli bir bölümünü kapsayan coğrafi dağılımları ve yıllar boyunca sağladıkları verilerin kalitesi ve sürekliliği de dahil olmak üzere belirli kriterlere göre seçilmiştir ([Şekil 1](#)). Verilerin zaman aralığı 16 Ocak 2009'dan 31 Ekim 2015'e kadar uzanmakta ve yaklaşık yedi yıllık gözlemleri kapsamaktadır. Her bir istasyon için Doğu, Kuzey ve Düşey bileşenlerine ait veriler ayrı ayrı değerlendirilmiştir.

Gerçekleştirilen çalışma ile ilgili adımları gösteren blok diyagram [Şekil 2](#)'de gösterilmiştir. Analiz amacıyla, veri kümesi zaman sırasına göre bölümlendirilmiş,

verilerin ilk %80'i yani daha eski tarihli veriler modelin eğitimi için ayrılmış ve kalan %20'si test kümesi olarak değerlendirilmiştir. Bu oranlar zaman serisi analizinde yaygın olarak kullanılan oranlar olduğu için seçilmiştir. Eğitim ve test setleri üzerinde; T-test ve Kolmogorov-Smirnov (KS) testi ile yapılan istatistiksel karşılaştırmalarda, tüm bileşenler için p-değerleri 0.05'in üzerinde bulunmuştur. Bu sonuçlar, eğitim ve test setleri arasında istatistiksel olarak anlamlı bir fark olmadığını ve her iki setin de aynı dağılımdan geldiğini dolayısıyla homojen olduklarını göstermektedir. Bu bölümlenme yaklaşımı, kapsamlı bir eğitim sürecini kolaylaştırırken, modelin tahmin doğruluğunun görünmeyen veriler üzerinde sağlam bir şekilde test edilmesi ve doğrulanması için yeterli bir veri kümesinin mevcut olmasını sağlamıştır. Bu altı farklı istasyon üzerinde yinelemeli sinir ağlarından olan LSTM ve GRU modelleri kullanılarak kestirimler gerçekleştirilmiştir. Eğitim setleri, modellerin öğrenmesi için kullanılmış, test setleri ise modellerin kestirim performansını değerlendirmek amacıyla ayrılmıştır.

Çalışma iki farklı senaryo kapsamında yürütülmüştür:

**Senaryo I:** Her bir istasyonun verilerinin ayrı ayrı eğitim ve test edilmesi.

**Senaryo II:** Tüm istasyonların eğitim verilerinin birleştirilerek ortak bir modelin eğitilmesi ve bu modelin her bir istasyonun test verileri üzerinde değerlendirilmesi.

Veri setinde, 12 zaman adımın hareketli pencereler (sliding windows) kullanılarak özellik çıkarımı yapılmıştır. Her pencere, ardışık 12 zaman adımından oluşmakta ve bu pencereler veri seti boyunca bir adım kaydırılmaktadır. Model, one-step ahead forecasting yöntemi kullanılarak eğitilmiştir. Bu yaklaşım, her 12 zaman adımın pencerenin hemen ardındaki tek bir zaman adımın kestirilmesini sağlamaktadır.

Bu sıralı girdilerin oluşturulmasının ardından, derin öğrenme modelleri her bir diziyi işlemeye başlar. Modelin mimarisi 100 nöronluk bir GRU/LSTM katmanı ile başlar. Bunu, modelin hesaplama sürecine doğrusal olmayan dönüşümleri dahil etmek için ReLU aktivasyon fonksiyonunu uygulayan 100 nöronlu oluşan yoğun bir katman izlemektedir. Mimari yapılandırma, tahmin edilen değerleri sağlamak için tasarlanmış yoğun bir çıktı katmanı ile sonuçlanır. Bu noktada, işlenen zamansal veriler nihai tahminlere dönüşmektedir.

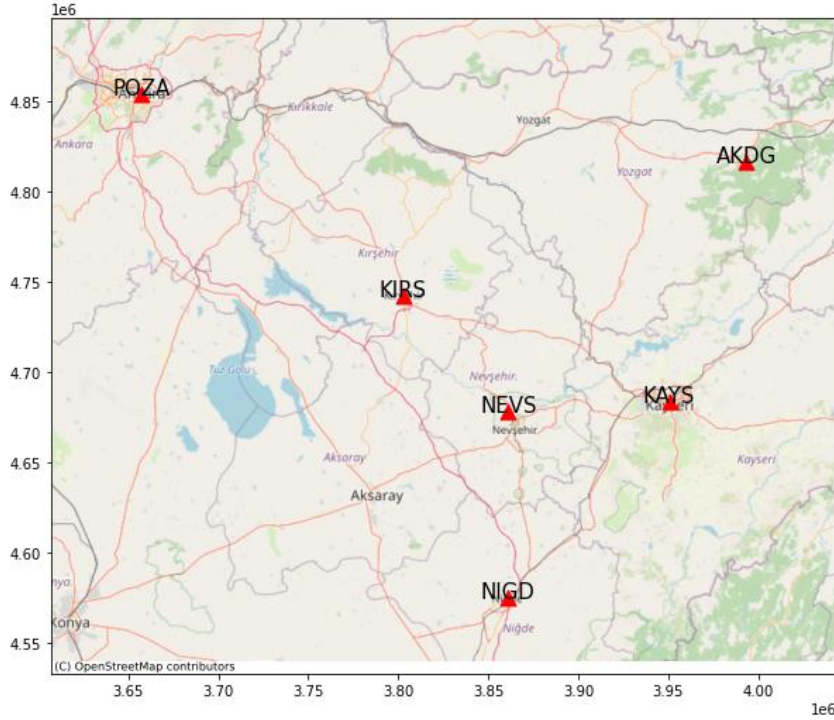
[Tablo 1](#)'de sunulan hiperparametreler, çeşitli kombinasyonları deneyerek en etkili yapılandırmayı belirlemek için bir ızgara arama (grid search) yaklaşımı kullanılarak seçilmiştir. ızgara araması sırasında, batch boyutları (32 ve 64), işlem katmanlarındaki nöron sayıları (64, 100, 128, 200) ve yoğun katmanlar için hem nöron sayıları (50, 100, 128, 200) hem de aktivasyon fonksiyonları (ReLU ve tanh) ayarlanmıştır.

Modelin hesaplama karmaşıklığı ve performansını değerlendirmek amacıyla, toplam parametre sayısı, eğitim süresi ve çıkarım süresi gibi metrikler hesaplanmıştır. Birleştirilmiş tek modelin toplam parametre sayısı 483,005 olup, eğitilebilir parametre sayısı 161,001'dir. Eğitim ortalama olarak toplamda 18.51 saniye sürmüştür. Tek bir örnek için çıkarım süresi

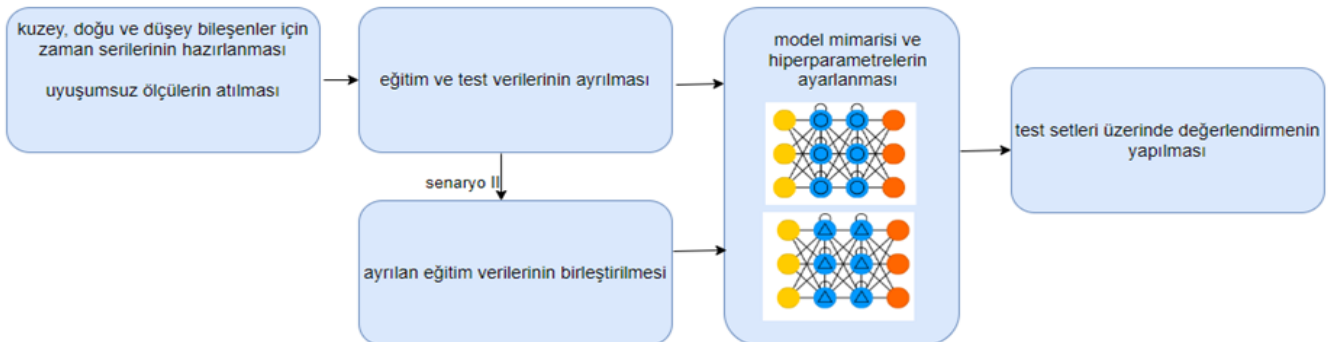
ortalama 100.41 milisaniye iken, tüm test verileri için toplam çıkarım süresi 0.16 saniye olarak ölçülmüştür. İstasyon bazında eğitilen ayrı modellerde ise, her bir modelin toplam parametre sayısı 453,305 ve eğitilebilir parametre sayısı 151,101'dir. Her bir istasyon için eğitim süresi ortalama 7.62 saniye olup, 6 istasyon için toplam eğitim süresi 45.72 saniyeye ulaşmaktadır. Çıkarım süresi her bir model için ortalama 0.64 saniye olup, 6 istasyon için toplam çıkarım süresi 3.84 saniyedir. Bu sonuçlar, birleştirilmiş modelin istasyon bazında eğitilen modellere göre eğitim süresinde yaklaşık %59'luk bir azalma ve çıkarım süresinde %95.8'lik bir azalma sağladığını göstermektedir. Tüm deneyler, Windows 10 işletim sistemi üzerinde, Intel64 Family 6 Model 183 Stepping 1, Genuine Intel işlemci (14 fiziksel çekirdek, 20 mantıksal işlemci) ve 15.69 GB RAM ile gerçekleştirilmiştir.

Modelin aşırı uyumunu (overfitting) önlemek ve genel performansını artırmak amacıyla, eğitim sürecinde validasyon seti kullanılarak erken durdurma (Early Stopping), öğrenme oranı azaltma (ReduceLRonPlateau) ve öğrenme oranı zamanlayıcısı (Learning Rate

Scheduler) teknikleri kullanılmıştır. Eğitim verilerinin %10'u validasyon seti olarak ayrılmıştır. Validasyon seti, modelin eğitim süreci boyunca performansını izlemek ve hiperparametre ayarlarını optimize etmek için kullanılmıştır. Bu teknikte, doğrulama kaybı (validation loss) belirli bir süre boyunca (patience değeri kadar) iyileşme göstermediğinde eğitim durdurulur. Ayrıca, iterasyon sayısına bağlı olarak öğrenme oranını dinamik olarak değiştiren bir öğrenme oranı zamanlayıcısı göz önüne alınmıştır. Bu zamanlayıcı, ilk 10 iterasyon boyunca öğrenme oranını sabit tutmuş, ardından her iterasyon sonunda %5 oranında azaltmıştır. Sonunda en iyi doğrulama kaybına sahip model ağırlıkları geri yüklenir (restore\_best\_weights=True), böylece modelin en iyi genel performansı sağlanır. Bu teknikler, modelin aşırı uyumunu önlemenin yanı sıra eğitim süresini kısaltarak hesaplama kaynaklarının verimli kullanılmasını sağlar. Modelin eğitimi, 200 iterasyon boyunca, 32 batch boyutu ile gerçekleştirilmiş olup, bu ve diğer parametre bilgileri Tablo 1'de verilmektedir.



Şekil 1. GNSS istasyonlarının konumu.



Şekil 2. Akış şeması.

**Tablo 1.** Modelin hiperparametreleri.

Hiperparametre	Değer
Girdi Biçimi (input_shape)	(12, 1)
LSTM / GRU Katmanı	100 nöron, return_sequences=True
YoğunKatman (Dense)	100 nöron, ReLU aktivasyon fonksiyonu
Kayıp Fonksiyonu (loss)	Ortalama Kare Hatası (MSE)
Optimizatör	Adam, öğrenme oranı: 0.001
Değerlendirme Metrikleri	Karekök Ortalama Hata (RMSE), Ortalama Mutlak Hata (MAE)
Erken Durdurma (Early Stopping)	İzlenen metrik: Val_loss, patience: 10, restore_best_weights: True
Öğrenme Oranı Zamanlayıcısı	İterasyon < 10: mevcut oran, İterasyon ≥ 10: oran %5 azaltılır
Öğrenme Oranı Azaltma (ReduceLROnPlateau)	İzlenen metrik: Val_loss, factor: 0.5, patience: 5, min_lr: 0.0001
İterasyon Sayısı	200
Batch Boyutu	32

### 2.1. Uzun kısa süreli bellek (LSTM)

LSTM, zamansal bilginin ne kadarının unutulduğunu veya hatırlandığını dikkate alan ve yaygın olarak kullanılan bir Tekrarlayan Sinir Ağıdır (RNN)(Hochreiter ve Schmidhuber, 1997). LSTM, geleneksel RNN'lerin kaybolan gradyan sorunu gibi sınırlamalarının üstesinden gelmek için tasarlanmıştır. Sıralı verilerdeki uzun vadeli bağımlılıkları yakalama yeteneklerini vurgulayarak, onları özellikle zaman serisi analizi, doğal dil işleme ve sıralı verileri içeren diğer uygulamalar için kullanışlı hale getirmektedir

LSTM algoritması, uzun dönemler boyunca bilgiyi işlemesine ve hatırlamasına izin vermek için hücre yapısı içinde bir dizi matematiksel işlem içerir. Bir LSTM hücresi, üç ana kapı (giriş, unutma ve çıkış) ve bilgiyi tutmasına yardımcı olan bir iç durum ile ifade edilir (Demiryeye ve Ulukavak, 2022).

•**Unutma Kapısı ( $f_t$ ):** unutma kapısı hücre durumundan ( $C_{t-1}$ ) hangi bilginin korunacağını veya atılacağını mevcut zaman adımı ( $t$ ) için belirler. Bu, mevcut girdi ( $x_t$ ) ve önceki çıktı ( $h_{t-1}$ ), işlenerek, hücre durumundaki her sayı için 0 (atma) ile 1 (koruma) arasında bir değer üretilerek çalışmaktadır.

Matematiksel olarak,

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (1)$$

ifade edilir. Burada,  $\sigma$  sigmoid fonksiyonu,  $W_f$  unutma kapısının ağırlık matrisi,  $[h_{t-1}, x_t]$  önceki çıktı ve mevcut girdinin birleştirilmesi ve  $b_f$  unutma kapısının biasıdır.

•**Giriş Kapısı ( $i_t$ ):**

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (2)$$

$$\tilde{C}_t = \tanh(W_C \cdot [h_{t-1}, x_t] + b_C) \quad (3)$$

$\tilde{C}_t$  aday hücre durumudur,  $W_i$  ve  $W_C$  ağırlık matrisleridir,  $b_i$  and  $b_C$  giriş kapısı ve aday değerler için biaslardır.

### Hücre Durumu Güncellemesi:

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad (4)$$

burada,  $C_t$  yeni hücre durumu,  $C_{t-1}$  önceki hücre durumu ve  $*$  eleman bazında çarpımı ifade eder..

Giriş kapısı, herhangi bir zaman adımında hücre durumunun ( $C_t$ ) güncellenmesinde çok önemli bir rol oynar. İlgili bilgileri hücre durumuna etkin bir şekilde dahil etmek için iki ana adımda çalışır. İlk olarak, gelen verileri filtrelemek için bir Sigmoid katman kullanır ve mevcut zaman adımı için hangi bilgilerin uygun olduğunu seçer. Bu seçim sürecinin ardından, bir tanh katmanı seçilen bilgiyi değerlendirerek önem düzeyini belirler ve bu bilginin hücre durumunu ne kadar etkilemesi gerektiğini ölçer.

•**Çıkış Kapısı:** Çıkış kapısı, hücre durumunun ( $C_t$ ) mevcut çıktısı ( $h_t$ ) ne kadar etkileyeceğini belirlemekle görevlidir. Bunu başarmak için, öncelikle mevcut anda hücre durumunun önemini değerlendirmek üzere bir Sigmoid fonksiyonu kullanır. Bu değerlendirme, ardından, nihai çıktıyı oluşturmak için değerlendirilen önemi modüle eden bir *tanh* fonksiyonu ile işlenir.

Bu işlemler matematiksel olarak şu formüllerle temsil edilir:

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (5)$$

$$h_t = o_t * \tanh(C_t) \quad (6)$$

Burada,  $W_o$  çıkış kapısının ağırlık matrisi, çıkış kapısının biası,  $h_t$  LSTM hücresinin mevcut çıktısıdır.

### 2.2. Geçitli tekrarlayan birim (GRU)

LSTM'nin daha sade bir çeşididir ve dizilim modellemede yüksek performans sağlarken hesaplama verimliliğini artırmak için optimize edilmiştir. GRU'lar, hücre ve gizli durumları birleştirerek LSTM yapısını basitleştirir ve böylece sistemin karmaşıklığını azaltır. Her GRU hücresi iki kapı ile çalışır: sıfırlama ve güncelleme kapıları. Bu kapılar, yeni girdinin önceki çıktı ile entegrasyonunu ayarlayarak bilgi akışını düzenler ve böylece gelecekteki dizilimler için gerekli olan geçmiş bilgileri etkin bir şekilde korur (Chung ve ark, 2014).

•**Sıfırlama Kapısı ( $r_t$ ):** Sıfırlama kapısı, mevcut girdi ( $x_t$ ) işlenirken geçmiş bilgilerin (önceki gizli durum  $h_{t-1}$ 'den) ne kadarının unutulması gerektiğini belirler. Bu kapı, modelin geçmiş bilgilerin mevcut durumu ne kadar etkilemesi gerektiğine karar vermesine yardımcı olur. Sıfırlama kapısının işlemi matematiksel olarak şu şekilde temsil edilir:

$$r_t = \sigma(W_r \cdot [h_{t-1}, x_t] + b_r) \quad (7)$$

Burada,  $\sigma$  sigmoid fonksiyonudur,  $W_r$  sıfırlama kapısının ağırlık matrisi ve  $b_r$  sıfırlama kapısının biasıdır.

•**Güncelleme Kapısı ( $z_t$ ):** Güncelleme kapısı, önceki gizli durumun ( $h_{t-1}$ ) ne kadarının bir sonraki duruma aktarılacağını belirler. Güncelleme kapısının işlemi şu şekilde temsil edilir:

$$z_t = \sigma(W_i \cdot [h_{t-1}, x_t] + z_i) \quad (8)$$

$$\hat{h}_t = \tanh(W \cdot [r_t * h_{t-1}, x_t] + b) \quad (9)$$

$$h_t = z_t * h_{t-1} + (1 - z_t) * \hat{h}_t \quad (10)$$

Burada,  $W$  ağırlık matrislerini,  $b$  biasları,  $\sigma$  sigmoid aktivasyon fonksiyonunu ve  $\tanh$  hiperbolik tanjant aktivasyon fonksiyonunu temsil eder.

### 3. Bulgular

İlk olarak her bir GNSS istasyonu için ayrı ayrı eğitilen LSTM ve GRU modellerinin ve tüm istasyonlardan gelen birleşik veriler üzerinde eğitilen tek bir modelin performansı değerlendirilmiş, sonrasında tek bir modelin zaman serisinin kestirimi için ayrı ayrı eğitilmiş modellerle karşılaştırılabilir doğruluğa ulaşabilirliği analiz edilmeye çalışılmıştır. İlk senaryoda modellerin her istasyon için ayrı ayrı eğitilmesi durumunda tipik olarak yüksek performans ölçütleri sağlanmıştır. Bu durum, modellerin her istasyonun verilerini etkili bir şekilde öğrenip kestirim yapabildiğini göstermektedir.

Doğu bileşeni için ilk senaryoda hem LSTM hem de GRU modelleri, özellikle Şekil 5'teki AKDG ve NEVS gibi istasyonlar için yüksek  $R^2$  değerleriyle güçlü performans göstermiştir. Örneğin, LSTM modeli AKDG'nin Doğu bileşeni için 0.77 ve NIGD için 0.92  $R^2$  elde ederken, GRU modeli de sırasıyla 0.70 ve 0.89  $R^2$  değerleriyle yüksek performans göstermiştir. İkinci senaryoda yani tek ortak bir model eğitildiğinde Doğu bileşeni için tek modelin performans ölçütlerinin, ayrı ayrı eğitilen modellerin performans ölçütlerine yakın olduğu görülmektedir. Daha düşük olan metrikler Tablo 3-6 üzerinde koyu olarak işaretlenmiştir. Örneğin, tek model AKDG için 0.78 ve NIGD için 0.86  $R^2$  değerlerine ulaşmıştır, NEVS istasyonunda RMSE ve MAE sırasıyla %20 ve %25 oranında azalmış ve birleşik modelin bu bölgedeki verilere iyi genelleme yapabildiğini ve birden fazla istasyondan gelen verilerin toplanmasına rağmen temel özellikleri etkili bir şekilde yakaladığını göstermiştir. Şekil 6'daki KIRS istasyonu için birleştirilmiş modelin RMSE değeri 1.30, MAE değeri 1.0 ve  $R^2$  değeri 0.75 olup ayrı ayrı eğitilmiş modellerle benzer özellikler göstermekte ve bu da KIRS verilerinin örüntülerinin birleştirilmiş veri kümesinde iyi temsil edildiğini göstermektedir. POZA istasyonunda birleştirilmiş


modelin RMSE değeri 3.30 mm, MAE değeri 2.30 mm ve  $R^2$  değeri 0.51 olup bireysel model performansı karşılaştırılabilir. Bu, birleştirilmiş modelin POZA gibi karmaşık verileri makul bir doğrulukla işleyebileceğini göstermektedir. Tablo 2'de gösterildiği gibi özellikle GRU için ortalama RMSE ve MAE değerlerine bakıldığında ayrı ayrı eğitilen modellerin ortalama RMSE değeri 1.68 mm iken ortak modelin 1.67 mm ve MAE değerleri de sırasıyla 1.24 ve 1.27 mm'dir burada doğruluk seviyesi aynıdır. Ancak Tablo 5'e bakıldığında LSTM modeli kullanıldığında ortak modelin doğruluğu daha düşüktür. Kuzey bileşende ise, tüm istasyonlarda daha da yüksek  $R^2$  değerleri görülmektedir. NEVS ve NIGD gibi istasyonlar Tablo 3'de gösterildiği üzere GRU ile sırasıyla 0.96 ve 0.95  $R^2$  değerlerine ulaşmıştır. Bu tutarlılık, kuzey bileşenden gelen verilerin daha öngörülebilir olduğunu göstermektedir. Genel olarak yüksek performans, hem LSTM'nin hem de GRU'nun bu bileşendeki zaman serisi verilerini işlemedeki sağlamlığını vurgulamaktadır. İkinci senaryo yani ortak (tek) model de iyi performans göstermiş ve ayrı ayrı eğitilen modellere yakın yüksek  $R^2$  değerlerini korumuştur. Örneğin, ortak model AKDG'nin Kuzey bileşeni için 0.91 ve Şekil 4'te gösterilen NEVS istasyonu için 0.94  $R^2$  değerine sahiptir. Ortalama MAE ve RMSE değerleri açısından GRU modeliyle ilk senaryo yani ayrı modellerden elde edilen ortalama RMSE ve MAE değerleri sırasıyla 1.32 ve 1.70 mm iken ortak modelinki 1.33 ve 1.72 mm olup neredeyse aynı değerlerdir (Tablo 3). LSTM modeli sonuçlarının verildiği Tablo 6'ya bakıldığında ortak model ve ayrı modeller arasındaki fark daha açıktır. KAYS istasyonunun Kuzey bileşeninde gerçek değerler ve kestirim değerleri Şekil 3'te sunulmuştur.

Düsey bileşenin doğası gereği daha karmaşık oluşu daha düşük  $R^2$  değerleri ve daha yüksek RMSE ve MAE metriklerine sebep olmuştur. Örneğin, POZA istasyonunun GRU modeliyle sadece 0.25 ve LSTM modeliyle 0.22  $R^2$  değerine sahip olması, modellerin bu istasyondan gelen verilerdeki karmaşık veya daha az tahmin edilebilir kalıpları yakalamakta zorlandığını göstermektedir. Şekil 8'de gösterilen AKDG istasyonunun Düsey bileşeninde GRU ve LSTM modellerinin her ikisi de zorluklarla karşılaşmıştır; GRU 3.80 mm RMSE, 3.0 mm MAE ve 0.53  $R^2$ , LSTM ise 3.70 mm RMSE, 2.90 mm MAE ve 0.56  $R^2$  performansı göstermiştir. KAYS istasyonunda GRU 5.10 RMSE, 4.00 MAE ve 0.30  $R^2$  değerlerine sahipken, LSTM 5.10 RMSE, 4.10 MAE ve 0.28  $R^2$  değerlerini göstermiştir. Bu sonuçlar, her iki modelin de KAYS istasyonunun düsey bileşenindeki örüntüleri yakalamada karşılaştığı zorluğu göstermektedir.


Düsey bileşende, tek model, ayrı ayrı eğitilen modellere kıyasla ortalama olarak GRU modeliyle ilk ve ikinci senaryo için sırasıyla 4.50 ve 4.43 mm RMSE; 3.58 ve 3.50 mm MAE değerleri elde edilmiştir. LSTM modelinde ise 4.55 ve 4.43 mm RMSE ve 3.63 mm ve 3.50 mm MAE değerleri elde edilmiştir ve değerler Tablo 4 ve 7'de sunulmaktadır. Bu verilere bakarak Düsey bileşen için ortak model daha düşük metrikler sağlamıştır. Şekil 7'deki NIGD istasyonunda ortak model metrikleri RMSE için %7 ve MAE için %8 civarı iyileşme sağlamıştır. Bu durumdan ortak eğitimin karmaşık veri senaryolarında

bazen istasyon bazında eğitimden daha iyi performans gösterebileceği anlaşılmaktadır.


Genel olarak incelendiğinde; Doğu bileşeninde RMSE ve MAE değerleri, her iki senaryoda da benzer düzeyde olup, LSTM modelinde senaryo II'nin performansı biraz daha düşük kalmıştır. Kuzey bileşeninde ise özellikle LSTM modelinde senaryo II'nin RMSE ve MAE değerleri belirgin şekilde daha yüksek olup, bu bileşende ortak modelin performansının daha düşük olduğunu göstermektedir. Düşey bileşende ise LSTM ve GRU algoritmalarının ikisi için de ortak modelin RMSE ve MAE değerleri ayrı modellerden daha düşük olup, bu bileşende ortak modelin daha iyi performans sergilediğini ortaya koymaktadır. Genel olarak, ortak modelin performansı, bileşen ve metriklere bağlı olarak değişiklik göstermekte ve bazı durumlarda ayrı modellerden daha iyi ya da hemen hemen aynı seviyede sonuçlar verebilmektedir.




Şekil 3. KAYS istasyonunun kuzey bileşeni için LSTM modeliyle elde edilen kestirim değerleri ve gerçek değerler.




Şekil 4. NEVS istasyonunun kuzey bileşeni için LSTM modeliyle elde edilen kestirim değerleri ve gerçek değerler.




Şekil 5. AKDG istasyonunun doğu bileşeni için LSTM modeliyle elde edilen kestirim değerleri ve gerçek değerler.



Şekil 6. KIRS istasyonunun doğu bileşeni için LSTM modeliyle elde edilen kestirim değerleri ve gerçek değerler.



Şekil 7. NIGD istasyonunun düşey bileşeni için GRU modeliyle elde edilen kestirim değerleri ve gerçek değerler.



Şekil 8. AKDG istasyonunun düşey bileşeni için GRU modeliyle elde edilen kestirim değerleri ve gerçek değerler.

Tablo 2. Doğu bileşeni için GRU modelinin farklı senaryolardaki değerlendirme metrikleri.

İstasyon	Senaryo I (ayrı modeller)			Senaryo II (tek model)		
	RMSE (mm)	MAE (mm)	R <sup>2</sup>	RMSE (mm)	MAE (mm)	R <sup>2</sup>
AKDG	1.40	1.06	0.70	<b>1.20</b>	<b>0.90</b>	<b>0.78</b>
KIRS	1.30	1.00	0.75	1.30	<b>1.00</b>	0.75
POZA	3.10	<b>2.10</b>	0.59	3.30	2.30	0.51
NEVS	1.50	1.20	0.80	<b>1.20</b>	<b>0.90</b>	<b>0.86</b>
NIGD	1.30	<b>1.00</b>	0.89	1.40	1.20	0.86
KAYS	1.50	<b>1.10</b>	0.81	1.60	<b>1.30</b>	0.76
Ort	1.68	1.24		1.67	1.27	

**Tablo 3.** Kuzey bileşeni için GRU modelinin farklı senaryolardaki değerlendirme metrikleri.

İstasyon	Senaryo I (ayrı modeller)			Senaryo II (tek model)		
	RMSE (mm)	MAE (mm)	R <sup>2</sup>	RMSE (mm)	MAE (mm)	R <sup>2</sup>
AKDG	<b>1.80</b>	<b>1.40</b>	<b>0.92</b>	2.00	1.50	0.91
KIRS	1.30	1.00	0.94	<b>1.20</b>	<b>1.00</b>	<b>0.95</b>
POZA	2.40	1.90	0.86	<b>2.20</b>	<b>1.70</b>	<b>0.88</b>
NEVS	1.30	1.00	0.96	1.30	1.00	0.96
NIGD	1.40	1.10	0.95	1.40	1.10	0.96
KAYS	<b>2.00</b>	<b>1.50</b>	<b>0.92</b>	2.20	1.70	0.91
Ort	1.70	1.32		1.72	1.33	

**Tablo 4.** Düşey bileşen için GRU modelinin farklı senaryolardaki değerlendirme metrikleri.

İstasyon	Senaryo I (ayrı modeller)			Senaryo II (tek model)		
	RMSE (mm)	MAE (mm)	R <sup>2</sup>	RMSE (mm)	MAE (mm)	R <sup>2</sup>
AKDG	3.80	3.00	0.53	<b>3.60</b>	<b>2.80</b>	<b>0.57</b>
KIRS	4.00	3.20	0.50	4.10	3.20	0.51
POZA	6.40	5.10	0.25	6.50	5.20	0.22
NEVS	3.50	2.80	0.52	<b>3.30</b>	<b>2.60</b>	<b>0.57</b>
NIGD	4.20	3.40	0.17	<b>3.90</b>	<b>3.10</b>	0.30
KAYS	5.10	4.00	0.30	5.20	4.10	0.27
Ort	4.50	3.58		<b>4.43</b>	<b>3.50</b>	

**Tablo 5.** Doğu bileşeni için LSTM modelinin farklı senaryolardaki değerlendirme metrikleri.

İstasyon	Senaryo I (ayrı modeller)			Senaryo II (tek model)		
	RMSE (mm)	MAE (mm)	R <sup>2</sup>	RMSE (mm)	MAE (mm)	R <sup>2</sup>
AKDG	1.20	0.90	0.77	1.20	0.90	0.78
KIRS	<b>1.30</b>	<b>1.00</b>	<b>0.75</b>	1.40	1.10	0.73
POZA	<b>3.30</b>	<b>2.30</b>	<b>0.54</b>	4.30	3.60	0.21
NEVS	1.30	1.20	0.80	<b>1.10</b>	<b>0.90</b>	<b>0.88</b>
NIGD	<b>1.10</b>	<b>0.90</b>	<b>0.92</b>	1.90	1.60	0.77
KAYS	<b>1.50</b>	<b>1.20</b>	<b>0.81</b>	1.60	1.30	0.77
Ort	<b>1.62</b>	<b>1.25</b>		1,92	1,57	

**Tablo 6.** Kuzey bileşeni için LSTM modelinin farklı senaryolardaki değerlendirme metrikleri.

İstasyon	Senaryo I (ayrı modeller)			Senaryo II (tek model)		
	RMSE (mm)	MAE (mm)	R <sup>2</sup>	RMSE (mm)	MAE (mm)	R <sup>2</sup>
AKDG	1.50	1.10	0.95	2.50	2.10	0.86
KIRS	1.30	1.00	0.93	<b>1.20</b>	<b>1.00</b>	<b>0.95</b>
POZA	2.20	1.70	0.88	2.50	1.90	0.85
NEVS	1.20	0.90	0.96	1.60	1.30	0.94
NIGD	1.60	1.20	0.94	1.80	1.40	0.93
KAYS	1.70	1.20	0.94	2.70	2.20	0.86
Ort	<b>1.58</b>	<b>1.18</b>		2.05	1.65	

**Tablo 7.** Düşey bileşen için LSTM modelinin farklı senaryolardaki değerlendirme metrikleri.

İstasyon	Senaryo I (ayrı modeller)			Senaryo II (tek model)		
	RMSE (mm)	MAE (mm)	R <sup>2</sup>	RMSE (mm)	MAE (mm)	R <sup>2</sup>
AKDG	3.70	2.90	0.56	3.60	2.90	0.56
KIRS	4.10	3.20	0.51	4.10	3.20	0.50
POZA	6.50	5.20	0.22	6.60	5.20	0.20
NEVS	3.50	2.80	0.53	3.30	2.60	0.49
NIGD	4.40	3.60	0.07	<b>3.80</b>	<b>3.00</b>	0.32
KAYS	5.10	4.10	0.28	5.20	4.10	0.25
Ort	4.55	3.63		<b>4.43</b>	<b>3.50</b>	

#### 4. Sonuçlar

Bu çalışmada, Türkiye'nin Orta Anadolu Bölgesinde bulunan altı GNSS istasyondan alınan verilerin üç bileşeni üzerinde LSTM ve GRU algoritmalarıyla kestirim çalışmaları yapılmış 2 senaryo üzerinde değerlendirilmiştir. İlk olarak her istasyon için ayrı modeller eğitilmiş ve performansları tüm istasyonlardan gelen birleştirilmiş veriler üzerinde eğitilen tek bir modelle karşılaştırılmıştır.

Sonuçlar, tek bir modelin çeşitli veri kümelerinde ayrı ayrı eğitilmiş modellerle karşılaştırılabilir yeterli doğruluğa ulaşabileceği hatta daha yüksek doğruluk elde ettiği durumlar olduğunu ortaya koymuştur. Örneğin NEVS istasyonunun Doğu bileşeninde, KIRS ve POZA istasyonunun Kuzey bileşeninde, AKDG, NEVS ve NIGD istasyonlarının Düşey bileşende GRU algoritması kullanımıyla; NEVS istasyonunun Doğu bileşeninde, KIRS istasyonunun Kuzey bileşeninde, NEVS ve NIGD istasyonlarının Düşey bileşenlerinde LSTM algoritmasıyla elde edilen sonuçlar ayrı ayrı eğitilmiş modellerinkinden yüksek olmuştur.

Sonuçlar, birleştirilmiş veriler üzerinde eğitilen tek bir modelin zaman serisi kestirimleri için yeterli doğruluğa ulaşabileceği hipotezini doğrulamakta ve çeşitli pratik avantajlar sağlamaktadır. Örneğin model yönetimi açısından tek bir modelin eğitilmesi ve sürdürülmesi daha basit ve daha verimlidir, dağıtım ve bakım için gereken karmaşıklığı ve kaynakları azaltmaktadır. Bu, özellikle birden fazla modeli yönetmenin zahmetli olabileceği büyük ölçekli uygulamalarda faydalıdır. Kaynak Optimizasyonu açısından tek bir model hem eğitim hem de çıkarım aşamalarında daha az hesaplama kaynağı gerektirir, bu da onu daha uygun maliyetli bir çözüm haline getirmektedir. Ayrıca tek bir model, ek istasyonlardan gelen yeni verileri içerecek şekilde kolayca genişletilebilir. Yeni veriler elde edildikçe, model minimum ayarlamalarla yeniden eğitilebilir veya ince ayar yapılabilir, bu da sürekli iyileştirmeyi ve uyarlanabilirliği kolaylaştırır. Sonuç olarak birleşik model yaklaşımı, basitlik ve doğruluk arasında bir denge sunarak belirli bağlamlarda uygulanabilir bir alternatif olmaktadır.

Kullanılan veri seti Türkiye'nin İç Anadolu Bölgesi'ndeki 6 GNSS istasyonu ile sınırlıdır, bu da modelin genelleme yeteneğini kısıtlayabilir. Farklı



coğrafi bölgelerden ve daha fazla sayıda istasyondan elde edilecek verilerle, modelin performansı daha kapsamlı bir şekilde değerlendirilebilir ve genelleme kapasitesi artırılabilir. Ayrıca, modelimiz yalnızca GNSS koordinat zaman serisi verilerini kullanmıştır; atmosferik koşullar, jeolojik olaylar veya insan kaynaklı faktörler gibi ek değişkenlerin modele dahil edilmesi, tahmin doğruluğunu daha da artırabilir.

Gelecekte, birleşik modeller genelleme ve kestirim doğruluğunu artırmak için birden fazla istasyondan gelen verilerden yararlanarak GNSS veri kestirimini önemli ölçüde geliştirebilir. Farklı bölgelerdeki istasyon verilerinin modele dahil edilmesiyle, modelin genelleme yeteneği artırılabilir ve çeşitli jeolojik ve çevresel koşullara uyum sağlanabilir. Bu, modelin farklı coğrafi alanlarda da güvenilir tahminler yapabilmesini mümkün kılabilir. Gelecekte, daha geniş ve çeşitli veri setleriyle modelin eğitilmesi ve transfer öğrenme gibi tekniklerin kullanılmasıyla, tek model yaklaşımının farklı bölgelerdeki GNSS veri kestiriminde etkinliği daha da artırılabilir. Bu yaklaşım, model yönetimini ve dağıtımını basitleştirerek gerçek zamanlı izleme sistemlerinde uygulanmasını ve sürdürülmesini kolaylaştırır. Kaynak verimliliğini ve ölçeklenebilirliği optimize ederek, risk değerlendirme çalışmalarını daha iyi destekleyebilir ve sonuçta daha etkili afet yönetimi planlamasına katkıda bulunabilir.

#### Araştırmacıların katkı oranı

**Merve Şimşek:** Literatür taraması, Modelleme, Makale yazımı; **Murat Taşkıran:** Düzenleme; **Uğur Doğan:** Düzenleme

#### Çatışma Beyanı

Herhangi bir çıkar çatışması bulunmamaktadır.

#### Kaynakça

Altamimi, Z., Rebischung, P., Métivier, L., & Collilieux, X. (2016). ITRF2014: A new release of the International Terrestrial Reference Frame modeling nonlinear station motions. *Journal of geophysical research: solid earth*, 121(8), 6109-6131.

Bevis, M., Alsdorf, D., Kendrick, E., Fortes, L. P., Forsberg, B., Smalley Jr, R., & Becker, J. (2005). Seasonal fluctuations in the mass of the Amazon River system and Earth's elastic response. *Geophysical research letters*, 32(16).

Blewitt, G., & Lavallée, D. (2002). Effect of annual signals on geodetic velocity. *Journal of Geophysical Research: Solid Earth*, 107(B7), ETG-9.

Chen, Q., Jiang, W., Meng, X., Jiang, P., Wang, K., Xie, Y., & Ye, J. (2018). Vertical deformation monitoring of the suspension bridge tower using GNSS: A case study of the forth road bridge in the UK. *Remote Sensing*, 10(3), 364.

Chung J, Gulcehre C, Cho K, et al (2014). Empirical evaluation of gated recurrent neural networks on sequence modeling. arXiv preprint arXiv:

Demiryeye, İ., & Ulukavak, M. (2022). Derin öğrenme tabanlı iyonosferik TEC tahmini. *Geomatik*, 7(2), 80-87.

Deng, Z., Jiang, S., Mo, J., & Yu, S. (2017). Design of a new carrier tracking loop in a positioning receiver. In *Automotive, Mechanical and Electrical Engineering* (pp. 157-160). CRC Press.

Hochreiter S, Schmidhuber J (1997). Long short-term memory. *Neural Computation* 9(8):1735–1780

Hu, W. H., Rea, C., Yuan, Q. P., Erickson, K. G., Chen, D. L., Shen, B., ... & EAST Team. (2021). Real-time prediction of high-density EAST disruptions using random forest. *Nuclear Fusion*, 61(6), 066034.

Jiang Y, Liao L, Luo H, et al (2023) Multi-scale response analysis and displacement prediction of landslides using deep learning with jfta: A case study in the three gorges reservoir, china. *Remote Sensing* 15(16):3995.

Jiang, W., Wang, J., Li, Z., Li, W., & Yuan, P. (2024). A new deep self-attention neural network for GNSS coordinate time series prediction. *GPS Solutions*, 28(1), 3.

Li, X., Ge, M., Dai, X., Ren, X., Fritsche, M., Wickert, J., & Schuh, H. (2015). Accuracy and reliability of multi-GNSS real-time precise positioning: GPS, GLONASS, BeiDou, and Galileo. *Journal of Geodesy*, 89(6), 607-635.

Li, Z., Chen, P., Zheng, N., & Liu, H. (2021). Accuracy analysis of GNSS-IR snow depth inversion algorithms. *Advances in space research*, 67(4), 1317-1332.

Liao, K., Wu, Y., Miao, F., Li, L., & Xue, Y. (2020). Using a kernel extreme learning machine with grey wolf optimization to predict the displacement of step-like landslide. *Bulletin of Engineering Geology and the Environment*, 79, 673-685.

Lian, C., Zeng, Z., Yao, W., & Tang, H. (2015). Multiple neural networks switched prediction for landslide displacement. *Engineering geology*, 186, 91-99.

Meng, X., Dodson, A. H., Roberts, G. W., Cosser, E., Barnes, J., & Rizos, C. (2004). Impact of GPS Satellite Geometry on Structural Deformation Monitoring: analytical and empirical studies. *Journal of Geodesy*, 77(2), 809-822

Miao, X., Liu, Y., Zhao, H., & Li, C. (2018). Distributed online one-class support vector machine for anomaly detection over networks. *IEEE transactions on cybernetics*, 49(4), 1475-1488.

Mufundirwa, A., Fujii, Y., & Kodama, J. (2010). A new practical method for prediction of geomechanical failure-time. *International Journal of Rock Mechanics and Mining Sciences*, 47(7), 1079-1090

Ohta, Y., Kobayashi, T., Tsushima, H., Miura, S., Hino, R., Takasu, T., ... & Umino, N. (2012). Quasi real-time fault model estimation for near-field tsunami forecasting based on RTK-GPS analysis: Application to the 2011 Tohoku-Oki earthquake (Mw 9.0). *Journal of Geophysical Research: Solid Earth*, 117(B2).

Raj, N., & Brown, J. (2023). Prediction of Mean Sea Level with GNSS-VLM Correction Using a Hybrid Deep Learning Model in Australia. *Remote Sensing*, 15(11), 2881.

Serwa, A., Qasimi, A. B., & Isazade, V. (2024). Registration of interferometric DEM by deep artificial neural networks using GPS control points coordinates as

- network target. *International Journal of Engineering and Geosciences*, 9(2), 292-301.
- Şimşek, M., Özarpacı, S., & Doğan, U., (2019). Yer Kabuğu Hareketlerinin Belirlenmesinde Web Tabanlı Çevrimiçi GNSS Servislerinin Performans Analizi. *Geomatik*, vol.4, no.2, 147-159.
- Tregoning, P., Burgette, R., McClusky, S. C., Lejeune, S., Watson, C. S., & McQueen, H. (2013). A decade of horizontal deformation from great earthquakes. *Journal of Geophysical Research: Solid Earth*, 118(5), 2371-2381.
- Wang, J., Nie, G., Gao, S., Wu, S., Li, H., & Ren, X. (2021). Landslide deformation prediction based on a GNSS time series analysis and recurrent neural network model. *Remote Sensing*, 13(6), 1055.
- Xi, R., Meng, X., Jiang, W., An, X., & Chen, Q. (2018). GPS/GLONASS carrier phase elevation-dependent stochastic modelling estimation and its application in bridge monitoring. *Advances in Space Research*, 62(9), 2566-2585.
- Xie, P., Zhou, A., & Chai, B. (2019). The application of long short-term memory (LSTM) method on displacement prediction of multifactor-induced landslides. *IEEE Access*, 7, 54305-54311.
- Xie, Y., Wang, J., Li, H., Dong, A., Kang, Y., Zhu, J., ... & Yang, Y. (2024). Deep Learning CNN-GRU Method for GNSS Deformation Monitoring Prediction. *Applied Sciences*, 14(10), 4004.
- Xing Y, Yue J, Chen C (2019a). Interval estimation of landslide displacement prediction based on time series decomposition and long short-term memory network. *IEEE Access* 8:3187–3196
- Xing Y, Yue J, Chen C, et al (2019b). Dynamic displacement forecasting of dashuitian landslide in china using variational mode decomposition and stack long short-term memory network. *Applied Sciences* 9(15):2951.
- Yang, B., Yin, K., Lacasse, S., & Liu, Z. (2019). Time series analysis and long short-term memory neural network to predict landslide displacement. *Landslides*, 16, 677-694.
- Yang, C., Yin, Y., Zhang, J., Ding, P., & Liu, J. (2024). A graph deep learning method for landslide displacement prediction based on global navigation satellite system positioning. *Geoscience Frontiers*, 15(1), 101690.
- Yi, T. H., Li, H. N., & Gu, M. (2013). Experimental assessment of high-rate GPS receivers for deformation monitoring of bridge. *Measurement*, 46(1), 420-432.
- Yu, J., Meng, X., Shao, X., Yan, B., & Yang, L. (2014). Identification of dynamic displacements and modal frequencies of a medium-span suspension bridge using multimode GNSS processing. *Engineering Structures*, 81, 432-443.
- Yurdakul, Ö., & Kalaycı, İ. (2022). The effect of GLONASS on position accuracy in CORS-TR measurements at different baseline distances. *International journal of engineering and geosciences*, 7(3), 229-246.
- Zhu X, Xu Q, Tang M, et al (2017). Comparison of two optimized machine learning models for predicting displacement of rainfall-induced landslide: A case study in sichuan province, china. *Engineering Geology* 218:213–222.

