

PS-InSAR Verileri Üzerinden Makine Öğrenimi ile Yerkabuğu Hareketlerinin Analizi ve Tahmini

Sinan Kucur ^{1,2*}, Murat Uysal ^{3,4}

¹ Nuri Şeker Uşak Şeker Fabrikası, 64400, Uşak, Türkiye; (sinankucur@gmail.com)

² Afyon Kocatepe Üniversitesi, Fen Bilimleri Enstitüsü, Harita Mühendisliği Programı, 03204, Afyonkarahisar, Türkiye; (sinankucur@gmail.com)

³ Afyon Kocatepe Üniversitesi, Mühendislik Fakültesi, Harita Mühendisliği, 03204, Afyonkarahisar, Türkiye; (muysal@aku.edu.tr)

⁴ Afyon Kocatepe Üniversitesi Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Uygulama ve Araştırma Merkezi, 03204, Afyonkarahisar, Türkiye; (muysal@aku.edu.tr)



*Sorumlu Yazar:
sinankucur@gmail.com

Araştırma Makalesi

Alıntı: Kucur, S. & Uysal, M. (2025). PS-InSAR Verileri Üzerinden Makine Öğrenimi ile Yerkabuğu Hareketlerinin Analizi ve Tahmini. *Türkiye LiDAR Dergisi*, 7(1), 01-07.

Geliş : 29.01.2025
Revize : 13.05.2025
Kabul : 19.05.2025
Yayınlama : 30.06.2025

Özet

Bu çalışmada, Bolvadin bölgesindeki zemin hareketleri Yapay Açıklı Uydu Radar İnterferometrisi (InSAR) tekniği ile analiz edilmiştir. Kalıcı Saçıcı (PS) InSAR yöntemi kullanılarak farklı yıllara ait yüzey deformasyonları belirlenmiş ve zaman serisi verileri oluşturulmuştur. Elde edilen hız verileri temel alınarak, Random Forest makine öğrenimi algoritmasıyla gelecekteki hareketler tahmin edilmiştir. Modelleme sürecinde iki yıllık veri seti dört döneme ayrılmış, ilk üç döneme ait verilerle yapılan eğitim sonucunda dördüncü dönemin hareketleri başarıyla tahmin edilmiş ve ardından ileriye yönelik tahminler gerçekleştirilmiştir. Modelin dördüncü döneme yönelik tahminleri, gözlemlerle yüksek uyum göstermiş ve farkların büyük kısmı ± 1.5 mm sınırları içinde kalmıştır. Sonuçlar, makine öğrenimi destekli InSAR analizlerinin, zemin hareketlerinin daha güvenilir ve hassas bir şekilde belirlenmesine katkı sağladığını göstermektedir. Farklı yıllara ait hız verilerinin modellenmesi, zamansal eğilimlerin tespit edilmesi açısından önemli bilgiler sunmaktadır. Ayrıca, elde edilen deformasyon tahminleri, bölgedeki zemin hareketlerinin mekansal ve zamansal dağılımını daha ayrıntılı inceleme olanağı sağlamıştır. Bu yöntemle, deformasyon süreçleri daha kapsamlı biçimde değerlendirilerek büyük hacimli uydu verilerinin etkin kullanımı mümkün hale gelmektedir.

Anahtar Kelimeler: Sentinel-1, PS-InSAR, makine öğrenimi, rastgele orman.

Analysis and Prediction of Crustal Movements Using Machine Learning on PS-InSAR Data

*Corresponding Author:
sinankucur@gmail.com

Research Article

Citation: Kucur, S. & Uysal, M. (2025). Analysis and Prediction of Crustal Movements Using Machine Learning on PS-InSAR Data. *Turkish Journal of LiDAR*, 7(1), 01-07 (in Turkish).

Received : 29.01.2025
Revised : 13.05.2025
Accepted : 19.05.2025
Published : 30.06.2025

Abstract

In this study, ground movements in the Bolvadin region were analyzed using the Synthetic Aperture Radar Interferometry (InSAR) technique. Surface deformations over different years were identified using the Persistent Scatterer (PS) InSAR method, and corresponding time series data were generated. Based on the obtained velocity data, future ground displacements were predicted using the Random Forest machine learning algorithm. During the modeling process, the two-year dataset was divided into four temporal periods. The model was trained using the first three periods to successfully predict deformation in the fourth, after which forward estimations were generated. The model's predictions for the fourth period showed a high level of agreement with the observations, with the majority of differences falling within the ± 1.5 mm range. The results demonstrate that machine learning-supported InSAR analyses contribute to the more reliable and precise detection of ground movements. Modeling velocity data from different years provides valuable insights into the identification of temporal trends. Additionally, the predicted deformations enabled a more detailed examination of the spatial and temporal distribution of ground movements in the region. This approach allows for a more comprehensive assessment of deformation processes and facilitates the effective utilization of large-scale satellite data.

Keywords: Sentinel-1, PS-InSAR, machine Learning, random forest.

1. Giriş

Tarihi Radar interferometri, yeryüzünün belirli bir bölgesine ait iki radar görüntüsü arasındaki faz farklarını analiz ederek haritalama yapılmasını sağlayan bir ölçüm yöntemidir. Piksel düzeyinde hesaplanan bu faz farkları, interferogram adı verilen ve yer ile radar uydusu arasındaki mesafeyi eşyükselti eğrileriyle gösteren bir harita oluşturur. Farklı zamanlarda ve konumlardan elde edilen görüntüler sayesinde, bölgenin topoğrafik yapısı, atmosfer koşulları, fiziksel ve kimyasal özellikleri ile bu özelliklerdeki zaman içindeki değişimler belirlenebilir. Ancak, bu verilerin doğruluğu ve güvenilirliği, yöntemin uygulanış biçimine ve kullanılan parametrelere bağlıdır. Uydularda kullanılan SAR (Synthetic Aperture Radar), yani yapay açıklıklı radar tekniği, mikrodalga frekanslarıyla çalışır. Bu özellik, sistemin gece-gündüz fark etmeksizin, her türlü hava koşulunda yüzeyin geometrik ve elektriksel özelliklerini görüntüleyebilmesini sağlar (Rosen vd., 1998). InSAR tekniği ise iki SAR görüntüsünü karşılaştırarak bir interferogram oluşturur. Bu interferogram, hedef bölgenin yüksekliğine (topoğrafyasına) dair bilgi sunarken, aynı zamanda iki görüntü arasında geçen sürede yer mesafesindeki küçük değişimleri de ortaya koyar. SAR görüntüsü, radar sinyallerinin yüzeyden yansmasıyla oluşan genlik ve faz verilerini içerir. Genlik yansıma özelliklerini, faz ise hedefe olan uzaklığı temsil eder. InSAR, iki görüntünün karşılık gelen piksellerindeki faz farklarını hesaplayarak interferogram üretir (Bürgmann vd., 2000). Bu yöntem, hem topoğrafya hem de yeryüzü deformasyonlarının ölçümünde etkili bir araçtır.

Son yıllarda, InSAR verilerinin daha etkin analiz edilmesi için makine öğrenimi yöntemleri giderek daha fazla benimsenmektedir. Özellikle Random Forest gibi gözetimli öğrenme algoritmaları, büyük hacimli zamansal deformasyon verilerinden eğilimleri öğrenerek gelecekteki hareketleri tahmin etmede başarılı sonuçlar verebilmektedir. Makine öğrenimi, geleneksel istatistiksel yöntemlere kıyasla daha esnek modelleme yetenekleri sunarak, yer hareketlerinin daha doğru tahmin edilmesine yardımcı olmaktadır.

2. Materyal ve Yöntem

Bu çalışmada, veri seti olarak 10 Ekim 2022 ile 11 Ekim 2024 tarihleri arası 25 uydu görüntüsü seçilerek, iki yıllık veri seti altı aylık dört döneme ayrılmıştır. PS-InSAR yöntemi ile elde edilen nokta bazlı hız verileri kullanılarak, ilk üç altı aylık ölçümlerine dayalı olarak dört dönemin hareketi tahmin edilmiştir. Daha sonra, bu tahmin modeli genişletilerek beşinci dönem için çıkarımda bulunulmuştur. Çalışmanın temel amacı,

PS-InSAR verilerinden faydalanarak makine öğrenimi tabanlı bir yaklaşım ile zemin hareketlerini modellemek ve tahmin etmektir. Böylece, farklı yıllara ait verilerin entegrasyonu ile InSAR analizlerinin doğruluğu artırılarak, gelecekteki deformasyonların daha güvenilir bir şekilde belirlenmesi sağlanabilir.

2.1. Çalışma Alanı

Bolvadin, üçüncü ve dördüncü jeolojik devirlerde oluşmuş bir ovadır. İlçenin güneyinde Sultandağları, kuzeydoğusunda Emirdağları ve kuzeybatısında Paşadağları bulunmaktadır. Coğrafi olarak, 31°2' doğu meridyeni ile 38°43' kuzey paralelinin kesişim noktasında, geniş ve derin bir alüvyon ovası üzerine kurulmuştur. İç Batı Anadolu'nun Ege Bölgesi sınırları içinde yer alan Bolvadin, genellikle düz ve verimli arazilerden oluşmaktadır.

Deniz seviyesinden ortalama 1.016 metre yükseklikte bulunan ilçenin yüzölçümünün %12,84'ünü ova alanları oluşturur. Tarımsal faaliyetler açısından önemli bir bölge olan Bolvadin'de, arazinin yaklaşık %40'ı tarım alanı olarak kullanılmaktadır. Yeraltı su kaynakları bakımından oldukça zengin olan ilçe, yüzey akarsuları açısından ise sınırlı su varlığına sahiptir.

2.2. Sentinel Uydusu

Sentinel-1A, Avrupa Uzay Ajansı (ESA) tarafından geliştirilen ve Copernicus Programı kapsamında 3 Nisan 2014 tarihinde Fransız Guyanası'ndan Soyuz roketiyle uzaya fırlatılan bir radar görüntüleme uydusudur (ESA, 2014). Bu uydu, Dünya'yı kesintisiz bir şekilde izleme kapasitesiyle çevresel izleme, afet yönetimi ve iklim değişikliği gibi konularda kritik veriler sunmak amacıyla tasarlanmıştır. Sentinel-1A, ikiz uydusu Sentinel-1B ile birlikte çalışarak Dünya yüzeyinin yüksek çözünürlüklü görüntülerini toplar ve bu veriler bilim insanları, hükümetler ve araştırmacılar için önemli bir kaynak oluşturur (Torres vd., 2012).

Yapay Açıklıklı Radar (SAR) teknolojisiyle donatılmıştır. SAR, uydunun hava koşullarından veya gün ışığından bağımsız olarak çalışmasını sağlar (Woodhouse, 2006). Bulut örtüsü, karanlık veya yoğun sis gibi faktörler optik uyduların veri toplamasını engellerken, Sentinel-1A'nın C-bant radar sistemi bu koşullarda dahi kesintisiz çalışır (ESA, 2020). Uydu, 250 kilometrelik bir alanı tarayabilir ve 5x5 metrelik bir çözünürlükle detaylı görüntüler elde edebilir (Potin vd., 2016). Yörünge süresi yaklaşık 12 gün olan Sentinel-1A, Dünya'nın hemen hemen her noktasını düzenli olarak tarar ve bu özellik, zaman içindeki değişikliklerin izlenmesi için kritik bir altyapı sunar.

Copernicus Programı'nın bir parçası olarak Sentinel-1A, çevresel sürdürülebilirlik ve afetlere hazırlık gibi alanlarda önemli bir rol oynar. Uydunun sağladığı veriler, tarım alanlarının izlenmesi, orman kaybının takibi, deniz buzullarının gözlemlenmesi ve okyanus akıntılarının analizi gibi çok çeşitli uygulamalarda kullanılmaktadır (Malenovsky vd., 2012). Ayrıca, afet durumlarında hızlı müdahale gerektiren bölgelerde gerçek zamanlı veri sağlayarak kurtarma ekiplerine destek olur (Joyce vd., 2009). Örneğin, 2015 Nepal depremi sonrası yer hareketlerinin analizi Sentinel-1A verileriyle yapılmıştır (ESA, 2015). İklim değişikliğiyle mücadeledeki katkıları da dikkat çekicidir. Buzulların hareketlerini ve erime oranlarını izleyerek küresel ısınmanın etkilerini anlamada araştırmacılara yardımcı olur (Strozzi vd., 2017). Deniz seviyesindeki değişiklikler ve kıyı erozyonu gibi süreçlerin gözlemlenmesinde de önemli bir rol oynar (Ponte vd., 2019). Fırlatıldığı günden bu yana Dünya üzerindeki birçok önemli olayı belgeledi, 2019 Amazon orman yangınlarının izlenmesi ve 2020'de Arktik buzulların rekor düzeyde erimesinin analizi gibi olaylarda uydunun verileri hem bilimsel çalışmalar hem de insani yardım çabaları için temel teşkil etti (ESA, 2020). İkiz uydusu Sentinel-1B'nin 2016'da fırlatılmasıyla birlikte, sistemin veri toplama sıklığı ve kapsama alanı daha da genişledi (Potin vd., 2016).

2.3. Snap2StaMPS

Snap2StaMPS, Sentinel-1 radar verilerini kullanarak yer yüzeyindeki deformasyonları analiz etmek için SNAP yazılımını StaMPS ile entegre eden açık kaynaklı bir araçtır. Bu sistem, Yapay Açıklıklı Radar (SAR) interferometrisi (InSAR) tekniklerini kullanarak, özellikle Persistent Scatterer Interferometry (PSI) yöntemiyle zaman serisi analizlerini gerçekleştirmek için tasarlanmıştır (Hooper vd., 2004). Snap2StaMPS'in temel mantığı, SNAP'in güçlü veri işleme kapasitesini kullanarak ham Sentinel-1 verilerini StaMPS'in PSI analizine uygun hale getirmektir. Bu süreç, karmaşık InSAR iş akışlarını otomatikleştirerek araştırmacıların deformasyon haritaları oluşturmasını kolaylaştırır (Foumelis vd., 2018).

Snap2StaMPS, Sentinel-1 SLC (Single Look Complex) verilerinden başlayarak, interferogram oluşturma, faz açılımı ve nihayetinde StaMPS ile PSI analizine kadar olan süreçleri kapsar. SNAP, veri ön işleme adımlarını gerçekleştirirken, StaMPS bu verileri kullanarak zaman serisi boyunca kalıcı saçıcı noktaları (persistent scatterers) tespit eder ve bu noktaların hareketlerini hesaplar. Sistem, atmosferik etkileri ve topografik hataları ayırıştırarak yüksek hassasiyetli deformasyon ölçümleri sağlar (Ferretti vd., 2001).

Snap2StaMPS'in avantajı, bu iki yazılımın yeteneklerini birleştirerek manuel müdahaleyi en aza indirmesi ve tekrarlanabilir bir iş akışı sunmasıdır.

Snap2StaMPS, deprem izleme, heyelan analizi ve altyapı stabilitesi gibi alanlarda yaygın olarak kullanılır (Blasco vd., 2019). Ancak, sistemin başarısı veri kalitesine, bölge topoğrafyasına ve atmosferik koşullara bağlıdır. Yoğun bitki örtüsü veya hızlı değişen yüzeyler, PSI analizinde sınırlamalara yol açabilir (Hooper vd., 2012).

2.4. Makine Öğrenimi

Zemin hareketlerinin analizi ve tahmini, jeodezik ve jeofizik çalışmalarda kritik bir öneme sahiptir. Bu açıdan, makine öğrenimi teknikleri, büyük veri setlerinin işlenmesi ve karmaşık modellerin geliştirilmesi için güçlü bir araç olarak ortaya çıkmıştır. Özellikle Random Forest algoritması, makine öğrenimi yöntemleri arasında öne çıkar. Leo Breiman tarafından geliştirilen bu algoritma, çok sayıda karar ağacını bir araya getirerek toplu bir tahmin modeli oluşturur ve overfitting riskini azaltarak yüksek doğruluk sağlar (Beriman, 2001). Random Forest, hem sınıflandırma hem de regresyon problemlerinde etkili bir performans sergiler ve bu özellikleriyle zemin deformasyonlarının zaman serisi analizinde tercih edilmiştir. Bu çalışmada, Random Forest algoritması, InSAR verilerinden elde edilen hız ölçümleriyle gelecekteki zemin hareketlerini tahmin etmek için kullanılmıştır. Modelin başarısı, farklı yıllara ait verilerin zamansal ve mekansal korelasyonlarını değerlendirme yeteneğine dayanır. Random Forest'in güçlü yapısının, gürültülü veri setlerinde bile güvenilir sonuçlar ürettiğini vurgulanmaktadır (Hastie vd., 2009). Bu nedenle, Bolvadin bölgesindeki deformasyon süreçlerinin modellenmesinde, algoritmanın sunduğu esneklik ve hassasiyet önemli bir avantaj sağlamıştır. Makine öğrenimi destekli yaklaşımlar, uydu verilerinin etkin kullanımını mümkün kılarak bilimsel araştırmalara katkı sunmaktadır.


Random Forest algoritması, ağaç sayısı 100 ve maksimum derinlik 20 olacak şekilde yapılandırılmıştır. Veriler %70 eğitim ve %30 test oranında ayrılmış, modelin genellenebilirliğini artırmak ve aşırı öğrenme (overfitting) riskini azaltmak amacıyla eğitim verisi üzerinde 5 katlı çapraz doğrulama (5-fold cross-validation) uygulanmıştır. Modelin nihai performansı, test verisi üzerinde hesaplanan RMSE = 2.5 mm ve $R^2 = 0.82$ başarı metrikleriyle değerlendirilmiştir.

Bu sonuçlar, modelin oldukça yüksek bir doğrulukla tahmin yapabildiğini ve aşırı öğrenme eğilimi göstermediğini ortaya koymaktadır. Özellikle PS-InSAR verilerine dayalı regresyon modelleri

açısından, bu düzeyde düşük hata değerleri modelin güvenilirliğini desteklemektedir.

3. Bulgular

Sentinel-1 uydu görüntüleri kullanılarak gerçekleştirilen PS-InSAR analizleri sonucunda, Bolvadin bölgesi genelinde toplam 38.013 adet PS noktasına ulaşılmıştır. PS noktalarının özellikle yapılaşmış ve yüksek yansıtıcılığa sahip alanlarda daha yoğunlaştığını ortaya koymaktadır.




Şekil 1. Oluşturulan PS noktalarının mekansal dağılım haritası. Sıcak renkler uydu bakış doğrultusunda çökmeyi gösterirken soğuk renkler uydu bakış doğrultusunda yükselmeyi temsil etmektedir.

İki yıllık gözlem sürecine ait veriler, her biri altı aylık olmak üzere dört eşit döneme ayrılmıştır. Elde edilen zaman serisi hız verileri temel alınarak, ilk üç döneme ait ölçümlerden oluşan eğitim seti ile dördüncü döneme ait yüzey deformasyonları, Random Forest algoritması aracılığıyla tahmin edilmiştir.


Bu doğrultuda model, çalışma alanındaki tüm PS noktaları için dördüncü dönem deformasyonlarını yüksek başarı oranıyla öngörebilmiştir. Dördüncü döneme yönelik tahmin doğruluğunun değerlendirilmesinin ardından, model üzerinde beşinci bir dönem için projeksiyon yapılmıştır. Henüz gözlemlenmemiş olan bu sonraki altı aylık döneme ilişkin öngörüler, modelin eğitildiği verilerden öğrenilen zamansal eğilimler doğrultusunda gerçekleştirilmiştir. Böylece, çalışma yalnızca geçmişe dönük modelleme ile sınırlı kalmayıp, ileriye dönük tahmin kapasitesini de ortaya koymuştur.

Mekansal dağılım analizi, PS noktalarının yoğunlaştığı alanlarda deformasyon hızlarının da arttığını göstermiştir. Özellikle Bolvadin merkez ve güneydoğu bölgelerinde çökme eğilimlerinin daha belirgin olduğu kuzey ve kuzeybatı kesimlerde ise daha stabil yüzey hareketlerinin gözlemlendiği tespit edilmiştir.


Şekil 3 incelendiğinde, noktaların 1:1 referans çizgisi etrafında yoğunlaştığı ve modelin çökme eğilimlerini yüksek doğrulukla öngörebildiği görülmektedir. Bu durum, tahmin performansının güvenilir olduğunu göstermektedir.



Şekil 2. Oluşturulan PS noktalarının yeryüzündeki konumu. Soğuk renkler uydu bakış doğrultusunda çökmeyi gösterirken sıcak renkler uydu bakış doğrultusunda yükselmeyi temsil etmektedir.



Şekil 3. Random Forest algoritması tarafından tahmin edilen deformasyon değerleri ile PS-InSAR yöntemiyle elde edilen çökme gözlemleri arasındaki uyumu gösteren regresyon grafiği.



Şekil 4. Seçilmiş 20 PS noktasına ait 2., 3. ve 4. dönem gözlemsel deformasyon değerleri ile Random Forest modeli tarafından yapılan tahmin değerinin zaman serisi grafiği.

Şekil 4'te, her bir çizgi, seçilmiş 20 PS noktasından birine karşılık gelmekte olup, bu noktaların 2., 3. ve 4. dönemlerdeki gözlemsel deformasyon değerleri ile Random Forest algoritması tarafından tahmin edilen sonraki dönem çıkarım değerlerini içermektedir. Grafik, zamansal eğilimlerin her bir noktada nasıl geliştiğini görsel olarak yansıtarak, modelin geçmiş deformasyon verilerinden öğrenerek sonraki dönem için nasıl bir tahminde bulunduğunu değerlendirme imkanı sunmaktadır.

4. Sonuçlar ve Tartışma

PS-InSAR yöntemiyle elde edilen PS noktaların ilk dört döneme ait yüzey deformasyon hızları kullanılarak, Random Forest algoritması ile beşinci döneme ait yüzey hareketlerinin tahmin edilmesini amaçlamıştır. Modelleme sürecinde, iki yıllık zaman serisi verileri her biri altı aylık olmak üzere dört eşit döneme ayrılmış ve ilk üç dönemin verileriyle eğitilen model, dördüncü dönem için tahminlerde bulunmuştur. Elde edilen sonuçlar, modelin bu dönemdeki hareketleri yüksek doğruluk oranıyla öngörebildiğini göstermiştir. Dördüncü döneme yönelik tahminler ile gerçek gözlemler arasında büyük ölçüde uyum olduğu ve farkların genellikle $\pm 1,5$ mm sınırları içerisinde kaldığı görülmüştür.

Modelin dördüncü döneme ilişkin tahmin performansı doğrulandıktan sonra, mevcut veriler kullanılarak henüz gözlemlenmemiş olan beşinci dönem için projeksiyon gerçekleştirilmiştir. Bu sayede çalışma yalnızca geçmiş verilerin analiziyle sınırlı kalmamış, aynı zamanda ileriye dönük tahmin kapasitesiyle de değerlendirilmiştir. Beşinci döneme ilişkin tahminlerde, çökme eğilimlerinin bazı bölgelerde ivme kazandığı, bazı alanlarda ise durağanlaşma eğilimi gösterdiği gözlemlenmiştir. Bu farklılıkların, yerel zemin özellikleri, su seviyeleri, yapılaşma yoğunluğu ve diğer çevresel faktörlerle ilişkilendirilebileceği düşünülmektedir.

PS noktalarının mekansal dağılımı, deformasyon hızlarının bölgesel farklılıklar gösterdiğini ortaya koymuştur. Özellikle Bolvadin ilçe merkezi ve güneydoğu kesimlerinde çökme eğilimlerinin daha yoğun olduğu, kuzeybatı ve kuzey bölgelerde ise daha stabil bir zemin hareketi gözlemlendiği belirlenmiştir. Örnek olarak, ilçe merkezine yakın bir konumda bulunan 38.631611 derece kuzey enlemindeki ve 31.067768 derece doğu boylamındaki bir PS noktasında, iki yıllık süreçte $-24,6$ mm'lik bir yer değiştirme gözlemlenmiş, model bu noktadaki hareketi beşinci dönemde $-26,1$ mm olarak öngörmüştür. Benzer şekilde, 38.633648 derece kuzey enleminde ve 31.066811 derece doğu boylamında yer alan bir başka noktada $-21,6$ mm'lik gözlemsel yer değişimi, model tarafından $-23,4$ mm olarak öngörülmüştür.

Özellikle deformasyon eğilimlerinin kuvvetli olduğu alanlarda modelin öngörü kabiliyetinin daha yüksek olduğu görülmüştür. Modelin güçlü tahmin kabiliyeti, veri setinin yapısal bütünlüğü ve zamansal devamlılığı ile doğrudan ilişkilidir. Eğitim sürecinde kullanılan ilk üç döneme ait veriler, deformasyon dinamiklerini yeterli düzeyde temsil etmiş ve bu durum modelin genelleme başarısını artırmıştır. Ayrıca, kullanılan Random Forest algoritması, çok boyutlu verilerle çalışabilme ve karmaşık ilişkileri öğrenebilme yeteneği sayesinde, bölgedeki hareketleri başarıyla modelleyebilmiştir.

PS-InSAR verilerinin deformasyon analizinde etkin biçimde kullanılabileceği, bu alandaki önceki çalışmalarla da ortaya konmuştur. PS noktaların yüksek hassasiyetle yer değiştirme ölçümlerinde kullanılabilirliği daha önce gösterilmiştir. Ayrıca, makine öğrenimi algoritmalarının, özellikle Random Forest yaklaşımının mekansal verilerle başarılı bir biçimde entegre edilerek yüksek öngörü performansı sağlayabileceği çeşitli çalışmalarda belirtilmiştir (Ferretti vd., 2001; Ghorbanzadeh vd., 2019). Söz konusu literatürle paralel biçimde, PS-InSAR ve makine öğrenimi entegrasyonunun zemin hareketlerinin modellenmesinde etkili bir yöntem olduğunu doğrulamaktadır.

Tablo 1. Bazı PS noktalarına ait 2 yıllık hızları ile RF modeli ile çıkarılmış 5. dönem hızları. ($R^2 = 0.82$, RMSE = 2.5 mm).

Enlem	Boylam	4. dönem hareket (mm/yıl)	RF ile çıkarım (mm/yıl)
31.631611	38.631611	-24,7	-26,0
31.067921	38.631504	-23,7	-24,4
31.066811	38.633648	-21,6	-23,4
31.066856	38.633652	-21,1	-22,0
31.068411	38.632343	-19,4	-20,5
31.069904	38.618248	-19,0	-19,7
31.004787	38.654396	-18,2	-19,1
31.061237	38.688156	-17,1	-18,2
31.068380	38.632851	-16,4	-17,2

Random Forest modeli deterministik karar ağaçlarıyla çalıştığı için doğrudan istatistiksel bir güven aralığı üretmese de, elde edilen düşük hata değerleri ve tahminlerin gözlemlerle yüksek uyumu, modelin öngörü potansiyelinin güvenilir olduğunu göstermektedir.

Elde edilen RMSE değeri, literatürde benzer amaçlarla gerçekleştirilen çalışmalarla karşılaştırıldığında oldukça tatmin edicidir. Örneğin, Çin'in Xi'an bölgesinde gerçekleştirilen bir çalışmada, PS-InSAR verileriyle birlikte Random Forest, Support Vector Regression ve XGBoost gibi makine öğrenimi modelleri kullanılarak mevcut deformasyonların analizi yapılmış, RF modeliyle 2.3 mm ile 3.9 mm arasında RMSE değerleri elde edilmiştir (Guo vd, 2023). Ancak söz konusu çalışmada yalnızca mevcut deformasyonlar değerlendirilmiş, geleceğe yönelik bir tahmin yapılmamıştır.

Random Forest algoritması, yüksek doğruluk sunmasına rağmen bazı sınırlamaları bulunmaktadır. Modelin deformasyon eğilimlerini güçlü şekilde yakalamasına rağmen, çok kısa süreli anomaliler veya ani zemin değişimleri gibi durumlarda tahmin performansı düşebilir. Benzer şekilde, PS yoğunluğunun düşük olduğu alanlarda modelin tahmin güvenilirliği azalabilir. Gelecek çalışmalarda, RF modelinin LSTM veya GRU gibi zamansal bağımlılık içeren derin öğrenme algoritmalarıyla desteklenmesi bu sınırlamaları azaltabilir.

Bu çalışma ile PS-InSAR verilerinin makine öğrenimi modelleriyle entegre edilerek yer yüzeyindeki deformasyonların yüksek doğrulukla tahmin edilebileceğini ortaya koymuştur. Random Forest algoritması, geçmiş verilere dayanarak hem mevcut dönemleri modelleyebilmiş hem de ileriye dönük tahminler üretme konusunda etkin bir yöntem olduğunu kanıtlamıştır. Bu yaklaşım, yalnızca akademik analizlerle sınırlı kalmayıp, çeşitli pratik uygulamalara da doğrudan katkı sunmaktadır. Örneğin, kentleşme ve altyapı yönetimi süreçlerinde zemin stabilitesi açısından riskli bölgelerin belirlenmesi, deformasyon eğilimlerinin izlenmesi

sayesinde daha güvenli yapılaşma stratejilerinin geliştirilmesini mümkün kılmaktadır. Ayrıca, ani çökmelerin önceden öngörülebilmesi, afet riski azaltımı, su kaynaklarının sürdürülebilir yönetimi ve tarım alanlarının korunması gibi alanlarda karar vericilere erken uyarı sağlayabilecek bir temel sunmaktadır.

Yazarların Katkısı

Sinan Kucur: Kaynaklar, Araştırma, Deney, Görselleştirme, Analiz ve yorumlama, Yazma – orijinal taslak.

Murat Uysal: Denetleme/danışmanlık, Proje yönetimi.

Çıkar Çatışması Beyanı

Bu çalışma da herhangi bir çıkar çatışması bulunmamaktadır.

Araştırma ve Yayın Etiği Beyanı

Yapılan çalışmada araştırma ve yayın etiğine uyulmuştur.

Kaynaklar

- Blasco, J. M. D. (2019). Persistent scatterer interferometry: A review of methods and applications. *Remote Sensing*, 11(8), 934. <https://doi.org/10.3390/rs11080934>
- Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5–32. <https://doi.org/10.1023/A:1010933404324>
- Bürgmann, R., Rosen, P. A., & Fielding, E. J. (2000). Synthetic aperture radar interferometry to measure Earth's surface topography and its deformation. *Annual Review of Earth and Planetary Sciences*, 28(1), 169–209. <https://doi.org/10.1146/annurev.earth.28.1.169>
- Ferretti, A., Prati, C., & Rocca, F. (2001). Permanent scatterers in SAR interferometry. *IEEE Transactions on Geoscience and Remote Sensing*, 39(1), 8–20. <https://doi.org/10.1109/36.898661>
- Foumelis, M., Delgado Blasco, J. M., Brito, F., Pacini, F., Papageorgiou, E., Pishehvar, P., & Bally, P. (2022). SNAPPING services on the Geohazards Exploitation Platform for Copernicus Sentinel-1 surface motion mapping. *Remote Sensing*, 14(23), 6075. <https://doi.org/10.3390/rs14236075>
- Ghorbanzadeh, O., Blaschke, T., Gholamnia, K., Meena, S. R., Tiede, D., & Aryal, J. (2019). Evaluation of different machine learning methods and deep-learning convolutional neural networks for landslide detection. *Remote Sensing*, 11(2), 196. <https://doi.org/10.3390/rs11020196>

- Guo, X., Zhao, C., Li, G., Peng, M., & Zhang, Q. (2023). A multifactor-based random forest regression model to reconstruct a continuous deformation map in Xi'an, China. *Remote Sensing*, 15(19), 4795. <https://doi.org/10.3390/rs15194795>
- Hastie, T., Tibshirani, R., & Friedman, J. (2009). *The elements of statistical learning: Data mining, inference, and prediction* (2nd ed.). Springer.
- Hooper, A., Bekaert, D., Spaans, K., & Arıkan, M. (2012). Recent advances in SAR interferometry time series analysis for measuring crustal deformation. *Tectonophysics*, 514–517, 1–13. <https://doi.org/10.1016/j.tecto.2011.10.013>
- Hooper, A., Zebker, H., Segall, P., & Kampes, B. (2004). A new method for measuring deformation on volcanoes and other natural terrains using InSAR persistent scatterers. *Geophysical Research Letters*, 31(23), L23611. <https://doi.org/10.1029/2004GL021737>
- Joyce, K. E., Belliss, S. E., Samsonov, S. V., McNeill, S. J., & Glassey, P. J. (2009). A review of the status of satellite remote sensing and image processing techniques for mapping natural hazards and disasters. *Progress in Physical Geography*, 33(2), 183–207. <https://doi.org/10.1177/0309133309339563>
- Malenovsky, Z., Rott, H., Cihlar, J., Schaepman, M. E., García-Santos, G., Fernandes, R., & Berger, M. (2012). Sentinels for science: Potential of Sentinel-1, -2, and -3 missions for scientific observations of land, oceans, and ice. *Remote Sensing of Environment*, 120, 91–101. <https://doi.org/10.1016/j.rse.2011.09.026>
- Ponte, R. M., Carson, M., Cirano, M., Domingues, C. M., Jevrejeva, S., Marcos, M., ... & Zhang, X. (2019). Towards comprehensive observing and modeling systems for monitoring and predicting regional-to-coastal sea level. *Frontiers in Marine Science*, 6, 437. <https://doi.org/10.3389/fmars.2019.00437>
- Potin, P., Rosich, B., Miranda, N., & Grimont, P. (2016). Sentinel-1 mission status. *Procedia Computer Science*, 100, 1297–1304. <https://doi.org/10.1016/j.procs.2016.09.179>
- Strozzi, T., Wiesmann, A., Kääb, A., & Schellenberger, T. (2017). Glacial and periglacial environment monitoring in the Swiss Alps using Sentinel-1 SAR interferometry. *Remote Sensing*, 9(12), 1238. <https://doi.org/10.3390/rs9121238>
- Torres, R., Snoei, P., Geudtner, D., Bibby, D., Davidson, M., Attema, E., ... & Rostan, F. (2012). GMES Sentinel-1 mission. *Remote Sensing of Environment*, 120, 9–24. <https://doi.org/10.1016/j.rse.2011.05.028>
- Woodhouse, I. H. (2006). *Introduction to microwave remote sensing*. CRC Press. <https://doi.org/10.1201/9781315272573>

İnternet kaynakları

- European Space Agency (ESA). (2024, May 1). *Sentinel-1 mission overview*. Retrieved from <https://sentinel.esa.int/web/sentinel/missions/sentinel-1>
- European Space Agency (ESA). (2024, May 1). *Sentinel-1A launch*. Retrieved from https://www.esa.int/Applications/Observing_the_Earth/Copernicus/Sentinel-1A_launch
- European Space Agency (ESA). (2024, May 1). *Nepal earthquake displacement maps from Sentinel-1A*. Retrieved from https://www.esa.int/Applications/Observing_the_Earth/Sentinel-1/Nepal_earthquake



© Author(s) 2025.

This work is distributed under <https://creativecommons.org/licenses/by-sa/4.0/>