



**PS-INSAR VE DERİN ÖĞRENME İLE
YERKABUĞU HAREKETLERİNİN KESTİRİMİ**

DOKTORA TEZİ

Sinan KUCUR

Danışman

Prof. Dr. Murat UYSAL

HARİTA MÜHENDİSLİĞİ ANABİLİM DALI

TEMMUZ 2025

AFYON KOCATEPE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

DOKTORA TEZİ

PS-INSAR VE DERİN ÖĞRENME İLE YERKABUĞU
HAREKETLERİNİN KESTİRİMİ

Sinan KUCUR

Danışman

Prof. Dr. Murat UYSAL

HARİTA MÜHENDİSLİĞİ ANABİLİM DALI

Temmuz 2025

TEZ ONAY SAYFASI

Sinan KUCUR tarafından hazırlanan “PS-InSAR ve Derin Öğrenme ile Yer kabuğu Hareketlerinin Kestirimi” adlı tez çalışması lisansüstü eğitim ve öğretim yönetmeliğinin ilgili maddeleri uyarınca 26 / 06 / 2025 tarihinde aşağıdaki jüri tarafından **oy birliği** ile Afyon Kocatepe Üniversitesi Fen Bilimleri Enstitüsü **Harita Mühendisliği Anabilim Dalı’nda DOKTORA TEZİ** olarak kabul edilmiştir.

Danışman : Prof. Dr. Murat UYSAL

Başkan : Prof. Dr. Hacı Murat YILMAZ
Aksaray Üniversitesi,
Mühendislik Fakültesi

Üye : Prof. Dr. Hakan KARABÖRK
Konya Teknik Üniversitesi,
Mühendislik ve Doğa Bilimleri Fakültesi

Üye : Prof. Dr. Mustafa YILMAZ
Afyon Kocatepe Üniversitesi,
Mühendislik Fakültesi

Üye : Dr. Öğr. Üyesi Abdullah VARLIK
Necmettin Erbakan Üniversitesi,
Mühendislik Fakültesi

Afyon Kocatepe Üniversitesi
Fen Bilimleri Enstitüsü Yönetim Kurulu’nun
..... /..... /..... tarih ve
..... sayılı kararıyla onaylanmıştır.

.....
Prof. Dr. Bekir YALÇIN
Enstitü Müdürü

BİLİMSEL ETİK BİLDİRİM SAYFASI
Afyon Kocatepe Üniversitesi

Fen Bilimleri Enstitüsü, tez yazım kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez içindeki bütün bilgi ve belgeleri akademik kurallar çerçevesinde elde ettiğimi,
- Görsel, işitsel ve yazılı tüm bilgi ve sonuçları bilimsel ahlak kurallarına uygun olarak sunduğumu,
- Başkalarının eserlerinden yararlanılması durumunda ilgili eserlere bilimsel normlara uygun olarak atıfta bulunduğumu,
- Atıfta bulunduğum eserlerin tümünü kaynak olarak gösterdiğimi,
- Kullanılan verilerde herhangi bir tahrifat yapmadığımı,
- Ve bu tezin herhangi bir bölümünü bu üniversite veya başka bir üniversitede başka bir tez çalışması olarak sunmadığımı

beyan ederim.

/ /

İmza

Sinan KUCUR

ÖZET
Doktora Tezi

**PS-INSAR VE DERİN ÖĞRENME İLE YERKABUĞU HAREKETLERİNİN
KESTİRİMİ**

Sinan KUCUR
Afyon Kocatepe Üniversitesi
Fen Bilimleri Enstitüsü
Harita Mühendisliği Anabilim Dalı
Danışman: Prof. Dr. Murat UYSAL

Yerkabuğu hareketleri, özellikle antropojenik etkilerle artan bir problem olup, sürdürülebilir kaynak yönetimi ve afet risk azaltımı için bu hareketlerin izlenmesi ve gelecekteki davranışlarının tahminlenmesi kritik öneme sahiptir. Bu doktora tezi, Afyonkarahisar-Bolvadin'deki yerkabuğu hareketlerinin uzun dönemli analizini ve geleceğe yönelik tahminlerini, PS-InSAR ve derin öğrenme tekniklerini entegre ederek gerçekleştirmeyi amaçlamıştır.

Çalışmada, 2015-2024 arasını kapsayan 240 adet Sentinel-1A SAR görüntüsü PS-InSAR tekniğiyle işlenerek yıllık LOS hareket hızı zaman serileri üretilmiştir. Analizler, bölgede +1 ila -14 mm/yıl arasında değişen, genel olarak çökme yönlü ve özellikle yeraltı suyu çekiminin yoğun olduğu düşünülen güneybatı kesimlerde yoğunlaşan hareketler tespit etmiştir. Bu zaman serileri; LSTM, GRU, TCN, CNN ve Transformer derin öğrenme modelleriyle, Yinelemeli Çok Adımlı Tahmin (RMF) stratejisi kullanılarak 2025-2026 yılları için modellenmiştir.

Bulgular, tüm modellerin tek adımlı tahminlerde yüksek başarı ($R^2 > 0.92$) gösterdiğini, CNN mimarisinin ise en iyi performansı sergilediğini ortaya koymuştur. RMF projeksiyonları, çökme eğiliminin devam edeceğini öngörmüş, CNN ve LSTM modelleri çok adımlı tahminlerde daha stabil bulunmuştur. Bu çalışma, PS-InSAR ve derin öğrenme entegrasyonunun yüzey hareketlerinin izlenmesi ve anlamlı gelecek tahminleri için potansiyelini göstermiş olup, bölgesel planlama ve yönetim stratejilerine

bilimsel bir zemin sunmaktadır. Yardımcı parametrelerin dahil edilmesi ve yer bazlı doğrulama gelecek çalışmalar için önerilmektedir.

2025, 92 + 11 sayfa

Anahtar Kelimeler: Uzaktan Algılama, PS-InSAR, Yerkabuğu Hareketleri, Derin Öğrenme.



ABSTRACT
Ph.D. Thesis

**PREDICTION OF CRUSTAL MOVEMENTS WITH PS-INSAR AND DEEP
LEARNING**

Sinan KUCUR

Afyon Kocatepe University

Graduate School of Natural and Applied Sciences

Department of Geomatic Engineering

Supervisor: Prof. Dr. Murat UYSAL

Crustal movements, which are an increasing problem especially due to anthropogenic effects such as excessive groundwater use, are critically important to monitor and predict for sustainable resource management and disaster risk reduction. This doctoral thesis aimed to perform a long-term analysis of crustal movements in Afyonkarahisar-Bolvadin and their future prediction by integrating PS-InSAR and deep learning techniques.

In this study, 240 Sentinel-1A SAR images covering the period 2015-2024 were processed using the PS-InSAR technique to produce annual LOS movement velocity time series. Analyses revealed subsidence-dominated movements in the region, ranging from +1 to -14 mm/year, particularly concentrated in the southwestern parts where groundwater extraction is intensive. These time series were modeled for the years 2025-2026 using LSTM, GRU, TCN, CNN, and Transformer deep learning models with a Recursive Multi-step Forecasting (RMF) strategy.

The findings showed that all models exhibited high success ($R^2 > 0.92$) in single-step predictions, with the CNN architecture demonstrating the best performance. RMF projections predicted the continuation of the subsidence trend, and CNN and LSTM models were found to be more stable in multi-step predictions. This study has demonstrated the potential of PS-InSAR and deep learning integration for monitoring surface movements and making meaningful future predictions, providing a scientific

basis for regional planning and management strategies. The inclusion of auxiliary parameters and ground-based validation are recommended for future studies.

2025, 92 + 11 pages

Keywords: Remote Sensing, PS-InSAR, Crustal Movements, Deep Learning.



TEŐEKKÖR

Bu tez alıřmamda danıřmanlıęımı űstlenen ve alıřmamın her ařamasında bilgi ve deneyimleriyle bana yol gōsteren sayın hocam Prof. Dr. Murat UYSAL’a ve her konuda űneri ve eleřtirileriyle yardımlarını gōrdüğüm hocalarıma teőekkür ederim.

Bu alıřma boyunca maddi ve manevi desteklerinden dolayı aileme ve tüm arkadaşlarıma teőekkür ederim.

Sinan KUCUR
Afyonkarahisar 2025

İÇİNDEKİLER DİZİNİ

	Sayfa
ÖZET	i
ABSTRACT	iii
TEŞEKKÜR	v
İÇİNDEKİLER DİZİNİ.....	vi
SİMGELER ve KISALTMALAR DİZİNİ	viii
ŞEKİLLER DİZİNİ.....	ix
ÇİZELGELER DİZİNİ.....	xi
1. GİRİŞ.....	1
2. LİTERATÜR BİLGİLERİ	5
2.1 PS-InSAR Tekniği.....	5
2.2 Zemin Çökmeleri ve Yer Altı Suyu Etkileşimi	7
2.3 Derin Öğrenme ve Zaman Serisi Tahmini.....	9
2.4 Mevcut Çalışmalar ve Araştırma Boşluğu	11
3. MATERYAL ve METOT	14
3.1 Çalışma Alanı	14
3.2 Sentinel 1 Görüntüleri	16
3.3 SNAP2StaMPS ve StaMPS Tabanlı PS-InSAR İş Akışı	17
3.3.1 SNAP2StaMPS İş Akışı.....	17
3.3.2 StaMPS ile PS Analizi	19
3.4 Derin Öğrenme ile Tahmin Yöntemi.....	22
3.4.1 Model Seçimi ve Kuramsal Temel	23
3.4.2 Girdi Verilerinin Hazırlanması	26
3.4.2.1 Ham Veri ve Zaman Serisi Yapısı	27
3.4.2.2 Veri Normalizasyonu	27
3.4.2.3. Denetimli Öğrenme Problemi için Zaman Serisi Dönüşümü	28
3.4.2.4 Girdi Verilerinin Derin Öğrenme Modelleri İçin Yeniden Şekillendirilmesi	28
3.4.2.5 RMF Veri Hazırlığı.....	29
3.4.3 Model Mimarisi ve Eğitim Aşamaları	29
3.4.3.1 Yinelemeli Çok Adımlı Tahmin (RMF) Stratejisi	30
3.4.3.2 Model Mimarileri ve Katman Yapısı	31
3.4.3.3. Modelin Uygulama Ortamı	39

3.4.3.4. Model Kaydı ve Tekrar Üretilirlik	40
3.4.4. Eğitim-Test Bölünmesi ve Validasyon	40
3.4.4.1 Eğitim-Test Bölünmesinin Zaman Temelli Yapısı.....	41
3.4.4.2. Doğrulama (Validation) Stratejisi	41
3.4.4.3. Modelin Eğitildiği Veri ve Tahmin Yapısı	41
3.4.4.4. Modelin Değerlendirme Süreci: Test Kümesi.....	42
3.4.4.5. Tekrarlanabilirlik ve Tahmin Senaryosu.....	42
3.4.5 Performans Kriterleri	42
4. BULGULAR	47
4.1 PS-InSAR ile Elde Edilen Ortalama Hız Haritaları	47
4.2 Derin Öğrenme Modelleri ile Yerkabuğu Hareketleri Tahmini Sonuçları.....	49
4.2.1. LSTM Sonuçları	49
4.2.2. CNN Sonuçları.....	55
4.2.3 TCN Sonuçları	60
4.2.4 GRU Sonuçları.....	65
4.2.5. Transformer Sonuçları	70
4.3 Tahmin Performansının Karşılaştırmalı Değerlendirilmesi	75
4.3.1 Tek Adımlı Tahmin Performansı	75
4.3.2 RMF Tahmin Performansı	76
4.3.3 Genel Değerlendirme	77
5. TARTIŞMA ve SONUÇ	79
6. KAYNAKLAR.....	85

SİMGELER ve KISALTMALAR DİZİNİ

Simgeler

mm	Milimetre
----	-----------

Kısaltmalar

AOE	Mutlak Yörünge Hatası
APS	Atmosferik Faz Penceresi
ASF	Alaska Satellite Facility
CNN	Evrişimli Sinir Ağları
ESA	Avrupa Uzay Ajansı
GRU	Kapılı Tekrarlayan Birim
LSTM	Uzun Kısa Süreli Bellek
LoS	Uydu Bakış Doğrultusu
MAE	Ortalama Mutlak Hata
POD	Hassas Yörünge Belirleme
PS	Kalıcı Yansıtıcı
PS-INSAR	Kalıcı Yansıtıcı İnterferometrik Yapay Açıklıklı Radar
R^2	Determinasyon Katsayısı
R	Pearson Korelasyon Katsayısı
RMSE	Karesel Ortalama Hata
SAR	Yapay Açıklıklı Radar
SLC	Tek Bakışlı Kompleks
SNAP	Sentinel Application Platform
STAMPS	Stanford Method for Persistent Scatterers
SYM	Sayısal Yükseklik Modeli
TCN	Zamansal Evrişimli Ağ

ŞEKİLLER DİZİNİ

Sayfa

Şekil 3.1 Bolvadin ilçesinin Türkiye’deki konumu.....	15
Şekil 3.2 Sentinel 1 uydusu	17
Şekil 3.3 Serinin son 4 verisini tahmin edici olarak kullanarak geleceğe yönelik 3 adımı tahmin eden RMF diyagramı	31
Şekil 3.4 Modellerin kavramsal mimarisi ve modüler yapısı.....	32
Şekil 4.1 Bolvadin ortalama hız haritası.	49
Şekil 4.2 LSTM 10. yıla ait eğitim kayıp grafiği.	50
Şekil 4.3 LSTM tahmin hatalarının dağılımı.	51
Şekil 4.4 LSTM gerçek değerlere karşı tahmin hataları.....	51
Şekil 4.5 LSTM tahmin hatalarının coğrafi dağılımı.	52
Şekil 4.6 LSTM RMF ile 11. yıl tahmin dağılımı.	53
Şekil 4.7 LSTM RMF ile 12. yıl tahmin dağılımı.	53
Şekil 4.8 LSTM RMF ile PS noktalarının 12. yıldaki hareketi.....	54
Şekil 4.9 CNN 10. yıla ait eğitim kayıp grafiği.	55
Şekil 4.10 CNN tahmin hatalarının dağılımı.....	56
Şekil 4.11 CNN gerçek değerlere karşı tahmin hataları.....	56
Şekil 4.12 CNN tahmin hatalarının coğrafi dağılımı	57
Şekil 4.13 CNN RMF ile 11. yıl tahmin dağılımı	58
Şekil 4.14 CNN RMF ile 12. yıl tahmin dağılımı.....	58
Şekil 4.15 CNN RMF ile PS noktalarının 12. yıldaki hareketi	36
Şekil 4.16 TCN 10. yıla ait eğitim kayıp grafiği.....	60
Şekil 4.17 TCN tahmin hatalarının dağılımı	61
Şekil 4.18 TCN gerçek değerlere karşı tahmin hataları	61
Şekil 4.19 TCN tahmin hatalarının coğrafi dağılımı.....	62
Şekil 4.20 TCN RMF ile 11. yıl tahmin dağılımı.....	63
Şekil 4.21 TCN RMF ile 12. yıl tahmin dağılımı.....	63
Şekil 4.22 TCN RMF ile PS noktalarının 12. yıldaki hareketi.....	64
Şekil 4.23 GRU 10. yıla ait eğitim kayıp grafiği.....	65
Şekil 4.24 GRU tahmin hatalarının dağılımı.....	66
Şekil 4.25 GRU gerçek değerlere karşı tahmin hataları	66
Şekil 4.26 GRU tahmin hatalarının coğrafi dağılımı	67

Şekil 4.27 GRU RMF ile 11. yıl tahmin dağılımı	68
Şekil 4.28 GRU RMF ile 12. yıl tahmin dağılımı	68
Şekil 4.29 GRU RMF ile PS noktalarının 12. yıldaki hareketi	69
Şekil 4.30 GRU 10. yıla ait eğitim kayıp grafiği.....	36
Şekil 4.31 Transformer tahmin hatalarının dağılımı	70
Şekil 4.32 Transformer gerçek değerlere karşı tahmin hataları	71
Şekil 4.33 Transformer tahmin hatalarının coğrafi dağılımı.....	72
Şekil 4.34 Transformer RMF ile 11. yıl tahmin dağılımı.....	73
Şekil 4.35 Transformer RMF ile 12. yıl tahmin dağılımı.....	74
Şekil 4.36 Transformer RMF ile PS noktalarının 12. yıldaki hareketi	75



ÇİZELGELER DİZİNİ

Sayfa

Çizelge 3.1 Ortak hiperparametreler tablosu	39
Çizelge 4.1 Derin Öğrenme Modellerinin Tahmin Performans Metrikleri.....	76



1. GİRİŞ

Yeryüzü, hem doğal jeodinamik süreçler hem de artan insan faaliyetlerinin etkisiyle sürekli bir değişim ve hareketlilik içindedir. Bu değişimlerin en belirgin ve çoğu zaman olumsuz sonuçlar doğuran göstergelerinden biri olan yüzey çökmeleri, karmaşık yer değiştirme olayları olarak karşımıza çıkmaktadır (Galloway ve Burbey, 2011, Chaussard vd. 2014). Doğal süreçler arasında tektonik hareketler, volkanik faaliyetler ve yer kabuğunun elastik tepkileri gibi etkenler yer alırken özellikle son yüzyılda antropojenik etkiler, yani insan kaynaklı faktörler, yüzey hareketlerinin hem şiddetini hem de yaygınlığını önemli ölçüde artırmıştır (Poland, 1984, Sneed vd. 2013). Bu antropojenik etkiler arasında yeraltı su kaynaklarının aşırı ve bilinçsiz kullanımı, madencilik faaliyetleri, büyük ölçekli inşaat projeleri, baraj gibi su tutma yapılarının inşası ve hidrokarbon üretimi gibi faaliyetler başı çekmektedir (Galloway ve Burbey, 2011, Chaussard vd. 2014, Osmanoglu vd. 2011). Özellikle kontrolsüz ve sürdürülebilir olmayan bir anlayışla gerçekleştirilen yeraltı suyu çekimi, dünyanın birçok bölgesinde yüzey çökmelerinin en yaygın ve uzun vadeli yıkıcı etkileri olan nedenlerinden biri olarak kabul edilmektedir. Yeraltı akiferlerinin, doğal yenilenme hızlarının çok üzerinde bir oranda ve sürekli olarak pompalanarak boşaltılması, suyun zemin taneleri arasında sağladığı mekanik desteğin azalmasına ve yeraltı formasyonlarının sıkışarak oturmasına yol açmaktadır. Bu durum, yüzeyde ölçülebilir ve çoğu zaman geri dönüşü olmayan çökmelere (subsidence) neden olmaktadır (Poland, 1984, Sneed vd. 2013). Bu tür zemin çökmeleri, yapılarda hasara, tarımsal verimsizliğe, altyapı sorunlarına ve bazı durumlarda geri dönüşü olmayan çevresel hasarlara yol açabilmektedir (Galloway vd. 1999).

Türkiye, hem aktif tektonik yapısı hem de özellikle son yıllarda artan su ihtiyacına bağlı olarak yoğunlaşan yeraltı suyu kullanımı nedeniyle yüzey çökmeleri açısından riskli bölgeler arasında yer almaktadır. Afyonkarahisar iline bağlı Bolvadin ilçesi ve onu çevreleyen Bolvadin Ovası da, son yıllarda bu tür yüzey çökmeleri ve bunların olumsuz etkileriyle gündeme gelen önemli bölgelerden biridir. Tarımsal üretimin oldukça yoğun olduğu Bolvadin Ovası'nda, sulama için gerekli olan su ihtiyacının çok büyük bir kısmı yeraltı kuyuları aracılığıyla karşılanmaktadır. Bu durum, bölgenin hassas hidrojeolojik dengesini bozmakta ve özellikle gevşek alüvyal zeminlerin bulunduğu alanlarda belirgin

zemin çökmelerine neden olmaktadır (Imamoglu vd. 2019). Bölgedeki bazı köylerde, artezyen kuyularının çevresinde zemin yüzeyinde çatlaklar, bina temellerinde kaymalar ve sulama altyapısında eğim bozulmaları rapor edilmiştir (İnt.Kyn.1). Bu yüzey çökmelerinin doğru bir şekilde izlenmesi, zamansal ve mekansal değişimlerinin anlaşılması ve gelecekteki potansiyel davranışlarının modellenmesi, hem bölgesel ölçekte afet yönetimi stratejilerinin geliştirilmesi hem de sürdürülebilir arazi ve su kaynakları kullanımı politikalarının oluşturulması açısından büyük ve acil bir önem taşımaktadır.

Yüzey çökmelerinin geleneksel izleme yöntemleri olan nivelman, GNSS ve jeoteknik sensör sistemleri, bazı avantajlarına rağmen geniş alanlarda sürekli ve yoğun veri sağlama konusunda maliyet ve lojistik açılardan kısıtlı kaldığı bilinmektedir (Ferretti vd. 2001, Hooper vd. 2004). Bu durum, uydu tabanlı uzaktan algılama teknolojilerinde yaşanan gelişmelerle birlikte, Yapay Açıklıklı Radar (SAR) görüntülerinin interferometrik analizine dayanan Kalıcı Yansıtıcı İnterferometrik Radar (PS-InSAR) tekniğinin önemini artırmıştır (Crosetto vd. 2008, Ferretti vd. 2011). PS-InSAR, farklı zamanlarda alınmış çok sayıda SAR görüntüsü üzerinden, zaman içinde radar sinyalinin kararlı bir şekilde geri yansıtan noktaları (PS) tespit ederek ve bu noktaların faz değişimlerini analiz ederek, yüzeydeki milimetrik hassasiyette çökme hızlarını ve zaman serilerini belirlemeyi mümkün kılmaktadır (Hooper vd. 2007). Avrupa Uzay Ajansı'nın (ESA) Sentinel-1 uydu takımı gibi yüksek zamansal tekrar frekansına sahip ve ücretsiz veri politikası güden SAR görevleri, PS-InSAR tekniğinin geniş alanlardaki çökmelerin uzun dönemli ve etkin takibi için güçlü bir araç haline gelmesini sağlamıştır (Yague-Martinez vd. 2016). Bolvadin bölgesinde daha önce uygulanan klasik ölçüm yöntemlerinin, yaygın ve yavaş ilerleyen bu çökmeleri tanımlamakta yetersiz kaldığı düşünüldüğünden, düzenli ve yoğun veri üreten PS-InSAR gibi uydu temelli yöntemlere olan ihtiyaç artmıştır (Ferretti vd. 2001, Hooper vd. 2004). Ayrıca, 10 yıla ulaşan uzun dönemli radar veri arşivlerinin analizi, çökme süreçlerinin daha güvenilir bir şekilde anlaşılmasına olanak tanımaktadır (Bawden vd. 2001, Chaussard vd. 2017).

Bu çalışma, Bolvadin bölgesinde özellikle yeraltı suyu çekimine bağlı olarak geliştiği düşünülen zemin çökmelerinin, Sentinel-1A uydu görüntülerinden oluşan 10 yıllık bir

zaman serisi kullanılarak PS-InSAR tekniğiyle detaylı bir şekilde izlenmesi, bu izleme sonucunda elde edilen yer kabuğu hareketleri zaman serilerinin ve mekansal trendlerinin çıkarılması ve ardından bu karmaşık zamansal örüntülerin, çeşitli derin öğrenme yöntemleri (LSTM, CNN, TCN, GRU, Transformer) ile işlenerek bölgedeki gelecekteki (2025-2026 yılları için) çökme eğilimlerinin Yinelemeli Çok Adımlı Tahmin (Recursive Multi-step Forecasting - RMF) stratejisiyle modellenmesini amaçlamaktadır. Bu entegre yaklaşımla, hem bölgedeki mevcut çökme hareketliliğinin bilimsel temelleri, mekansal dağılımı ve zamansal karakteristiği yüksek bir hassasiyetle ortaya konulacak, hem de ilerleyen yıllara ilişkin potansiyel risk projeksiyonları oluşturularak sürdürülebilir kaynak yönetimi ve afet risk azaltma çabalarına katkı sağlanacaktır.

Temel sınırlılıklar arasında, derin öğrenme modellerine ek fiziksel parametrelerin (meteorolojik, hidrolojik vb.) dahil edilmemesi, analizin yalnızca uydu bakış yönündeki (LOS) hareketi temel alması ve çalışma alanında yer doğrulama verilerinin bulunmaması sayılabilir. Bu sınırlılıklara karşın tez, Bolvadin gibi kırsal bir hidrojeolojik alanda 10 yıllık Sentinel-1A verileriyle uzun dönemli ve çift yörüngeli PS-InSAR analizi yapması, bu zaman serilerini beş farklı derin öğrenme mimarisi kullanarak RMF stratejisiyle geleceğe yönelik tahminlemesi ve zaman serisi uzunluğunun model performansına etkisini incelemesi gibi yönleriyle literatüre özgün katkılar sunmaktadır. Çalışma, PS-InSAR ve derin öğrenmenin entegrasyonunu kırsal bir alanda uzun dönemli analiz ve tahmin bağlamında uygulayan sayılı örneklerden biri olarak, yöntemsel derinliği ve veri uzunluğu ile literatürdeki pek çok çalışmadan farklılaşmaktadır (Zhang vd. 2019, Samsonov ve Tiampo 2006, Li vd. 2021, Sun vd. 2022).

Çalışma, bilimsel bir araştırmanın gerektirdiği sistematik ve mantıksal bir yapı çerçevesinde, beş ana bölüm halinde kurgulanmıştır. Bu birinci bölüm olan Giriş, çalışmanın genel arka planını, problemini, amaçlarını, hipotezlerini, kapsamını, sınırlılıklarını ve özgün katkılarını ortaya koyduktan sonra tezin genel yapısını sunmaktadır. İkinci Bölümde, PS-InSAR, zemin çökmeleri ve derin öğrenme konularındaki teorik temeller ve kapsamlı bir literatür özeti yer almaktadır. Üçüncü Bölüm olan Materyal ve Metot'ta, çalışma alanı, kullanılan Sentinel-1A verileri, detaylı

PS-InSAR iş akışı ve derin öğrenme ile tahmin yöntemleri ayrıntılı bir şekilde açıklanmaktadır. Dördüncü Bölüm olan Bulgular, PS-InSAR analizinden elde edilen yerkabuğu hareketi haritaları ve zaman serileri ile beş farklı derin öğrenme modelinin tek adımlı ve RMF tabanlı çok adımlı tahmin sonuçlarını, başarı metriklerini ve karşılaştırmalı performans değerlendirmelerini içermektedir. Bulgular, bölgedeki jeolojik ve hidrojeolojik süreçlerle de ilişkilendirilmiştir. Son olarak, Beşinci Bölüm olan Tartışma ve Sonuç'ta, elde edilen tüm bulgular mevcut literatür ışığında yorumlanmakta, çalışmanın güçlü ve zayıf yönleri ile kısıtlılıkları ele alınmakta, tezin bilimsel ve pratik katkıları özetlenmekte ve gelecek çalışmalara yönelik önemli öneriler sunulmaktadır. Bu yapı, tezin bilimsel argümanlarının tutarlı bir şekilde sunulmasını ve okuyucu tarafından kolaylıkla takip edilebilmesini amaçlamaktadır.

2. LİTERATÜR BİLGİLERİ

2.1 PS-InSAR Tekniği

Yüzey çökmelerinin mekansal olarak sürekli ve milimetre altı duyarlılıkla izlenebilmesi, uzaktan algılamanın gelişimiyle birlikte özellikle radar teknolojileri sayesinde mümkün hale gelmiştir. Radar sistemleri, elektromanyetik dalgaları kullanarak yüzey özelliklerini algılayan aktif sensörlerdir. Optik sistemlerden farklı olarak gece ve gündüz, bulutluluk gibi atmosferik koşullardan bağımsız olarak çalışabilmeleri, radar tabanlı ölçüm tekniklerini arazi çökmelerin izlenmesinde güçlü bir alternatif haline getirmiştir (Curlander ve McDonough, 1991, Henderson ve Lewis, 1998).

Radar verilerinin hareket analizine entegrasyonunun temelini Yapay Açıklıklı Radar (SAR) sistemleri oluşturur. SAR, hareketli bir radar platformundan (uydu veya hava aracı) gönderilen ve yüzeyden geri yansıyan sinyallerin faz ve genlik bilgilerinin sayısal olarak işlenmesiyle yüksek çözünürlüklü görüntüler üretir. Gerçek açıklığın yerini elektronik olarak simüle edilen bir açıklığın alması, bu sistemlere "yapay" niteliğini kazandırır. SAR sistemleri, elektromanyetik sinyalin geri saçılım karakteristiklerini kaydettiğinden, yüzey yapıları ve değişimlerinin fiziksel özellikleri hakkında bilgi sağlayabilir (Massonnet ve Souyris, 2008).

SAR sistemlerinin farklı zamanlarda aynı bölgeden alınmış görüntü çiftleriyle faz farklarının analiz edilmesiyle interferometrik SAR (InSAR) tekniği geliştirilmiştir. InSAR, yüzeyin arazi modeli ve yer değişimi bileşenlerini içeren faz farkı bilgisini kullanarak yerkabuğu hareketlerinin ölçümüne olanak tanır (Gabriel vd. 1989). Ancak tek bir interferogram atmosferik gecikme, yörünge hatası ve topoğrafik artık gibi birçok bozucu bileşen içerdiğinden, hareketin doğru olarak ayrıştırılması çoğu zaman mümkün olmaz (Hanssen, 2001). Bu nedenle, faz sinyallerindeki bozulmaların azaltılması ve hareketin net olarak ölçülebilmesi için zaman serisi analizine dayalı yöntemler geliştirilmiştir.

Bu bağlamda ortaya çıkan ve bu tezin temel analiz aracını oluşturan teknik, Kalıcı Yansıtıcı İnterferometrik SAR (PS-InSAR) yaklaşımıdır. PS-InSAR, uzun süreli SAR veri setleri içinde faz sinyali kararlılığı yüksek olan noktalara, yani kalıcı yansıtıcılara (persistent scatterers) odaklanarak, zaman içinde yeryüzünde meydana gelen yer değiştirmelerin yüksek doğrulukla izlenmesini sağlar (Ferretti vd. 2000, Ferretti vd. 2001). Kalıcı yansıtıcılar genellikle binalar, yollar, sabit altyapılar gibi yapay yapılar olmakla birlikte, kayalık alanlar veya sabit doğal yüzeyler de PS adayı olabilir. Bu noktaların uzun dönemli analizinde sinyal-gürültü oranı yüksek olduğundan, hareketin zamansal değişimi milimetre düzeyinde duyarlılıkla izlenebilir.

PS-InSAR yöntemi, bir referans tarih ve bir referans piksel belirlenerek başlatılır ve her PS pikseli için zaman içinde farklı tarihlerde alınmış interferogramlardan faz değerleri analiz edilir. Bu süreçte atmosferik gecikmelerin zaman serisi içerisindeki düşük frekanslı etkileri model dışı bırakılır ve yüzey hareketleri yüksek frekanslı bileşenler üzerinden çözümlenir (Hooper vd. 2007). Böylece, klasik D-InSAR tekniklerinde görülen atmosferik parazitlerin etkisi büyük ölçüde azaltılarak hareketin gerçek bileşeni ortaya konur (Ferretti vd. 2011).

PS-InSAR'ın en önemli avantajı, geniş alanlarda, uzun zaman serileriyle, yersel ölçüm altyapısına gerek kalmaksızın, hareket verisi üretmesidir. Sentinel-1 gibi kısa tekrar süreli SAR görevleri sayesinde haftalık gözlemler mümkündür. Ayrıca her bir PS pikseli için bir zaman serisi elde edilmesi, hareketin zamansal yapısının analizine de olanak tanır. Bu durum, mevsimsel hareketler, yer altı suyu çekimi gibi süregelen yerkabuğu hareketlerinin kaynaklarının belirlenmesinde büyük avantaj sağlar (Galloway ve Burbey, 2011). PS-InSAR yaklaşımının yanı sıra, literatürde zaman serisi analizi için geliştirilmiş bir diğer önemli yöntem ise kısa baz uzunluğu interferometrisine dayanan SBAS tekniğidir (Berardino vd. 2002).

Bununla birlikte PS-InSAR tekniğinin bazı sınırlılıkları da mevcuttur. Yoğun bitki örtüsü, su yüzeyleri veya nemli toprak gibi yüzeylerde radar sinyalinin geri saçılımı zayıf olduğundan PS noktası üretimi mümkün olmayabilir. Bu nedenle, kırsal ve tarımsal alanlarda PS yoğunluğu düşebilir ve yerkabuğu hareketinin çözünürlüğü

sınırlanabilir (Crosetto vd. 2008). Ayrıca, tek yörüngeyle yapılan analizlerde yalnızca LOS yönündeki hareket bileşeni ölçülebilir, üç boyutlu yer değiştirme vektörlerinin hesaplanması için çok yörüngeli veya GNSS destekli veri birleşimine ihtiyaç duyulmaktadır (Samsonov ve Tiampo, 2006).

Bu tez çalışmasında kullanılan PS-InSAR yöntemi, Sentinel-1A uydusuna ait 120 adet yükselen ve 120 adet alçalan yörünge SAR görüntüsünden oluşan toplam 240 veri ile uygulanmıştır. SNAP-StaMPS iş akışı kullanılarak interferogramlar oluşturulmuş, kalıcı yansıtıcılar seçilmiş ve her bir nokta için zaman serileri üretilmiştir. Bu zaman serileri hem mevcut çökme eğilimlerinin incelenmesi hem de derin öğrenme modellerinin eğitimi için temel veri seti olarak kullanılmıştır. Böylece PS-InSAR sadece geçmiş analiz aracı olarak değil, aynı zamanda tahmine dayalı modellemeye zemin hazırlayan bir yapı olarak bu tezin merkezinde yer almıştır.

2.2 Zemin Çökmeleri ve Yer Altı Suyu Etkileşimi

Yerkabuğu hareketlerinin en yaygın ve uzun vadeli nedenlerinden biri olan zemin çökmeleri, doğrudan veya dolaylı olarak yer altı suyu çekimiyle ilişkilendirilen karmaşık hidrojeolojik süreçlerin sonucudur. Zemin oturmaları, genellikle kohezyonlu ve gevşek tortul zeminlerin bulunduğu bölgelerde, yer altı akiferlerinin sürdürülebilir olmayan biçimde kullanılması durumunda ortaya çıkar. Bu tür çökmeler, altyapı hasarları, bina deformasyonları, kanalizasyon eğim bozuklukları, yüzey akış değişimleri gibi ciddi mühendislik ve çevresel sonuçlar doğurur (Holzer, 1984, Poland, 1984).

Yer altı suyu çekimine bağlı çökmeler esasen akiferlerin elastik olmayan konsolidasyonu sonucu gelişir. Su basıncının azalmasıyla birlikte akifer içerisindeki boşluklar kapanır, bu da hacim kaybına ve dolayısıyla yüzeyde çökmeye neden olur. Özellikle kil ve silt gibi düşük geçirgenlikli malzemeler bu tip deformasyonlara daha yatkındır çünkü bu tür zeminlerin suyu tutma kapasiteleri yüksek olup boşluk oranlarının kapanması kalıcıdır (Galloway ve Burbey, 2011). Bu süreç, genellikle sismik olarak sessiz bölgelerde bile yılda birkaç mm'den birkaç cm'ye kadar ulaşabilen hareketlere yol açabilir (Erban vd. 2014).

Hidrojeolojik olarak yarı kapalı akiferlerde, su seviyesindeki düşüş doğrudan zemin oturmasına neden olurken, çok katmanlı sistemlerde üst ve alt birimlerin farklı sıkışma özellikleri, çökmenin uzaysal heterojenliğine neden olur (Zhou vd. 2016). Zemin çökmelerinin hızı çekim süresine, su seviyesi düşüşünün büyüklüğüne, jeolojik yapı ve litolojiye bağlı olarak önemli ölçüde değişiklik gösterebilir. Bu değişkenlik, farklı disiplinlerden gelen araştırmacıların zemin çökmelerini sadece hidrostatik bir olay değil, aynı zamanda jeomekanik ve jeofiziksel bir süreç olarak ele almalarını zorunlu kılmaktadır (Gambolati ve Teatini, 2015).

Özellikle hızlı kentleşme ve kontrolsüz sulama faaliyetlerinin bulunduğu bölgelerde, yer altı suyu rezervleri geri kazanılamayacak ölçüde tükenebilmekte ve bu durum çökmelerin de kalıcı hale gelmesine yol açmaktadır. Kaliforniya'daki San Joaquin Vadisi, Bangkok, Mexico City, Jakarta ve İstanbul gibi dünya genelindeki birçok metropol bu durumun etkili örnekleri olarak gösterilmiştir (Chaussard vd. 2014, Osmanoglu vd. 2011, Geymen ve Baz, 2008).

Türkiye'de yer altı suyu kaynaklarının aşırı kullanımıyla oluşan zemin çökmeleri özellikle İç Anadolu ve Ege Bölgelerinde sıkça rapor edilmiştir. Konya Ovası, Gediz Havzası, Büyük Menderes Ovası ve Afyonkarahisar-Bolvadin Ovası, bu tür çökmelere maruz kalan başlıca alanlardır (Imamoglu vd. 2019, Duran vd. 2021). Bolvadin özelinde yapılan önceki çalışmalar, özellikle güney-güneybatı yönündeki bölgelerde yılda 5–15 mm aralığında çökmelerin meydana geldiğini ve bu çökmelerin büyük ölçüde yer altı suyu seviyesindeki düşüşlerle paralellik gösterdiğini ortaya koymuştur.

Zemin çökmelerinin uzaktan algılama ile izlenmesi, özellikle 2000'li yıllardan itibaren SAR interferometrisinin yaygınlaşmasıyla yeni bir boyut kazanmıştır. Başta D-InSAR teknikleri kullanılsa da bu yöntem, atmosferik etkiler ve uydu yörünge hatalarına duyarlı olması nedeniyle sınırlı başarı sağlamıştır. Buna karşın PS-InSAR yöntemi, çoklu görüntü setleri üzerinden uzun dönemli analizlere izin vererek, zemin çökmelerinin zamansal gelişimini milimetre hassasiyetinde ve yüksek mekansal çözünürlükte haritalayabilmiştir (Ferretti vd. 2001, Hooper vd. 2007). Örneğin, Tayland'ın Bangkok bölgesinde Chaussard vd. (2014), PS-InSAR ile 2007–2011 yılları

arasında yılda 20–30 mm’ye varan çökmeleri yer altı suyu tüketimiyle ilişkilendirmiştir. Benzer şekilde, Mexico City’de su çekimiyle ilişkili çökmeleri başarılı şekilde modellemiştir (Osmanoglu vd. 2011).

Bu bağlamda PS-InSAR yöntemi, yer kabuğu hareketinin analizlerinin yalnızca mevcut durumun belirlenmesinde değil, hareketin nedenlerinin ortaya konmasında ve yer altı suyu yönetimi politikalarının bilimsel temellere dayandırılmasında da etkili bir araç olarak öne çıkmaktadır. Bu çalışmada Bolvadin bölgesine özgü 10 yıllık PS-InSAR zaman serilerinin, yıl bazında analiz edilerek ve sonraki yıllara çıkarım yaparak yer altı suyu etkilerinin uzamsal ve zamansal etkilerinin çıkarılması hedeflenmiştir. Bu analiz, zemin çökmelerinin yalnızca fiziksel bir sonuç değil, aynı zamanda hidrojeolojik dinamiklerin uzamsal ifadesi olduğunu ortaya koymakta; yer altı suyu çekimi ile yüzey çökmeleri arasındaki güçlü ilişkiyi bilimsel olarak belgelemeyi amaçlamaktadır.

2.3 Derin Öğrenme ve Zaman Serisi Tahmini

Derin öğrenme, çok katmanlı yapay sinir ağlarını kullanarak büyük ve karmaşık veri kümelerinde anlamlı örüntüleri otomatik olarak öğrenme yeteneğine sahiptir. Derin öğrenme modelleri, geleneksel makine öğrenimi algoritmalarının aksine, öz nitelik (feature) çıkarımını el yordamıyla yapmak yerine, bu süreçleri doğrudan verinin kendisinden öğrenebilir. Bu özellik, zaman serisi gibi yapılandırılmış ancak çoğunlukla gürültülü ve çok boyutlu veriler için özellikle avantajlıdır (Goodfellow vd. 2016).

Zaman serisi tahmini, geçmiş verilerden öğrenilerek geleceğe yönelik öngörülerde bulunmayı amaçlayan önemli bir modelleme problemidir. Klasik yöntemlerle (örneğin ARIMA, Holt-Winters, vb.) yapılan zaman serisi analizleri, özellikle doğrusal eğilim ve sabit mevsimsellik barındıran verilerde oldukça başarılıdır. Ancak günümüzde doğal sistemlerin yüksek karmaşıklık, değişkenlik ve doğrusal olmayan dinamikler içermesi, daha esnek ve güçlü modelleme yöntemlerini gerekli kılmıştır. Bu ihtiyaç doğrultusunda özellikle derin öğrenme tabanlı modeller, zaman serisi tahmininde önemli avantajlar sağlamaya başlamıştır (Zhang vd. 2019, Hewamalage vd. 2021).

Zaman serilerinin derin öğrenme ile modellenmesinde en çok tercih edilen yapılardan

biri Uzun Kısa Süreli Bellek (LSTM) ağlarıdır. LSTM, klasik RNN'lerin (Recurrent Neural Network) uzun süreli bağımlılıkları öğrenmekte yaşadığı “gradyan sönmesi” (vanishing gradient) problemini çözmek üzere geliştirilmiş bir türdür (Hochreiter ve Schmidhuber, 1997). LSTM, içsel kapı mekanizmaları (giriş, unutma, çıkış kapıları) sayesinde geçmişteki önemli bilgileri uzun süre hafızada tutabilir ve zaman içinde belirli örüntüleri öğrenebilir. Bu özellik, yerkabuğu hareketleri zaman serileri gibi hem yavaş hem de dönemsel değişimleri içeren verilerde oldukça etkilidir (Zhang vd. 2019).

Son yıllarda LSTM'ye ek olarak geliştirilen GRU (Gated Recurrent Unit), CNN (Convolutional Neural Networks) Transformer, gibi mimariler de zaman serisi tahmininde yaygın biçimde kullanılmaktadır. Özellikle dikkat mekanizmasına dayanan Transformer modelleri, tüm zaman adımları arasındaki ilişkileri paralel biçimde modelleyebilme kapasitesi ile öne çıkar (Vaswani vd. 2017). Ancak bu modellerin veri ihtiyacı ve hesaplama maliyeti yüksek olduğundan, nispeten daha düşük boyutlu veri setlerinde LSTM hâlen yaygın biçimde kullanılmaktadır.

Bununla birlikte, yerkabuğu hareketleri zaman serilerinin derin öğrenme modelleriyle tahmini için en önemli unsurlardan biri, yeterli uzunlukta ve sürekli bir zaman dizisine sahip olmaktır. Kısa seriler, modellerin uzun dönemli bağımlılıkları öğrenmesini engelleyebilir ve model başarısını düşürebilir. Bu nedenle bu tezde olduğu gibi 10 yıllık sürekli gözlem dizileri, derin öğrenme temelli zaman serisi tahmin modelleri için oldukça elverişlidir (Lyu vd. 2021).

Derin öğrenme modellerinin doğruluğunun değerlendirilmesinde ise RMSE (Root Mean Square Error), MAE (Mean Absolute Error) ve R^2 (Determination Coefficient) gibi istatistiksel ölçütler kullanılır. Ayrıca derin öğrenme modellerinin karar yapılarının açıklanabilirliğini artırmak için SHAP (SHapley Additive exPlanations) veya Permütasyon Öznitelik Önemi gibi yöntemlerle özelliklerin modele katkısı sayısallaştırılabilmektedir (Lundberg ve Lee, 2017). Bu sayede sadece yüksek doğruluk elde etmekle kalınmaz, aynı zamanda modelin hangi girişler üzerinden tahminde bulunduğu da analiz edilebilir.

Bu tez çalışmasında kullanılan zaman serileri, Sentinel-1A verilerinden türetilmiş uzun süreli PS-InSAR ölçümlerinden oluşmaktadır. Bu zaman serileri çeşitli derin öğrenme modelleri ile modellenmiş ve elde edilen tahmin çıktıları karşılaştırılmıştır. Böylece hareketin tahmini farklı derin öğrenme yöntemleri kullanılarak gerçekleştirilmiş ve bu yöntemlerin literatürdeki klasik yaklaşımlarla kıyaslandığında avantaj ve sınırlılıkları analiz edilmiştir.

2.4 Mevcut Çalışmalar ve Araştırma Boşluğu

Yüzey çökmeleri izlenmesi, modellenmesi ve tahminine yönelik çalışmalar, özellikle son yirmi yılda uzaktan algılama, jeoloji, hidrojeoloji ve yapay zekâ gibi disiplinlerin kesişiminde önemli bir araştırma alanı haline gelmiştir. Hareket süreçlerinin milimetre düzeyinde hassasiyetle izlenmesi için radar interferometrisi, özellikle de PS-InSAR yöntemi, bilimsel çalışmalarda giderek daha fazla tercih edilmektedir (Ferretti vd. 2001, Crosetto vd. 2016). Bu yöntemin başarısı, farklı zamanlarda alınmış SAR görüntülerinden oluşturulan interferogramlar yoluyla uzun süreli hareket analizleri yapılabilmesine dayanır. Kalıcı yansıtıcıların zamansal faz kararlılığı sayesinde, yüzeyde meydana gelen hareketlerin gürültüden arındırılarak zamansal eğilimleri belirlenebilir (Hooper vd. 2007).

PS-InSAR yöntemi, birçok çalışmada kentleşme, madencilik, baraj etkileri, yer altı suyu çekimi, sismik etkinlik ve volkanik kabarma gibi geniş bir spektrumda incelemek üzere uygulanmıştır. Örneğin Mexico City’de, PS-InSAR ile yer altı suyu çekimine bağlı olarak yılda 300 mm’ye varan zemin çökmelerini belgeneyerek, yerleşim alanlarının uzun dönemli çökme risklerini ortaya koymuştur (Osmanoglu vd. 2011). Benzer şekilde, Endonezya’nın Jakarta ve Bandung kentlerinde yer altı suyu ve gaz çekiminin zemin çökmesine neden olduğunu, PS-InSAR ile 2007–2011 döneminde yüksek doğrulukta tespit etmiştir (Chaussard vd. (2014). Yöntem, aynı zamanda petrol platformları gibi büyük mühendislik yapılarının stabilitesini izlemek için de başarıyla kullanılmıştır (Latip vd. 2010). Türkiye’de ise Konya Ovası, Büyük Menderes Havzası, Gediz Ovası gibi bölgelerde yapılan çalışmalarda, özellikle tarımsal sulama amaçlı yer altı suyu kullanımının zemin çökmeleriyle doğrudan ilişkili olduğu gösterilmiştir (Duran vd. 2021, Geymen ve Baz, 2008). Benzer şekilde, Serpelloni vd. (2023)

tarafından İtalya'nın kuzeydoğusunda yapılan çalışmada da InSAR ve GNSS verileri entegre edilerek bölgesel yüzey deformasyonları incelenmiştir.

Türkiye'de InSAR ve makine öğrenmesi yöntemlerinin entegrasyonu üzerine yapılan güncel ve kapsamlı bir çalışmada, Yağmur (2023), İstanbul Havalimanı'ndaki çökme hareketlerini PS-InSAR ve SBAS yöntemleriyle belirlemiş; ardından ARIMA, XGBoost ve LSTM gibi farklı model ailelerini kullanarak deformasyon tahmini gerçekleştirmiştir. Söz konusu çalışmada, deformasyonun temel nedeninin dolgu zeminler olduğu ve modellere meteorolojik verilerin eklenmesinin tahmin doğruluğunu artırdığı gösterilmiştir.

Afyonkarahisar-Bolvadin Ovası özelinde yapılan çalışmalar sınırlı olmakla birlikte, GNSS verileri ile PS-InSAR sonuçlarını karşılaştırarak yılda ortalama 5–15 mm arasında değişen hareket oranlarının olduğunu raporlamışlardır (Imamoglu vd. 2019). Ancak bu çalışmalarda çökme verilerinin ileriye dönük tahminine ilişkin herhangi bir modelleme yapılmamıştır. Literatürde hareketin yalnızca haritalanması değil, aynı zamanda tahmin edilmesi yönünde de önemli bir araştırma eğilimi oluşmuştur. Özellikle derin öğrenme modellerinin zaman serisi tahmininde gösterdiği başarı, yer kabuğu hareketlerinin eğilimlerinin öngörüsünde kullanılmasına yönelik çok sayıda çalışmayı beraberinde getirmiştir (Zhang vd. 2019, Lyu vd. 2021).

Mevcut literatürdeki birçok çalışma, ya sınırlı sayıda yıl ile çalışmakta, ya da hareketin tahmin kısmına derinlemesine odaklanmamaktadır. Ayrıca hareket–çevresel değişken ilişkisi çoğu çalışmada yalnızca korelasyon analizleriyle sınırlandırılmıştır, oysa özellikle yer altı suyu gibi antropojenik etkiler zamanla değişkenlik gösterdiğinden, bu etkilerin zamansal örüntülerle birlikte modellenmesi gereklidir (Gambolati ve Teatini, 2015, Sun vd. 2022).

Bu bağlamda bu tez çalışması, aşağıdaki yönleriyle mevcut literatürdeki boşluklara doğrudan yanıt vermektedir:

- 10 yıllık Sentinel-1A verisiyle oluşturulmuş uzun dönem zaman serileri

üzerinden yıl bazlı PS-InSAR analizleri yapılmış ve bu, literatürde nadiren görülen bir zaman derinliği sunmuştur.

- Oluşturulan tüm PS noktaları işleme katılmış ve tüm bölge üzerinde çalışma yapılmıştır.
- Elde edilen zaman serileri klasik yaklaşımlar yerine yalnızca derin öğrenme (LSTM, CNN, GRU, Transformer) modelleriyle analiz edilmiştir
- Hareketlerin sadece mekansal haritalaması yapılmakla kalmayıp, bu değişimlerin zamansal örüntüler üzerinden tahmini gerçekleştirilmiştir.
- Bölgesel literatürde ilk kez, Bolvadin’de yer altı suyu kaynaklı çökmelerin hem izlenmesi hem de öngörüsü derin öğrenme temelli olarak modellenmiştir.

Bu yönleriyle bu tez, yer kabuğu hareketlerinin tahmini açısından PS-InSAR zaman serilerinin derin öğrenmeyle bütünleştirilmesi anlamında özgün bir katkı sunmakta, aynı zamanda veri yoğunluklu uzaktan algılama çıktılarının karar destek sistemlerine entegre edilmesine olanak tanımaktadır.

3. MATERYAL ve METOT

Bu bölümde, PS-InSAR tabanlı yerkabuğu hareketi analizlerinin uygulandığı Afyonkarahisar ili Bolvadin ilçesine ait fiziksel, jeolojik ve hidrojeolojik karakteristikler detaylı biçimde sunulmaktadır. Ayrıca, Sentinel-1A uydusu tarafından sağlanan ve çalışmanın ana veri setini oluşturan SAR görüntüleri, bu görüntülerin zamansal kapsamı, işlenme yöntemleri ve veri kalitesi açısından değerlendirilmiştir. Bölgenin doğal koşulları ile kullanılan radar verilerinin uyumu, hareket analizi ve derin öğrenme temelli tahminlerin doğruluğunu doğrudan etkilemektedir.


3.1 Çalışma Alanı

Afyonkarahisar il merkezinin doğusunda yer alan Bolvadin ilçesi, Türkiye'nin Batı Anadolu Fay Zonu ile Orta Anadolu'nun çöküntü ovaları arasında bir geçiş alanında konumlanmaktadır. Bölge, Neojen yaşlı sedimanter birimlerin egemen olduğu, geniş alüvyonel örtüye sahip tektonik kökenli bir ova sistemi olarak tanımlanabilir (MTA, 2019). Jeolojik açıdan bölge, genellikle killi-merkezli tortul tabakalar, çakıllı ve kumlu alüvyon dolgular, bazı yerlerde ise jipsli birimler ile temsil edilmektedir. Bu litolojik çeşitlilik, zemin oturmalarına ve dolayısıyla yüzey çökmelerine karşı yüksek duyarlılık yaratmaktadır.

Bolvadin Ovası, Sultandağı Fayı'nın uzantısında yer almakta olup, aktif fay zonları tarafından çevrelenmiştir. Özellikle Afyon–Akşehir fay hattı bölgenin doğusunda belirgin tektonik hareketliliğe işaret ederken, graben yapısının etkisiyle çökme ve dolgu süreçleri bölgenin yüzey jeomorfolojisini belirlemiştir (Emre vd. 2018). Bu fay sistemleri hem doğrudan yer değiştirme potansiyeli yaratmakta, hem de sedimanter tabakaların sıkışabilirliğini artırarak dolaylı yoldan deformasyona katkı sağlamaktadır.

Hidrojeolojik olarak Bolvadin, önemli yer altı suyu rezervlerine sahip, çok katmanlı akifer sistemleriyle tanımlı bir kapalı havzadır. Özellikle gevşek alüvyon dolgular içerisindeki akiferler, yüzeye yakın ve yüksek geçirgenlikli olmaları nedeniyle yer altı suyu çekimi açısından yoğun kullanılmaktadır (DSİ, 2020). Tarım ve hayvancılığa dayalı kırsal ekonomi nedeniyle, bölgede yaz aylarında artezyen kuyularından yapılan

pompajlar ciddi oranlara ulaşmaktadır. Bu durum, akiferlerdeki hidrolik dengeleri bozarak, zamanla elastik olmayan konsolidasyon sonucu zemin çökmelerine neden olmaktadır (Galloway ve Burbey, 2011, Erban vd. 2014).




Şekil 3.1 Bolvadin çalışma bölgesi.

Imamoglu vd. (2019) tarafından InSAR verileriyle yapılan çalışmada, Bolvadin’de yılda ortalama 15 mm arasında değişen yüzey hareketlerini raporlanmış ve bu çökme hızlarının, yer altı suyu seviyesindeki düşüşlerle doğrudan ilişkili olduğu belirlenmiştir. Bu bulgular, bölgedeki zemin oturmalarının yalnızca tektonik veya doğal konsolidasyon süreçlerinden değil, yoğun antropojenik su kullanımıyla tetiklenen hidrojeolojik dengesizliklerden kaynaklandığını göstermektedir.

3.2 Sentinel 1 Görüntüleri

Bu tezde kullanılan radar görüntüleri, Avrupa Uzay Ajansı'nın (ESA) Copernicus Programı kapsamında faaliyet gösteren Sentinel-1A uydusu tarafından sağlanmıştır. Sentinel-1A, C-bandı SAR sensörü ile çalışmakta olup, 12 günlük tekrar frekansı, yüksek geometrik doğruluk, bulut ve atmosfer etkisinden bağımsız veri üretimi gibi özellikleri nedeniyle yer kabuğu hareketi izleme çalışmalarında yaygın biçimde kullanılmaktadır (Torres vd. 2012). Ayrıca IW (Interferometric Wide Swath) modu, üç alt bant üzerinden faz uyumunu yüksek tutarak PS-InSAR uygulamaları için ideal veri sağlamaktadır.



Şekil 3.2 Sentinel 1 uydusu.

Bu çalışmada Bolvadin bölgesini kapsayan toplam 240 adet Sentinel-1A SLC (Single Look Complex) görüntüsü kullanılmıştır. Bu görüntülerin 120'i alçalan, 120'i yükselen yörüngeye aittir ve 2015–2024 yılları arasındaki dönemi kapsayacak şekilde ASF (Alaska Satellite Facility) veri havuzundan indirilmiştir. Görüntüler, PS-InSAR analizi açısından zaman içindeki faz tutarlılığını maksimize etmek ve eşleşebilirliği artırmak amacıyla VV polarizasyonunda kullanılmıştır.

Görüntüler, ESA'nın SNAP yazılımı aracılığıyla ön işleme alınmış ve ana görüntü

seçilmiş daha sonra Snap2StaMPS arayüzü ile StaMPS analizine uygun formatta veri dönüştürülmüş ve her bir referans görüntüye karşılık gelen interferogramlar üretilmiştir. StaMPS ortamında kalıcı yansıtıcı seçimi, ağ yapısının kurulması, atmosferik faz ayırıştırması ve zaman serisi hareketlerinin çıkarımı işlemleri tamamlanarak her bir PS noktası için milimetre düzeyinde zaman serileri elde edilmiştir (Hooper vd. 2004; Kampes, 2006).

Görüntülerin seçiminde, alçalan ve yükselen yörüngelerde ayrı ayrı olarak 10 yıllık periyottaki 12 ayın her biri için 120 görüntü seçilmiş, toplamda 120 alçalan 120 yükselen olarak 240 görüntü kullanılmıştır. Görüntü yoğunluğu, uzamsal çözünürlük ve veri arşivine erişim kolaylığı sayesinde Sentinel-1A verileri, hem analiz hem de derin öğrenme modeli eğitimi açısından güvenilir ve sürdürülebilir bir temel veri kaynağı sunmuştur

3.3 SNAP2StaMPS ve StaMPS Tabanlı PS-InSAR İş Akışı

3.3.1 SNAP2StaMPS İş Akışı

Sentinel-1A verileriyle PS-InSAR analizinin uygulanabilmesi için, radar görüntülerinin işlenmesinde belirli yazılımsal araçlara ve çok aşamalı bir iş akışına ihtiyaç vardır. Bu kapsamda Avrupa Uzay Ajansı (ESA) tarafından geliştirilen Sentinel Application Platform (SNAP) yazılımı ve buna bağlı olarak çalışan Snap2StaMPS aracı, StaMPS (Stanford Method for Persistent Scatterers) yazılımına uygun veri çıktısı üretmek için kullanılmaktadır. Snap2StaMPS aracı, SNAP üzerinde gerçekleştirilen tüm ön işlemleri organize ederek interferogram üretiminden referans görüntü atamasına kadar olan süreci yarı otomatik hale getirir (Martinis vd. 2016).

Bu çalışmada kullanılan SNAP2StaMPS iş akışı, ESA'nın Sentinel-1 IW modunda, VV polarizasyonlu, SLC formatındaki verileri esas alarak yapılandırılmıştır. Süreç aşağıdaki temel adımları içermektedir.

1. Sentinel-1A verileri, ASF (Alaska Satellite Facility) veri arayüzünden belirlenen yörünge (alçalan ve yükselen) ve çerçeve numaralarına göre indirilmiştir. Tüm

görüntüler, aynı yörünge ve aynı sahayı kapsayacak şekilde seçilmiştir. Veri organizasyonu, “ana görüntü” ve “ikincil görüntü” ayrımı dikkate alınarak yapılmıştır. Ana görüntü olarak belirlenen görüntü en az speckle ve geometrik bozulma içeren, genellikle orta tarihli görüntüdür (Yague-Martinez vd. 2016).

2. Yörünge verileri ESA tarafından sürekli güncellenmekte ve Precise Orbit Determination (POD) dosyaları olarak sunulmaktadır. SNAP üzerinde, Apply Orbit File adımıyla tüm ana ve ikincil görüntülere en güncel yörünge bilgileri atanarak coğrafi doğruluk artırılır. Bu adım özellikle interferogramların doğru eşleşmesi açısından kritiktir (Potin vd. 2016).
3. Topografik faz bileşenini ortadan kaldırmak için sayısal yükseklik modeli (DEM) kullanılarak fark interferogramlar (differential interferograms) üretilir. Bu tezde ESA tarafından sağlanan 30 m çözünürlüklü SRTM DEM kullanılmıştır. Bu işlem ile DEM kaynaklı fazlar düşülerek sadece deformasyon sinyali elde edilir (Hooper vd. 2004).
4. Tüm ikincil görüntüler, seçilen ana görüntüye göre görüntü çakıştırma işlemine tabi tutulur. Bu işlemde her pikselin faz bilgisi, konumsal olarak karşılık geldiği piksel ile örtüşecek şekilde hizalanır. Görüntü çakıştırma doğruluğu, özellikle PS-InSAR analizinde çok önemli olup, hata kaynaklı faz kaymaları deformasyon sinyalini boğabilir (Scheiber vd. 2007). Sentinel-1 TOPS verilerinin kendine has yapısı nedeniyle, bu işlemde çok yüksek bir doğruluk gereklidir ve bu amaçla spektral çeşitlilik gibi gelişmiş yöntemler kullanılmaktadır (Scheiber ve Moreira 2000).
5. Görüntü çakıştırma işlemi tamamlanan her bir görüntü çifti için interferogramlar üretilir. Interferogram, iki radar görüntüsünün faz farkı bilgisini içerir ve yüzeydeki deformasyonlar hakkında bilgi sağlar. SNAP modülünde “Interferogram Formation” işlemiyle bu ürünler elde edilir. Ardından “TOPS Deburst” işlemi ile alt bantlardaki hatalar düzeltilerek birleşik görüntü haline getirilir (Yague-Martinez vd. 2016).

6. SNAP ile üretilen tüm interferogram, tutarlılık ve metadata ürünleri, Snap2StaMPS aracı ile organize edilir ve StaMPS yazılımının tanıyacağı klasör yapısında dışa aktarılır. Bu işlemde .mat ve .rsc uzantılı dosyalar, PS seçimi ve zaman serisi analizinin yapılacağı StaMPS dizinine aktarılır. Ayrıca interferogram ağ yapısı (.base) ve görüntü tarih bilgisi (.dates) dosyaları oluşturularak StaMPS iş akışı için gerekli yapı tamamlanmış olur (Hooper, 2008).

Bu işlemler sonucunda, her bir ana-ikincil çifti için üretilmiş interferogramlar ve yardımcı ürünler, StaMPS yazılımına aktarılmak üzere hazır hale getirilmiştir. Bu yapı ile PS noktalarının seçimi, zaman serilerinin oluşturulması ve hareket analizlerinin yürütülmesi için temel veri setini oluşturmuş olur. Bu araçların entegre kullanımı, Sentinel-1 verileriyle PSI analizi yapmak için literatürde kabul görmüş bir yaklaşımdır (Veci vd. 2018).

3.3.2 StaMPS ile PS Analizi

PS-InSAR analizinin bu aşamasında, SNAP2StaMPS aracı ile ön işlemleri tamamlanmış olan Sentinel-1A interferogramları ve ilgili veriler, StaMPS (Stanford Method for Persistent Scatterers) yazılımı kullanılarak işlenmiştir. StaMPS, özellikle zaman içindeki faz kararlılığına odaklanarak Kalıcı Yansıtıcı (PS) noktalarını belirleyen ve bu noktalar üzerinden milimetre hassasiyetinde yer kabuğu hareketi zaman serileri üreten gelişmiş bir algoritmadır. Bu çalışmada, Bolvadin bölgesi için 2015-2024 yılları arasındaki SAR görüntüleri kullanılarak StaMPS'in temel 8 adımı uygulanmıştır.

1. StaMPS iş akışının ilk adımı, SNAP2StaMPS ile ön işlenmiş diferansiyel interferogramlar, eşleniklenmiş SLC yığını ve ilgili meta verilerin MATLAB ortamına yüklenmesidir. Bu aşamada, başlangıç PS adayları genellikle genlik dağılım indeksi (amplitude dispersion index) gibi bir eşik değeri kullanılarak, özellikle kentsel ve kırsal alanların bir arada bulunduğu Bolvadin gibi karmaşık bölgelerde faz kararlılığı potansiyeli taşıyan mümkün olduğunca çok sayıda

pikseli içerecek şekilde seçilir. StaMPS, bu aday pikseller için gerekli tüm verileri .mat formatında kaydeder.

2. İkinci adımda, her bir PS aday pikselindeki faz değişkenliği (gürültüsü) nicel olarak değerlendirilir. StaMPS, her aday pikselin tüm interferogramlardaki sarılmış (wrapped) faz değerlerini kullanarak, o pikselin fazının zaman içindeki kararlılığını ifade eden bir zamansal koherans değeri tahmin eder. Bu süreç, atmosferik gecikme, yörünge hataları gibi mekansal olarak korelasyonlu faz bileşenlerinin ve topoğrafik SYM hatasından kaynaklanan artık fazın modellenip çıkarıldığı iteratif bir çözümleme ile gerçekleştirilir. Bu süreç, özellikle büyük veri yığınlarında hesaplama açısından zorlayıcı olabildiğinden, literatürde bu adımı optimize etmeye yönelik verimli faz kestirim algoritmaları da sunulmuştur (Ansari vd. 2020).
3. Bir önceki adımda hesaplanan zamansal koherans değerleri kullanılarak, başlangıçtaki aday piksel havuzundan istatistiksel olarak anlamlı faz kararlılığı gösteren noktalar PS olarak seçilir. StaMPS, bu seçimi kullanıcı tarafından belirlenen bir oranla (örneğin, km² başına kabul edilebilir hatalı PS sayısı) dikkate alan yoğunluk tabanlı bir yöntemle yapar. Bu aşamada, özellikle güvenilir PS noktalarının elde edilmesi hedeflenir.
4. Bu adım, Adım 3'te seçilen PS listesinin daha da iyileştirilmesi ve güvenilirliği düşük olan aykırı noktaların ayıklanması işlemidir. Ayıklama işlemi temel olarak iki kriter dayanır: komşu PS pikselleri arasındaki faz yakınlığı ve her bir PS noktasına ait faz zaman serisinin pürüzsüzlüğü (smoothness). Faz zaman serisi aşırı düzensiz ve gürültülü olan PS noktaları, komşularıyla olan faz farklarının standart sapması gibi ölçütler kullanılarak elenir.
5. Ayıklama işleminden sonra kalan yüksek güvenilirlikteki PS noktalarının fazlarından, her birine özgü ve Adım 2'de tahmin edilmiş olan artık topoğrafik SYM hata bileşeni çıkarılır. Bu düzeltme, özellikle SRTM DEM gibi genel amaçlı yükseklik modellerinin kullanıldığı durumlarda, analiz edilen

deformasyon sinyalinin saflığını artırır. Eğer çalışma alanı çok genişse ve parçalar (patches) halinde işlendiyse, bu adımda yama birleştirme işlemi de yapılabilir; ancak Bolvadin çalışmasında tek bir parça kullanılmıştır.

6. InSAR analizinin en kritik adımlarından biri olan faz açılımı (phase unwrapping), sarılmış faz değerlerindeki 2π sınırlılığını ortadan kaldırarak gerçek, mutlak faz değişimlerini elde etmeyi amaçlar. StaMPS, bu işlemi tüm PS noktaları ve tüm interferogramlar için eş zamanlı olarak, genellikle SNAPHU gibi algoritmalara dayanan bir üç boyutlu ağ akışı yöntemiyle çözer. Bu, her interferogramı ayrı ayrı açmaktan daha sağlam sonuçlar verir. Faz açılımı öncesinde, gürültüyü azaltmak için bir ön filtreleme (Goldstein filtresi) uygulanabilir (Goldstein ve Werner, 1998).
7. Bu adımda, faz açılımı yapılmış veriler üzerinden iki önemli sistematik hata kaynağı daha modellenir ve giderilir: Mekansal ilintili bakış açısı hatası (Spatially-Correlated Look Angle error - SCLA), ki bu genellikle SYM'deki bölgesel sistematik hatalar veya radar koordinat dönüşümündeki kalibrasyon hatalarıyla ilişkilidir ve perpendiküler baza bağlı bir faz rampası olarak ortaya çıkar. Master Atmosfer ve Yörünge Hatası (AOE), yani referans (ana) görüntünün alındığı andaki spesifik atmosferik faz gecikmesi ve yörünge model hatasının birleşik etkisi. Bu hataların giderilmesi, deformasyon sinyalinin daha doğru elde edilmesini sağlar.
8. StaMPS iş akışının son ana adımı, atmosferik faz bileşenlerinin (Atmospheric Phase Screen - APS) filtrelenerek nihai deformasyon sinyalinin izole edilmesidir. Atmosferik gecikmeler, genellikle uzayda geniş ölçekli ve yüksek korelasyonlu, zamanda ise düşük korelasyonlu bir davranış sergiler. StaMPS, bu özellikleri dikkate alarak, genellikle zamanda yüksek geçiren (high-pass) ve uzayda düşük geçiren (low-pass) bir filtre kombinasyonu (scn_time_win ve scn_wavelength parametreleriyle kontrol edilir) kullanarak atmosferik etkileri deformasyon sinyalinden ayırır. Bu işlem sonucunda, her bir PS noktası için

atmosferik gürültüden arındırılmış, LOS (Line-Of-Sight) yönündeki nihai deformasyon zaman serileri (mm/yıl cinsinden ortalama hız ve her görüntü tarihi için mm cinsinden yer değiştirme) elde edilir.

Bu 8 adımlık sistematik süreç sonunda, 5656 adet PS noktası oluşturularak, Bolvadin bölgesindeki yüzey hareketlerini yansıtan güvenilir yerkabuğu hareketlerinin zaman serileri üretilmiş olup, bu seriler tezin bir sonraki aşamasında derin öğrenme modelleri ile analiz edilerek geleceğe yönelik tahminler için kullanılmıştır.

3.4 Derin Öğrenme ile Tahmin Yöntemi

Bu çalışmanın ikinci temel hedefi, PS-InSAR tekniği ile elde edilen yerkabuğu hareketi zaman serilerinin geleceğe yönelik olarak tahmin edilmesi ve bu sayede bölgedeki zemin hareketlerinin dinamik yapısının anlaşılmasına katkı sağlanmasıdır. Sentinel-1A uydusuna ait 10 yıllık (2015–2024) zaman serileri üzerinden çıkarılan her bir PS noktasına ait hareket profili, hem lineer hem de lineer olmayan örüntüler sergilemekte; dönemsel su kullanımı, mevsimsel değişimler, antropojenik etkiler ve topografik koşullara bağlı olarak farklılaşabilmektedir. Bu tür örüntülerin doğru modellenmesi için klasik istatistiksel ve makine öğrenmesi yöntemlerinin ötesinde, yüksek düzeyde temsil yeteneğine sahip modellerin kullanılması gereklidir (Hewamalage vd. 2021).

Bu bağlamda tez kapsamında, yerkabuğu hareketi zaman serilerinin geleceğe yönelik tahmininde çeşitli derin öğrenme temelli modeller tercih edilmiştir. Derin öğrenme, çok katmanlı yapay sinir ağı mimarileriyle çalışarak veriden otomatik olarak örüntü öğrenebilen, doğrusal olmayan ilişkileri modelleyebilen ve özellikle uzun süreli bağımlılıkları öğrenme yeteneğine sahip algoritmalarla oluşur (Goodfellow vd. 2016). Kullanılan modeller, zaman içinde birbirini etkileyen ardışık değerleri öğrenme kapasitesine sahip olduğu için, hareket tahmini açısından ideal bir çözüm sunar (Hochreiter ve Schmidhuber, 1997; Zhang vd. 2019).

Bu bölümde, önce model seçiminde izlenen bilimsel gerekçeler ortaya konacak, ardından yerkabuğu hareketi zaman serilerinin veri hazırlama süreçleri

detaylandırılacaktır. Devamında model mimarisi, eğitim-test bölünmesi, doğrulama teknikleri ve başarı kriterleri açıklanacaktır. Değerlendirme süreci, doğrusal doğruluk ölçütleri (RMSE, MAE, R^2 gibi) yanında modelin tahmin kapasitesini zamansal düzlemde irdeleyen görsel analizlerle de desteklenecektir.

Dolayısıyla bu bölüm, yalnızca bir derin öğrenme uygulaması değil, aynı zamanda PS-InSAR zaman serilerinin geleceğe dönük öngörüsüne yönelik olarak yapılandırılmış veri bilimi sürecinin tüm adımlarını kapsamaktadır. Amaç, doğruluğu yüksek, açıklanabilir, tekrar üretilebilir bir tahmin modeli geliştirmektir.

3.4.1 Model Seçimi ve Kuramsal Temel

Zaman serilerinin modellenmesi ve geleceğe yönelik öngörülmesi, çeşitli istatistiksel ve makine öğrenimi yöntemleriyle gerçekleştirilebilmekle birlikte, özellikle doğrusal olmayan, yüksek frekanslı bileşenler içeren, uzun vadeli bağımlılıklar barındıran karmaşık verilerde bu yöntemlerin performansı sınırlı kalmaktadır. PS-InSAR tabanlı yerkabuğu hareketi zaman serileri, doğaları gereği mevsimsel değişkenlikler, hidrojeolojik etmenlere bağlı ani sıçramalar ve kümülatif doğrusal eğilimler barındıran bir yapıya sahiptir (Galloway ve Burbey, 2011; Hanssen, 2001). Bu tür karmaşık yapıların modellenmesinde klasik regresyon ya da istatistiksel öngörü modellerinin yeterli olmaması, zaman içinde derin öğrenme tabanlı mimarilerin öne çıkmasına yol açmıştır.

Zaman serilerinin modellenmesi ve geleceğe yönelik öngörülmesi amacıyla geliştirilen derin öğrenme mimarileri, özellikle doğrusal olmayan, dinamik yapıya sahip ve mevsimsel bileşenler içeren karmaşık veriler üzerinde geleneksel yöntemlere kıyasla daha başarılı sonuçlar sunmaktadır (Hewamalage vd. 2021). PS-InSAR yöntemiyle elde edilen yerkabuğu hareketi zaman serileri de bu kapsama giren, hem kümülatif doğrusal eğilimler hem de ani sıçramalar veya yavaşlamalar gibi doğrusal olmayan bileşenler içeren çok boyutlu veri setleridir. Bu nedenle, klasik istatistiksel modelleme ya da yüzeysel regresyon yaklaşımları bu tür verilerde sınırlı başarı sağlayabilmektedir.

Bu çalışmada, PS-InSAR verileriyle oluşturulan zaman serilerini kullanarak hareketin

geleceğe yönelik tahmin edilmesi amacıyla LSTM (Long Short-Term Memory), GRU (Gated Recurrent Unit), TCN (Temporal Convolutional Network), CNN (Convolutional neural network) ve Transformer gibi modern ve derin yapay sinir ağı mimarileri kullanılmıştır. Her biri, zaman serisi tahmini açısından kendi güçlü yönleriyle değerlendirilmiş ve performansları karşılaştırmalı olarak analiz edilmiştir.

Geleneksel zaman serisi modelleri olan ARIMA ve FFT bazı küçük ölçekli pilot çalışmalar için önerilmekte ve uygulanmaktadır. Ancak bu yöntemlerin her bir PS noktası için ayrı ayrı uygulanması, hem işlem süresi hem de modelleme bütünlüğü açısından mümkün olmamaktadır. Bu nedenle çalışmamızda tüm PS noktalarının birlikte modellenebileceği daha uygun derin öğrenme tabanlı yapılar tercih edilmiştir.

Bu çalışmada sadece belirli PS noktaları üzerinden yapılan tahminler yerine, Bolvadin ilçesindeki tüm noktaların zaman serileri işlenmiş, yüksek hacimli bir veri üzerinde modern derin öğrenme algoritmaları ile kapsamlı projeksiyonlar gerçekleştirilmiştir. Tahminlerin doğruluğu başarı metrikleri ile değerlendirilerek, modelin varyans açıklama gücü daha net şekilde ortaya konmuştur.

LSTM, zaman serilerindeki uzun vadeli bağımlılıkları öğrenebilmek için geliştirilmiş özel bir tekrarlayan sinir ağı (RNN) mimarisidir. Geleneksel RNN'lerin uzun ardışık dizilerde karşılaştığı bilgi kaybı ve gradyan sönümlenmesi gibi problemlerin üstesinden gelmek amacıyla Hochreiter ve Schmidhuber (1997) tarafından geliştirilmiştir. LSTM, hücre içinde yer alan unutma (forget), giriş (input) ve çıkış (output) kapıları sayesinde, belirli bilginin hangi zaman adımlarında ne kadar süre ile tutulacağına karar verebilmektedir. Bu özellik sayesinde zemin çökmeleri gibi uzun vadeli ve birikimli süreçlerin modellenmesinde etkili bir performans sunar. LSTM modeli mimarilerden biri olarak ele alınmış, hareketin hızla değiştiği dönemlerde bile görelilik olarak kararlı tahmin eğrileri üretmiştir.

GRU, LSTM'ye alternatif olarak geliştirilen daha sade ve daha az parametre içeren bir RNN çeşididir (Cho vd. 2014). GRU hücresinde unutma ve giriş kapıları birleşik bir güncelleme kapısı ile temsil edilirken, sıfırlama kapısı ile geçmiş bilginin ne kadarının

dikkate alınacağı kontrol edilir. Bu yapı sayesinde daha düşük hesaplama maliyeti ile öğrenme gerçekleştirebilir. Özellikle daha kısa zaman serileriyle çalışıldığında ya da yüksek hesaplama verimliliği istendiğinde tercih edilir. GRU, LSTM'ye alternatif bir model olarak değerlendirilmiş ve belirli PS noktalarında daha hızlı eğitilmesiyle avantaj sağlamıştır. Genel eğilimleri LSTM ile benzerlik göstermiştir.

TCN, zaman serisi verisinde doğrusal olmayan örüntüleri yakalamak için evrimsel ağlara dayalı olarak geliştirilmiş bir modeldir. RNN mimarilerinden farklı olarak ardışık veri ile değil, paralel veri işleme yapısı ile çalışır. TCN mimarileri, causal (nedensel) padding ve dilated convolution teknikleri sayesinde geçmiş bilginin kaybolmadan işlenmesini sağlar (Bai vd. 2018). TCN modeli, paralel işleme avantajı sayesinde eğitim süresi diğer modellere göre daha kısa olmuştur. Uzun zaman serilerinde, LSTM'ye göre daha yüksek hesaplama verimliliği elde edilmiştir.

Evrimsel Sinir Ağları (CNN), başlangıçta görüntü işleme alanındaki başarılarıyla tanınsa da, zaman serisi verilerindeki yerel örüntüleri ve özellikleri çıkarma konusundaki yetenekleri sayesinde zaman serisi tahmini ve sınıflandırması problemlerinde de etkin bir şekilde kullanılmaya başlanmıştır (LeCun vd., 1998; Kiranyaz vd., 2021). Özellikle tek boyutlu (1D) CNN'ler, sıralı verilerdeki alt dizileri (segmentleri) analiz ederek önemli özellikleri otomatik olarak öğrenme kapasitesine sahiptir. CNN mimarisi, özellikle zaman serisindeki belirli tekrarlayan motiflerin veya şekillerin tahmin için önemli olduğu durumlarda etkili olabilmektedir. RNN tabanlı modellere kıyasla paralel işleme yeteneği sayesinde daha hızlı eğitilebilme potansiyeline sahiptir.

Transformer modeli, doğal dil işleme alanında devrim yarattıktan sonra zaman serisi tahmininde de başarıyla uygulanmaya başlamıştır. Bu model, ardışık veri işlemek yerine self-attention mekanizması kullanarak tüm zaman adımlarını aynı anda analiz edebilir (Vaswani vd. 2017). Böylece, uzun dönemli bağımlılıkları modelin dikkat mekanizmasıyla öğrenmesi mümkün olur. Transformer modeli, diğer modellere kıyasla daha hatalı çıkışlar üretmiş, bazı bölgelerde hareket tahmini konusunda R^2 değeri

açısından en başarısız model olmuştur. Bununla birlikte, modelin eğitimi daha fazla veri ve belleğe ihtiyaç duymaktadır.

Bu tez çalışmasında kullanılan derin öğrenme modellerinin seçimi yalnızca tek bir performans ölçütüne dayanmamış, çok yönlü bir değerlendirme yaklaşımı benimsenmiştir. Seçilen LSTM, CNN, GRU, TCN, Transformer modellerinin her biri, zaman serisi tahmini bağlamında literatürde güçlü temsil kabiliyeti göstermiş, farklı yapısal avantajlar sunan mimarilerdir. Model seçim sürecinde dikkate alınan temel gerekçeler aşağıda detaylandırılmıştır.

Bu bütüncül değerlendirme neticesinde, her bir model aynı veri kümesi ve zaman dilimleri üzerinde eğitilmiş ve test edilmiştir. Bu sayede hangi modelin daha iyi tahmin yaptığı ve bu çalışma bazında zaman serileri için hangi modelin daha uygun olduğu da belirlenmeye çalışılmıştır. İlgili karşılaştırmalar ve istatistiksel sonuçlar 4. bölümde detaylı olarak sunulacaktır. Bu süreç, PS-InSAR tabanlı yerkabuğu hareketi zaman serilerinin ileri düzey analizi için derin öğrenme yöntemlerinin potansiyelini çok boyutlu olarak ortaya koymaktadır. Sonuçların karşılaştırılması 5. bölümde ayrıntılı olarak sunulacaktır.

Bu çalışmada hibrit modelleme yapılmamıştır. Örneğin CNN-LSTM veya GRU-TCN gibi birleşik katman yapıları kullanılmamış, her model saf haliyle uygulanmıştır. Bu tercih, modeller arası kıyaslamanın objektif şekilde yapılabilmesini sağlamıştır.

3.4.2 Girdi Verilerinin Hazırlanması

Derin öğrenme modellerinin zaman serisi tahmini problemlerinde başarılı olabilmesi, büyük ölçüde girdi verilerinin doğru ve uygun bir şekilde hazırlanmasına bağlıdır. Bu alt bölümde, üretilen PS-InSAR yerkabuğu hareketi zaman serilerinin, derin öğrenme modelleri (LSTM, GRU, TCN, CNN ve Transformer) için nasıl hazırlandığı adım adım açıklanmaktadır. Veri hazırlama süreci, ham zaman serilerinin temizlenmesi, normalleştirilmesi ve denetimli öğrenme problemine uygun bir formata dönüştürülmesini kapsamaktadır.

3.4.2.1 Ham Veri ve Zaman Serisi Yapısı

Bu çalışmada kullanılan temel girdiler, her bir Kalıcı Yansıtıcı (PS) noktası için SNAP-StaMPS iş akışı sonucunda elde edilen ve yıllık ortalama LOS (Line-Of-Sight) hareket hızı zaman serileridir. Her bir PS noktası için, 2015-2024 yıllarını kapsayan 10 adet yıllık çökme hız değeri mevcuttur. Derin öğrenme modelleri, bu zaman serilerindeki zamansal bağımlılıkları ve örüntüleri öğrenerek gelecekteki çökme hızlarını tahmin etmek üzere eğitilmiştir. Her bir PS noktasına ait zaman serisi, diğerlerinden bağımsız birer örnek olarak ele alınmıştır.

3.4.2.2 Veri Normalizasyonu

Derin öğrenme modelleri, özellikle farklı ölçeklerdeki girdi özelliklerine sahip olduğunda veya aktivasyon fonksiyonlarının doygunluğa ulaşmasını engellemek için genellikle veri normalizasyonundan fayda görür (Goodfellow vd., 2016). Normalizasyon, eğitim sürecinin kararlılığını artırabilir ve modelin daha hızlı yakınsamasına yardımcı olabilir.

Bu çalışmada, her bir PS noktasına ait bireysel zaman serisi (yani 1. yıldan 10.yıl'a kadar olan 10 yıllık veri), derin öğrenme modellerine girdi olarak verilmeden önce Min-Max Ölçekleyici (MinMaxScaler) kullanılarak normleştirilmiştir. Bu ölçekleyici, veriyi genellikle 0 ile 1 arasına veya -1 ile 1 arasına dönüştürür. Bu tez kapsamında, değerler aşağıdaki formül kullanılarak 0 ile 1 aralığına ölçeklenmiştir:

$$X_{\text{norm}} = (X - X_{\text{min}}) / (X_{\text{max}} - X_{\text{min}})$$

Burada X, orijinal hareket hızı değerini; X_{min} ve X_{max} ise ilgili PS noktasına ait zaman serisindeki minimum ve maksimum hareketinin hız değerlerini; X_{norm} ise normleştirilmiş değeri ifade eder.

Önemli bir nokta, veri sızıntısını (data leakage) önlemek için ölçekleyicinin yalnızca eğitim verisi üzerinde fit edilmesi ve ardından hem eğitim hem de test-validasyon verilerine bu fit edilmiş ölçekleyici ile transform işlemi uygulanmasıdır (Brownlee,

2018). Bu sayede model, test aşamasında karşılaşacağı veriler hakkında önceden bilgi sahibi olmamış olur. Tahminler yapıldıktan sonra, sonuçların orijinal milimetre/yıl birimine geri dönüştürülmesi için ters normalizasyon (inverse transform) işlemi uygulanmıştır.

3.4.2.3. Denetimli Öğrenme Problemi için Zaman Serisi Dönüşümü

Zaman serisi tahmini, denetimli bir öğrenme problemine dönüştürülerek modellenenir. Bu dönüşüm, geçmiş zaman adımlarından oluşan bir diziyi (girdi penceresi veya look-back window) kullanarak gelecekteki bir veya daha fazla zaman adımını (tahmin penceresi) öngörmeyi içerir (Hewamalage vd., 2021).

Bu çalışmanın ilk aşamasında, 10 yıllık hız değerinin tahmini için aşağıdaki pencereleme yapısı kullanılmıştır:

- Girdi Penceresi (Look-back window): Her bir PS noktası için geçmiş 9 yıllık hız değerleri (1 yıllık hareket ile 9 yıllık hareket). Bu, $k=9$ zaman adımını ifade eder.
- Hedef Değer (Prediction window): Girdi penceresini takip eden bir sonraki zaman adımındaki hız değeri. Bu, $H=1$ adımlık bir tahmindir.

Bu yaklaşımla, her bir PS noktasının 10 yıllık zaman serisinden,

$$([y_1, y_2, y_3, y_4, y_5, y_6, y_7, y_8, y_9] \rightarrow y_{10})$$

şeklinde tek bir girdi-çıkı çifti oluşturulmuştur.

3.4.2.4 Girdi Verilerinin Derin Öğrenme Modelleri İçin Yeniden Şekillendirilmesi

Derin öğrenme modelleri (özellikle LSTM, GRU, TCN, CNN gibi dizisel veya evrimsel katmanlar içerenler), girdileri belirli bir formatta bekler. Genellikle bu format örnekleme sayısı, zaman adımı sayısı, özellik sayısı şeklindedir. Bu çalışmada, her bir PS noktası tek bir örnekleme, girdi penceresi (9 yıllık veri) zaman adımlarını ve her

zaman adımındaki hareket hızı da tek bir özelliği temsil etmektedir. Dolayısıyla, her bir PS noktası için hazırlanan 9 adımlık girdi dizisi, (1,9,1) boyutunda bir tensöre dönüştürülmüştür. Tüm PS noktaları için bu işlem tekrarlandığında, modelin toplu eğitim (batch training) için alacağı toplam girdi verisi [PS_nokta_sayısı, 9, 1] boyutunda olmuştur. Bu yeniden şekillendirme, Keras gibi derin öğrenme kütüphanelerinin beklentileriyle uyumludur (Chollet, 2017).

3.4.2.5 RMF Veri Hazırlığı

Bölüm 3.4.3’de detaylandırılan Yinelemeli Çok Adımlı Tahmin (RMF) stratejisi için de benzer veri hazırlama prensipleri geçerlidir. 11 yıllık hareket tahmini için, temel modelin eğitildiği aynı normalizasyon ve pencereleme mantığı kullanılarak 2 yıllık hareketten, 10 yıllık harekete kadar olan seriler girdi olarak hazırlanır. Benzer şekilde, 12 yıllık hareket tahmini için de girdi penceresi, önceki adımların tahminlerini içerecek şekilde güncellenir. Bu iteratif süreç, RMF bölümünde açıklanan matematiksel formülasyona uygun olarak yürütülür.

Bu veri hazırlama adımları, ham PS-InSAR zaman serilerinin, çalışmada kullanılan çeşitli derin öğrenme mimarileri tarafından etkin bir şekilde işlenebilmesi ve geleceğe yönelik hareket tahminlerinin güvenilir bir şekilde yapılabilmesi için kritik öneme sahiptir. Hazırlanan bu yapılandırılmış veriler, ileride açıklanacak olan eğitim, doğrulama ve test setlerine ayrılarak model geliştirme sürecine dahil edilmiştir.

3.4.3 Model Mimarisi ve Eğitim Aşamaları

Derin öğrenme modellerinin başarısı yalnızca veri kalitesine değil, aynı zamanda modelin yapısına (mimarisi) ve nasıl eğitildiğine de doğrudan bağlıdır. Örneğin zaman serilerinin tahmininde yaygın olarak kullanılan LSTM mimarisi, belleğe dayalı hücre yapısı ile geçmiş verilerden öğrenilen bilgiye dayanarak geleceği tahmin edebilme yeteneğine sahiptir (Hochreiter ve Schmidhuber, 1997). Bu bağlamda, bu tez kapsamında kullanılan bu ve diğer modellerin tasarımı, yalnızca teorik gerekçelerle değil; aynı zamanda veri setinin yapısı, boyutu, örüntü karmaşıklığı ve modelin


genelleme kapasitesi göz önünde bulundurularak yapılandırılmıştır.

Bu bölümde, derin öğrenme tahmin sürecinde kullanılan derin öğrenme modellerinin katman yapısı, aktivasyon fonksiyonları, optimizasyon süreci, hiperparametre ayarları, eğitim stratejisi ve düzenleme (regularization) teknikleri ayrıntılı olarak sunulmaktadır.

3.4.3.1 Yinelemeli Çok Adımlı Tahmin (RMF) Stratejisi

Zaman serisi tahmin problemlerinde temel amaç genellikle tek bir gelecek zaman adımını öngörmek olsa da, birçok pratik uygulamada birden fazla adımdan oluşan bir tahmin ufku (forecasting horizon) gereklidir. Bu çalışmada, PS-InSAR yer kabuğu hareketleri zaman serilerinin gelecekteki birden fazla zaman adımına yönelik eğilimlerini tahmin etmek amacıyla Yinelemeli Çok Adımlı Tahmin (Recursive Multi-step Forecasting - RMF) stratejisi benimsenmiştir. RMF, literatürde "özyinelemeli" veya "iteratif" tahmin olarak da adlandırılmaktadır (Taieb vd. 2010, Taieb vd. 2012, Girardone vd. 2023).

Aşağıdaki Şekil RMF yaklaşımının adım adım nasıl işlediğini göstermektedir:



Şekil 3.3 Serinin son 4 verisini tahmin edici olarak kullanarak geleceğe yönelik 3 adımı tahmin eden RMF diyagramı (İnt.Kyn.2).

RMF stratejisinin temel mantığı, tek adımlı bir tahmin modelini ardışık olarak kullanarak çok adımlı tahminler üretmektir. Model, geçmiş ve mevcut zaman adımlarına (örneğin $T-4$, $T-3$, $T-2$, $T-1$) dayanarak bir sonraki zamanı ($T+1$) tahmin eder. Bu tahmin daha sonra yeni bir giriş olarak kullanılarak bir sonraki zaman adımı ($T+2$) için tahmin yapılır. Bu süreç, istenen tahmin ufkuna kadar devam ettirilir.

Şekilde:

- Mavi kutular: Gözlenen (gerçek) geçmiş değerleri temsil eder.
- Turuncu kutular: Model tarafından tahmin edilen gelecekteki değerlerdir.
- Kırmızı kesikli kutu: Her bir tahmin için kullanılan giriş değerlerini temsil eder.
- Beyin simgesi: Modelin her adımda aynı yapıda eğitildiğini ve tekrar kullanıldığını simgeler.

Adımlar:


1. $T+1$ Tahmini: Model, geçmişte gözlenen değerleri ($T-4$ ila $T-1$) giriş olarak kullanır ve $T+1$ değerini tahmin eder.
2. $T+2$ Tahmini: $T+1$ artık gözlemlenmiş bir veri değil, tahmin edilmiş bir değerdir. Bu tahmin, giriş vektörüne dahil edilerek $T+2$ tahmini yapılır.
3. $T+3$ Tahmini: Bu adıma kadar yapılan tahminlerin hepsi yeni giriş setine dahil edilir ve zincirleme bir şekilde $T+3$ tahmini yapılır.

Bu çalışmada kullanılan LSTM, GRU, TCN, CNN ve Transformer modelleri, öncelikle tek bir gelecek zaman adımını (10 yıllık hareket) tahmin etmek üzere eğitilmiş, ardından var olan 10 yıllık hareket verisiyle kıyaslanıp incelenmiş ve başarı metrikleri paylaşılmıştır. Ardından bu bölümde açıklanan RMF stratejisi kullanılarak 11 yıllık hareket ve 12 yıllık hareket gibi daha ileri zaman adımları için yinelemeli tahminler üretilmiştir.

3.4.3.2 Model Mimarileri ve Katman Yapısı

Bu bölümde, LSTM, GRU, CNN, TCN ve Transformer modellerinin zaman serisi tahmini için uygulanan mimari yapıları, eğitim süreçleri ve hiperparametre ayarlamaları ayrıntılı şekilde sunulmuştur. Tüm modeller Python ortamında, Keras ve TensorFlow

kütüphaneleri ile eğitilmiş, her biri için benzer eğitim stratejileri ve yapılandırmalar uygulanmıştır. Eğitim süreci boyunca erken durdurma (early stopping), dropout ve batch optimizasyon gibi yaygın düzenleme teknikleri de model performansını artırmak için kullanılmıştır.



Şekil 3.4 Modellerin kavramsal mimarisi ve modüler yapısı.

1. LSTM Mimarisi: Katman Yapısı

PS-InSAR verilerinden elde edilen zaman serisi halindeki yıllık hız değişimlerini modellemek ve gelecekteki hızları tahmin etmek amacıyla LSTM ağı kullanılmıştır. Model, Keras kütüphanesi ile oluşturulmuş olup aşağıdaki katman yapısına sahiptir:

a) Girdi Katmanı:

- Model, her bir PS noktası için geçmiş 9 yıllık hız verisini girdi olarak alır.
- Bu girdi, (9, 1) boyutunda bir tensöre dönüştürülür; burada 9 zaman adımını (timesteps), 1 ise her bir zaman adımındaki özellik sayısını (hız) temsil eder.

b) LSTM Katmanı:

- Girdi katmanını takiben, 128 hücreye (unit) sahip tek yönlü bir LSTM katmanı gelir.
- Bu katman, zaman serisindeki sıralı bilgiyi ve uzun vadeli bağımlılıkları öğrenmekten sorumludur.

c) Dropout Katmanı:

- LSTM katmanının hemen ardından, aşırı öğrenmeyi (overfitting) azaltmak amacıyla bir Dropout katmanı eklenmiştir (Srivastava vd. 2014).
- Bu katman, eğitim sırasında rastgele olarak LSTM katmanından gelen bağlantıların %30'unu geçici olarak devre dışı bırakır (rate=0.3).

d) Ara Yoğun (Dense) Katman:

- Dropout katmanından sonra, 64 üniteye sahip ve ReLU (Rectified Linear Unit) aktivasyon fonksiyonunu kullanan tam bağlı bir yoğun katman (Dense layer) bulunur.
- Bu katman, LSTM tarafından çıkarılan özelliklerden daha üst düzey ve doğrusal olmayan kombinasyonlar öğrenmeye yardımcı olur.

e) Çıkış Yoğun (Dense) Katmanı:

- Modelin son katmanı, tek bir üniteye sahip yoğun bir katmandır.
- Bu katman, bir sonraki zaman adımına ait hız değerini tahmin eder.
- Regresyon problemi olduğu için bu katmanda varsayılan olarak lineer bir aktivasyon fonksiyonu kullanılır.

2. GRU Mimarisi: Katman Yapısı

Bu çalışmada, PS-InSAR verilerinden elde edilen zaman serisi yer değiştirme hızlarını modellemek ve gelecekteki hızları tahmin etmek amacıyla GRU tabanlı bir derin öğrenme modeli de geliştirilmiştir. Model, geçmiş hız verilerindeki zamansal bağımlılıkları öğrenerek bir sonraki zaman adımı için tahmin üretme yeteneğine sahiptir. Modelin mimarisi aşağıdaki katmanlardan oluşmaktadır:

a) Giriş Katmanı:

- Modele, her bir PS noktası için geçmiş 9 yıllık normalize edilmiş hız verileri sunulur.
- Bu girdi, (9, 1) boyutunda bir tensör olarak şekillendirilir, burada 9 zaman adımını ve 1 ise her bir zaman adımındaki özelliği (hız değeri) temsil eder.

b) GRU Katmanı:

- Modelin çekirdeğini oluşturan bu katman, 128 GRU hücresinden meydana gelir.
- GRU üniteleri, LSTM'e benzer şekilde kapı mekanizmalarını (reset gate ve update gate) kullanarak zaman serisindeki önemli bilgilerin akışını kontrol eder ve uzun vadeli bağımlılıkları daha verimli bir şekilde öğrenir. LSTM'e kıyasla daha az parametreye sahip olması, bazı durumlarda daha hızlı eğitim ve daha az aşırı öğrenme riski sunabilir.

c) Dropout Katmanı:

- GRU katmanının ardından, aşırı öğrenmeyi (overfitting) engellemek ve modelin genelleme yeteneğini artırmak amacıyla %30 (rate=0.3) oranında bir Dropout katmanı eklenmiştir.
- Bu katman, eğitim sırasında rastgele olarak bir önceki katmandan gelen bağlantıların bir kısmını devre dışı bırakır.

d) Ara Yoğun (Dense) Katman:

- Dropout katmanından sonra, 64 üniteye sahip ve ReLU (Rectified Linear Unit) aktivasyon fonksiyonunu kullanan tam bağlı bir (Dense) katman yer alır.

- Bu katman, GRU tarafından çıkarılan özelliklerden daha üst düzey ve doğrusal olmayan kombinasyonlar öğrenmeye yardımcı olur.
- e) Çıkış Yoğun (Dense) Katmanı:
- Modelin son katmanı, tek bir üniteye sahip tam bağlı bir (Dense) katmandır.
 - Bu katman, bir sonraki zaman adımına ait hız değerini tahmin eder.
 - Regresyon problemi çözüldüğü için bu katmanda varsayılan olarak lineer bir aktivasyon fonksiyonu kullanılır, bu da çıktının herhangi bir sürekli değer alabilmesini sağlar.

3. TCN Mimarisi: Katman Yapısı

Bu çalışmada, zaman serisi halindeki PS noktalarına ait yıllık hız verilerinden bir sonraki zaman adımındaki hızı tahmin etmek amacıyla bir TCN modeli de kullanılmıştır. TCN, özellikle sıralı verilerdeki uzun vadeli bağımlılıkları yakalamak için tasarlanmış, evrişimli sinir ağlarının (CNN) bir türüdür. Tekrarlayan sinir ağlarına (RNN) kıyasla paralel hesaplama avantajı sunar ve gradyan kaybolması/patlama sorunlarına karşı daha dirençlidir. Model, Keras Sequential API kullanılarak aşağıdaki katmanlarla oluşturulmuştur:

- a) Giriş Verisi:
- Model, her bir PS noktası için geçmiş 9 yıllık hız verisini girdi olarak alır. Bu girdi, (9, 1) boyutunda olup; 9 zaman adımını ve her adımda 1 özelliği (hız) temsil eder.
- b) TCN Katmanı: Modelin ana bileşeni olan bu katman, aşağıdaki parametrelerle yapılandırılmıştır:
- input_shape: (9, 1) (9 zaman adımı, 1 özellik).
 - Katmanda kullanılan evrişim filtrelerinin sayısı 128'dir. Bu filtreler, zaman serisindeki farklı örüntüleri öğrenir.

c) Dropout Katmanı:

- dropout_rate=0.3: Aşırı öğrenmeyi (overfitting) engellemek amacıyla TCN katmanı içinde %30 oranında dropout uygulanır.
- Bu katman, eğitim sırasında rastgele olarak bir önceki katmandan gelen bağlantıların bir kısmını devre dışı bırakır.

d) Dense Katman (Çıkış Katmanı)

- Dense(64, activation='relu'): TCN katmanından gelen özellikleri işlemek ve daha karmaşık ilişkiler öğrenmek için 64 üniteye sahip, ReLU aktivasyon fonksiyonlu tam bağlı bir ara katman kullanılır.

e) Dense Katman (Çıkış Katmanı)

- Dense(1): Bir sonraki zaman adımındaki hızı tahmin etmek için tek bir üniteye sahip, varsayılan olarak lineer aktivasyonlu bir çıkış katmanı kullanılır. Bu, regresyon problemi için uygundur.

4. Transformer Mimarisi: Katman Yapısı

Bu çalışmada, zaman serisi verilerindeki karmaşık zamansal bağımlılıkları yakalamak ve gelecek değerleri tahmin etmek amacıyla bir Transformer modeli mimarisi de kullanılmıştır. Model, "Attention is All You Need" (Vaswani vd., 2017) makalesinde sunulan orijinal Transformer yapısının temel prensiplerinden esinlenerek, özellikle tek değişkenli zaman serisi regresyon problemine uyarlanmıştır. Model, Keras Fonksiyonel API kullanılarak inşa edilmiş olup aşağıdaki ana bileşenlerden oluşmaktadır:

a) Giriş Katmanı (Input):

- Model, her bir PS noktası için geçmiş 9 yıllık hız verisini girdi olarak alır. Bu girdi, (9, 1) boyutunda olup; 9 zaman adımını ve her adımda 1 özelliği (hız) temsil eder.

b) Giriş Projeksiyonu:

- Modelin çekirdeğini oluşturan bu katman, giriş verisi ile 128 boyut hücrelerinden meydana gelir.

c) Konumsal Kodlama (PositionalEncoding):

- Transformer mimarisi, tekrarlayan (recurrent) veya evrişimli (convolutional) katmanlar içermediği için sekans içindeki elemanların pozisyon bilgisini doğal olarak alamaz. Bu eksikliği gidermek amacıyla, giriş sekansındaki her bir zaman adımının pozisyon bilgisini içeren sabit bir PositionalEncoding katmanı eklenir. Bu kodlama, modelin sekans içindeki sıralamayı öğrenmesine yardımcı olur.

d) Transformer Encoder Bloğu:

- Bu blok, Transformer mimarisinin temel yapı taşıdır ve iki ana alt bileşenden oluşur:
- Çok Başlı Dikkat Mekanizması (MultiHeadAttention): Bu mekanizma, modelin giriş sekansının farklı kısımlarına aynı anda odaklanmasını ve sekans içindeki her bir elemanın diğer tüm elemanlarla olan ilişkisini ağırlıklı olarak hesaplamasını sağlar ve kaç farklı dikkat temsili öğrenileceğini belirler.
- Konum Bazlı İleri Beslemeli Ağ (Position-wise Feed-Forward Network): Bu aşama, dikkat mekanizmasından gelen temsilleri daha da işlemeye yarar.
- Bu çalışmada bir adet Transformer encoder bloğu kullanılmıştır, ancak problem karmaşıklığına göre bu bloklar art arda eklenebilir.

e) Global Ortalama Havuzlama (GlobalAveragePooling1D):

- Transformer encoder bloğundan çıkan tensör, zaman adımı boyutu boyunca ortalaması alınarak sabit bir vektöre indirgenir. Bu, tüm zaman adımlarından elde edilen bilgiyi özetler.

f) Çıkış Katmanları (Dense):

- Aşırı öğrenmeyi engellemek amacıyla katman içinde %30 oranında dropout uygulanır. Ardından, 64 üniteli ve ReLU aktivasyonlu bir ara Dense katmanı gelir.
- Son olarak, tek bir üniteye sahip ve lineer aktivasyonlu bir katman, bir sonraki zaman adımı için hız değeri tahmin eder.

5. CNN Mimarisi: Katman Yapısı

Bu çalışmada, zaman serisi verilerinden 10 yıllık hareket değerini ve sonraki adımları (RMF ile 11 yıllık hareket, 12 yıllık hareket) tahmin etmek amacıyla bir CNN modeli kullanılmıştır.

Model, geçmiş 9 zaman adımına (timesteps=9) ait tek bir özellik (input_dim=1, yani hız değeri) içeren zaman serisi segmentlerini girdi olarak alır. Modelin mimarisi aşağıdaki katmanlardan oluşmaktadır:

- a) Giriş Katmanı:
 - Boyut: (9, 1) (9 zaman adımı, her adımda 1 özellik).
- b) Evrişim Katmanı (Conv1D):
 - Giriş zaman serisinden yerel örüntüleri veya özellikleri çıkarır.
 - Filtre Sayısı: 128
- c) Düzleştirme Katmanı (Flatten):
 - Evrişim katmanından gelen çok boyutlu özellik haritalarını, tam bağlı katmanlara (Dense) giriş olarak verilebilecek tek boyutlu bir vektöre dönüştürür.
- d) Seyreltme Katmanı (Dropout):
 - Aşırı öğrenmeyi (overfitting) engellemek için eğitim sırasında rastgele olarak nöronların %30'unun geçici olarak devre dışı bırakılır.
 - Oran: 0.3
- e) Birinci Tam Bağlı Katman (Dense):
 - Düzleştirilmiş özelliklerden daha üst düzey kombinasyonlar öğrenir.
- f) Çıkış Katmanı (Dense):
 - Regresyon görevini gerçekleştirerek bir sonraki zaman adımı için sürekli bir hız değeri tahmin edilir.
 - Ünite Sayısı: 1

Çizelge 3.1 Ortak hiperparametreler tablosu.

Model	LSTM	GRU	TCN	CNN	Transformer
Kayıp Fonksiyonu	MSE	MSE	MSE	MSE	MSE
Optimizasyon	Adam	Adam	Adam	Adam	Adam
Öğrenme Oranı	0.001	0.001	0.001	0.001	0.001
Max. Epoch Sayısı	100	100	100	100	100
Batch Size	32	32	32	32	32
EarlyStopping	15	15	15	15	15
Dropout Oranı	30%	30%	30%	30%	30%

Modeller, adam optimizasyon algoritması (Kingma ve Ba, 2015) ve kayıp fonksiyonu olarak Karesel Ortalama Hata kullanılarak derlenmiş ve Çizelge 3.1'de belirtilen ortak hiperparametreler ve EarlyStopping mekanizması ile eğitilmiştir. SBu mimari, tek adımlı tahminler üretmekte ve bu tahminler, RMF stratejisi kapsamında daha ileri zaman adımlarındaki hızları öngörmek için kullanılmıştır.

3.4.3.3. Modelin Uygulama Ortamı

Model, Python ortamında TensorFlow 2.8 kütüphanesi ve Keras API kullanılarak geliştirilmiştir. Eğitim, aşağıdaki sistemde gerçekleştirilmiştir:

- İşlemci: AMD Ryzen 5 7600X
- GPU: NVIDIA RTX 3060 12 GB
- RAM: 32 GB DDR5
- PSU: 650 W
- İşletim Sistemi: Ubuntu 22.04 LTS

Bu altyapı, hem GPU hızlandırması hem de yüksek RAM kapasitesi sayesinde modelin eğitiminde zaman etkinliği sağlamıştır.

3.4.3.4. Model Kaydı ve Tekrar Üretilirlik

Eğitilen model .keras formatında kayıt altına alınmış ve test aşamasında kullanılmak üzere saklanmıştır. Bu, yeniden eğitime gerek kalmaksızın yeni PS noktaları için doğrudan tahmin yapılabilmesini sağlamaktadır. Bu yaklaşım, tezdeki bilimsel bulguların tekrar üretilebilirliğini garanti altına almaktadır (Chollet, 2017).

3.4.4. Eğitim-Test Bölünmesi ve Validasyon

Zaman serisi tahmini amacıyla geliştirilen derin öğrenme modellerinde, eğitim sürecinin başarımı kadar modelin doğrulama (validasyon) performansı da büyük önem taşır. Zira modelin yalnızca öğrenme verisi üzerinde yüksek doğruluk göstermesi, genelleme kabiliyeti olduğunu göstermez. Aksine, doğrulama seti üzerindeki performansı düşük olan bir model, aşırı öğrenmiş (overfit) kabul edilir ve gerçek dünya verilerine uygulandığında güvenilir sonuçlar üretmez (Goodfellow vd. 2016).

Bu bağlamda, bu tez çalışmasında kullanılan derin öğrenme modelleri, zaman serisinin geçmiş kısmı ile eğitilip gelecekteki değerleri tahmin edecek şekilde yapılandırılmıştır. Bu nedenle eğitim ve test bölünmesi, klasik rastgele bölmeden farklı olarak zaman eksenini boyunca sıralı (causal) bir yapı izlemelidir (Hyndman ve Athanasopoulos, 2018). Ayrıca test süreci sırasında elde edilen performans metrikleri, modelin gelecekteki hareketleri ne ölçüde öngörebildiğini gösterecek kritik kriterlerdir.

Çalışmada kullanılan toplam 5656 adet PS noktası, derin öğrenme modellerinin geliştirilmesi ve test edilmesi amacıyla rastgele bir şekilde üç ayrı veri setine bölünmüştür. Veri setinin %64'ü (3620 adet PS noktası), modellerin temel örüntüleri öğrenmesi için eğitim seti olarak kullanılmıştır. Modelin her epoch sonrasında performansını izlemek, hiperparametre optimizasyonu yapmak ve aşırı öğrenmeyi (overfitting) engellemek amacıyla verinin %16'sı (905 adet PS noktası) doğrulama (validation) seti olarak ayrılmıştır. Son olarak, eğitilmiş modellerin daha önce hiç görmediği veriler üzerindeki genelleme yeteneğini ve nihai performansını nesnel olarak ölçmek için verinin %20'si (1131 adet PS noktası) test seti olarak kullanılmıştır. Tüm performans metrikleri (RMSE, MAE, R^2) bu test seti üzerinde elde edilen sonuçlara göre raporlanmıştır.

3.4.4.1 Eğitim–Test Bölünmesinin Zaman Temelli Yapısı

Zaman serisi verilerinde geçmişin geleceği etkilemesi ama geleceğin geçmişe etki etmemesi kuralı gereği, klasik “shuffle–split” yöntemleri burada uygulanamaz. Bu tezde kullanılan veri setlerinde her bir PS noktası için 120 zaman adımı (2015–2024) mevcuttur. Bunun ilk 108’si (9 yıl) eğitim, son 12’ü (1 yıl) ise test bölümü olarak ayrılmıştır.

Bu yapı, derin öğrenme yöntemlerinin geleceği öngörmek için yalnızca geçmiş veriye bakmasını garanti altına alır. Böylece modelin tahmin ettiği değerler, test kümesinde gerçek zamanlı öngörü simülasyonu yaratır (Bandara vd. 2021).

3.4.4.2. Doğrulama (Validation) Stratejisi

Modelin öğrenme sırasında optimize edilmesi için eğitim verisi içinden ayrıca doğrulama alt kümesi (validation set) ayrılmıştır. Bu alt küme, train kümesinin %20’si olacak şekilde seçilmiştir. Bu sayede:

- Modelin hiperparametreleri validation kümesi üzerinde değerlendirilmiş,
- early stopping uygulanarak aşırı öğrenme önlenmiş,
- Loss fonksiyonu yalnızca eğitim verisine göre değil, doğrulama performansına göre optimize edilmiştir.

3.4.4.3. Modelin Eğitildiği Veri ve Tahmin Yapısı

Kullanılan RMF yaklaşımında:

- Girdi penceresi: 9 zaman adımı
- Tahmin penceresi: 1 zaman adımı

olarak belirlenmiştir. Böylece her PS noktası için çok sayıda pencere oluşturulmuş ve model, bu örnekler üzerinden hem geçmiş örüntüleri öğrenmiş hem de gelecekteki eğilimleri tahmin etmeyi öğrenmiştir (Hewamalage vd. 2021).

3.4.4.4. Modelin Değerlendirme Süreci: Test Kümesi

Eğitim tamamlandıktan sonra model, daha önce hiç görmediği test kümesine uygulanmış ve önceden ayrılmış hareket tahminleri yapılmıştır. Elde edilen tahmin değerleri, gerçek hareket ölçümleriyle karşılaştırılmış ve hem mutlak hata değerleri (RMSE, MAE) hem de doğrusal uyum (R^2) metrikleri hesaplanmıştır.

Bu yapı, literatürde “walk-forward validation” ya da “one-shot test” olarak tanımlanmakta ve zaman serisi tahmini için önerilen en uygun değerlendirme yaklaşımı olarak kabul edilmektedir (Hyndman ve Athanasopoulos, 2018; Bergmeir ve Benítez, 2012).

3.4.4.5. Tekrarlanabilirlik ve Tahmin Senaryosu

Modelin tekrar üretilebilirliği için tüm eğitim-test ayrımları sabit random seed kullanılarak yapılmış ve kullanılan zaman dizileri, model kaydına entegre edilmiştir. Böylece tahminler aynı eğitim verisiyle tekrarlandığında aynı çıktıları üretmektedir.

Ayrıca model, her bir PS noktasının hızını sonraki yıllar boyunca ayrı ayrı tahmin üretmiş, böylece mekansal-zamansal öngörü haritaları oluşturulmuştur. Bu çıktıların zamana bağlı animasyonları, bölgesel hareket trendlerinin değişimini gözlemlemek açısından değerli bir kaynak oluşturmuştur.

3.4.5 Performans Kriterleri

Derin öğrenme temelli zaman serisi tahmin modellerinin başarımının nesnel şekilde değerlendirilebilmesi için çeşitli ölçütlerin kullanılması gerekmektedir. Bu ölçütler, modelin tahmin ettiği değerlerle gerçek ölçümler arasındaki farkı sayısal olarak ifade eder ve modelin doğruluğu, tutarlılığı ve genelleme yeteneği hakkında bilgi verir.

Bu tez kapsamında, farklı derin öğrenme modelleri ile yapılan denemeler sonucunda, RMSE değeri en düşük ve R^2 skorları incelenmiştir. Performans kıyaslaması yalnızca tek bir metrik üzerinden yapılmamış; birden çok metrik birlikte değerlendirilerek daha

objektif bir sonuç elde edilmiştir. Bu yaklaşım, literatürde çoklu metrik temelli model seçimi (multi-metric model selection) olarak adlandırılmaktadır (Chai ve Draxler, 2014).

Bu çalışmada, geliştirilen LSTM, GRU, CNN, TCN ve Transformer modelleri ile yapılan hareket tahminlerinin değerlendirilmesinde aşağıdaki temel performans kriterleri kullanılmıştır:

1. Ortalama Karesel Hata (Mean Squared Error – MSE):

MSE, tahmin edilen değerlerle gerçek değerler arasındaki farkın karesinin ortalamasını alır ve özellikle büyük hatalara daha fazla ağırlık verir. Matematiksel olarak:

$$MSE = (1/n) * \sum (y_i - \hat{y}_i)^2$$

şeklinde tanımlanır. Burada:

n: Toplam örnek sayısı (veri noktası sayısı)

y_i : Gerçek (gözlemlenen) değer

$\hat{y}_i$: Tahmin edilen değer (model çıktısı)

$(y_i - \hat{y}_i)^2$: Her bir örnekteki tahmin hatasının karesi

$\sum$: Tüm veri noktaları üzerinden toplam alma işlemi

$(1/n)$: Ortalama alma işlemi (toplam hata / veri sayısı)

MSE, regresyon problemlerinde sıklıkla kullanılan bir kayıp fonksiyonu olup modelin genel hata büyüklüğü hakkında bilgi verir (Goodfellow vd. 2016).

2. Karesel Ortalama Hata (Root Mean Squared Error – RMSE):

RMSE, MSE'nin karekökü alınarak hesaplanır ve tahmin hatalarının fiziksel birimle (örneğin mm) ifade edilmesini sağlar:

$$RMSE = \sqrt{MSE}$$

RMSE değeri, modelin yaptığı hatanın ortalama ne kadar olduğunu doğrudan milimetre cinsinden sunar. Bu özelliği nedeniyle, PS-InSAR yerkabuğu hareketleri tahmin çalışmalarında yaygın olarak kullanılmaktadır (Zhang vd. 2019; Lyu vd. 2021). RMSE'nin düşük olması, tahminlerin gerçek ölçümlere yakın olduğunu gösterir.

3. Ortalama Mutlak Hata (Mean Absolute Error – MAE):

MAE, tahmin hatalarının mutlak değerlerinin ortalamasıdır:

$$MAE = (1/n) * \sum |y_i - \hat{y}_i|$$

Burada:

n: Toplam örnek sayısı (veri noktası sayısı)

y_i : Gerçek (gözlemlenen) değer

$\hat{y}_i$: Tahmin edilen değer (model çıktısı)

$|y_i - \hat{y}_i|$: Her bir örnekteki tahmin hatasının mutlak değeri

$\sum$: Tüm veri noktaları üzerinden toplam alma işlemi

$(1/n)$: Ortalama alma işlemi (toplam hata / veri sayısı)

MAE, MSE ve RMSE'ye kıyasla büyük hatalara karşı daha az duyarlıdır ve bu nedenle özellikle outlier (aykırı) verilerin bulunduğu serilerde tercih edilen daha dengeli bir ölçüttür (Willmott ve Matsuura, 2005).

4. Determinasyon Katsayısı (R^2 Skoru):

R^2 skoru, modelin tahmin ettiği değişimin ne kadarının gerçek veri tarafından açıklandığını gösteren istatistiksel bir uyum ölçüsüdür:

$$R^2 = 1 - [\sum (y_i - \hat{y}_i)^2 / \sum (y_i - \bar{y})^2]$$

Burada:

y_i : Gerçek (gözlemlenen) değer

$\hat{y}_i$: Tahmin edilen değer (model çıktısı)

$\bar{y}$: Gerçek değerlerin ortalaması

$\sum(y_i - \hat{y}_i)^2$: Tahmin hatalarının kareleri toplamı

$\sum(y_i - \bar{y})^2$: Gerçek değerlerin ortalamadan sapmalarının kareleri toplamı

R^2 değeri 1'e yaklaştıkça modelin tahmin kapasitesi artar. $R^2 = 0$, modelin rastgele tahmin yaptığını; negatif R^2 ise modelin ortalama değer tahmininden bile daha kötü sonuç ürettiğini gösterir. Bu metrik, derin öğrenme modellerinin PS-InSAR hareket verileri üzerindeki uyumluluğunu göstermek için oldukça etkilidir (Sun vd. 2022).

5. Pearson Korelasyon Katsayısı (R):

Pearson korelasyon katsayısı, iki değişken arasındaki doğrusal ilişkiyi ölçer. Tahmin edilen değerlerin, gerçek değerlere ne kadar paralel değiştiğini gösterir.

$$R = \frac{\sum[(y_i - \bar{y})(\hat{y}_i - \bar{\hat{y}})]}{\sqrt{\sum(y_i - \bar{y})^2} * \sqrt{\sum(\hat{y}_i - \bar{\hat{y}})^2}}$$

Burada:

y_i : Gerçek (gözlemlenen) değer

$\hat{y}_i$: Tahmin edilen değer

$\bar{y}$: Gerçek değerlerin ortalaması

$\bar{\hat{y}}$: Tahmin edilen değerlerin ortalaması

$\sum[(y_i - \bar{y})(\hat{y}_i - \bar{\hat{y}})]$: Gerçek ve tahmin edilen değerlerin kovaryansı

$\sqrt{\sum(y_i - \bar{y})^2}$: Gerçek değerlerin standart sapması

$\sqrt{\sum(\hat{y}_i - \bar{\hat{y}})^2}$: Tahmin edilen değerlerin standart sapması

$R = 1$ ise mükemmel pozitif doğrusal ilişki, $R = -1$ ise mükemmel negatif doğrusal ilişki, $R = 0$ ise Doğrusal ilişki yok anlamına gelir.

6. Görsel ve Zaman Serisi Karşılaştırmaları

Sayısal metriklerin yanında, modelin tahmin performansını zamansal düzlemde değerlendirmek için:

- Gerçek ve tahmin edilen zaman serilerinin gösterimi,
- Hata eğrilerinin (residuals) analizi,
- Zamansal hata yoğunluğu haritaları
- 11. Ve 12. yıllardaki PS hızlarının coğrafi dağılımı

gibi görsel karşılaştırma yöntemleri de kullanılmıştır. Bu grafiksel karşılaştırmalar, modelin hangi dönemlerde sapma yaptığını ve hataların sistematik mi yoksa rastlantısal mı olduğunu anlamak açısından önemlidir (Bergmeir ve Benítez, 2012).

4. BULGULAR

4.1 PS-InSAR ile Elde Edilen Ortalama Hız Haritaları

Bu tez kapsamında, Bolvadin ilçesini kapsayan alan için Sentinel-1A uydu verilerine dayalı olarak 10 yıllık dönem boyunca (2015–2024) alçalan ve yükselen yörüngelere ait SAR görüntüleri kullanılarak PS-InSAR analizi gerçekleştirilmiştir. SNAP–StaMPS tabanlı iş akışıyla yürütülen bu analiz sonucunda 5656 PS noktalarının dağılımı, bölgedeki yapısal, topoğrafik ve arazi kullanım farklılıklarını da yansıtır niteliktedir. Özellikle kent merkezinin bulunduğu alanlarda yapılaşma ve sert yüzeyler nedeniyle PS yoğunluğu artarken, tarım arazilerinde ve çıplak toprak alanlarında bu yoğunluk azalmıştır.

StaMPS yazılımında kullanılan `ps_plot` komutu yardımıyla oluşturulan ortalama hız haritaları üzerinden, PS noktalarının yıllık hareket hızları milimetre cinsinden hesaplanmıştır. Bu hesaplamada, her bir PS noktasının 10 yıllık faz değişimi, sabit bir referans noktasına bağlanarak çözümlenmiş ve doğrusal hareket hızı (mm/yıl) değeri elde edilmiştir.

Analiz sonuçlarına göre, hem alçalan hem de yükselen yörünge verileri için yerkabuğu hareketi hızları yaklaşık olarak: +1 ila -14 mm/yıl aralığında değişmektedir. Bu değerler, tüm hareketin çökme yönlü (negatif işaretli) olduğunu göstermektedir. Yani, bölgedeki yüzey hareketleri esas olarak yer değiştirme değil, düşey ekseninde aşağıya doğru oturma (subsidence) şeklindedir. Bu hareketler, bölgede uzun yıllardır devam eden yeraltı suyu çekiminin neden olduğu düşünülen zemin sıkışmasının bir sonucu olarak yorumlanmaktadır, bu durum literatürdeki temel çalışmalarla da uyumludur (Galloway ve Burbey, 2011; Duran vd. 2021).

Ortalama hız haritaları üzerinden yapılan analizler, en yüksek çökme oranlarının Bolvadin ilçe merkezinin güney ve güneybatı kesimlerinde yoğunlaştığını göstermektedir. Bu alanlar, özellikle yaz aylarında sulama amaçlı yoğun yer altı suyu çekiminin yapıldığı, aynı zamanda yerleşim ve yol altyapısının bulunduğu bölgelerle çakıştığı görülmektedir. Yerel zemin koşullarının gevşek, çakıllı ve siltli yapısı, bu

alanların oturmaya karşı hassasiyetini artıran önemli bir faktör olarak öne çıkmaktadır (Imamoglu vd. 2019).

Haritalarda görülen hareketin mekansal dağılımı, PS yoğunluğu ve hareket hızı bir arada analiz edildiğinde, bölgedeki zemin davranışının sistematik ve süreğen bir çökme eğilimi sergilediği açıkça gözlemlenmiştir. Yükselen ve alçalan yörünge verilerinin birleştirilmesiyle oluşturulan bileşik yerkabuğu hareketi haritalarında bu bölgelerde 14 mm/yıl'a varan hareket değerleri doğrulanmıştır.

Ortalama hız haritaları, StaMPS yazılımı içinde yer alan MATLAB tabanlı `ps_plot('v')`, `ps_plot('v-d')` ve `ps_plot('v-do')` gibi komutlar kullanılarak oluşturulmuştur. Bu komutlar sayesinde her PS noktası için:

- Ortalama hız değeri (mm/yıl),
- Topografik etkilerden arındırılmış hız,
- Yörünge ve topografik etkilerden arındırılmış hız.


görsel olarak sunulmuştur. Haritalar ve görseller, MATLAB üzerinden alınmış ardından .mat .tiff ve .png formatında dışa aktarılmış.

Harita çıktıları üzerinden hareket değerlerinin renklendirilmesi, -14 mm/yıl ile 1 mm/yıl aralığında yapılmıştır. Negatif hızlar kırmızı tonlarda (şiddetli çökme), daha durağan bölgeler ise yeşil-mavi tonlarda gösterilmiştir. Böylece çökme riski taşıyan bölgeler görsel olarak da ayırt edilebilir hâle gelmiştir.

Bu çalışmada, Sentinel-1A'ya ait hem alçalan hem de yükselen yörünge verileri kullanılmış; ancak analizler öncelikle her yörünge için ayrı ayrı yapılmıştır. Her iki yörüngeye ait LOS hız haritaları bağımsız olarak üretildikten sonra, hareket vektörlerinin yön bilgileri kullanılarak birleştirilmiş ortalama hız haritası oluşturulmuştur.

Alçalan yörünge LOS hareketi aşağıya ve doğuya duyarlıyken; yükselen yörünge kuzey ve batı yönlü hareketlere karşı duyarlıdır. Her iki yörünge kombinasyonu sayesinde,

hareket bileşenlerinin hem genliği hem de yönü daha sağlıklı şekilde çözümlenmiştir.




Şekil 4.1 PS-InSAR ile hesaplanan uydu bakış doğrultusundaki (LOS) değişim.

4.2 Derin Öğrenme Modelleri ile Yerkabuğu Hareketleri Tahmini Sonuçları


4.2.1. LSTM Sonuçları

Öncelikle LSTM modelinin eğitim süreci, eğitim ve doğrulama kaybı grafiği ile incelenmiştir.



Şekil 4.2 LSTM 10. yıla ait eğitim kayıp grafiği.


Grafik, modelin 100 epoch sonrasında doğrulama kaybında stabilizasyon göstererek optimum noktada eğitimi tamamladığını ve aşırı öğrenmenin (overfitting) önüne geçildiğini göstermektedir. Bu temel modelin 10 yıllık hareket tahminlerindeki performansı oldukça yüksektir.



Şekil 4.3 LSTM tahmin hatalarının dağılımı.


Ortalama Mutlak Hata (MAE) 0.5214 mm/yıl, Karesel Ortalama Hata (RMSE) 0.7083 mm/yıl, determinasyon katsayısı (R^2) değeri 0.9481 ve Pearson korelasyon katsayısı (R) 0.9745 olarak hesaplanmıştır. Bu metrikler, modelin gözlemlenen varyansın büyük bir kısmını başarıyla açıkladığını ve tahminlerinin gerçek değerlerle yüksek korelasyon gösterdiğini ortaya koymaktadır.

10 yıllık hareket tahminlerine ait hata analizleri de gerçekleştirilmiştir. Şekil 4.3'de sunulan tahmin hatalarının dağılımı incelendiğinde, hataların sıfır merkezli ve Gauss dağılımına yakın bir yapıda olduğu, büyük çoğunluğunun -1 ile +1 mm/yıl aralığında yoğunlaştığı görülmektedir.



Şekil 4.4 LSTM gerçek değerlere karşı tahmin hataları.


Şekil 4.4'de Tahmin hataları grafiği, hataların gerçek 10 yıllık hareket değerleri boyunca rastgele dağıldığını ve belirgin bir sistematik örüntü veya heteroskedastisite problemi olmadığını işaret etmektedir.



Şekil 4.5 LSTM tahmin hatalarının coğrafi dağılımı.


Şekil 4.5'de sunulan hataların coğrafi dağılımı ise, tahmin hatalarının belirli bir bölgede kümelenmediğini, genel olarak homojen bir dağılım sergilediğini göstermektedir.

Bu başarılı temel model kullanılarak, RMF yöntemiyle gelecekteki iki yıl için, yani 11 yıllık hareket (2025 yılı) ve 12 yıllık hareket (2026 yılı) değerleri tahmin edilmiştir.



Şekil 4.6 LSTM RMF ile 11. yıl tahmin dağılımı.


Şekil 4.6’da 11 yıllık hareket için yapılan tahminlerin dağılımı sunulmuştur. Bu dağılım, -13 mm/yıl ile +2 mm/yıl aralığında değişen değerler göstermekte olup, yaklaşık -9 mm/yıl, -5 mm/yıl ve -2.5 mm/yıl civarında belirgin frekans yoğunlukları gözlenmektedir.



Şekil 4.7 LSTM RMF ile 12. yıl tahmin dağılımı.

Benzer şekilde, Şekil 4.7’de 12 yıllık hareket için yapılan RMF tahminlerinin dağılımı yer almaktadır. 12 yıllık hareket tahminleri de -14 mm/yıl ile +2.5 mm/yıl arasında bir yayılım göstermekte, en yoğun frekanslar yaklaşık -9.5 mm/yıl civarında olmakla birlikte, -5 mm/yıl ve -3 mm/yıl dolaylarında da sekonder yoğunluklar dikkat

çekmektedir.




Şekil 4.8 LSTM RMF ile PS noktalarının 12. yıldaki hareketi.

2026 yılı (12 yıllık hareket) tahminlerinin coğrafi dağılımı ise Şekil 4.8 'de görselleştirilmiştir. Bu harita, tahmin edilen 12 yıllık hareket değerlerinin mekansal değişimini ve belirli bölgelerdeki potansiyel hareketlilik örüntülerini ortaya koymaktadır. Renk skalası -16 mm/yıl ile +2 mm/yıl arasında değişen tahmin değerlerini göstermekte, mavi tonlar pozitif (yükselme), kırmızı tonlar ise negatif (çökme) hareketleri temsil etmektedir. Grafik, genel olarak negatif değerlerin (çökme) hakim olduğu bir örüntüye işaret etmektedir.

4.2.2. CNN Sonuçları

Temel CNN modelinin eğitim süreci, Şekil 4.9’de sunulan eğitim ve doğrulama kaybı grafikleri ile detaylı bir şekilde incelenmiştir.




Şekil 4.9 CNN 10. yıla ait eğitim kayıp grafiği.

Şekil 4.9, modelin eğitim ve doğrulama kayıplarının birlikte azalarak yaklaşık 0.0015 gibi düşük bir MSE değerine yakınsadığını ve aşırı öğrenme (overfitting) problemi olmaksızın başarılı bir şekilde eğitildiğini göstermektedir.

Bu temel CNN modelinin 10 yıllık hareket tahminlerindeki performansı, başarı metrikleri değerlendirilmiştir: Ortalama Mutlak Hata (MAE) 0.4490 mm/yıl, Karesel Ortalama Hata (RMSE) 0.6129 mm/yıl, determinasyon katsayısı (R^2) değeri 0.9611 ve Pearson korelasyon katsayısı (R) 0.9817 olarak elde edilmiştir.


Bu yüksek performans metrikleri, CNN modelinin 10 yıllık hareket değişimlerindeki varyansın büyük bir bölümünü başarıyla açıkladığını ve gerçek değerlerle son derece uyumlu tahminler ürettiğini kanıtlamaktadır.



Şekil 4.10 CNN tahmin hatalarının dağılımı.


10 yıllık hareket tahminlerine yönelik hata analizleri, modelin güvenilirliğini pekiştirmektedir.

Şekil 4.10’da görüldüğü üzere, tahmin hataları sıfır etrafında yoğunlaşan ve Gauss dağılımına yakın bir örüntü sergilemektedir.



Şekil 4.11 CNN gerçek değerlere karşı tahmin hataları.


Şekil 4.11'deki artık değerler grafiği, hataların gerçek 10 yıllık hareket değerleri karşısında rastgele dağıldığını ve herhangi bir sistematik sapma içermediğini göstermektedir.



Şekil 4.12 CNN tahmin hatalarının coğrafi dağılımı.


Ayrıca, Şekil 4.12'de hataların coğrafi dağılımı incelendiğinde, hataların belirli bir bölgede kümelenme eğilimi göstermediği, genel olarak homojen bir dağılım sergilediği tespit edilmiştir.

Başarılı temel CNN modeli kullanılarak, RMF yöntemiyle sonraki iki yıl için, yani 11 yıllık hareket (2025 yılına karşılık gelen) ve özellikle bu bölümün odak noktası olan 12 yıllık hareket (2026 yılına karşılık gelen) değerleri tahmin edilmiştir.



Şekil 4.13 CNN RMF ile 11. yıl tahmin dağılımı.


Şekil 4.13, 2025 yılı (11 yıllık hareket) için yapılan RMF tahminlerinin dağılımını sunmaktadır. Bu dağılım, değerlerin ağırlıklı olarak -15 mm/yıl ile +2.5 mm/yıl arasında değiştiğini ve yaklaşık -8 mm/yıl ile -2.5 mm/yıl aralıklarında pik yaptığını göstermektedir.



Şekil 4.14 CNN RMF ile 12. yıl tahmin dağılımı.

2026 yılına ait 12 yıllık hareket tahminlerinin dağılımı Şekil 4.14'de sunulmuştur. Bu şekle göre, 12 yıllık hareket tahminleri -15 mm/yıl ile +2.5 mm/yıl arasında bir yayılım

göstermekte olup, en yoğun frekanslar yaklaşık -8 mm/yıl civarında gözlenirken, -5 mm/yıl ve -2.5 mm/yıl civarında da dikkate değer yoğunluklar bulunmaktadır.



Şekil 4.15 CNN RMF ile PS noktalarının 12. yıldaki hareketi.


2026 yılı (12 yıllık hareket) tahminlerinin coğrafi dağılımı ise Şekil 4.15 'de görselleştirilmiştir. Bu harita, tahmin edilen 12 yıllık hareket değerlerinin mekansal değişimini ve belirli bölgelerdeki potansiyel hareketlilik örüntülerini ortaya koymaktadır. Renk skalası -16 mm/yıl ile +2 mm/yıl arasında değişen tahmin değerlerini göstermekte, mavi tonlar pozitif (yükselme), kırmızı tonlar ise negatif (çökme) hareketleri temsil etmektedir. Grafik, genel olarak negatif değerlerin (çökme) hakim olduğu bir örüntüye işaret etmektedir.

Bu analizler, geliştirilen CNN tabanlı RMF modelinin, özellikle 2026 yılı için potansiyel yeryüzü hareketlerini tahmin etme ve bu tahminlerin istatistiksel ve coğrafi

dağılımlarını belirleme konusundaki yeteneğini göstermektedir. Elde edilen sonuçlar, gelecekteki hareketlerin izlenmesi ve potansiyel risklerin değerlendirilmesi açısından önemli bilgiler sunmaktadır.


4.2.3 TCN Sonuçları

Temel TCN modelinin eğitim performansı, eğitim ve doğrulama kaybı grafikleri üzerinden değerlendirilmiştir.




Şekil 4.16 TCN 10. Yıla ait eğitim kayıp grafiği.

Bu şekil, modelin eğitim ve doğrulama kayıplarının hızla azalarak yaklaşık 0.003 gibi oldukça düşük bir Ortalama Karesel Hata (MSE) değerinde istikrar kazandığını ve aşırı öğrenme (overfitting) problemi olmaksızın başarıyla eğitildiğini göstermektedir. Temel TCN modelinin 10 yıllık hareket tahminlerindeki nicel performansı, başarı metriklerle ortaya konmuştur: Ortalama Mutlak Hata (MAE) 0.5685 mm/yıl, Karesel Ortalama Hata (RMSE) 0.7507 mm/yıl, determinasyon katsayısı (R^2) değeri 0.9417 ve Pearson korelasyon katsayısı (R) 0.9736 olarak hesaplanmıştır. Bu metrikler, TCN modelinin gözlemlenen 10 yıllık hareket değişimlerindeki varyansın büyük bir kısmını yüksek doğrulukla açıkladığını ve gerçek değerlerle güçlü bir korelasyon sergilediğini teyit etmektedir.




Şekil 4.17 TCN tahmin hatalarının dağılımı.

10 yıllık hareket tahminlerine ilişkin hata analizleri, modelin güvenilirliğini destekler niteliktedir. Şekil 4.17’de tahmin hatalarının sıfır değeri etrafında yoğunlaştığı ve yaklaşık olarak Gauss dağılımına uyduğu görülmektedir; hataların büyük çoğunluğu ± 2 mm/yıl aralığında kalmaktadır.




Şekil 4.18 TCN gerçek değerlere karşı tahmin hataları.

Şekil 4.18'deki artık değerler grafiği, hataların gerçek 10 yıllık hareket değerleri boyunca rastgele ve homojen bir dağılım gösterdiğini, bu durumun da modelde belirgin bir sistematik sapma olmadığını işaret ettiğini göstermektedir.



Şekil 4.19 TCN tahmin hatalarının coğrafi dağılımı.


Şekil 4.19'deki hataların coğrafi dağılımı incelendiğinde ise, hataların belirli bir bölgede kümelenmediği ve genel olarak yaygın bir dağılım sergilediği anlaşılmaktadır.



Şekil 4.20 TCN RMF ile 11. yıl tahmin dağılımı.


Bu başarılı temel TCN modeli kullanılarak, RMF yöntemiyle gelecek iki yıl için, yani 11 yıllık hareket (2025 yılı) ve bu bölümün ana odağı olan 12 yıllık hareket (2026 yılı) değerleri tahmin edilmiştir. 2025 yılı (11 yıllık hareket) için yapılan RMF tahminlerinin dağılımı Şekil 4.21 grafiğinde sunulmuştur.

Bu dağılım, tahminlerin genellikle -14 mm/yıl ile +1 mm/yıl arasında değiştiğini ve yaklaşık -9 mm/yıl, -6 mm/yıl ve -4 mm/yıl civarında belirgin frekans yoğunlukları olduğunu göstermektedir.



Şekil 4.21 TCN RMF ile 12. yıl tahmin dağılımı.

Özellikle 2026 yılına ait 12 yıllık hareket tahminlerinin dağılımı Şekil 24 'de detaylandırılmıştır. 12 yıllık hareket tahminleri de benzer şekilde -14 mm/yıl ile +1 mm/yıl arasında bir yayılım sergilemekte olup, en yoğun frekans yaklaşık -9 mm/yıl değerinde gözlenirken, -6 mm/yıl ve -4 mm/yıl civarında da sekonder yoğunluklar dikkat çekmektedir.




Şekil 4.22 TCN RMF ile PS noktalarının 12. yıldaki hareketi.

2026 yılı (12 yıllık hareket) için yapılan bu RMF tahminlerinin coğrafi dağılımı ise Şekil 4.22 ile görselleştirilmiştir. Bu harita, tahmin edilen 12 yıllık hareket değerlerinin -16 mm/yıl (koyu kırmızı, belirgin çökme) ile yaklaşık +2 mm/yıl (mavi tonlar, hafif yükselme) arasında değiştiğini göstermektedir. Harita, 2026 yılı için potansiyel çökmelerin mekansal örüntüleri hakkında kritik bilgiler sunmakta ve farklı bölgelerdeki beklenen hareketlilik düzeylerini ortaya koymaktadır.

Bu bulgular, geliştirilen TCN tabanlı RMF modelinin, özellikle 2026 yılı için yeryüzü hareketlerini tahmin etme ve bu tahminlerin hem istatistiksel hem de coğrafi dağılımlarını belirleme konusundaki kabiliyetini vurgulamaktadır. Elde edilen sonuçlar, gelecekteki çökmelerin takibi, potansiyel risklerin analizi ve ilgili önlemlerin planlanması açısından değerli öngörüler sağlamaktadır.


4.2.4 GRU Sonuçları

Temel GRU modelinin eğitim performansı, eğitim ve doğrulama kaybı grafikleri ile değerlendirilmiştir.




Şekil 4.23 GRU 10. yıla ait eğitim kayıp grafiği.

Şekil 4.23, modelin eğitim ve doğrulama kayıplarının birlikte azalarak yaklaşık 0.0018 gibi düşük bir Ortalama Karesel Hata (MSE) değerine ulaştığını ve aşırı öğrenme (overfitting) belirtisi göstermeden başarılı bir şekilde eğitildiğini ortaya koymaktadır. Temel GRU modelinin 10 yıllık hareket tahminlerindeki sayısal performansı, başarı metrikleri ile ölçülmüştür: Ortalama Mutlak Hata (MAE) 0.5401 mm/yıl, Karesel Ortalama Hata (RMSE) 0.7410 mm/yıl, determinasyon katsayısı (R^2) değeri 0.9432 ve Pearson korelasyon katsayısı (R) 0.9759 olarak hesaplanmıştır. Bu metrikler, GRU modelinin gözlemlenen 10 yıllık hareket değişimlerindeki varyansın önemli bir bölümünü yüksek bir uyumla açıkladığını ve gerçek değerlerle kuvvetli bir doğrusal ilişki sergilediğini göstermektedir.




Şekil 4.24 GRU tahmin hatalarının dağılımı.

10 yıllık hareket tahminlerine yönelik hata analizleri, modelin tahmin yeteneğini desteklemektedir. Şekil 4.24’de, tahmin hatalarının sıfır değeri etrafında yoğunlaştığı ve simetrik bir dağılıma sahip olduğu görülmektedir; hataların büyük bir kısmı ± 2 mm/yıl aralığında yer almaktadır.



Şekil 4.25 GRU gerçek değerlere karşı tahmin hataları.

Şekil 4.25’de tahmin hataları grafiği, hataların gerçek 10 yıllık hareket değerleri boyunca rastgele ve homojen bir şekilde dağıldığını, bu durumun modelde belirgin bir yanlılık (bias) veya sistematik hata olmadığını ortaya koymaktadır.




Şekil 4.26 GRU tahmin hatalarının coğrafi dağılımı.

Şekil 4.26’da hataların coğrafi dağılımı incelendiğinde ise, hataların belirli bir bölgede yoğunlaşmadığı ve genel olarak alana yaygın bir dağılım sergilediği anlaşılmaktadır; bu da modelin coğrafi bir yanlılığa sahip olmadığını düşündürmektedir.


Bu başarılı temel GRU modeli kullanılarak, RMF yöntemiyle gelecek iki yıl için, yani

11 yıllık hareket (2025 yılı) ve bu bölümün temel odak noktası olan 12 yıllık hareket (2026 yılı) değerleri tahmin edilmiştir.




Şekil 4.27 GRU RMF ile 11. yıl tahmin dağılımı.

2025 yılı için yapılan RMF tahminlerinin dağılımı Şekil 4.28 grafiğinde sunulmuştur. Bu dağılım, tahminlerin genellikle -14 mm/yıl ile +2 mm/yıl arasında değiştiğini ve yaklaşık -9.5 mm/yıl, -6 mm/yıl ve -4 mm/yıl civarında belirgin frekans yoğunlukları olduğunu göstermektedir.



Şekil 4.28 GRU RMF ile 12. yıl tahmin dağılımı.

Özellikle 2026 yılına ait 12 yıllık hareket tahminlerinin dağılımı Şekil 4.28'de detaylandırılmıştır. 12 yıllık hareket tahminleri de benzer şekilde -14 mm/yıl ile +1.5 mm/yıl arasında bir yayılım sergilemekte olup, en yoğun frekans yaklaşık -9.5 mm/yıl değerinde gözlenirken, -6 mm/yıl, -4 mm/yıl ve -2 mm/yıl civarında da dikkate değer yoğunluklar bulunmaktadır.



Şekil 4.29 GRU RMF ile PS noktalarının 12. yıldaki hareketi.


2026 yılı (12 yıllık hareket) için yapılan bu RMF tahminlerinin coğrafi dağılımı ise Şekil 4.29 ile görselleştirilmiştir. Bu harita, tahmin edilen 12 yıllık hareket değerlerinin -16 mm/yıl (koyu kırmızı, belirgin çökme) ile yaklaşık +2 mm/yıl (mavi tonlar, hafif yükselme) arasında değiştiğini göstermektedir. Harita, 2026 yılı için potansiyel

çökmelerin mekansal örüntüleri hakkında önemli bilgiler sunmakta ve farklı bölgelerdeki beklenen hareketlilik seviyelerini ve eğilimlerini ortaya koymaktadır.

Bu bulgular, geliştirilen GRU tabanlı RMF modelinin, özellikle 2026 yılı için yeryüzü hareketlerini tahmin etme ve bu tahminlerin hem istatistiksel hem de coğrafi dağılımlarını belirleme konusundaki potansiyelini göstermektedir. Elde edilen sonuçlar, gelecekteki çökmelerin izlenmesi, potansiyel jeodezik risklerin değerlendirilmesi ve ilgili mühendislik ile planlama çalışmalarına girdi sağlanması açısından değerli öngörüler sunmaktadır.


4.2.5. Transformer Sonuçları

Temel Transformer modelinin eğitim süreci, eğitim ve doğrulama kaybı grafikleri aracılığıyla incelenmiştir.




Şekil 4.30 Transformer 10. yıla ait eğitim kayıp grafiği.

Şekil 4.30, modelin eğitim ve doğrulama kayıplarının hızla azalarak yaklaşık 0.0025 gibi düşük bir Ortalama Karesel Hata (MSE) değerinde stabilize olduğunu ve erken durdurma kriterlerine göre yaklaşık 85. epoch civarında eğitimi tamamlayarak aşırı öğrenmenin (overfitting) önüne geçildiğini göstermektedir.



Şekil 4.31 Transformer tahmin hatalarının dağılımı


10 yıllık hareket tahminlerine ilişkin hata analizleri, modelin performansını daha detaylı bir şekilde ortaya koymaktadır. Şekil 4.31 grafiğinde, tahmin hatalarının sıfır değeri etrafında yoğunlaştığı ve yaklaşık olarak normal bir dağılım sergilediği, hataların büyük bir kısmının ± 2 mm/yıl aralığında kaldığı görülmektedir.



Şekil 4.32 Transformer gerçek değerlere karşı tahmin hataları.


Şekil 4.32’de artık değerler grafiği, hataların gerçek 10 yıllık hareket değerleri boyunca rastgele ve homojen bir dağılım gösterdiğini, bu durumun modelde belirgin bir sistematik sapma veya yanlılık olmadığını işaret ettiğini göstermektedir.

Temel Transformer modelinin 10 yıllık hareket tahminlerindeki performansı, başarı metrikleri ile değerlendirilmiştir: Ortalama Mutlak Hata (MAE) 0.6116 mm/yıl, Karesel Ortalama Hata (RMSE) 0.8256 mm/yıl, determinasyon katsayısı (R^2) değeri 0.9295 ve Pearson korelasyon katsayısı (R) 0.9651 olarak hesaplanmıştır. Bu metrikler, Transformer modelinin 10 yıllık hareket değişimlerindeki varyansın önemli bir bölümünü başarıyla modellediğini ve tahminlerinin gerçek değerlerle yüksek bir uyum içinde olduğunu göstermektedir.




Şekil 4.33 Transformer tahmin hatalarının coğrafi dağılımı.

Şekil 4.33'deki hataların coğrafi dağılımı incelendiğinde ise, hataların belirli bir bölgede kümelenmediği ve genel olarak yaygın bir dağılım sergilediği, bu durumun modelin coğrafi bir yanlılığa sahip olmadığını düşündürdüğü anlaşılmaktadır. Bu başarılı temel Transformer modeli kullanılarak, RMF yöntemiyle gelecek iki yıl için, yani 11 yıllık hareket (2025 yılı) ve bu bölümün asıl odak noktası olan 12 yıllık hareket (2026 yılı) değerleri tahmin edilmiştir.




Şekil 4.34 Transformer RMF ile 11. yıl tahmin dağılımı

2025 yılı (11 yıllık hareket) için yapılan RMF tahminlerinin dağılımı Şekil 4.34 sunulmuştur. Bu dağılım, tahminlerin genellikle -12 mm/yıl ile +1 mm/yıl arasında değiştiğini ve yaklaşık -11.5 mm/yıl, -9 mm/yıl, -5.5 mm/yıl ve -3.5 mm/yıl civarında belirgin multimodal frekans yoğunlukları olduğunu göstermektedir.



Şekil 4.35 Transformer RMF ile 12. yıl tahmin dağılımı.

Özellikle 2026 yılına ait 12 yıllık hareket tahminlerinin dağılımı Şekil 4.35’de detaylandırılmıştır. 12 yıllık hareket tahminleri de benzer şekilde -12 mm/yıl ile +1 mm/yıl arasında bir yayılım sergilemekte olup, belirgin pikler yaklaşık -11.5 mm/yıl, -9 mm/yıl, -5.5 mm/yıl ve -3.5 mm/yıl değerlerinde gözlenmektedir. Bu multimodal dağılım, farklı bölgelerde veya farklı zaman serisi dinamiklerine sahip noktalarda çeşitli hareketlilik senaryolarının olasılığını yansıtabilir.



Şekil 4.36 Transformer RMF ile PS noktalarının 12. yıldaki hareketi

2026 yılı (12 yıllık hareket) için yapılan bu RMF tahminlerinin coğrafi dağılımı ise Şekil 4.36 ile görselleştirilmiştir. Bu harita, tahmin edilen 12 yıllık hareket değerlerinin -16 mm/yıl (koyu kırmızı, belirgin çökme) ile yaklaşık +2 mm/yıl (mavi tonlar, hafif yükselme) arasında değiştiğini göstermektedir. Harita, 2026 yılı için potansiyel çökmelerin mekansal örüntülerini ve farklı bölgelerdeki beklenen hareketlilik

düzeylerini ve eğilimlerini ortaya koymaktadır. Bu analizler, geliştirilen Transformer tabanlı RMF modelinin, özellikle 2026 yılı için yeryüzü hareketlerini tahmin etme ve bu tahminlerin hem istatistiksel hem de coğrafi dağılımlarını belirleme konusundaki kabiliyetini ve potansiyelini göstermektedir. Elde edilen sonuçlar, gelecekteki çökmelerin takibi, potansiyel jeodezik risklerin ve etkilerinin değerlendirilmesi ve ilgili stratejik planlamalara bilimsel bir temel sağlanması açısından değerli öngörüler sunmaktadır.

4.3 Tahmin Performansının Karşılaştırmalı Değerlendirilmesi

Bu bölümde, önceki alt bölümlerde bireysel olarak sunulan derin öğrenme modellerinin (LSTM, GRU, TCN, CNN ve Transformer) 10 yıllık hareket (tek adımlı) ve RMF stratejisiyle elde edilen 11 yıllık hareket ile 12 yıllık hareket (çok adımlı) tahmin performansları karşılaştırmalı olarak değerlendirilecektir. Değerlendirme, Bölüm 3.4.4'te tanımlanan performans kriterleri (MAE, RMSE, R^2 ve Pearson R) temel alınarak yapılacaktır.

4.3.1 Tek Adımlı Tahmin Performansı

Beş farklı derin öğrenme modelinin 10 yıllık hareket tahminleri için elde edilen temel başarı metrikleri Çizelge 4.1'de özetlenmiştir.

Çizelge 4.1 Derin Öğrenme Modellerinin Tahmin Performans Metrikleri.

Model Adı	MAE (mm/yıl)	RMSE (mm/yıl)	R^2 Değeri	Pearson R
LSTM	0.5214	0.7083	0.9481	0.9745
CNN	0.4490	0.6129	0.9611	0.9817
TCN	0.5685	0.7507	0.9417	0.9736
GRU	0.5401	0.7410	0.9432	0.9759
Transformer	0.6116	0.8256	0.9295	0.9651

Çizelge 4.1 incelendiğinde, tek adımlı 10 yıllık hareket tahmininde en düşük MAE (0.4490 mm/yıl) ve RMSE (0.6129 mm/yıl) değerleri ile en yüksek R^2 (0.9611) ve Pearson R (0.9817) katsayısına CNN modelinin ulaştığı görülmektedir. Bu durum, CNN mimarisinin zaman serisindeki yerel örüntüleri ve kısa vadeli bağımlılıkları yakalamada diğer modellere kıyasla daha başarılı olabildiğini düşündürmektedir. CNN modelini, R^2 ve RMSE değerleri açısından sırasıyla LSTM, GRU, TCN ve Transformer modelleri takip etmektedir. Transformer modeli, bu özel tek adımlı tahmin görevinde diğer modellere göre biraz daha yüksek hata metrikleri ve biraz daha düşük bir R^2 değeri sergilemiştir. Ancak tüm modellerin R^2 değerlerinin 0.92'nin üzerinde ve Pearson R katsayılarının 0.96'nın üzerinde olması, kullanılan tüm derin öğrenme yaklaşımlarının 10 yıllık hareket verisindeki varyansın büyük bir kısmını başarıyla açıkladığını ve yüksek bir tahmin tutarlılığına sahip olduğunu göstermektedir.

4.3.2 RMF Tahmin Performansı

RMF stratejisi ile 11 yıllık hareket (2025 yılı) ve 12 yıllık hareket (2026 yılı) için yapılan tahminler, modellerin hata birikimine karşı ne kadar hassas olduğunu ve daha uzun vadeli öngörülerdeki tutarlılığını değerlendirmek açısından önemlidir. Bölüm 4.2'te sunulan 11 yıllık hareket ve 12 yıllık hareket tahminlerinin dağılım grafikleri (histogramlar) ve 12 yıllık hareket için coğrafi dağılım haritaları bu değerlendirmeye temel oluşturmaktadır.

LSTM, CNN, TCN, GRU ve Transformer modellerinin 11 yıllık hareket ve 12 yıllık hareket için ürettiği tahminlerin histogramları incelendiğinde, tüm modellerin ağırlıklı olarak negatif (çökme yönlü) hareketler öngördüğü görülmektedir. Ancak, tahmin edilen değerlerin yayılımı ve pik yaptığı noktalar modelden modele farklılık göstermektedir. Örneğin, CNN ve TCN modelleri 11 yıllık hareket ve 12 yıllık hareket için benzer aralıklarda (-15/+2.5 mm/yıl ve -14/+1 mm/yıl civarı) ve benzer pik noktalarında yoğunlaşmalar gösterirken, LSTM ve GRU modelleri de kendi içlerinde benzer dağılımlar sergilemiştir. Transformer modelinin tahmin dağılımı ise daha belirgin multimodal bir yapı göstermiştir bu da farklı PS noktaları için farklı hareket senaryolarının olasılığına işaret edebilir.

Her model için oluşturulan 12 yıllık hareket tahminlerinin coğrafi dağılım haritaları karşılaştırıldığında, genel çökme alanlarının konumu modeller arasında büyük ölçüde tutarlılık gösterebilirken, çökme miktarlarının büyüklüğü ve en yoğun çökmenin yaşandığı spesifik bölgelerde farklılıklar gözlemlenebilir. Tüm modeller Bolvadin'in güneybatı kesimlerinde yoğun çökme öngörmekle birlikte, CNN modeli bu bölgedeki çökme hızını diğerlerine göre ortalama daha yüksek tahmin etmiştir.

RMF sürecinde hata birikimi kaçınılmaz bir durumdur. 10 yıllık hareket tahminlerindeki başarı (11 yıllık hareket ve 12 yıllık hareket için doğrudan metriklerimiz olmasa da), modellerin ilk adımdaki performansları RMF'nin ilerleyen adımlarını etkileyecektir. En düşük tek adım hatasına sahip olan CNN modelinin, RMF adımlarında da daha stabil sonuçlar vermesi beklenebilir. Tersine, tek adımda daha yüksek hata yapan bir modelin (örneğin Transformer) RMF ile tahmin ufku uzadıkça hatasının daha hızlı artması muhtemeldir. 11 yıllık hareket ve 12 yıllık hareket tahminlerinin dağılımlarındaki genel dağılım veya beklenmedik piklerin oluşumu, hata birikiminin bir göstergesi olabilir.

4.3.3 Genel Değerlendirme

Bu çalışmada incelenen beş farklı derin öğrenme mimarisi (LSTM, GRU, TCN, CNN, Transformer), Bolvadin bölgesindeki PS-InSAR zaman serilerinden elde edilen tek adımlı (10 yıllık hareket) hareket hızlarını yüksek bir başarıyla tahmin etme potansiyeli göstermiştir. Özellikle CNN modeli, en düşük MAE ve RMSE değerleri ile en yüksek R^2 ve Pearson R katsayısını sunarak tek adımlı tahminlerde öne çıkmıştır.

Çok adımlı RMF tahminlerinde (11 yıllık hareket ve 12 yıllık hareket) ise, modellerin tahmin dağılımları ve coğrafi örüntüleri genel olarak benzer çökme eğilimlerine işaret etmekle birlikte, tahmin edilen değerlerin aralığı ve yoğunlaştığı noktalar farklılıklar göstermiştir. RMF sürecinde hata birikimi göz önünde bulundurulduğunda, tek adımda daha başarılı olan modellerin çok adımlı tahminlerde de daha güvenilir sonuçlar vermesi beklenir. Ancak, Transformer gibi bazı modellerin farklı dinamiklere sahip zaman serilerinde farklı davranışlar sergileyebileceği de dikkate alınmalıdır.

Bu çalışmanın amaçları doğrultusunda, hem tek adımlı tahmin doğruluğu hem de RMF ile elde edilen çok adımlı tahminlerin tutarlılığı göz önüne alındığında, CNN ve LSTM modelleri, hem tek adımlı tahminlerdeki yüksek doğrulukları hem de RMF adımlarındaki görece stabil tahmin dağılımları nedeniyle bu tür bir hareket tahmini problemi için daha uygun görünmektedir.

Bu karşılaştırmalı analiz, Bolvadin örneğinde PS-InSAR verileriyle geleceğe yönelik yerkabuğu hareketlerinin tahminlerinde farklı derin öğrenme mimarilerinin potansiyelini ve sınırlılıklarını ortaya koymaktadır. Elde edilen sonuçlar, benzer hidrojeolojik ve deformasyon karakteristiğine sahip diğer alanlarda yapılacak çalışmalara ışık tutabilir.

5. TARTIŞMA ve SONUÇ

Bu çalışmanın temelini oluşturan PS-InSAR analizi, Bolvadin bölgesinde 2015-2024 yılları arasındaki 10 yıllık bir periyodu kapsayan Sentinel-1A uydu görüntülerinden 240 adet veri kullanılarak gerçekleştirilmiştir. Bu analiz sonucunda, genel olarak çökme yönlü (negatif işaretli) hareketlerin hakim olduğunu ve bu hızların yaklaşık -15 mm/yıl ile +2 mm/yıl aralığında değiştiğini ortaya koymuştur. Bu çalışmada elde edilen PS-InSAR sonuçları, Bolvadin Ovası'ndaki deformasyonun baskın karakterinin çökme (subsidence) olduğunu açıkça göstermektedir. Bununla birlikte, sonuçlar incelendiğinde, genel çökme trendi içinde bazı PS noktalarında +1 ila +2 mm/yıl gibi düşük genlikli pozitif hareket değerleri de gözlemlenmiştir. Bu durum bir çelişki olarak değil, deformasyon sürecinin heterojen yapısının bir yansıması olarak yorumlanmalıdır. PS-InSAR tekniğinin milimetrik hassasiyeti göz önüne alındığında, bu küçük pozitif değerlerin önemli bir kısmı, tekniğin ölçüm hata payı içinde kalmakta ve bu noktaların gerçek bir yükselmeden ziyade göreceli olarak stabil (hareketsiz) bir davranış sergilediğine işaret etmektedir. Ayrıca, bu noktaların, çevresindeki gevşek zeminlerin aksine, daha sağlam jeolojik birimler veya derin temellere sahip yapılar üzerinde yer alması da bu tür lokal farklılıklara neden olabilir. Dolayısıyla, bu lokal ve düşük genlikli pozitif değerler genel çökme bulgusunu geçersiz kılmamakta, aksine bölgedeki deformasyon paterninin karmaşık doğasını detaylandırmaktadır.

Bu çalışmada yürütülen PS-InSAR analiziyle, en yüksek çökme oranlarının Bolvadin ilçe merkezinin güney ve güneybatı kesimlerinde yoğunlaştığı tespit edilmiştir. Bu mekansal bulgu, tezin literatür bölümünde de atıfta bulunulan Imamoglu vd. (2019) tarafından yapılan çalışmanın sonuçlarıyla doğrudan örtüşmektedir. Söz konusu çalışmada da hem GNSS istasyonları hem de InSAR verileriyle yine aynı coğrafi bölgeler için yıllık 15 mm'ye varan çökme hızları raporlanmış ve bu durumun bölgedeki yoğun tarımsal sulama amaçlı yeraltı suyu kullanımıyla güçlü bir ilişkisi olduğu vurgulanmıştır. Dolayısıyla, bu tezde bağımsız olarak elde edilen çökme örüntüsünün, daha önceki çalışmalarla mekansal olarak uyumlu olması, bölgedeki deformasyonun ana tetikleyicisinin antropojenik etkiler, özellikle de yeraltı suyu çekimi olduğu hipotezini önemli ölçüde güçlendirmektedir. Tezin önemli bir yönü olan 10 yıllık uzun bir veri serisinin kullanılması, yerkabuğunun süregelen bir çökme eğilimi sergilediğini

ve kısa dönemli analizlerin yanıltıcı olabileceği yönündeki hipotezi desteklemiş, literatürdeki uzun dönemli analizlerin önemine dikkat çeken Bawden vd. (2001) ve Chaussard vd. (2017) gibi çalışmalarla paralellik göstermiştir.

Yerkabuğu hareketi zaman serilerinin geleceğe yönelik tahmini amacıyla test edilen beş farklı derin öğrenme mimarisinin (LSTM, GRU, TCN, CNN ve Transformer) tamamı, tek adımlı (10. yıl) tahminlerde genel olarak yüksek bir başarıya ulaşmıştır. Çizelge 4.1'deki metriklerin de ortaya koyduğu gibi, tüm modeller $R^2 > 0.92$ değeriyle gözlemlenen varyansın büyük bir bölümünü açıklayabilmiştir. Bu modeller arasında, zaman serilerindeki yerel örüntüleri yakalama kabiliyeti sayesinde en düşük hata metriklerine (MAE: 0.4490 mm/yıl) ve en yüksek R^2 (0.9611) katsayısına ulaşan CNN mimarisi, en başarılı sonuçları vermiştir. LSTM, GRU ve TCN modelleri de CNN'e yakın performans sergilerken, Transformer modelinin bu görevde bir miktar daha yüksek hata oranları kaydetmesi, bu tür bir veri seti için diğer mimarilerin daha uygun olabileceğine işaret etmektedir. Elde edilen bu sonuçlar, PS-InSAR zaman serilerinin derin öğrenme ile modellenmesi üzerine yapılan ve özellikle tekrarlayan ağların etkinliğini vurgulayan önceki çalışmalarla (Zhang vd., 2019; Lyu vd., 2021) da genel bir uyum içerisinde.

Yinelemeli Çok Adımlı Tahmin (RMF) stratejisiyle 2025 ve 2026 yılları için üretilen gelecek projeksiyonları, test edilen tüm modellerin bölgedeki çökme eğiliminin devam edeceğini öngördüğünü ortaya koymuştur. Bununla birlikte, tahmin edilen hareket değerlerinin dağılımı ve yoğunlaştığı noktalar, modellerin yapısal farklılıklarına bağlı olarak değişkenlik göstermiştir. Örneğin, Transformer modelinin diğerlerine kıyasla daha çok tepeli (multimodal) bir dağılım üretmesi, farklı mimarilerin zaman serisindeki doğrusal olmayan dinamikleri geleceğe yansıtma biçimlerindeki çeşitliliği göstermektedir.

Metodolojik olarak bu çalışmanın gücü, 10 yıllık uzun bir dönemi kapsayan çift yörlü Sentinel-1A verilerinin kullanılması ve bu verilerden elde edilen zaman serilerinin beş farklı modern derin öğrenme mimarisiyle karşılaştırmalı olarak modellenmesinden gelmektedir. RMF stratejisinin uygulanması ise, yöntemin sadece

mevcut durumu analiz etme değil, aynı zamanda geleceğe yönelik anlamlı projeksiyonlar üretme potansiyelini de ortaya koymuştur.

Bununla birlikte, çalışmanın önemli kısıtlılıkları da mevcuttur. Bunlardan ilki, PS-InSAR tekniğinin doğası gereği bitki örtüsü yoğun alanlarda düşük performans göstermesi ve analizin yalnızca uydu bakış yönündeki (LOS) hareketi ölçmesidir. Daha da önemli bir kısıtlılık ise, yer kabuğu hareketlerini tetikleyebilecek yağış, yeraltı suyu seviyesi gibi yardımcı (exogenous) fiziksel parametrelerin modellere dahil edilmemiş olmasıdır. Nitekim, literatürdeki çalışmalar (Yağmur, 2023; Sun vd., 2022) bu tür verilerin tahmin doğruluğunu artırdığını göstermektedir. Son olarak, PS-InSAR ve derin öğrenme tahmin sonuçlarını doğrulamak için eş zamanlı yer kontrol verilerinin (GNSS, nivelman vb.) bulunmaması, sonuçların mutlak doğruluk yerine göreceli bir analiz sunduğu anlamına gelmektedir.

Çalışmanın en önemli metodolojik kısıtlılıklarından biri, derin öğrenme modellerinin eğitiminde yalnızca PS-InSAR'dan türetilen yer kabuğu hareket zaman serilerinin kullanılmasıdır. Yağış, yeraltı suyu seviyesi, kuyu pompaj miktarları, evaporasyon veya jeolojik birimlerin litolojik özellikleri gibi hareket süreçlerini doğrudan veya dolaylı olarak etkileyebilecek yardımcı (exogenous) değişkenlerin modellere dahil edilmemesi, yer kabuğu hareketlerinin çok değişkenli ve daha bütüncül bir analizini sınırlamıştır. Nitekim, Yağmur (2023) tarafından yapılan çalışmada, tahmin modellerine yağış ve sıcaklık gibi meteorolojik yardımcı verilerin dahil edilmesinin tahmin doğruluğunu önemli ölçüde artırabildiği gösterilmiştir. Gelecekte yapılacak çalışmalarda, Bolvadin bölgesine ait hidrojeolojik ve meteorolojik verilerin de modellere entegre edilmesi, daha bütüncül ve doğru sonuçlar üretebilir. Literatürde, bu tür ek fiziksel parametrelerin zaman serisi tahmin modellerinin performansını ve yorumlanabilirliğini önemli ölçüde artırabildiği gösterilmiştir (Sun vd., 2022; Chaussard vd., 2017). Bir diğer önemli kısıtlılık ise, çalışma alanında PS-InSAR sonuçlarını ve derin öğrenme tahminlerini doğrulamak için kullanılabilecek yeterli sayıda ve eş zamanlı yer kontrol verisinin (GNSS, nivelman vb.) bulunmamasıdır. Bu durum, elde edilen hareket değerlerinin ve tahminlerin mutlak doğrulukları yerine göreceli (relative) bir analiz sunduğu ve özellikle tahmin performanslarının kalibrasyonunda bir belirsizlik taşıdığı anlamına gelmektedir;

nitekim bu görelî analizîin yarattığı kalibrasyon belirsizliği, literatürde de bilinen bir sorundur (Crosetto vd., 2008).

Bu kısıtlılıklara rağmen, kullanılan veri setinin 10 yıllık uzun bir süreyi kapsaması, hem alçalan hem de yükselen yörüngelerden veri kullanılması, PS-InSAR işleme adımlarının detaylı bir şekilde uygulanması ve beş farklı derin öğrenme mimarisinin sistematik bir yaklaşımla test edilmesi, elde edilen bulguların bilimsel temelini güçlendirmektedir.

Uzun dönemli ve çift yörüngeli PS-InSAR analizinin kırsal alanda uygulanması literatürde PS-InSAR çalışmaları sıklıkla kentsel alanlara odaklansa da (Crosetto vd., 2016 ; Ferretti vd., 2011), bu çalışma Bolvadin Ovası gibi tarımsal faaliyetlerin ve yeraltı suyu kullanımının yoğun olduğu kırsal bir alanda, 10 yıllık (2015-2024) gibi uzun bir dönemi kapsayan Sentinel-1A verileriyle hem alçalan hem de yükselen yörüngelerden elde edilen toplam 240 SAR görüntüsü kullanarak detaylı bir yer kabuğu hareketi analizi sunmaktadır. Bu, literatürde genellikle daha kısa zaman aralıklarıyla (Zhang vd., 2019) veya tek yörüngeyle sınırlı kalan çalışmalara kıyasla, hareket eğilimlerinin dönemsel doğasının ve güvenilirliğinin daha iyi ortaya konulmasına olanak tanımıştır.

PS-InSAR ile üretilen zaman serilerinin geleceğe yönelik tahmini için LSTM, GRU, TCN, CNN ve Transformer olmak üzere beş farklı modern derin öğrenme mimarisi karşılaştırmalı olarak değerlendirilmiştir. Bu modellerin tek adımlı (10 yıllık hareket) ve Yinelemeli Çok Adımlı Tahmin (RMF) stratejisiyle çok adımlı (11 yıllık hareket, 12 yıllık hareket) tahmin performanslarının incelenmesi, SAR tabanlı yer kabuğu hareket verilerinin sadece geçmişi analiz etmekle kalmayıp, geleceğe yönelik kestirimsel analizlerde de etkin bir şekilde kullanılabileceğini göstermiştir (Li vd., 2021; Sun vd., 2022). Özellikle kırsal bölgelerdeki doğal süreçlerle (örneğin hidrojeolojik etkiler) ilişkili hareketlerin derin öğrenme ile tahmini, literatürde henüz daha az çalışılmış bir alandır.

Tezin amaçlarından biri olan uzun dönemli veri setleriyle model performansının karşılaştırılması, derin öğrenme uygulamalarında model güvenilirliği açısından önemli

olan bu faktöre dikkat çekmektedir. Bu tür bir analiz, gelecekteki çalışmalarda kullanılacak veri miktarı ve modelleme stratejileri için yol gösterici olabilir.

Bolvadin gibi orta ölçekli bir kırsal havzada, yeraltı suyu çekimine bağlı olduğu düşünülen zemin çökmelerinin hem uzun dönemli PS-InSAR teknikleriyle detaylı bir şekilde izlenmesi hem de çeşitli derin öğrenme yaklaşımlarıyla geleceğe yönelik tahminlerinin yapılması, bölgesel literatüre önemli ve özgün bir katkı sağlamaktadır.

PS-InSAR ve derin öğrenme entegrasyonuna dayalı bu bütüncül yaklaşım, benzer jeolojik ve hidrojeolojik koşullara sahip diğer alanlardaki yüzey hareketleri problemlerinin incelenmesi ve gelecekteki risklerin değerlendirilmesi için bir model oluşturabilir. Çalışma bulguları, sadece akademik bilgi üretimiyle sınırlı kalmayıp, aynı zamanda bölgesel planlama, altyapı güvenliği ve sürdürülebilir su kaynakları yönetimi gibi alanlarda karar vericiler için stratejik girdiler sunma potansiyeline sahiptir.

Elde edilen ana sonuçlar şu şekilde özetlenebilir. Bolvadin bölgesinde, özellikle ilçe merkezinin güney ve güneybatı kesimlerinde yılda -15 mm'ye ulaşan belirgin çökme hareketleri tespit edilmiştir. Bu çökme örüntüleri, bölgedeki yoğun tarımsal faaliyetler ve buna bağlı yeraltı suyu kullanımıyla güçlü bir mekansal ve zamansal ilişki göstermektedir. Test edilen beş derin öğrenme modeli de tek adımlı (10 yıllık hareket) hareket hızlarını yüksek bir doğrulukla ($R^2 > 0.92$) tahmin etme potansiyeli göstermiştir. Bu modeller arasında CNN, en düşük hata metrikleri ve en yüksek R^2 değeri ile en iyi performansı sergilemiştir. RMF stratejisi kullanılarak yapılan iki yıllık (11 yıllık hareket ve 12 yıllık hareket) gelecek projeksiyonları, bölgedeki genel çökme eğiliminin devam edeceğini öngörmekle birlikte, farklı modellerin tahmin dağılımları ve coğrafi örüntüleri arasında belirli farklılıklar ortaya koymuştur. Çalışma, uzun dönemli PS-InSAR verilerinin ve çeşitli derin öğrenme mimarilerinin, yeraltı suyu kaynaklı zemin çökmelerinin anlaşılması ve gelecekteki davranışlarının tahminlenmesi için güçlü bir entegre yaklaşım sunduğunu göstermiştir.

Bu bulgular ışığında, hem bilimsel araştırmalara hem de pratik uygulamalara yönelik çeşitli öneriler geliştirilebilir. Bolvadin Belediyesi, DSİ Bölge Müdürlüğü ve İl Özel

İdaresi gibi kurumların, bu çalışmada belirlenen aktif çökme alanlarını ve geleceğe yönelik olası risklerini, altyapı planlaması (yol, bina, kanalizasyon vb.), kentsel gelişim stratejileri ve özellikle tarımsal sulama amaçlı yeraltı suyu kullanımının yönetimi politikalarında dikkate almaları büyük önem taşımaktadır. Yoğun çökme gözlemlenen ve öngörülen bölgelerde, kritik altyapıların (okullar, hastaneler, kamu binaları) düzenli olarak jeodezik ve jeoteknik yöntemlerle izlenmesi ve gerekirse güçlendirme çalışmalarının yapılması önerilir. Sürdürülebilir yeraltı suyu yönetimi planlarının hayata geçirilmesi, alternatif sulama tekniklerinin teşvik edilmesi ve kaçak kuyuların önlenmesi, uzun vadede zemin çökmelerinin kontrol altına alınması için kritik adımlardır.

Gelecekteki çalışmalarda, derin öğrenme modellerine yeraltı suyu seviyesi değişimleri, kuyu pompaj verileri, yağış miktarları, evaporasyon, toprak özellikleri ve detaylı litolojik birimler gibi yardımcı değişkenlerin de girdi olarak dahil edilmesi, modellerin tahmin doğruluğunu ve yorumlanabilirliğini önemli ölçüde artırabilir. Ayrıca PS-InSAR sonuçlarının ve derin öğrenme tahminlerinin, bölgede kurulacak sürekli GNSS istasyonları veya periyodik nivelman ölçümleri gibi yer bazlı doğrulama verileriyle kalibre edilmesi ve karşılaştırılması, modellerin mutlak doğruluklarının değerlendirilmesi açısından faydalı olacaktır.

Sonuç olarak, bu doktora tezi, Bolvadin örneğinde Sentinel-1A PS-InSAR verileri ve çeşitli derin öğrenme algoritmalarını birleştirerek yeraltı suyu çekimiyle ilişkili zemin çökmelerinin uzun dönemli analizini ve geleceğe yönelik çok adımlı tahminini başarıyla gerçekleştirmiştir. Ortaya konulan bulgular ve metodolojik yaklaşım, hem ilgili bilimsel literatüre katkı sunmakta hem de bölgesel ölçekte sürdürülebilir kaynak yönetimi ve afet risk azaltma çalışmalarına önemli bir bilimsel zemin sağlamaktadır.

6. KAYNAKLAR

- Ansari H, De Zan F, Bamler R, 2020, Efficient phase estimation for interferogram stacks, *IEEE Transactions on Geoscience and Remote Sensing*, 58, 4604–4616.
- Bai S, Kolter J Z, Koltun V, 2018, An Empirical Evaluation of Generic Convolutional and Recurrent Networks for Sequence Modeling, *arXiv*, 1803.01271.
- Bandara K, Bergmeir C, Smyl S, 2021, Forecasting across time series databases using recurrent neural networks on groups of similar series: A clustering approach, *Expert Systems with Applications*, 140, Article number 112896.
- Bawden G W, Thatcher W, Stein R S, Hudnut K W, Peltzer G, 2001, Tectonic contraction across Los Angeles after removal of groundwater pumping effects, *Nature*, 412, 812–815.
- Berardino P, Fornaro G, Lanari R, Sansosti E, 2002, A new algorithm for surface deformation monitoring based on small baseline differential SAR interferograms, *IEEE Transactions on Geoscience and Remote Sensing*, 40, 2375–2383.
- Bergmeir C, Benítez J M, 2012, On the use of cross-validation for time series predictor evaluation, *Information Sciences*, 191, 192–213.
- Brownlee J, 2018, Deep Learning for Time Series Forecasting, *Machine Learning Mastery*.
- Chai T, Draxler R R, 2014, Root mean square error (RMSE) or mean absolute error (MAE)?—Arguments against avoiding RMSE in the literature, *Geoscientific Model Development*, 7, 1247–1250.
- Cho K, Van Merriënboer B, Gulcehre C, vd., 2014, Learning Phrase Representations using RNN Encoder-Decoder for Statistical Machine Translation, *Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP)*, 25-29 Ekim, Doha, Katar, 1724-1734.

- Chaussard E, Amelung F, Abidin H, Hong S-H, 2014, Sinking cities in Indonesia: ALOS PALSAR detects rapid subsidence due to groundwater and gas extraction, *Remote Sensing of Environment*, 128, 150–161.
- Chaussard E, Bürgmann R, Shirzaei M, Fielding E J, Baker B, 2017, Predictability of land subsidence due to groundwater withdrawal, *Geophysical Research Letters*, 44, 10223–10231.
- Cheng S, Wei L, Chang S, 2006, A new methodology for multi-step-ahead time series prediction based on an auto-regressive (AR) model and a radial basis function neural network (RBFNN), *Journal of the Chinese Institute of Industrial Engineers*, 23, 421-430.
- Chollet F, 2017, *Deep Learning with Python*, Manning Publications.
- Crosetto M, Monserrat O, Crippa B, Castillo M, 2008, Persistent Scatterer Interferometry: Potential and Limitations, *Sensors*, 8, 5245-5262.
- Crosetto M, Monserrat O, Cuevas-González M, Devanthéry N, Crippa B, 2016, Persistent Scatterer Interferometry: A review, *ISPRS Journal of Photogrammetry and Remote Sensing*, 115, 78–89.
- Crosetto M, Monserrat O, Crippa B, Wagner W, 2008, Monitoring land subsidence using synthetic aperture radar interferometry: Some examples from Europe, *Remote Sensing of Environment*, 112, 167–174.
- Curlander J C, McDonough R N, 1991, *Synthetic Aperture Radar: Systems and Signal Processing*, John Wiley & Sons.
- DSİ, 2020, Yeraltı Suyu Seviye Raporları, Devlet Su İşleri Genel Müdürlüğü, Ankara.
- Duran B, Öztürk M, Geymen A, 2021, Investigation of land subsidence due to groundwater extraction using InSAR: A case study in Konya Plain, Turkey, *Arabian Journal of Geosciences*, 14, Article number 457.
- Emre Ö, Duman T Y, Özalp S, Elmacı H, 2018, *Türkiye Diri Fay Haritası*, MTA Genel Müdürlüğü, Ankara.

- Erban L E, Gorelick S M, Zebker H A, 2014, Groundwater extraction, land subsidence, and sea-level rise in the Mekong Delta, Vietnam, *Environmental Research Letters*, 9, Article number 084010.
- Ferretti A, Prati C, Rocca F, 2000, Nonlinear subsidence rate estimation using permanent scatterers in differential SAR interferometry, *IEEE Transactions on Geoscience and Remote Sensing*, 38, 2202–2212.
- Ferretti A, Prati C, Rocca F, 2001, Permanent scatterers in SAR interferometry, *IEEE Transactions on Geoscience and Remote Sensing*, 39, 8–20.
- Ferretti A, Prati C, Rocca F, 2011, *Radar Interferometry: Persistent Scatterer Technique*, Springer.
- Gabriel A K, Goldstein R M, Zebker H A, 1989, Mapping small elevation changes over large areas: Differential radar interferometry, *Journal of Geophysical Research: Solid Earth*, 94, 9183–9191.
- Galloway D L, Burbey T J, 2011, Regional land subsidence accompanying groundwater extraction, *Hydrogeology Journal*, 19, 1459–1486.
- Galloway D L, Jones D R, Ingebritsen S E, 1999, Land subsidence in the United States, U.S. Geological Survey Circular 1182, 177s, Reston, Virginia..
- Gambolati G, Teatini P, 2015, Groundwater withdrawal, land subsidence and sea level rise in the Venice Lagoon, *Environmental Earth Sciences*, 73, 4123–4136.
- Geymen A, Baz I, 2008, Monitoring urban growth and detecting land-cover changes on the Istanbul metropolitan area, *Environmental Monitoring and Assessment*, 136, 449–459.
- Girardone M, Taieb S B, Goude Y, 2023, Recursive and direct multi-step forecasting: The best of both worlds, *International Journal of Forecasting*, 39, 1734-1753.
- Goldstein R M, Werner C L, 1998, Radar interferogram filtering for geophysical applications, *Geophysical Research Letters*, 25, 4035–4038.
- Goodfellow I, Bengio Y, Courville A, 2016, *Deep Learning*, MIT Press.
- Hanssen R F, 2001, *Radar Interferometry: Data Interpretation and Error Analysis*, Springer.

- Henderson F M, Lewis A J, 1998, Principles and Applications of Imaging Radar, Manual of Remote Sensing, Volume 2, John Wiley & Sons.
- Hewamalage H, Bergmeir C, Bandara K, 2021, Recurrent neural networks for time series forecasting: Current status and future directions, *International Journal of Forecasting*, 37, 388–427.
- Hochreiter S, Schmidhuber J, 1997, Long short-term memory, *Neural Computation*, 9, 1735–1780.
- Holzer T L, 1984, Ground failure induced by ground-water withdrawal from unconsolidated sediment, *Reviews in Engineering Geology*, 6, 67–105.
- Hooper A, 2008, A multi-temporal InSAR method incorporating both persistent scatterer and small baseline approaches, *Geophysical Research Letters*, 35, 16302.
- Hooper A, Bekaert D, Spaans K, Arikan M, 2007, Recent advances in SAR interferometry time series analysis for measuring crustal deformation, *Tectonophysics*, 514, 1–13.
- Hooper A, Segall P, Zebker H, 2007, Persistent scatterer interferometric synthetic aperture radar for crustal deformation analysis, with application to Volcán Alcedo, Galápagos, *Journal of Geophysical Research: Solid Earth*, 112.
- 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, 23611.
- Hyndman R J, Athanasopoulos G, 2018, *Forecasting: Principles and Practice* (2nd ed.), OTexts.
- Imamoglu M, Kahraman F, Cakir Z, Sanli F B, 2019, Ground Deformation Analysis of Bolvadin (W. Turkey) by Means of Multi-Temporal InSAR Techniques and Sentinel-1 Data, *Remote Sensing*, 11, 1069.
- Kampes B M, 2006, *Radar Interferometry: Persistent Scatterer Technique*, Springer.

- Kiranyaz S, Avci O, Abdeljaber O, Ince T, Gabbouj M, Inman D J, 2021, 1D convolutional neural networks and applications: A survey, *Mechanical Systems and Signal Processing*, 151, 107398.
- Kingma D P, Ba J L, 2015, Adam: A method for stochastic optimization, *International Conference on Learning Representations*.
- Latip A S A, Matori A, Aobpaet A, Din A H M, 2010, Monitoring of offshore platform deformation with Stanford method of Persistent Scatterer InSAR, *First Break*, 28, 29–37.
- LeCun Y, Bottou L, Bengio Y, Haffner P, 1998, Gradient-based learning applied to document recognition, *Proceedings of the IEEE*, 86, 2278-2324.
- Li W, Du Y, Liu X, 2021, Deep Learning for Spatiotemporal Prediction of Surface Subsidence Based on InSAR Time-Series Data, *Remote Sensing*, 13, Article number 33.
- Lundberg S M, Lee S-I, 2017, A unified approach to interpreting model predictions, *Advances in Neural Information Processing Systems* 30, 4765–4774.
- Lyu Y, Liu S, Zhu J, Wang Y, 2021, PS-InSAR time series prediction using LSTM neural networks, *Remote Sensing*, 13, Article number 2916.
- Martinis S, Plank S, Voigt S, 2016, SNAP and StaMPS integration for high-resolution PSI processing, *European Space Agency Proceedings*.
- Massonnet D, Souyris J-C, 2008, *Imaging with Synthetic Aperture Radar*, CRC Press.
- MTA, 2019, Türkiye Jeoloji Haritası ve 1:500.000 Ölçekli Levhalar, Maden Tetkik ve Arama Genel Müdürlüğü, Ankara.
- Osmanoglu B, Dixon T H, Wdowinski S, Cabral-Cano E, Jiang Y, 2011, Mexico City subsidence observed with persistent scatterer InSAR, *ISPRS Journal of Photogrammetry and Remote Sensing*, 66, 447–456.
- Poland J F, 1984, *Guidebook to studies of land subsidence due to ground-water withdrawal*, UNESCO Studies and Reports in Hydrology, 40, UNESCO, Paris.

- Potin P, Miranda N, Rosich B, Manunta P, Goryl G, Small D, Bignami C, Nagler T, Recchia A, 2016, Sentinel-1 Mission Status and System Performance, ESA Living Planet Symposium, May 9–13, Prague, Czech Republic.
- Samsonov S V, Tiampo K F, 2006, Analytical solution for modeling deformation due to a long dislocation in an elastic half-space, *Geophysical Research Letters*, 33, L04304.
- Scheiber R, Moreira A, 2000, Coregistration of interferometric SAR images using spectral diversity, *IEEE Transactions on Geoscience and Remote Sensing*, 38, 2179–2191.
- Serpelloni E, Zuliani D, Bonini L, 2023, Present-Day Surface Deformation in North-East Italy Using InSAR and GNSS Data, *Remote Sensing*, 15, Article number 1704.
- Sneed M, Brandt J T, Solt M, 2013, Land subsidence, groundwater levels, and geology in the Coachella Valley, California, 1993–2010, USGS Scientific Investigations Report 2013–5142, USGS, Reston, Virginia.
- Srivastava N, Hinton G, Krizhevsky A, Sutskever I, Salakhutdinov R, 2014, Dropout: A simple way to prevent neural networks from overfitting, *Journal of Machine Learning Research*, 15, 1929–1958.
- Sun Y, Zhang L, Liu C, Wu J, 2022, Integrating SAR-based InSAR time series and deep learning for subsidence prediction in mining areas, *Journal of Hydrology*, 604, Article number 127236.
- Taieb S B, Bontempi G, Sorjamaa A, Lendasse A, 2012, A review and comparison of strategies for multi-step ahead time series forecasting based on the NN5 forecasting competition, *Expert Systems with Applications*, 39, 7067–7083.
- Taieb S B, Sorjamaa A, Bontempi G, 2010, Long-term prediction of time series by combining direct and indirect strategies, *The 2010 International Joint Conference on Neural Networks*, 1-8.
- Torres R, Snoeij P, Geudtner D, Bibby D, Davidson M, vd., 2012, GMES Sentinel-1 mission, *Remote Sensing of Environment*, 120, 9–24.

- Vaswani A, Shazeer N, Parmar N, Uszkoreit J, Jones L, Gomez A N, vd., 2017, Attention is all you need, *Advances in Neural Information Processing Systems* 30, 5998–6008.
- Veci L, Lu J, Wong C, 2018, ESA SNAP–StaMPS integrated processing for Sentinel-1 persistent scatterer interferometry, *IGARSS 2018 - 2018 IEEE International Geoscience and Remote Sensing Symposium*, 22-27 July 2018, Valencia, Spain, 1364–1367.
- Willmott C J, Matsuura K, 2005, Advantages of the mean absolute error (MAE) over the root mean square error (RMSE) in assessing average model performance, *Climate Research*, 30, 79–82.
- Yague-Martinez N, Prats-Iraola P, Scheiber R, Wollstadt S, De Zan F, Geudtner D, 2016, Interferometric processing of Sentinel-1 TOPS data, *Procedia Computer Science*, 100, 870–877.
- Zhang L, Ding X, Lu Z, Wang H, 2019, Time series deformation prediction using a deep long short-term memory network, *IEEE Geoscience and Remote Sensing Letters*, 16, 1220–1224.
- Zhou D, Guo G, Liu Y, 2016, Response characteristics of land subsidence to groundwater withdrawal in multi-aquifer systems, *Hydrological Processes*, 30, 4316–4329.

İnternet Kaynakları

- 1- https://eski.jmo.org.tr/genel/bizden_detay.php?kod=7258, 10.03.2024
- 2- <https://cienciadedatos.net/documentos/py27-time-series-forecasting-python-scikitlearn.html>, 04.05.2024