

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

**INSAR VE MAKİNE ÖĞRENMESİ YÖNTEMLERİ KULLANILARAK YÜZEY
HAREKETLERİNİN ZAMAN SERİLERİ İLE MODELLENMESİ: İSTANBUL
HAVALİMANI ÖRNEĞİ**

DOKTORA TEZİ

Nur YAĞMUR

Geomatik Mühendisliği Anabilim Dalı

Geomatik Mühendisliği Programı

Tez Danışmanı: Prof. Dr. Nebiye MUSAOĞLU

MAYIS 2023

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

**INSAR VE MAKİNE ÖĞRENMESİ YÖNTEMLERİ KULLANILARAK YÜZEY
HAREKETLERİNİN ZAMAN SERİLERİ İLE MODELLENMESİ: İSTANBUL
HAVALİMANI ÖRNEĞİ**

DOKTORA TEZİ

**Nur YAĞMUR
(501182615)**

Geomatik Mühendisliği Anabilim Dalı

Geomatik Mühendisliği Programı

**Tez Danışmanı: Prof. Dr. Nebiye MUSAOĞLU
Eş Danışman: Prof. Dr. Erdal ŞAFAK**

MAYIS 2023

ISTANBUL TECHNICAL UNIVERSITY ★ GRADUATE SCHOOL

**TIME SERIES MODELING OF SURFACE MOVEMENTS USING INSAR AND
MACHINE LEARNING METHODS: THE CASE STUDY OF ISTANBUL
AIRPORT**

Ph.D. THESIS

**Nur YAĞMUR
(501182615)**

Department of Geomatics Engineering

Geomatics Engineering Programme

**Thesis Advisor: Prof. Dr. Nebiye MUSAOĞLU
Thesis Co-Advisor: Prof. Dr. Erdal ŞAFAK**

MAY 2023



İTÜ, Lisansüstü Eğitim Enstitüsü'nün 501182615 numaralı Doktora Öğrencisi Nur YAĞMUR, ilgili yönetmeliklerin belirlediği gerekli tüm şartları yerine getirdikten sonra hazırladığı “INSAR VE MAKİNE ÖĞRENMESİ YÖNTEMLERİ KULLANILARAK YÜZEY HAREKETLERİNİN ZAMAN SERİLERİ İLE MODELLENMESİ: İSTANBUL HAVALİMANI ÖRNEĞİ” başlıklı tezini aşağıda imzaları olan jüri önünde başarı ile sunmuştur.

Tez Danışmanı : **Prof. Dr. Nebiye MUSAOĞLU**
İstanbul Teknik Üniversitesi

Eş Danışman : **Prof. Dr. Erdal ŞAFAK**
Boğaziçi Üniversitesi

Jüri Üyeleri : **Prof. Dr. Esra ERTEN**
İstanbul Teknik Üniversitesi

Doç. Dr. Gülşen TAŞKIN KAYA
İstanbul Teknik Üniversitesi

Prof. Dr. Özer ÇİNİCİOĞLU
Boğaziçi Üniversitesi

Prof. Dr. Şinasi KAYA
İstanbul Teknik Üniversitesi

Prof. Dr. Füsun BALIK ŞANLI
Yıldız Teknik Üniversitesi

Teslim Tarihi : 12 Nisan 2023
Savunma Tarihi : 30 Mayıs 2023





Canım aileme ve sevdiklerime,



ÖNSÖZ

Gerek tez çalışmam süresince gerek akademik kariyerimin başından itibaren benden desteklerini esirgemeyen, bilgi ve deneyimleriyle beni yönlendiren ve motive eden kıymetli danışman hocam Prof. Dr. Sayın Nebiye MUSAOĞLU'na ve kıymetli fikirleriyle yol gösteren eş danışmanım Prof. Dr. Sayın Erdal ŞAFAK'a teşekkürlerimi sunuyorum. Doktora tezimin oluşmasında katkı sağlayan, çok değerli görüş ve önerileri için kıymetli tez komite üyelerim Prof. Dr. Esra ERTEN, Prof. Dr. Özer ÇİNİCİOĞLU ve Doç. Dr. Gülşen TAŞKIN KAYA'ya teşekkürlerimi sunuyorum.

Akademik hayatıma başlangıç dönemimden beri yanımda olan ve destekleyen İstanbul Teknik Üniversitesi ve Gebze Teknik Üniversitesi öğretim üyelerine ve değerli çalışma arkadaşlarıma teşekkürü bir borç bilirim. Ayrıca yolumun kesiştiği, destek olan ve olmayan tüm akademisyenlere de bana kattıkları tecrübeler için teşekkür ederim. Bu yolda desteğini hiç esirgmeden hem akademisyen hem de anne şefkatiyle yanımda olan Dr. Öğretim Üyesi Adalet DERVİŞOĞLU'na çok teşekkür ederim. Hem meslektaşım olarak hem de dostluklarıyla beni onurlandıran arkadaşlarım Ceren CİHAN SOYSAL ve Merve Gizem YAVUZ ÇIRAK'a desteklerinden dolayı gönülden teşekkür ederim. Gebze Teknik Üniversitesi'nin bana kazandırdığı, dostluğu ve desteğiyle hep yanımda olan ve geleceğinin parlak olduğundan hiç şüphe duymadığım değerli akademisyen Arş. Gör. İlyas AYDIN'a içtenlikle teşekkür ederim.

Tüm eğitim öğretim hayatım boyunca bana hep güvenen, bana dair inançlarıyla yolumu aydınlatan ve beni cesaretlendiren canım anneme ve canım babama sonsuz teşekkürlerimi sunuyorum, ki yine de haklarını ödeyemeyeceğimi biliyorum. Size layık bir evlat olmak için elimden geleni yapıyorum ve tüm hayatım boyunca yapmaya devam edeceğim. Beni akademisyen olmaya teşvik eden ve doğduğumdan beri elimi bırakmayan canım abim Özgür YAĞMUR ile canım ablam Özge YAĞMUR'a ve doğduğundan beri elini bırakmadığım, sevgisini hiç esirgemeyen canım kardeşim M. Dılşad YAĞMUR'a hep yanımda oldukları için teşekkür ediyorum, iyi ki varsınız. Ailemizin birer ferdi olan minik dostlarımız Kekik, Nane ve Karam'a da sevgi ve sadakatleriyle bizi ailesi olarak seçerek kalbimizi ısıttıkları için teşekkür ediyorum.

Uydu görüntü desteğiyle tez çalışmama katkı sağlayan İstanbul Teknik Üniversitesi Uydu Haberleşme ve Uzaktan Algılama Merkezi (UHUZAM)'ne sağladıkları Pleiades uydu görüntüleri için teşekkür ederim. Bu tez çalışması, İstanbul Teknik Üniversitesi MDK-2021-43006 numaralı Bilimsel Araştırma Projesi kapsamında desteklenmiştir.

Mayıs 2023

Nur YAĞMUR
(Yüksek Geomatik Mühendisi)



İÇİNDEKİLER

Sayfa

ÖNSÖZ.....	ix
İÇİNDEKİLER	xi
KISALTMALAR	xiii
SEMBOLLER	xv
ÇİZELGE LİSTESİ.....	xvii
ŞEKİL LİSTESİ.....	xix
ÖZET.....	xxiii
SUMMARY	xxvii
1. GİRİŞ	1
1.1 Tezin Amacı	4
1.2 Literatür Araştırması	7
2. YAPAY AÇIKLIKLI RADAR VE INTERFEROMETRİ TEKNİKLERİ....	15
2.1 SBAS INSAR.....	16
2.2 PSINSAR	19
2.3 Yatay ve Düşey Yöndeki Hareketlerin Belirlenmesi	20
3. UYDU GÖRÜNTÜLERİNİN SINIFLANDIRILMASI VE DEĞİŞİM ANALİZİ.....	23
3.1 Kontrollü Sınıflandırma	23
3.2 Tematik Doğruluk Değerlendirmesi.....	25
4. STEREO GÖRÜNTÜ ÇİFTİ KULLANILARAK SAYISAL YÜKSEKLİK MODELİ ÜRETİMİ	27
5. DEFORMASYON ZAMAN SERİLERİNİN GELECEK TAHMİN ANALİZİ.....	31
5.1 Zaman Serilerini Bileşenlerine Ayırıştırma.....	31
5.2 Geleneksel Yöntemler	32
5.2.1 ARIMA (AutoRegressive Integrated Moving Average).....	32
5.2.2 Hızlı fourier dönüşümü (Fast Fourier Transform-FFT).....	32
5.3 Regresyon Tabanlı Yöntemler.....	34
5.3.1 Rastgele orman regresyon	35
5.3.2 Destek vektör regresyon.....	36
5.3.3 Aşırı gradyan arttırma (XGBoost) regresyon.....	36
5.3.4 CatBoost regresyon metodu	37
5.4 Derin Öğrenme Yöntemleri.....	37
5.5 Tahmin Modellerinin Doğruluk Değerlendirmesi.....	39
5.6 Özniteliklerin Önem Derecelerinin Belirlenmesi	40
5.6.1 Permütasyon öznitelik önemi.....	40
5.6.2 SHAP (SHapley Additive exPlanations).....	40
6. ÇALIŞMA ALANI VE KULLANILAN VERİLER.....	41
6.1 Çalışma Alanı ve Özellikleri	41
6.2 Kullanılan Veriler.....	44

6.2.1 Optik uydu verileri	44
6.2.2 SAR uydu verileri.....	46
6.2.3 Meteorolojik veriler.....	47
7. YÜZEY HAREKETLERİNİN SEBEP-SONUÇ İLİŞKİLERİ ÇERÇEVESİNDE BELİRLENEREK ZAMAN SERİLERİ İLE MODELLENMESİ.....	49
7.1 Çalışma Alanının Sınıflandırılması ve Değişim Analizi	49
7.2 INSAR Zaman Serisi Analiz Sonuçları	51
7.2.1 SBAS zaman serisi analizi	51
7.2.2 PSInSAR zaman serisi analizi.....	56
7.2.3 PSInSAR zaman serilerinin bileşenlerine ayrılması	67
7.3 SYM Üretimi ve Kazı-Dolgu Alanlarının Belirlenmesi.....	69
7.4 Deformasyon Zaman Serilerinin Tahmin Analizi	72
7.4.1 ARIMA ile tahmin analizi.....	74
7.4.2 FFT ile tahmin analizi	77
7.4.3 Regresyon tabanlı yöntemler ile tahmin analizi.....	80
7.4.3.1 1. bölge analiz sonuçları.....	80
7.4.3.2 2. bölge analiz sonuçları.....	82
7.4.3.3 3. bölge analiz sonuçları.....	85
7.4.3.4 4. bölge analiz sonuçları.....	87
7.4.3.5 5. bölge analiz sonuçları.....	89
7.4.3.6 6. bölge analiz sonuçları.....	91
7.4.4 LSTM ile tahmin analizi	93
7.4.5 Tüm bölgelerde en uygun modelin seçilmesi.....	99
7.4.6 Özniteliklerin tahmin analizlerine katkısı ve önem derecelerinin belirlenmesi	101
7.4.6.1 1. bölgede yardımcı verilerin etkisi.....	101
7.4.6.2 2. bölgede yardımcı verilerin etkisi.....	104
7.4.6.3 3. bölgede yardımcı verilerin etkisi.....	107
7.4.6.4 4. bölgede yardımcı verilerin etkisi.....	110
7.4.6.5 5. bölgede yardımcı verilerin etkisi.....	113
7.4.6.6 6. bölgede yardımcı verilerin etkisi.....	116
7.4.7 Pilot bölgelerin gelecek tahmin analizi	119
8. SONUÇLAR	129
KAYNAKLAR.....	137
ÖZGEÇMİŞ.....	153

KISALTMALAR

ADF	: Augmented Dickey-Fuller
API	: Application Program Interface
ARIMA	: AutoRegressive Integrated Moving Average
ASTER	: Advanced Spaceborne Thermal Emission and Reflection Radiometer
CBR	: CatBoost Regresyon
ÇED	: Çevresel Etki Değerlendirmesi
DFT	: Discrete Fourier Transform
DINSAR	: Differential InSAR
EM	: Elektromanyetik
ESA	: European Space Agency
ETM+	: Enhanced Thematic Mapper Plus
FFT	: Fast Fourier Transform
GBDT	: Gradient Boosting Decision Tree
GDEM	: Global Digital Elevation Map
GDT	: Geriye Dönük Test
GEE	: Google Earth Engine
GNSS	: Global Navigation Satellite System
HDS	: Homogeneous Distributed Scatterer
InSAR	: Interferometrik SAR
IPTA	: Interferometric Point Target Analysis
ISBAS	: Intermittent Small Baseline Subset
IW	: Interferometric Wide Swath
JMO	: Jeoloji Mühendisleri Odası
LiCSAR	: Looking Into Continents from Space with Synthetic Aperture Radar
LiCSBAS	: Looking Inside The Continents From Space SBAS
LOS	: Line of Sight
LSTM	: Long Short Term Memory
MAE	: Mean Absolute Error
MGM	: Meteoroloji Genel Müdürlüğü
MSS	: Multispectral Scanner System
OLI	: Operational Land Imager
PAT	: Pist, Apron ve Taksirut
PSI	: Persistent Scatterers InSAR
RF	: Random Forest
RFR	: Random Forest Regression
RMF	: Recursive Multi-Step Forecasting
RMSE	: Root Mean Square Error
RNN	: Recurrent Neural Network
RPC	: Rational Polynomial Coefficient
SAR	: Synthetic Aperture Radar
SBAS	: Small Baseline Subset
SHAP	: SHapley Additive exPlanations

SHGM	: Sivil Havacılık Genel Müdürlüğü
SHM	: Structural Health Monitoring
SNAP	: Sentinel Application Platform
SRTM	: Shuttle Radar Topography Mission
SVD	: Singular Value Decomposition
SVR	: Support Vector Regression
SYM	: Sayısal Yükseklik Modeli
TM	: Thematic Mapper
TMMOB	: Türk Mühendis ve Mimar Odaları Birliği
TS-InSAR	: Time Series InSAR
UHUZAM	: Uydu Haberleşme ve Uzaktan Algılama Merkezi
VH	: Vertical-Horizontal
VV	: Vertical-Vertical
XGBR	: XGBoost Regresyon



SEMBOLLER

B_n	: Öncül Görüntüye Göre Normal Baz Uzaklığı
$D_{yük}, D_{dalç}$	: LOS Yönündeki Deformasyon
r	: Hedef Hareketi
T	: Öncül Görüntüye Göre Zamansal Baz Uzaklığı
α	: Atmosferik Faz Katkısı
$\alpha_{dalç, yük}$	: Uydu Başucu Açısı
$\Delta \varepsilon$	: PS Noktalarına Göre Sayısal Yükseklik Modelindeki Hata Farkı
$\Delta \phi$	: Faz Farkı
$\theta_{dalç, yük}$	: Geliş Açısı
v	: Ortalama Faz Hızı
n	: Dekorelasyon Gürültüsü
λ	: Dalga Boyu
ϕ	: Faz
$\phi_{topo-res}$	: Topografik Faz Katkısı



ÇİZELGE LİSTESİ

Sayfa

Çizelge 1.1	: Literatürde InSAR ile çalışmaların gerçekleştirildiği havalimanları ve çalışma detayları.	8
Çizelge 5.1	: Tahmin doğruluklarının belirlenmesinde kullanılan hata metrikleri. .	39
Çizelge 6.1	: Kullanılan veriler ve kullanım amaçları.	44
Çizelge 6.2	: Landsat uydu görüntülerinin teknik bilgileri.	45
Çizelge 6.3	: Pleiades uydu görüntülerinin teknik bilgileri.	46
Çizelge 6.4	: Sentinel-1 SAR uydu görüntülerinin teknik bilgileri.	46
Çizelge 6.5	: Meteorolojik parametreler ve temin edilen istasyon bilgileri.....	47
Çizelge 7.1	: Tematik doğruluk değerlendirme sonuçları.....	50
Çizelge 7.2	: Kullanılan Sentinel-1 uydu görüntülerinin tarih aralığı ve görüntü sayıları.....	56
Çizelge 7.3	: Kullanılan Sentinel-1 uydu yörüngelerinin geliş ve uydu başucu açıları.	65
Çizelge 7.4	: Pilot bölgelerde bulunan PS noktalarının detayları.	73
Çizelge 7.5	: ADF test sonuçları.	75
Çizelge 7.6	: Altı bölgenin seçilen ARIMA modellerine göre doğruluk değerlendirmesi sonuçları.	76
Çizelge 7.7	: Altı bölgenin seçilen FFT modellerine göre doğruluk değerlendirmesi sonuçları.	78
Çizelge 7.8	: 1. Bölge için regresyon tabanlı algoritmaların doğruluk değerlendirmesi sonuçları.	81
Çizelge 7.9	: 2. Bölge için regresyon tabanlı algoritmaların doğruluk değerlendirmesi sonuçları.	83
Çizelge 7.10	: 3. Bölge için regresyon tabanlı algoritmaların doğruluk değerlendirmesi sonuçları.	85
Çizelge 7.11	: 4. Bölge için regresyon tabanlı algoritmaların doğruluk değerlendirmesi sonuçları.	87
Çizelge 7.12	: 5. Bölge için regresyon tabanlı algoritmaların doğruluk değerlendirmesi sonuçları.	89
Çizelge 7.13	: 6. bölge için regresyon tabanlı algoritmaların doğruluk değerlendirmesi sonuçları.	91
Çizelge 7.14	: Altı bölgenin LSTM modellerine göre doğruluk değerlendirmesi sonuçları.	93
Çizelge 7.15	: Uygulanan bütün modellerin doğruluk değerlendirme sonuçlarının özet tablosu.	99
Çizelge 7.16	: 1. bölgede tek değişkenli ve çok değişkenli tahmin analizi sonuçları.	102
Çizelge 7.17	: 2. bölgede tek değişkenli ve çok değişkenli tahmin analizi sonuçları.	105

Çizelge 7.18 : 3. bölgede tek değişkenli ve çok değişkenli tahmin analizi sonuçları.....	108
Çizelge 7.19 : 4. bölgede tek değişkenli ve çok değişkenli tahmin analizi sonuçları.....	111
Çizelge 7.20 : 5. bölgede tek değişkenli ve çok değişkenli tahmin analizi sonuçları.....	114
Çizelge 7.21 : 6. bölgede tek değişkenli ve çok değişkenli tahmin analizi sonuçları.....	117



ŞEKİL LİSTESİ

Sayfa

Şekil 1.1	: Havalimanlarında InSAR kullanımı üzerine Web of Science ve Scopus veri tabanlarında taranan dergilerde gerçekleştirilen çalışmaların yıllara göre dağılımı.	10
Şekil 1.2	: Havalimanlarında InSAR kullanımı üzerine gerçekleştirilen makalelerin dergilere ve yayın sayılarına göre dağılımı.	12
Şekil 1.3	: Havalimanlarında InSAR kullanımı üzerine gerçekleştirilen çalışmaların uydulara ve yıllara göre dağılımı.	12
Şekil 1.4	: Havalimanlarında üzerinde gerçekleştirilen InSAR çalışmalarında uygulanan yöntemlerin dağılımı.....	13
Şekil 2.1	: InSAR çalışma prensibi (Zhang ve diğ., 2023).....	16
Şekil 2.2	: LiCSBAS uygulanan işlem adımları.....	18
Şekil 2.3	: SNAP ve StaMPS ile uygulanan işlem adımları.....	20
Şekil 2.4	: Uydularda yükselen ve alçalan uydu yörüngelerinin gösterimi (URL-2).....	21
Şekil 2.5	: Uydu yörüngeleri ile deformasyon bileşenlerinin gösterimi.	22
Şekil 3.1	: RF algoritmasının çalışma prensibi.	24
Şekil 3.2	: Hata matrisi ve elemanları (Foody, 2002).	25
Şekil 4.1	: Stereo görüntü çiftinden SYM oluşturma (URL-4).	28
Şekil 4.2	: SYM üretiminde izlenen akış şeması.....	29
Şekil 5.1	: Serinin son 4 verisini tahmin edici olarak kullanarak geleceğe yönelik 3 adımı tahmin eden RMF diyagramı (URL-5).	34
Şekil 5.2	: Artan eğitim seti ve geriye dönük test prensibi (URL-6).	35
Şekil 5.3	: RFR adımlarının gösterimi (Graw ve diğ., 2021).	35
Şekil 5.4	: Lineer regresyon için SVR modelinin gösterimi (Parbat ve Chakraborty, 2020).....	36
Şekil 5.5	: XGBoost çalışma prensibi (Li ve diğ., 2022).	37
Şekil 5.6	: LSTM mimarisi (Xu ve Niu, 2018).	38
Şekil 6.1	: Çalışma alanı.....	41
Şekil 6.2	: İstanbul Havalimanı'nın yapım aşamaları.	42
Şekil 7.1	: Çalışma bölgesine ait kontrollü sınıflandırma sonuçları.	50
Şekil 7.2	: Arazi örtüsü/arazi kullanımının alansal olarak zamansal değişimi.....	51
Şekil 7.3	: Yükselen (a) ve alçalan (b) yörüngede LiCSBAS ile gerçekleştirilen interferogram ağları.....	52
Şekil 7.4	: LiCSBAS (a) yükselen ve (b) alçalan zaman serisi deformasyon sonuçları.	53
Şekil 7.5	: Yükselen yörüngede üretilen LiCSBAS zaman serisi üzerinde gösterilen (a) bölgelerin zaman serisi grafikleri (b).....	54
Şekil 7.6	: Yükselen (a) ve alçalan (b) yörüngede üretilen LiCSBAS deformasyon hızı standart sapma haritası.	55
Şekil 7.7	: Kasım 2018-Eylül 2022 zaman aralığı için üretilen (a) yükselen ve (b) alçalan zaman serilerinin baz uzaklığı grafikleri.....	56

Şekil 7.8	: Yükselen (a) ve alçalan (b) yörüngelerde elde edilen PSInSAR deformasyon hızı sonuçları.	58
Şekil 7.9	: Yükselen (a) ve alçalan (b) yörüngelerde elde edilen PSInSAR deformasyon hızı standart sapma sonuçları.....	59
Şekil 7.10	: Temmuz 2020-Eylül 2022 zaman aralığı için üretilen (a) yükselen ve (b) alçalan zaman serilerinin baz uzaklığı grafikleri.....	60
Şekil 7.11	: C pisti için PSInSAR yöntemiyle yükselen (a) ve alçalan (b) yörüngede gerçekleştirilen analiz sonuçları.	61
Şekil 7.12	: C pisti için PSInSAR yöntemiyle üretilen deformasyon hız sonuçlarının yükselen (a) ve alçalan (b) yörüngede standart sapmaları.....	63
Şekil 7.13	: Farklı dönemlerde elde edilen deformasyon sonuçlarının bölgelere göre zaman serisi gösterimleri: a) Kasım 2018-Eylül 2022, b) Temmuz 2020-Eylül 2022.	64
Şekil 7.14	: Kasım 2018-Eylül 2022 düşey hız bileşeni (a) ve Temmuz 2020-Eylül 2022 düşey hız bileşeni (b).....	65
Şekil 7.15	: A, B ve C pistlerinin düşey deformasyon hızı üzerinden alınan profilleri.....	67
Şekil 7.16	: Belirlenen zaman serisinin toplamsal ayrıştırma yöntemiyle elde edilen bileşenleri.	68
Şekil 7.17	: Trend bileşeni ve MGM'den alınan günlük ortalama sıcaklık verilerinin gösterimi.....	69
Şekil 7.18	: SRTM verisi (a) ve bölgenin durumunu gösteren 2014 yılı Google Earth görüntüsü (b).	70
Şekil 7.19	: 2016 yılına ait Pleiades stereo görüntü çiftinden üretilen SYM ve bölgenin durumunu gösteren Google Earth görüntüsü (b).....	71
Şekil 7.20	: Sayısal yükseklik modellerinin farkından üretilen kazı dolgu haritası.	71
Şekil 7.21	: Belirlenen pilot bölgeler ve konumları.	73
Şekil 7.22	: 1. Bölgenin otokorelasyon grafiği.....	74
Şekil 7.23	: Zaman serisinin 1. ve 2. derece fark grafiği ve farkın otokorelasyonu.	75
Şekil 7.24	: Sırasıyla altı pilot bölgeye uygulanan ARIMA ile tahmin analizi sonuçları.	76
Şekil 7.25	: Sırasıyla altı pilot bölgeye uygulanan ARIMA ile tahmin analizi sonuçları.	78
Şekil 7.26	: Sırasıyla altı pilot bölgeye uygulanan FFT ile tahmin analizi sonuçları.	81
Şekil 7.27	: 2. bölgeye uygulanan regresyon tabanlı algoritmalar ile tahmin analizi sonuçları, sırasıyla a) CBR, b) XGBR, c) RFR ve d) SVR.	84
Şekil 7.28	: 3. bölgeye uygulanan regresyon tabanlı algoritmalar ile tahmin analizi sonuçları, sırasıyla a) CBR, b) XGBR, c) RFR ve d) SVR.	86
Şekil 7.29	: 4. bölgeye uygulanan regresyon tabanlı algoritmalar ile tahmin analizi sonuçları, sırasıyla a) CBR, b) XGBR, c) RFR ve d) SVR.	88
Şekil 7.30	: 5. bölgeye uygulanan regresyon tabanlı algoritmalar ile tahmin analizi sonuçları, sırasıyla a) CBR, b) XGBR, c) RFR ve d) SVR.	90
Şekil 7.31	: 6. bölgeye uygulanan regresyon tabanlı algoritmalar ile tahmin analizi sonuçları, sırasıyla a) CBR, b) XGBR, c) RFR ve d) SVR.	92
Şekil 7.32	: 1. bölgeye uygulanan regresyon tabanlı algoritmalar ile tahmin analizi sonuçları, sırasıyla a) LSTM ve b) Bütünleşik LSTM.	95
Şekil 7.33	: 2. bölgeye uygulanan regresyon tabanlı algoritmalar ile tahmin analizi sonuçları, sırasıyla a) LSTM ve b) Bütünleşik LSTM.	95

Şekil 7.34	: 3. bölgeye uygulanan regresyon tabanlı algoritmalar ile tahmin analizi sonuçları, sırasıyla a) LSTM ve b) Bütünleşik LSTM.	96
Şekil 7.35	: 4. bölgeye uygulanan regresyon tabanlı algoritmalar ile tahmin analizi sonuçları, sırasıyla a) LSTM ve b) Bütünleşik LSTM.	97
Şekil 7.36	: 5. bölgeye uygulanan regresyon tabanlı algoritmalar ile tahmin analizi sonuçları, sırasıyla a) LSTM ve b) Bütünleşik LSTM.	97
Şekil 7.37	: 6. bölgeye uygulanan regresyon tabanlı algoritmalar ile tahmin analizi sonuçları, sırasıyla a) LSTM ve b) Bütünleşik LSTM.	98
Şekil 7.38	: Özniteliklerin 1. bölgede elde edilen deformasyon zaman serisi ile korelasyon grafiği.	102
Şekil 7.39	: Yardımcı veriler ile 1. bölgede tahmin analizi sonuçları a) XGBR ve b) Bütünleşik LSTM.	103
Şekil 7.40	: XGBR yöntemi üzerinden SHAP, Permütasyon Öznitelik Önemi ve XGBoost ağırlıklarının karşılaştırılması.	103
Şekil 7.41	: Bütünleşik LSTM yöntemi üzerinden Permütasyon Öznitelik Önemi ile belirlenen öznitelik ağırlıkları.	104
Şekil 7.42	: Özniteliklerin 2. bölgede elde edilen deformasyon zaman serisi ile korelasyon grafiği.	104
Şekil 7.43	: Yardımcı veriler ile 2. bölgede tahmin analizi sonuçları a) XGBR ve b) Bütünleşik LSTM.	105
Şekil 7.44	: XGBR yöntemi üzerinden 2. bölge için SHAP, Permütasyon Öznitelik Önemi ve XGBoost ağırlıklarının karşılaştırılması.	106
Şekil 7.45	: Bütünleşik LSTM yöntemi üzerinden 2. bölge Permütasyon Öznitelik Önemi ile belirlenen ağırlıklar.	107
Şekil 7.46	: Özniteliklerin 3. bölgede elde edilen deformasyon zaman serisi ile korelasyon grafiği.	107
Şekil 7.47	: Yardımcı veriler ile 3. bölgede tahmin analizi sonuçları a) XGBR ve b) Bütünleşik LSTM.	108
Şekil 7.48	: XGBR yöntemi üzerinden 3. bölge için SHAP, Permütasyon Öznitelik Önemi ve XGBoost ağırlıklarının karşılaştırılması.	109
Şekil 7.49	: Bütünleşik LSTM yöntemi üzerinden 3. bölge Permütasyon Öznitelik Önemi ile belirlenen ağırlıklar.	110
Şekil 7.50	: Özniteliklerin 4. bölgede elde edilen deformasyon zaman serisi ile korelasyon grafiği.	110
Şekil 7.51	: Yardımcı veriler ile 4. bölgede tahmin analizi sonuçları a) XGBR ve b) Bütünleşik LSTM.	111
Şekil 7.52	: XGBR yöntemi üzerinden 4. bölge için SHAP, Permütasyon Öznitelik Önemi ve XGBoost ağırlıklarının karşılaştırılması.	112
Şekil 7.53	: Bütünleşik LSTM yöntemi üzerinden 4. bölge Permütasyon Öznitelik Önemi ile belirlenen ağırlıklar.	113
Şekil 7.54	: Özniteliklerin 5. bölgede elde edilen deformasyon zaman serisi ile korelasyon grafiği.	113
Şekil 7.55	: Yardımcı veriler ile 5. bölgede tahmin analizi sonuçları a) XGBR ve b) Bütünleşik LSTM.	114
Şekil 7.56	: XGBR yöntemi üzerinden 5. bölge için SHAP, Permütasyon Öznitelik Önemi ve XGBoost ağırlıklarının karşılaştırılması.	115
Şekil 7.57	: Bütünleşik LSTM yöntemi üzerinden 5. bölge Permütasyon Öznitelik Önemi ile belirlenen ağırlıklar.	116
Şekil 7.58	: Özniteliklerin 6. bölgede elde edilen deformasyon zaman serisi ile korelasyon grafiği.	116

Şekil 7.59	: Yardımcı veriler ile 6. bölgede tahmin analizi sonuçları a) XGBR ve b) Bütünleşik LSTM.	117
Şekil 7.60	: XGBR yöntemi üzerinden 6. bölge için SHAP, Permütasyon Öznitelik Önemi ve XGBoost ağırlıklarının karşılaştırılması.	118
Şekil 7.61	: Bütünleşik LSTM yöntemi üzerinden 6. bölge Permütasyon Öznitelik Önemi ile belirlenen ağırlıklar.	119
Şekil 7.62	: 1. pilot bölge için a) ARIMA, b) FFT, c) XGBR ve d) Bütünleşik LSTM yöntemleriyle gelecek tahmin analizi.	119
Şekil 7.63	: 2. pilot bölge için a) ARIMA, b) FFT, c) XGBR ve d) Bütünleşik LSTM yöntemleriyle gelecek tahmin analizi.	121
Şekil 7.64	: 3. pilot bölge için a) ARIMA, b) FFT, c) XGBR ve d) Bütünleşik LSTM yöntemleriyle gelecek tahmin analizi.	122
Şekil 7.65	: 4. pilot bölge için a) ARIMA, b) FFT, c) XGBR ve d) Bütünleşik LSTM yöntemleriyle gelecek tahmin analizi.	123
Şekil 7.66	: 5. pilot bölge için a) ARIMA, b) FFT, c) XGBR ve d) Bütünleşik LSTM yöntemleriyle gelecek tahmin analizi.	124
Şekil 7.67	: 6. pilot bölge için a) ARIMA, b) FFT, c) XGBR ve d) Bütünleşik LSTM yöntemleriyle gelecek tahmin analizi.	126

INSAR VE MAKİNE ÖĞRENMESİ YÖNTEMLERİ KULLANILARAK YÜZEY HAREKETLERİNİN ZAMAN SERİLERİ İLE MODELLENMESİ: İSTANBUL HAVALİMANI ÖRNEĞİ

ÖZET

Ulaşım trafiğinin önemli bir bölümünü hava taşımacılığı oluşturmaktadır. Özellikle mega kentlerde yer alan ve hem ulusal hem de uluslararası taşımacılığı sağlayan havalimanları önemli bir konuma sahiptir. Yılda milyonlarca insanın yolculuk yapmasına olanak sağlayan bu havalimanlarında yapı sağlığı konusu kritik bir öneme sahip olup, yapı hasarlarının maliyetinin yanı sıra oluşabilecek kazalar sonrası yolcuların can güvenliği de dikkate alınması gereken bir diğer konudur. Bu sebeple, pist ve yapılarda meydana gelebilecek hasarlar sürekli olarak izlenerek, ihtiyaç duyulması halinde yapı iyileştirmeleri gerçekleştirilmelidir.

Yapı sağlığı izleme konusunda birçok yersel ölçme yöntemi mevcuttur. GNSS, nivelman, inklinometre vb. sıklıkla kullanılan yersel ölçme yöntemlerine örnek verilebilmektedir. Ancak bu ölçme yöntemleri hassas ölçü sağlasa dahi nokta tabanlı olup, alansal bilgi çıkarımında kullanılması bir hayli güçtür. Ciddi iş yükü gereksiniminin yanı sıra maliyet ve zaman gerektirmektedir. Uzaktan algılama yöntemleri, sürekli periyotlarda uydu görüntüsü sağlama ve geniş kapsama alanı ile bu konuda önemli bir boşluğu doldurmaktadır. Son yıllarda farklı sensörlere sahip birçok uydudan ücretsiz uydu görüntülerinin temin edilebilmesi sayesinde, uydu görüntüsünün mekânsal çözünürlüğüne bağlı olarak farklı detaylarda alansal bilgi çıkarımı sağlanabilmektedir.

Yapılarda veya arazi yüzeylerinde meydana gelen yüzey hareketlerinin alansal olarak belirlenmesinde yapay açıklıklı radar (Synthetic Aperture Radar-SAR) uydu görüntüleri sıklıkla kullanılmaktadır. Avrupa Uzay Ajansı'nın Sentinel-1 SAR uydu görüntülerini ücretsiz olarak servis etmesiyle, yapı sağlığı izlemelerinde interferometrik SAR (InSAR) analizleri sıklıkla uygulanmaya başlanmıştır. Yüzey hareketlerinin zaman içerisinde davranışlarını belirlemek ve izlemek için zaman serisi InSAR yöntemleri geliştirilmiştir. Sabit Saçıcı İnterferometri (Persistent Scatterer Interferometry-PSInSAR) ve Küçük Baz Altküme InSAR (Small Baseline Subset InSAR - SBAS) yöntemleri en çok kullanılan yöntemlerdendir.

Havalimanlarının uygun arazi eksikliği sebebiyle deniz dolgu alanlarına veya sulak alanların ıslah edilmesiyle elde edilen boş alanlara inşa edilmesi, son yıllarda yüzey hareketlerinin oluşmasına ve bu yüzey hareketlerinin zaman serisi InSAR yöntemleriyle izlenmesi çalışmalarına konu olmuştur. Bu havalimanlarının, Türkiye'de de benzer örnekleri görülmeye başlanmıştır. İstanbul Havalimanı, bulunduğu jeolojik konum ve kullanıma açıldıktan sonra ulaşım trafiğindeki rolü sebebiyle önemli bir yere sahiptir. Terkedilen açık kum ve kömür ocaklarının zaman içerisinde sularla dolmasıyla oluşan sulak alanlar ve rehabilite edilen ağaçlık alanlar üzerine İstanbul Havalimanı inşa edilmiştir. Sulak alanlar ıslah edilmiş ve dolgu malzemeleriyle doldurularak havalimanı inşaatına uygun konuma getirilmiştir. Yüklü

miktarda dolgu yapıldığı bilinen havalimanı, zemin oturması ve yoğun dış yükler sebebiyle yüzey hareketlerine karşı hassas durumdadır. Bu sebeple, çalışma alanı olarak İstanbul Havalimanı seçilmiştir.

Landsat optik uydu görüntüleri kullanılarak 1984-2020 yılları arasında beşer yıllık periyotlar ile çalışma alanı sınıflandırılmıştır. Sınıflandırma sonrası gerçekleştirilen tematik doğruluk değerlendirmesi sonucunda, sınıflandırmalar yüksek doğruluk değerleri ile gerçekleştirilmiştir. Sınıflandırma sonucunda 1984 yılından 2010 yılına kadar sulak alanların 10 kat arttığı ancak havalimanı inşaatı sonrası %50'sinden fazlasının yok edildiği tespit edilmiştir. Bitki örtüsü yaklaşık olarak %24 azalmış, açık alan sınıfı ise %7 artış göstermiştir.

Havalimanında meydana gelen yüzey hareketlerini belirlemek üzere LiCSBAS uygulama paketi ile SBAS yöntemi, SNAP ve StaMPS yazılımları ile PSInSAR yöntemleri uygulanmıştır. Havalimanının kullanıma açıldığı Kasım 2018 ile Eylül 2022 zaman aralığını kapsayan analizlerde, Sentinel-1 ücretsiz SAR görüntüleri kullanılmıştır. Hem yükselen hem de alçalan geometride gerçekleştirilen analiz sonuçlarının birbirine oldukça yakın sonuç verdiği tespit edilmiştir. SBAS ve PSI analiz sonuçlarının birbirini destekleyici sonuç vermesinin yanı sıra mekânsal çözünürlüklerinin farklı olması sebebiyle sonuçlar birbirini tamamlayıcı nitelikte olmuştur. Elde edilen sonuçlar doğrultusunda, B ve C pisti ile terminal binası arasında bulunan ve havalimanı inşaatı sebebiyle ıslah edilen 88,6 ha alana sahip sulak alanın olduğu bölgede çökme eğilimli deformasyon hareketi tespit edilmiştir. Bu bölgeye yakın olan pistlerde (B ve C pisti) ve terminal binasının kuzey kesimlerinde de benzer şekilde çökme eğilimli hareket görülmektedir. A pistinin kuzey kesimlerinde de çökme eğilimli negatif yönde hareket görülürken, terminal binası üzerinde, binanın güney kesimlerinde ve B pistinin güney kesimlerinde kabarma eğilimli pozitif yönde hareket görülmektedir.

Kasım 2018-Eylül 2022 süre zarfında C pistinin inşaatına başlanıp tamamlanarak kullanıma açılmasından dolayı, PSI yöntemiyle sabit saçıcı noktaları tespit edilememiştir. Bu sebeple, C pistinin kullanıma açıldığı Temmuz 2020-Eylül 2022 zaman aralığında PSI analizleri tekrarlanmış ve C pistinin inşa edildiği bölgede yer alan ıslah edilmiş ufak sulak alanın üzerinde çökme eğilimli negatif yönde hareket olduğu tespit edilmiştir. Hem alçalan hem yükselen yörüngede elde edilen analiz sonuçları kullanılarak uydu bakış yönünde elde edilen yüzey hareketleri düşey ve yatay bileşenlerine ayrılmıştır. Her iki yörüngede elde edilen sonuçların birbirine benzerlik göstermesi, hareketin düşey yönde olduğunun göstergesidir. Elde edilen düşey bileşen de bu durumu doğrulamaktadır. Yatay bileşenden ise anlamlı sonuçlar elde edilememiştir. Terminal binası üzerinden alınan zaman serisi bileşenlerine ayrılarak trend bileşeni, Meteoroloji Genel Müdürlüğü (MGM)'den alınan sıcaklık verisi ile ilişkilendirilmiş ve yüksek korelasyon elde edilmiştir. Bu durum, terminal binasının çatı malzemesinin genleşmeye meyilli olduğunu göstermiştir.

Sayısal yükseklik modelleri (SYM) kullanılarak havalimanı inşaatında kazı ve dolgu yapılan alanlar tespit edilmiştir. Havalimanı inşaatı öncesi topoğrafyayı ifade eden SYM, SRTM verisi ile sağlanmıştır. İnşaat sonrası topoğrafya ise stereo Pleiades görüntüleri ile 2 m mekânsal çözünürlükte oluşturulmuş ve SRTM verisinin mekânsal çözünürlüğü olan 30 m'ye yeniden örneklenmiştir. İki verinin farkının alınmasıyla elde edilen sonuçlar doğrultusunda 88,6 ha alana sahip büyük sulak alana ortalama 60 m dolgu yapıldığı tespit edilmiştir. Ayrıca elde edilen kazı ve dolgu alanlarının deformasyon sonuçlarıyla örtüştüğü tespit edilmiştir.

Yüzey hareketlerinin belirlenmesi sonrası, zaman serileriyle tahmin analizleri gerçekleştirilmiştir. Tahmin analizlerinde altı farklı pilot bölge, yapı türü ve zaman serisinin karakteristiğine bağlı olarak belirlenmiştir. Tahmin analizleri geleneksel yöntemler, regresyon tabanlı yöntemler ve derin öğrenme yöntemleriyle gerçekleştirilmiştir. Analiz sonuçlarında, geleneksel yöntemler lineer bir yaklaşım sunarak başarılı bir sonuç vermiştir. Regresyon tabanlı yöntemlerden ise XGBoost Regresyon (XGBR) algoritmasının bütün bölgelerde başarılı sonuç verdiği tespit edilmiştir. Derin öğrenme yöntemlerinde ise Bütünleşik LSTM (Long Short Term Memory-LSTM) yönteminin başarılı sonuç verdiği tespit edilmiştir.

Zaman serileri bileşenlerine (trend, mevsimsel etki, artık) ayrılarak, ERA5-Land meteorolojik parametreleri (hava sıcaklığı, toprak sıcaklığı, yağış ve buharlaşma) ile beraber tahmin analizlerine dahil edilmiş ve XGBR ile Bütünleşik LSTM algoritmaları kullanılarak bu özneliklerin tahmin analizlerine katkısı incelenmiştir. Analiz sonucunda, özneliklerin eklenmesinin tahmin doğruluğunu arttırdığı tespit edilmiştir. Her bölge için özneliklerin önem dereceleri her iki yöntem üzerinden de belirlenmiştir. XGBR yöntemi üzerinden SHAP (SHapley Additive exPlanations), permütasyon öznelik önemi yöntemleri ve algoritmanın kendi ağaç yapısını oluştururken kullandığı önem dereceleri ile, Bütünleşik LSTM yöntemi üzerinden ise permütasyon öznelik önemi yöntemi ile eklenen yedi özneliğin önem dereceleri belirlenmiştir. XGBR yöntemi ile elde edilen önem dereceleri bütün yöntemlerde benzerlik göstermiş ve trend ile artık parametrelerinin en önemli öznelikler arasında yer aldığı belirlenmiştir. Ancak kontrollü ilerlenmediği takdirde bu parametrelerin aşırı öğrenmeye sebebiyet verdiği tespit edilmiştir. Pist üzerinden alınan iki farklı zaman serisinde buharlaşma parametresi öne çıkarken, bina üzerinden alınan zaman serilerinde de hava sıcaklığı parametresinin öne çıktığı belirlenmiştir. Bütünleşik LSTM yöntemi üzerinden permütasyon öznelik önemi yöntemiyle belirlenen önem derecelerinde, trend bileşeni zaman serilerinin genelinde önemli öznelikler arasında yer almaktadır. Pist üzerinden alınan zaman serilerinde yağış parametresi öne çıkarken, bina üzerinden alınan çökme ve kabarma zaman serilerinde buharlaşma parametresi öne çıkmaktadır. Terminal binası özelinde incelendiğinde ise toprak sıcaklığının öne çıktığı belirlenmiştir.

Elde edilen sonuçlar doğrultusunda tahmin analizlerinde yapı türü, yapı malzemesi ve kullanılan yöntemlere göre sonuçların değişkenlik gösterdiği söylenebilmektedir. LSTM katmanlarında bulunan seyreltme katmanı ile aşırı öğrenme engellenebilirken, regresyon tabanlı algoritmalarda bu durumun engellenememesi yanıltıcı sonuçlar elde edilmesine sebep olabilmektedir. Geleneksel yöntemlerden ARIMA ve FFT ile XGBR ve Bütünleşik LSTM yöntemleri kullanılarak zaman serilerinin gelecek tahmini analizi gerçekleştirilmiş, elde edilen sonuçlar doğrultusunda FFT ve Bütünleşik LSTM yöntemlerinin benzer bir yaklaşım sunduğu tespit edilmiştir.

Tez çalışması, İstanbul Havalimanı üzerinde gerçekleştirilen kapsamlı analizleri içermekte olup, İstanbul Havalimanı gibi büyük ve kritik öneme sahip ulaşım altyapılarında gerçekleştirilecek yapı sağlığı izleme çalışmalarına katkı sağlayacağı düşünülmektedir.



TIME SERIES MODELING OF SURFACE MOVEMENTS USING INSAR AND MACHINE LEARNING METHODS: THE CASE STUDY OF ISTANBUL AIRPORT

SUMMARY

Aerial transportation constitutes a significant part of transportation. Especially airports located in megacities and providing both national and international transportation have an important position. At these airports, which allow millions of people to travel every year, the issue of structural health is of critical importance, and the safety of passengers after accidents that may occur, as well as the cost of structural damage, which is another issue that needs to be taken into account. For this reason, damages that may occur on the runway and structures should be monitored permanently and structure rehabilitation, if needed, should be made.

There are many terrestrial measurement methods for structural health monitoring. GNSS, leveling, inclinometer, etc. can be given as examples of frequently used terrestrial measurement methods. However, although these measurement methods provide precise measurement, it is very difficult to obtain area-based spatial information with these methods because they are point-based methods. It requires a serious workload as well as cost and time. Remote sensing methods fill an important gap in this regard, by gathering satellite imagery in constant periods and wide coverage. Thanks to the availability of free satellite images from many satellites having different sensors in recent years, spatial information can be extracted in different details depending on the spatial resolution of the satellite image.

Synthetic aperture radar (SAR) satellite images are frequently used in the detection of surface movements occurring on structures or land surfaces. With the European Space Agency's free service of Sentinel-1 SAR satellite images, interferometric SAR (InSAR) analyses have been frequently applied in structural health monitoring. Time series InSAR methods have been developed to determine and monitor the behavior of surface movements over time. Persistent Scatterer Interferometry (PSInSAR) and Small Baseline Subset InSAR (SBAS) methods are the most widely used time series InSAR methods.

The construction of airports on sea fill areas or on empty areas obtained by reclamation of wetlands due to lack of suitable land has been the subject of studies on the formation of surface movements and the monitoring of these surface movements with time series InSAR methods in recent years. Similar examples of these airports have started to be seen in Turkey as well. Istanbul Airport has an important place due to its geological location and its role in aerial transportation after it was put into use. Istanbul Airport was built on the wetlands and rehabilitated wooded areas, which were formed by the abandoned open sand quarries and coal mines filled with water over time. Wetlands were reclaimed and filled with the material to make them suitable for airport construction. The airport, which is known to be constructed with a large amount of

filling, is sensitive to surface movements due to ground settlement and intense external loads. For this reason, Istanbul Airport was chosen as the study area.

The study area was classified in five-year periods between 1984 and 2020 using Landsat optical satellite images. As a result of the thematic accuracy evaluation performed after classification, classifications were carried out with high accuracy values. According to the classification results, it was determined that wetlands increased 10 times from 1984 to 2010, but more than 50% of them were destroyed after the airport construction. The vegetation area decreased by approximately 24%, and the bareland class increased by 7% in 36 years.

SBAS method using the LiCSBAS application package and PSInSAR method using SNAP and StaMPS softwares were applied to determine the surface movements that occurred at the airport. Sentinel-1 free SAR images were used in the analyzes covering the time period between November 2018 when the airport was opened for use and September 2022. It has been determined that the results of the analysis performed in both ascending and descending geometry give similar results. In addition to the fact that the SBAS and PSI analyses also give similar results, the results were complementary to each other due to their different spatial resolutions. According to the results obtained, surface movement with a tendency to subsidence has been detected in the wetland area with an area of 88.6 ha, which is located between Runway B, Runway C and the terminal building. It has been rehabilitated for the airport construction. A similar movement is observed on the runways close to this area (Runways B and C) and in the northern parts of the terminal building. Movements with a tendency to subsidence are also observed in the northern parts of Runway A, while movements with a tendency to uplift are observed on the terminal building, as well as the southern parts of the building and the southern parts of Runway B.

Persistent scatterers could not be determined by the PSI method, since the construction of Runway C was started and opened for use during the period of November 2018-September 2022. For this reason, PSI analyses were repeated in the time period between July 2020 and September 2022, when Runway C was put into use, and it was determined that there was a negative subsidence trend on the small reclaimed wetland in the area where Runway C was built. By using the analysis results obtained in both descending and ascending orbits, the surface movements obtained in the satellite line of sight direction are divided into vertical and horizontal components. The similarity of the results obtained in both orbit geometries indicates that the movement is in the vertical direction that is confirmed by the obtained vertical component. No significant results were obtained from the horizontal component. By decomposing the time series taken from the terminal building to its components, the trend component was found to be highly correlated with the temperature data obtained from the General Directorate of Meteorology. This indicated that the roofing material of the terminal building is prone to expansion.

By using digital elevation models (DEM), the areas where excavation and filling were made in the airport construction were determined. DEM, which expresses the topography before the airport construction, is provided with SRTM data. The post-construction topography was created with stereo Pleiades images at 2 m spatial resolution and resampled to 30 m which is the spatial resolution of the SRTM data. Cut and fill regions were determined by taking the difference between the two DEM data. According to the results, it was determined that approximately 60 m of filling was made in the large reclaimed wetland with an area of 88.6 ha. In addition, it has

been determined that the identified excavation and filling areas overlap with the deformation results.

After the determination of the surface movements, forecasting analyzes were carried out with surface movement time series. Six different pilot regions were determined depending on the structure type and the characteristics of the time series. Forecasting analyzes were performed with traditional methods, regression-based methods and deep learning methods. In the results of the analysis, traditional methods gave a successful result by presenting a linear approach. Among the regression-based methods, it has been determined that the XGBoost Regression (XGBR) algorithm gives successful results in all regions. In deep learning methods, it has been determined that the Stacked LSTM (Long Short Term Memory) method shows successful results.

The time series is divided into its components (trend, seasonal effect, residual) by additional decomposition method and included in the forecast analysis together with the ERA5-Land meteorological parameters (air temperature, soil temperature, precipitation and evaporation). The contribution of these features to the forecast analysis was investigated with XGBR and Stacked LSTM algorithms. It has been found that the addition of features to the forecasting analysis increases forecasting accuracy. The importance of the features for each region was determined through both forecasting methods.

The importance degrees of seven features were determined over the XGBR method by SHAP, permutation feature importance methods and the importance levels used by the XGBR algorithm while creating its tree structure, and the permutation feature importance method used only for the Stacked LSTM method. The importance degrees obtained by the XGBR method were similar in all methods, and it was determined that the trend and residual parameters were among the most important features. However, these parameters cause overtraining if not controlled. While the evaporation parameter stood out in two different time series taken from the runway, it was determined that the air temperature parameter came to the fore in the time series taken from the building. The trend component is among the most important features of the time series in the importance levels determined by the permutation feature importance method over the Stacked LSTM method. While the precipitation parameter stands out in the time series taken over the runway, the evaporation parameter stands out in the time series taken over the building showing subsidence and uplift characteristics. When the terminal building is examined specifically, it has been found that the soil temperature is prominent.

In line with the results obtained, it can be said that the results vary according to the type of building, building material and method used in the forecasting analysis. While overtraining can be prevented with the drop out layer in the LSTM layers, the inability to prevent this situation in regression-based algorithms may cause misleading results. The future forecasting of time series has been performed using ARIMA and FFT traditional methods, XGBR and Stacked LSTM methods. It has been determined that FFT and Stacked LSTM methods offer a similar approach according to the obtained results.

The thesis study includes comprehensive surface movement analyses carried out at Istanbul Airport. It provides an example for the structural health monitoring studies to be carried out in large and critical transportation infrastructures such as Istanbul Airport.



1. GİRİŞ

Mühendislik yapıları, sürekli olarak dış yüklerin etkisi altındadır. Bu yükler, yapının tasarımı esnasında göz önüne alınsa da yoğunluğuna göre farklılık göstermekte ve zamanla yapıda kalıcı deformasyona yol açmaktadır (Qin ve diğ., 2019). Deformasyonun zamansal ve mekânsal davranışını daha iyi anlayabilmek için, zeminde ve yapıda oluşan deformasyonları izlemek ve karakterize etmek önemli bir süreçtir. Ayrıca deformasyonlar ekonomik kayba sebep olmakla beraber can ve mal güvenliği açısından da bir tehdit unsurudur. Bu aşamada Yapı Sağlığı Takibi (Structural Health Monitoring-SHM) önem kazanmaktadır. SHM, can güvenliğini artırmak ve yapı bakım maliyetlerini azaltmak için sivil ve endüstriyel binaların sürekli izlenmesi ile ilgilenir (Scuro ve diğ. 2018). Liu ve diğ. (2009)'e göre, SHM'nin temel amaçları; yapısal deformasyonu belirlemek, yapı ömrü tahmini, maliyetli düzenlemelerden kaçınmak için karar verme sürecini iyi yönetmek olarak sıralanabilmektedir.

Mühendislik yapılarından olan havalimanları, ulaşım ağının en önemli parçalarından biridir. Hava taşımacılığı faaliyetinin ana altyapı sağlayıcısı olmakla beraber havaalanları; bölgeler, ülkeler, kıtalar ve topluluklar arasında bağlantılar kurmayı sağlar (Sengur, 2020). Emniyetli uçuşların gerçekleştirilebilmesi için pistlerin konumunun, yönünün ve sayısının belirlenmesinde hava şartları (rüzgar yönü, sis vb.), havaalanı sahasının çevresi ve topoğrafyası, hava trafiği ve birçok çevresel faktör etkilidir. Pist uzunluğunu etkileyen faktörler ise uçakların performansı, hava (yüzey rüzgarı ve sıcaklık), eğim ve pist yüzeyi gibi pist özellikleri ve rakım gibi havaalanı özellikleridir (SHGM, 2016).

Pistler, yoğunlukla uçakların kalkış ve inişine ilişkin iki temel ve en kritik manevralarına ayrılmış olduklarından, havalimanı altyapılarında merkezi unsurlardır. Bunun ışığında, pistler inşaat ve bakım standartları açısından çok katı şartlara uymalıdır. Bu bağlamda, tüm yaşam döngüleri boyunca pistlerde sürekli olarak düzenli bir yüzeyin sağlanması gerektiğinden ve uçakların güvenli manevra yapabilmeleri için yüzeysel (örn., çatlama veya tekerlek izi) veya derin (örn. taban altı

çökme) hasarın kabul edilemez olduğu belirtilmiştir (Bianchini Ciampoli ve diğ., 2020). Yollar ve havaalanı pistleri, kullanımları sırasında periyodik olarak aşırı yüklere maruz kalır. Ayrıca, zorlu çevre koşullarından kaynaklanan gerilmeler, kaplamaların yapısal özelliklerinde kayıplara neden olur. Pistler ve yollar düzenli olarak kontrol edilmelerine ve rutin bakım veya acil onarımları gerçekleştirilmelerine rağmen, bu altyapıların güvenliğini sağlamak ve orijinal mekanik özelliklerini eski haline getirmek için hala yeterli çözümlere ihtiyaç vardır. Çözüm genellikle bozulma tipine, çatlakların yayılmasına ve malzemelerin yorulmasına bağlıdır (Abdessamed ve diğ., 2015). Pist ve yolların şekillerini, boyutlarını ve altında yatan nedenleri tanımlayan distorsiyonların tespiti, disiplinler arası bir yaklaşım gerektiren karmaşık bir süreçtir (Wang ve diğ., 2015).

Dünya çapında birçok alanda ele alınan zemin çökmesi kavramı, köprüler, barajlar veya havaalanları gibi altyapıların stabilitesi için önemli bir sorundur (Cavalié ve diğ., 2015). Özellikle yavaş yavaş gerçekleşen çökmeler ve altyapı deformasyonları jeolojik stabiliteyi ve binaların güvenliğini tehdit etmektedir (Ma ve diğ., 2019). Hong-Kong, Güney Kore, Japonya, Fransa vb. birçok ülkede dolgu alanlar üzerine inşa edilen havaalanlarında da bu sorun mevcuttur. Deformasyonlar pistlerde, çoğunlukla uçak inişindeki büyük kuvvetler, tektonik ve meteorolojik değişiklikler, yeraltı suyu değişimleri veya diğer nedenlerden dolayı meydana gelir (Doler ve Kovačić, 2019).

Hızlı sosyo-ekonomik gelişme içerisinde olan birçok kıyı şehri, kentsel genişleme ve ulaşım için gerekli boş arazi problemini hafifletmek amacıyla, deniz veya sulak alan ıslahı yoluna başvurmaktadır (Martín Antón ve diğ., 2016; Sengupta ve diğ., 2018). Şehir planlamasını akılcı bir şekilde uygulamak ve hava taşımacılığının baskısını azaltmak için Hong Kong (Wu ve diğ., 2020), Shanghai (Jiang ve diğ., 2016) gibi kıyı şehirlerinin çoğu havalimanlarını denize yakın ve şehir merkezinden uzağa inşa etmişlerdir. Bu havalimanlarında, önemli bir güvenlik tehlikesi oluşturan kısa arazi ıslah süresi ve zayıf doğal temeller nedeniyle, kaçınılmaz olarak zemin deformasyon sorunları meydana çıkmaktadır (Yu ve diğ., 2017). Islah edilen arazi genellikle bazı konsolide olmayan deniz tortuları üzerinde olduğundan, toprağın sıkışması zaman içinde önemli ölçüde arazi çökmesine neden olabilmektedir (Yang ve diğ., 2018) ve bu bölgelere inşa edilen yollarda, havaalanı pistlerinde ve yer altı boru hatlarında geri dönüşü olmayan hasarlara yol açarak önemli ekonomik kayıplara ve yüksek bakım maliyetlerine neden olacaktır (Pepe ve diğ., 2016). Özellikle geri kazanılmış arazi

üzerine inşa edilen havalimanları, genellikle havalimanının işletim güvenliğini tehdit edecek olan, özellikle pist alanlarında meydana gelen arazi çökmesinden muzdariptir (Marshall ve diğ., 2018). Zemin oturmasının havalimanı yüzey döşemesi üzerindeki etkisi özellikle önemlidir. Havalimanı alanı içindeki zemin oturma oranı belirli bir eşiğe ulaştığında, pistte ve taksi yolunda tekerlek izleri, döşeme ucu çatlaması, düzensizlikler ve diğer dikey deformasyonlar ortaya çıkacaktır ve güvenlik açısından risk oluşturacaktır (Bingjun ve diğ., 2016; Yanbin ve diğ., 2017; Zhang ve diğ., 2023). Bu nedenle, havalimanlarının ıslah alanlarındaki zemin deformasyonunun zamanında kavranması ve güvenli havalimanı işletimi için buna karşılık gelen önleme ve kontrol stratejilerinin önerilmesi esastır (Bao ve diğ., 2022).

Günümüzde, uydu bazlı teknikler, ulaşım altyapılarının izlenmesi konusunda oldukça sık kullanılmaktadır. Bu tekniklerin en büyük avantajlarından biri, uydunun yörüngesi ve çözünürlük özellikleriyle ilişkili olarak hedeflerden belli periyotlarda bilgi çıkartılarak izlenebilmesidir. Bu özellikler, altyapıyı trafiğe kapatmaya gerek kalmadan, zaman içinde düzenli olarak önemli miktarda bilginin toplanmasını sağlar (Bianchini Ciampoli ve diğ., 2020).

Uzaktan algılama yöntemleri, yapı ve zemindeki deformasyonları belirlemek için de yaygın olarak kullanılmaktadır. Uydu görüntüleri, bölgesel ve yapısal deformasyon analizlerinde oldukça etkilidir. Özellikle Yapay Açıklıklı Radar (Synthetic Aperture Radar - SAR) görüntüleri ile interferometrik teknikler kullanılarak deformasyon tespit edilebilmekte ve interferometrik zaman serisi ile de bu deformasyonlar izlenebilmektedir. Yüksek çözünürlük ve uyduların görüntü algılama sıklığının fazla olması da dinamik olarak değişen fiziksel yeryüzünün izlenmesini kolaylaştırmaktadır. Bütün hava koşullarında aktif olarak veri sağlayabilen ve hem gündüz hem de gece algılama yapabilme kapasitesine sahip SAR teknolojisi, uzaktan algılama alanında yeri doldurulamaz bir rol oynamaktadır (Haikun ve diğ., 2018). Bu sebeple mühendislik yapılarının deformasyon analizinde de Interferometrik SAR (InSAR) kullanımı oldukça yaygındır.

Havalimanlarında meydana gelen bölgesel yüzey hareketlerinin geleneksel yöntemlerle izlenmesi için, nivelman, elektronik total station ve küresel navigasyon uydu sistemleri (Global Navigation Satellite System - GNSS) yöntemleri genellikle benimsenmektedir. Bu yöntemler havalimanı gerekliliklerini karşılarsa da uzun vadeli sürekli izleme çalışmalarında genellikle nokta tabanlı ayırık veri toplanması, yüksek

insan gücü maliyetleri ve zaman gereksinimleri gibi dezavantajları bulunmaktadır (Liu ve diğ., 2019; Zhang ve diğ., 2023). Özellikle havalimanı gibi geniş alanlara ve uzun açıklıklara sahip büyük altyapılar için, zaman alıcı doğası ve zemin deformasyonunun mekânsal dağılımını net bir şekilde gösterme zorluğu, bu geleneksel yöntemlerin kullanımını zorlaştırmaktadır (Bao ve diğ., 2022). InSAR teknolojisinin yükselişiyle birlikte, geleneksel yöntemlerin sınırlamaları aşarak daha yüksek mekânsal çözünürlük ve SAR uydu görüntülerinin mekânsal çözünürlüğüne bağlı olarak mm doğruluğuna kadar geniş alanların deformasyonunun izlenmesine olanak sağlanmıştır (Wu ve diğ., 2020; Zheng ve diğ., 2020). Ayrıca, SAR görüntülerinin mekânsal çözünürlüğü yatay yüzey yönünde metre seviyesinde iken düşey yönde izleme doğruluğu kullanılan yöntemle bağlı olarak milimetre seviyesine ulaşabilmektedir (Yang ve diğ., 2021), böylece çoğu yapısal deformasyon izleme uygulamasında doğruluk gereksinimlerini karşılamaktadır.

1.1 Tezin Amacı

Havalimanları taşımacılık sektöründe ve ulaşım altyapılarında önemli bir yere sahiptir. Hava araçlarının iniş kalkış gibi temel sürecinde yapılar üzerinde oluşan dış yükler ile havalimanında bulunan temel mühendislik yapıları (pist, terminal binası vb.) iç yüklerin etkisiyle (her ne kadar inşa edilirken hesaba katılsa da) zaman içerisinde deforme olmaktadır. Yol ve havalimanı gibi temel altyapıların inşası için uygun arazi eksikliği, organik açıdan zengin topraklara ya da dolgu veya ıslah edilen alanlara yönelime sebep olmuştur (Marshall ve diğ., 2018). Bu alanlar üzerine inşa edilen havalimanlarında ise aynı zamanda zemin oturmaları da meydana gelmektedir.

Mühendislik yapılarında meydana gelen deformasyonları belirlemek ve izlemek için birçok yöntem mevcuttur. Mevcut izleme yöntemleri arasında hassas nivelman, yer tabanlı GNSS araştırmaları ve InSAR dahil olmak üzere uzaktan algılama yöntemlerinin uygulanması yer alır. Bu yöntemler arasında geniş ölçekte ve alansal bazda deformasyonları ancak InSAR yöntemleri kolaylıkla sağlayabilmektedir. Özellikle Sentinel-1 SAR uydusunun ücretsiz SAR verisi temin etmeye başlaması bu yöntemleri oldukça popüler hale getirmiştir. Zaman serisi InSAR yöntemleri sayesinde ise deformasyonların zaman içerisindeki hareketi ve karakteristikleri belirlenebilmektedir.


Literatür incelendiğinde havalimanlarında deformasyonların belirlenmesi, son yıllarda incelenmeye başlanmış, deformasyonların tahmin analizinde ise henüz eser miktarda çalışma mevcuttur. Bu kapsamda, sulak alanların ıslah edilmesiyle elde edilen araziye yoğun dolgu yapılması sonucu inşa edildiği bilinen ve açılmasıyla birlikte hava taşımacılığında önemli bir yer edinen İstanbul Havalimanı, tez çalışması kapsamında çalışma bölgesi olarak belirlenmiştir. Çalışma bölgesinde meydana gelen deformasyonu belirlemek için analizler gerçekleştirilmiş ve sebep/sonuç ilişkileriyle incelenmiştir. Elde edilen deformasyonlar karakteristiklerine göre gruplandırılarak geleneksel, regresyon tabanlı ve derin öğrenme modelleri ile değerlendirilerek modellerin performansı ve InSAR zaman serisi deformasyonlarının tahmin analizinde kullanılabilirliği test edilmiştir. Tez çalışması kapsamında hem optik hem de SAR verileri ile analizler gerçekleştirilirken, aynı zamanda uluslararası ulaşım ağında kritik bir konumda olan büyük havalimanlarının detaylı olarak incelenmesinde yol gösterici bir nitelik taşıması hedeflenmiştir. Tez çalışmasının genel amaçları aşağıda maddeler halinde sıralanmıştır.

- Kasım 2018’de kullanıma açılan İstanbul Havalimanı’nın yüzey deformasyonları zaman serisi InSAR (Time Series InSAR – TS-InSAR) yöntemlerinden SBAS ve PSI yöntemleriyle Kasım 2018 - Eylül 2022 periyodu için belirlenecektir.
- Havalimanının inşa edildiği bölge sulak alanlar açısından zengin bir bölge olduğundan kontrollü sınıflandırma yöntemleri ile 1984-2020 yılları arasında beşer yıllık periyotlarda Landsat uydu görüntüleri kullanılarak arazi örtüsü/arazi kullanımı (AÖ/AK) haritaları oluşturulacak ve ıslah edilen sulak alanlar tespit edilecektir.
- Havalimanı inşaatına başladıktan sonra alınan Pleiades uydu görüntüleri kullanılarak sayısal yükseklik modeli (SYM) üretilecek ve inşaat öncesi-sonrası SYM’ler ile kazı/dolgu alanları tespit edilecektir.
- Sınıflandırma sonuçları ve kazı/dolgu alanları, deformasyon sonuçlarıyla birlikte değerlendirilerek sebep/sonuç ilişkileri ortaya konacaktır.
- Elde edilen deformasyonların gelecek tahmin analizlerini gerçekleştirmek üzere geleneksel yöntemler, regresyon tabanlı yöntemler ve derin öğrenme yöntemleri farklı yapı tipi ve deformasyon karakteristiğine sahip altı pilot

bölgede test edilerek, deformasyon zaman serilerinin tahmininde en uygun yöntemler belirlenecektir.

- Zaman serileri bileşenlerine ayrılarak deformasyon zaman serilerinin tahmin sürecine dahil edilecek ve sonuçlara katkısı araştırılacaktır.
- ERA5-Land meteorolojik uydu verilerinden temin edilen sıcaklık, yağış ve buharlaşma gibi meteorolojik parametreler de deformasyon zaman serilerinin tahmin sürecine dahil edilerek tahmin analizlerinde yardımcı verilerin tahmin doğruluğuna etkisi ve katkısı araştırılacaktır. Bunun yanı sıra, yapı malzemesi türüne (pist ve bina kaplama malzemeleri) ve deformasyon karakteristiğine (çökme, stabil, kabarma vb.) göre önem dereceleri SHAP ve permütasyon önem dereceleri ile en iyi sonuçları veren iki tahmin yöntemiyle değerlendirilecektir.

Planlanan çalışmalar Şekil 1.1’de detaylı bir şekilde verilmiştir.



Şekil 1.1 : Tez çalışması kapsamında gerçekleştirilecek çalışmaların akış şeması.

Tez çalışması kapsamında elde edilen sonuçların, havalimanlarında meydana gelen yapısal deformasyonların izlenmesi, uygulama süreçlerinin takibi ve önlem alma aşamalarında karar vericilere ve araştırmacılara katkı sağlayacağı düşünülmektedir. İçerdiği detaylı bilgiler sayesinde, benzer yapılarda gerçekleştirilecek çalışmalara ışık tutması hedeflenmektedir. Ulaşılan sonuç ve değerlendirmeler, ulusal ve uluslararası

dergilerde ve sempozyum bildiri kitaplarında yayınlanarak yaygın etkisinin artırılması hedeflenmiştir.

1.2 Literatür Araştırması

InSAR teknolojisinin kullanımı son yıllarda oldukça popüler hale gelmiştir. Xue ve diğ. (2020), InSAR kullanımının popülerliğini araştırmak için gerçekleştirdikleri çalışma kapsamında, 2000 yılından itibaren yapılan yayınların sayısını ve atıf sayılarını belirlemiştir. 2000 ve 2019 Eylül aralığını kapsayan bu araştırmada son 10 yıl içerisinde yayın ve dolayısıyla atıf sayısının oldukça arttığı gözlenmiş gelecekte de bu sayının artmaya devam edeceği belirtilmiştir.

InSAR teknolojisinin, birçok mühendislik yapısı üzerinde uygulama örneği literatürde yer alırken, havalimanları gibi büyük altyapı projeleri üzerinde de gerçekleştirilen çalışmalar mevcuttur. Bu amaçla, Google Akademik, Web of Science ve Scopus veritabanlarından “InSAR”, “havalimanı (airport)” ve deformasyon (deformation/movement)” kelime anahtarları ile havalimanlarında gerçekleştirilen InSAR çalışmaları incelenmiştir. 2023 yılı şubat ayına kadar yayınlanmış olan çalışmalar üzerinden incelemeler yapılmıştır. Çizelge 1.1’de havalimanlarında meydana gelen deformasyonlar üzerine yapılan çalışmalar detaylarıyla birlikte verilmektedir. Hong Kong Uluslararası Havalimanı ve Beijing Capital Uluslararası Havalimanı bölgelerinde çalışmaların yoğunlukta olduğu belirlenmiştir. Bu durumun temel sebebi, Hong Kong Uluslararası Havalimanı’nın iki adanın deniz dolgusuyla birleştirilerek oluşturulan alan üzerine inşa edilmesinin (Wu ve diğ., 2020) ve Beijing Capital Uluslararası Havalimanı’nın ise ortasından fay hattının geçiyor olmasının (Gao ve diğ., 2019) havalimanı güvenliği açısından önem arz etmesidir. Diğer havalimanlarında da bu amaçlar gözetilerek çalışmalar gerçekleştirilmiş ve sonuçları sunulmuştur.

Çizelge 1.1 : Literatürde InSAR ile çalışmaların gerçekleştirildiği havalimanları ve çalışma detayları.

Havalimanı	Ülke	SAR Verisi	Yöntem	Kaynak
Chek Lap Kok Airport Hong Kong Uluslararası Havalimanı	Hong Kong	Envisat Asar ERS-2	IPTA DINSAR SBAS	Jiang and Lin, 2010 Wu ve diğ., 2020 Zhao ve diğ., 2011 Liu ve diğ., 2001 Jiang ve diğ., 2010 Sun ve diğ., 2018 Ma ve diğ., 2019 Ma ve diğ., 2020 Sun ve diğ., 2016 Zhang ve diğ., 2022
Kuala Lumpur Uluslararası Havalimanı	Malezya	Sentinel-1	Intermittent Small Baseline Subset (ISBAS)	Marshall ve diğ., 2018
Iqaluit Havalimanı	Kanada	Radarsat-2 CSK	IPTA PSI	Short ve diğ., 2014 LeBlanc ve diğ., 2012 Ma ve diğ., 2022
Ordu-Giresun Havalimanı	Türkiye	Sentinel-1	PSI	Short ve diğ., 2013 Bayik ve Abdikan, 2021
Beijing Capital Uluslararası Havalimanı	Çin	Envisat Asar TerraSAR-X Sentinel-1 CSK Radarsat-2 ERS-1/2	SBAS PSI	Gao ve diğ., 2016 Hu ve diğ., 2019 Gao ve diğ., 2019 Dai ve diğ., 2020 Chen ve diğ., 2021 Yang ve diğ., 2019 Zhou ve diğ., 2020 Zhou ve diğ., 2022 Dong ve diğ., 2023 Xing ve diğ., 2022 Zhou ve diğ., 2015
Tehran Uluslararası Havalimanı	İran	Envisat Asar Alos Palsar TerraSAR-X Sentinel-1 ERS	SBAS	Haghighi ve Motagh, 2019
Tucson Uluslararası Havalimanı	Arizona, USA	Envisat Asar Alos	SBAS	Kim ve diğ., 2015
Xining Havalimanı	Çin	Sentinel-1	SBAS	Zhe ve diğ., 2020
Shenzhen Bao'an Uluslararası Havalimanı	Çin	Envisat Asar CSK	SBAS PSI	Xu ve diğ., 2016 Liu ve diğ., 2018
Jiuzhai-Huanglong Havalimanı	Çin	Sentinel-1 Alos/Palsar Sentinel-1	SBAS	Liu ve diğ., 2019 Chen ve diğ., 2018


Çizelge 1.1 (devam) : Literatürde InSAR ile çalışmaların gerçekleştirildiği havalimanları ve çalışma detayları.

Havalimanı	Ülke	SAR Verisi	Yöntem	Kaynak
Leonardo da Vinci Havalimanı	İtalya	ERS-1/2 Envisat Asar Sentinel-1 CSK	PSI	Comerci ve diğ., 2015 Gagliardi ve diğ., 2011 Bianchini Ciampoli ve diğ., 2020
San Francisco Uluslararası Havalimanı	Endonezya	ERS	SBAS PSI	Shanker ve diğ., 2011
Yogyakarta Uluslararası Havalimanı		Sentinel-1	SBAS	Dewanto ve diğ., 2021
Nice Côte d’Azur Uluslararası Havalimanı (NCA)	Fransa	Envisat Asar	SBAS	Cavalié ve diğ., 2015
Shanghai Hongqiao Havalimanı	Çin	TerraSAR-X	IPTA	Hu ve diğ., 2019
Suvarnabhumi Havalimanı	Tayland	Radarsat-1	Bütünleşik PS-SBAS	Aobpaet ve diğ., 2013
Yazd Sadooghi Uluslararası Havalimanı	İran	Envisat Asar Sentinel-1	SBAS	Mirzadeh ve diğ., 2021
Xiamen Xiang'an Uluslararası Havalimanı	Çin	Sentinel-1	SBAS PSI	Liu ve diğ., 2019 Zhuo ve diğ., 2020 Li ve diğ., 2022 Xiong ve diğ., 2022 Zhuo ve diğ., 2019 Jiang ve diğ., 2016 Ma ve diğ., 2018 Bao ve diğ., 2022
Pudong Uluslararası Havalimanı	Çin	TerraSAR-X Sentinel-1	SBAS PSI	Wu ve diğ., 2019
Yan'an new Havalimanı	Çin	Sentinel-1	SBAS	Wu ve diğ., 2019
Makedonia Havalimanı (Thessaloniki's Uluslararası Havalimanı)	Yunanistan	Sentinel-1 ERS1 ERS2 Envisat Asar	SBAS PSI	Svigkas ve diğ., 2020 Svigkas ve diğ., 2020 Raspini ve diğ., 2013
Tribhuvan Uluslararası Havalimanı	Nepal	Alos Palsar-2	DInSAR	Sato ve Une, 2016
Kangding Havalimanı	Çin	Sentinel-1	SBAS PSI	Chen ve diğ., 2018
Regina Havalimanı	Kanada	Radarsat-2	HDS	Sharma ve diğ., 2015
Málaga Uluslararası Havalimanı	İspanya	ERS-1/2 Envisat Asar Sentinel-1	PSI	Ruiz-Armenteros ve diğ., 2018
Mayo Havalimanı	Kanada	Radarsat-2	SBAS	Mohammadimanesh ve diğ., 2019

Çizelge 1.1 (devam) : Literatürde InSAR ile çalışmaların gerçekleştirildiği havalimanları ve çalışma detayları.

Havalimanı	Ülke	SAR Verisi	Yöntem	Kaynak
Kansai Uluslararası Havalimanı	Japonya	Alos Palsar-2	PSI	Susaki ve diğ., 2020
Cochin Uluslararası Havalimanı	Hindistan	Sentinel-1	PSI	Pooja ve diğ., 2021
New Delhi Havalimanı	Hindistan	Alos Palsar CSK Sentinel-1	PSI	Malik ve diğ., 2022
Ankang Havalimanı	Çin	Sentinel-1	PSI	Zhang ve diğ., 2022
Dalian Jinzhou Bay Uluslararası Havalimanı	Çin	Sentinel-1	SBAS	Shi ve diğ., 2022
Anju Havalimanı	Çin	Sentinel-1	SBAS	Wang ve diğ., 2022
Istanbul Havalimanı	Türkiye	Sentinel-1	SBAS PSI	Yagmur ve diğ., 2022

Çizelge 1.1’de tespit edilen çalışmaların yıllara göre dağılımı ise Şekil 1.1’de verilmiştir. 2001 yılında Diferansiyel InSAR (DInSAR) yöntemi (Liu ve diğ., 2001) ile başlayan çalışmalar, 2010 yılında TS-InSAR yöntemleri ile devam etmiştir. 2018 yılından sonra ise çalışma sayısında ciddi bir artış gözlenmiştir.




Şekil 1.1 : Havalimanlarında InSAR kullanımı üzerine Web of Science ve Scopus veri tabanlarında taranan dergilerde gerçekleştirilen çalışmaların yıllara göre dağılımı.

Şekil 1.1’de sayıları belirtilen çalışmalardan yayınlanan makalelerin dergilere göre dağılımı ve ilgili dergideki çalışma sayıları Şekil 1.2’de verilmiştir. Yayınlanan


makale sayılarına göre sıralandığında ‘Remote Sensing’, ‘Remote Sensing of Environment’, ‘International Journal of Remote Sensing’ gibi uzaktan algılama dergilerinin yanı sıra ‘Engineering Geology’ dergisi de yer almaktadır. Bu durumun temel sebebi, dolgu alanlar üzerinde inşa edilen havaalanlarının InSAR deformasyon sonuçlarının jeolojik olarak detaylı incelenmesidir (Jiang ve Lin, 2010; Marshall ve diğ., 2018).

Literatürde havalimanlarındaki deformasyonların belirlenmesi amacıyla kullanılan uydu görüntüleri incelenmiş ve uyduların çalışma ömrü ile havalimanı yayınlarında tercih edilme miktarları Şekil 1.3’te verilmiştir. Düşük mekânsal çözünürlükte L banda sahip olan ALOS PALSAR verilerinin kullanımının diğer uydulara nazaran az olduğu tespit edilmiştir. ERS 1/2, Sentinel-1, Envisat ASAR, Radarsat 1/2 uyduları C banda sahip oldukları için orta mekânsal çözünürlükte görüntü algılamaktadır ve çalışmaların büyük çoğunluğunda tercih edildiği belirlenmiştir. Özellikle görüntü temin etmeye başladığından beri ücretsiz olarak servis edilen Sentinel-1 uydu verilerinin literatürde önemli bir yer edindiği görülmektedir. Yüksek çözünürlükte X bandına sahip olan TerraSAR-X ve COSMO-SkyMed uydu görüntülerinin de çalışmalarda ilgi gördüğü görülmektedir. Ancak, bu uydu verileri ücret karşılığında veya proje kapsamında temin edilebildiğinden kolaylıkla erişim sağlanamamaktadır. C banda sahip uydu verilerinin yoğun kullanımı ücretsiz olarak temin edilebilmesinden kaynaklansa da orta mekânsal çözünürlükte verilerin havalimanlarında deformasyonların belirlenmesi ve izlenmesinde yeterli olabildiğinin de bir göstergesidir.


InSAR tekniği, dekorelasyon, atmosferik artefaktlar ve yörüngesel hatalara karşı hassastır (Liu ve diğ., 2010). Bu sebeple, geleneksel diferansiyel InSAR teknolojilerinin sınırlamalarının üstesinden gelmek ve yüksek hassasiyetli deformasyon zaman serilerini elde etmek için TS-InSAR yöntemleri geliştirilmiştir. Sabit Saçıcı InSAR (Persistent Scatterers InSAR - PSInSAR) ve Küçük Baz Altküme InSAR (Small Baseline Subset InSAR - SBAS-InSAR) yöntemleri literatürde de başlıca kullanılan yöntemlerdir. Şekil 1.4’te havalimanlarında kullanılan TS-InSAR yöntemlerinin kullanım yüzdeleri verilmiştir. Şekilde de görüldüğü üzere PSInSAR ve SBAS-InSAR yöntemleri en yoğun kullanılan yöntemler olurken, sonrasında sırasıyla İnterferometrik Nokta Hedef Analizi (Interferometric Point Target Analysis – IPTA) ve Homojen Dağıtılmış Saçıcı (Homogeneous Distributed Scatterer – HDS) InSAR yöntemleri gelmektedir, ancak bu yöntemler az sayıda çalışmada uygulanmıştır.



Şekil 1.2 : Havalimanlarında InSAR kullanımı üzerine gerçekleştirilen makalelerin dergilere ve yayın sayılarına göre dağılımı.



Şekil 1.3 : Havalimanlarında InSAR kullanımı üzerine gerçekleştirilen çalışmaların uydulara ve yıllara göre dağılımı.



Şekil 1.4 : Havalimanlarında üzerinde gerçekleştirilen InSAR çalışmalarında uygulanan yöntemlerin dağılımı.

PSInSAR yöntemi deformasyonu sadece mevcut sabit saçıcı (PS) noktaları üzerinden ölçülebilir, bu yüzden nokta yoğunluğu önem kazanmaktadır. PS yoğunluğu bitki örtüsü, ormanlık ve düşük yansıtma oranına sahip alanlarda (örneğin çok pürüzsüz yüzeyler) ve radar sensörlerine bakan dik arazilerde genellikle düşüktür. Alanın karla kaplı olması, inşaat çalışmaları, sokaklarda yeniden yol kaplamasının yapılması vb. PS'lerin tamamen veya kısmen kaybına neden olabilir. Buna karşılık, PS'ler genellikle binalarda, anıtlarda, antenlerde, direklerde, iletkenlerde, açıkta kalan kayalarda veya üst yüzeylerde bol miktarda bulunur. Genel olarak PS konumu, PSI analizi yapılmadan önce bilinemez. Bu, küçük alanların ve objelerin incelenmesi için kritik olabilir, çünkü noktalar yetersiz sayıda örneklenir veya hiç örneklenemez. Bu durum, X-banda sahip çok yüksek çözünürlüklü SAR verileri kullanılarak kısmen azaltılır (Crosetto ve diğ., 2016). C band ile PSI analizinde mm mertebesinde doğruluk sağlanırken, X band ile milimetrenin altında doğruluk elde edilmektedir (Ma ve diğ., 2019). SBAS metodu ise doğal yüzeylerin deformasyonunu izlemek için daha uygundur (Chen ve diğ., 2018). Ancak, yapıların deformasyon analizi için de kullanılabilir (Dong ve diğ., 2014; Castellazzi ve diğ., 2016).

Havalimanlarında deformasyonların belirlenmesi ve izlenmesinin yanı sıra oluşan deformasyonun nasıl ilerleyeceğinin tahmin analizi çalışmaları literatürde sınırlı sayıdadır. Geoteknik modeller (Li ve diğ., 2022), geleneksel eğri fonksiyonları modelleri (Xiong ve diğ., 2022), Terzaghi konsolidasyon teorisi (Shi ve diğ., 2022) gibi modeller kullanılarak gerçekleştirilen tahmin analizi çalışmaları olsa da genellikle günümüzde popülerlik kazanmış olan Uzun Kısa Süreli Bellek (Long Short Term

Memory – LSTM) metodunun kullanımı yoğunluktadır (Chen ve diğ., 2021; Bao ve diğ., 2022). Ancak bu çalışmalar literatürde henüz yer almaya başlamıştır.




2. YAPAY AÇIKLIKLI RADAR VE INTERFEROMETRİ TEKNİKLERİ

SAR sistemleri, elektromanyetik (EM) dalgalar yayar ve antenin bakış yönünde bir hedeften geri dönen enerjiyi toplar. SAR ölçümlerinin iki gözlenebilir değeri vardır: genlik ve faz. Genlik, geri saçılan EM dalgasının gücüdür ve hedefin şekli, yönü ve elektriksel özellikleri ile ilgilidir. Faz ise, dalga'nın konumunu tanımlar. Dalga havada yayılırken, dalga'nın fazı, kat edilen her dalga boyu için $-\pi$ 'den $+\pi$ 'ye değişir. SAR sistemleri, dönüş sinyalinin fazını çok hassas bir şekilde ölçebilir ve InSAR faz ölçümleri, genellikle ana/öncül (master) ve ikincil (slave) veriler olarak adlandırılan iki SAR verisi arasındaki faz farklılıklarına dayanır ve değişiklikleri tespit eder.

InSAR analizleri, hava koşullarından etkilenmeyen ve gece/gündüz algılama yapabilme kapasitesine sahip SAR görüntüleri kullanılarak gerçekleştirilir. Teknik, farklı zamanlarda aynı bölgeyi kapsayan en az iki SAR görüntüsünü kullanır ve uydu görüş hattı (Line of Sight - LOS) yönü boyunca yüzey yer değiştirmesini elde etmek için iki zaman periyodu arasındaki faz farkını ölçer (Gabriel ve diğ., 1989). Şekil 2.1'de InSAR çalışma prensibi 5,66 cm dalga boyuna sahip bir algılayıcı için görsel olarak gösterilmektedir. Deformasyonu belirlemek için, t_1 anında (olaydan önce) ve t_2 anında (olaydan sonra) alınan SAR uydu verileri karşılaştırılır. İnterferogram, birinci geçiş ve ikinci geçişteki faz farklarının çıkarılmasıyla oluşturulur ve halka şeklinde örgeler (fringe) oluşur. Ortaya çıkan renkli örgeler, zeminin hareket ettiği mesafeyi gösterir. Her örge arasındaki mesafe yer hareketini temsil etmektedir. Tam renkli örgeye ise interferometrik faz denir. Şekil 2.1'de verilen örnekte, uydunun ikinci geçişi aynı yüzeye giden daha uzun bir yol ölçer, bu da yerin uydudan uzaklaştığını gösterir.

Yüzey hareketlerini belirlemek için geliştirilen birçok yersel ölçme tekniği mevcuttur. Nivelman, GNSS ve inklonometre ölçmeleri gibi yüzey deformasyonlarını belirlemek için oldukça yaygın olarak kullanılan bu ölçme yöntemleri nokta bazlı ölçmeler olduğundan, bölgesel deformasyonları belirlemek yüksek maliyetli olmanın yanı sıra düşük mekânsal çözünürlüklüdür (Abidin ve diğ., 2005; Abidin ve diğ., 2015). Bu noktada InSAR, düşük maliyet, bütün hava koşullarında yüksek mekânsal çözünürlük

ve geniş yüzey alanlarını inceleyebilmesi bakımından büyük avantaja sahiptir (Hu ve diğ., 2014).



Şekil 2.1 : InSAR çalışma prensibi (Zhang ve diğ., 2023).

Sadece belirli bir tarih için değil uzun dönem zaman serisi olarak deformasyonların izlenebilirliğini sağlamak amacıyla da çok zamanlı InSAR yöntemleri geliştirilmiştir. Bu yöntemler arasında Ferretti ve diğ. (2000) tarafından geliştirilen PSInSAR ve Berardino ve diğ. (2002) tarafından geliştirilen SBAS-InSAR sıklıkla kullanılan yöntemlerdir. Bölüm 2.1’de SBAS, Bölüm 2.2’de ise PSInSAR yöntemi kullanılan metodoloji ile detaylı olarak verilmektedir.

2.1 SBAS INSAR

SBAS tekniği, Dünya yüzeyinin ve havaalanı gibi büyük insan yapımı altyapıların uzun vadeli ve yavaş deformasyon süreçlerini tespit etmek için çok uygundur (Chen ve diğ., 2018). SBAS tekniği aşağıda verilen formüllere dayanmaktadır (Berardino ve diğ., 2002):

$$\frac{N+1}{2} \leq M \leq N \frac{N+1}{2} \quad (2.1)$$

$$\phi_j(x, r) = \phi_j(t_B, x, r) - \phi_j(t_A, x, r) \approx \Delta\phi_{\text{disp}} + \Delta\phi_{\text{topo}} + \Delta\phi_{\text{orb}} + \Delta\phi_{\text{atm}} + \Delta\phi_{\text{noise}} \quad (2.1)$$

Eşitlik 2.1, $t_0, t_1, \dots, t_N$ anlarında aynı bölgede alınan $N+1$ sayıda SAR görüntüsünden elde edilen M fark interferogramının miktar aralığını temsil etmektedir. Eşitlik 2.2 ise, (x, r) pikselinde t_B ve t_A görüntülerinden elde edilen j interferogramının interferometrik faz birleşimini ifade etmektedir. Faz $\Delta\phi_{\text{disp}}$, bakış açısı (Line of Sight-LOS) boyunca hedef ve radar arasındaki mesafenin değişmesiyle oluşur. $\Delta\phi_{\text{topo}}, \Delta\phi_{\text{orb}}, \Delta\phi_{\text{atm}}, \Delta\phi_{\text{noise}}$ fazları ise sırasıyla arazi, uydu yörünge hatası, atmosfer etkisi (özellikle troposferik gecikmenin etkisi) ve diğer gürültülerden kaynaklanır. SBAS-InSAR deformasyon fazı $\Delta\phi_{\text{disp}}$ elde etmek için artık bileşenleri interferometrik fazdan uzaklaştırır. Daha sonra, N bilinmeyenli bir M denklem sistemi aşağıdaki gibi matris olarak düzenlenebilir:

$$A\phi = \delta\phi \quad (2.3)$$

A , $M \times N$ katsayı matrisi; $\phi = [\phi(t_1), \phi(t_2), \dots, \phi(t_N)]^T$ ölçüm noktaları ile bilinmeyen deformasyon faz değerlerinin $N \times 1$ vektörü; $\delta\phi = [\delta\phi(t_1), \delta\phi(t_2), \dots, \delta\phi(t_N)]^T$ ise çözümlenmiş faz değerlerinin $N \times 1$ vektörünü ifade etmektedir. Deformasyon hızı, Eşitlik 2.3'ü aşağıdaki denkleme yeniden yazarak elde edilebilir:

$$Bv = \delta\phi \quad (2.4)$$


B , $M \times N$ katsayı matrisi ve v ortalama faz hızını aşağıdaki gibi verir:

$$v = [v_1, v_2, \dots, v_N]^T = \left[\frac{\phi_1}{t_1 - t_0}, \frac{\phi_2 - \phi_1}{t_1 - t_0}, \dots, \frac{\phi_N - \phi_{N-1}}{t_N - t_{N-1}} \right]^T \quad (2.5)$$

Son olarak, deformasyon hızını hesaplamak için en küçük kare veya tekil değer ayrıştırma (singular value decomposition-SVD) algoritmaları Eşitlik 2.4 ve 2.5'e uygulanabilir. Kümülatif deformasyon, belirli bir zaman aralığında yukarıda belirtilen denklemler üzerinde hesaplama yapılarak oluşturulabilir (Mora ve diğ., 2003; Casu ve diğ., 2006).

Tez çalışması kapsamında, SBAS yöntemi LiCSBAS (Looking Inside The Continents From Space SBAS) uygulama paketi kullanılarak gerçekleştirilmiştir. LiCSBAS,

COMET-LiCS web portalında ücretsiz olarak bulunan LiCSAR (Looking Into Continents from Space with Synthetic Aperture Radar) ürünlerini (örn. çözülmemiş (unwrapped) interferogramlar ve tutarlılık (coherence) kullanarak InSAR zaman serisi analizini gerçekleştirmek için Python ve bash kullanan açık kaynaklı bir pakettir (URL-1). LiCSBAS, LiCSAR ürünlerini kullanır, böylece kullanıcıların SLC verilerinden interferogramlar üretmesine gerek kalmaz. LiCSAR ürünlerine uygulanan LiCSBAS, <1 cm/epoch ve ~ 2 mm/yıl hassasiyetle hem büyük ölçekli (> 100 km) hem de yerel ($\sim$ km) göreceli yer değiştirmeleri tespit edebilir. Böylece LiCSBAS, kullanıcıların yeterli LiCSAR ürünlerinin mevcut olduğu her yerde InSAR zaman serilerini ve hız tahminlerini kolayca elde etmelerini sağlar (Morishita ve diğ., 2020). LiCSAR interferogramları ücretsiz olan Sentinel-1 verilerinden üretilmiştir (Lazecký ve diğ., 2020). Ancak LiCSAR ürünleri yaklaşık olarak ~ 100 m mekânsal çözünürlüğe sahip olduğundan, çalışma alanında meydana gelen yüzey hareketlerinin genel değerlendirmesi için kullanılmıştır. LiCSBAS uygulama paketinin işlem adımları Şekil 2.2’de verilmiştir.



Şekil 2.2 : LiCSBAS uygulanan işlem adımları.

2.2 PSINSAR

PSInSAR yönteminde, sabit saçıcılar olarak anılan faz kararlı noktasal hedefler, elektromanyetik geri saçılımlarının genlikleri üzerinde istatistiksel bir analiz ile tespit edilebilir. $N + 1$ adet SAR görüntüsünden, ortak öncül görüntüye göre N interferogram üretilir. Sabit saçıcılar dekorelasyondan etkilenmediğinden, normal ve zamansal baz uzaklığına bakılmaksızın tüm interferogramlar PSInSAR işlemine dahil edilebilir. İnterferogram i'nin fazı (ϕ_i) Denklem 2.6'da verilmektedir.

$$\phi_i = \frac{4\pi}{\lambda} r_{Ti} + \alpha_i + n_i + \phi_{topo-res} \quad (2.6)$$


λ dalga boyunu; r_{Ti} hedef hareketini (master görüntünün algılandığı esnadaki konumuna göre); α_i atmosferik faz katkısını; n_i dekorelasyon gürültüsünü; $\phi_{topo-res}$ ise referans sayısal yükseklik modelindeki hata nedeniyle kalan topografik faz katkısını temsil etmektedir. Hedef hareketinin zaman içinde aynı olduğu varsayılarak denklem yeniden yazılır. 1 ve 2 sabit saçıcıları için i interferogramındaki faz farkı:

$$\Delta\phi_{1,2,i} = \frac{4\pi}{\lambda} \Delta v_{1,2} T_i + K_\varepsilon \Delta\varepsilon_{1,2} B_{n,i} + w_{1,2,i} \quad (2.7)$$

v , LOS boyunca ortalama deformasyon oranını ve T_i , öncül görüntüye göre zamansal baz uzaklığını temsil etmektedir. $\Delta v_{1,2}$ ve $\Delta\varepsilon_{1,2}$ PS noktalarına göre LOS hız farkı ve sayısal yükseklik modelindeki hata farkı, $B_{n,i}$ öncül görüntüye göre i interferogramındaki normal baz uzaklığıdır. $\Delta v_{1,2}$ ve $\Delta\varepsilon_{1,2}$ tahmin edildikten sonra faz belirsizliği (unwrapping) giderilir. $\Delta v_{1,2}$ ve $\Delta\varepsilon_{1,2}$ de entegre edilebilir (bir referans noktası için $v = v_0$ ve $\varepsilon = \varepsilon_0$ varsayılarak), ve daha sonra v ile ε elde edilir. Her bir PS noktasına göre çözümlenmiş atmosferik faz katkısı daha sonra fark olarak hesaplanır (Colesanti ve diğ., 2003):

$$[\alpha_i] = [\phi_i] - \frac{4\pi}{\lambda} v T_i + K_\varepsilon \varepsilon B_{n,i} \quad (2.8)$$

PSInSAR yöntemi, SNAP (Sentinel Application Platform) ve StaMPS yazılımları aracılığıyla gerçekleştirilmiştir. SNAP, Avrupa Uzay Ajansı (European Space Agency-ESA) tarafından uydu verilerinin işlenmesi için üretilen ücretsiz bir yazılımdır ve Sentinel-1 verilerinin işlenmesinde oldukça kolaylık sağlamaktadır. Interferogramların oluşturulması süreci SNAP yazılımı ile gerçekleştirilmiştir. PSInSAR analizi ise StaMPS uygulama paketi aracılığıyla tamamlanmıştır. StaMPS'in orijinal gelişimi Stanford Üniversitesi'nde yapılmıştır, ancak daha sonra StaMPS'in geliştirilmesi İzlanda Üniversitesi, Delft Teknoloji Üniversitesi ve Leeds Üniversitesi'nde gerçekleştirilmeye devam etmiştir. Ayrıca farklı kurumlardan kullanıcıların da katkılarının bulunduğu belirtilmektedir. SNAP ve StaMPS aracılığıyla gerçekleştirilen PSInSAR zaman serisi deformasyon analizinin iş akışı Şekil 2.3'te verilmiştir.




Şekil 2.3 : SNAP ve StaMPS ile uygulanan işlem adımları.

2.3 Yatay ve Düşey Yöndeki Hareketlerin Belirlenmesi

Radar sistemlerinin optik sensörlere göre bir diğer ayırt edici özelliği yandan görünüşlü bir geometriye sahip olmalarıdır. Bakış açısı uyduya bağlı olarak genellikle 20° - 50° arasında değişir. Uydu, yörüngesinin alçalan kısmında hareket ettiğinde, yani kuzeyden güneye hareket ederken, batıya bakan bir hedef alanı görürken; yörüngesinin yükselen kısmında, yani güneyden geri döndüğünde, kuzeyden aynı hedef bölgeyi

doğuya doğru bakıyor olarak görür. Yükselen ve alçalan yörünge geometrisi Şekil 2.4'te gösterilmiştir.




Şekil 2.4 : Uydularda yükselen ve alçalan uydu yörüngelerinin gösterimi (URL-2).

SAR uydularının yükselen ve alçalan yörüngede veri alma olanakları sayesinde iki farklı yörüngede elde edilen LOS yönündeki deformasyonlar yatay ve düşey bileşenlerine ayrılabilir. Yatay bileşen Doğu-Batı yönünde belirlenirken, Kuzey-Güney yönündeki bileşen uydu yörüngesi ile aynı doğrultuda olduğundan düşük hassasiyette belirlenir (Arıkan ve diğ., 2010; Dai ve diğ., 2015). Bu sebeple, düşey bileşenle beraber hesaplanan yatay bileşen Doğu-Batı yönündedir ve Şekil 2.5'te şematik gösterimi verilmiştir.

Deformasyon bileşenleri belirlenirken Eşitlik 2.9 kullanılmıştır (Motagh ve diğ., 2017). $D_{yük}$ ve $D_{alç}$, yükselen ve alçalan uydu yörüngelerinde elde edilen LOS yönündeki deformasyonu ifade etmektedir. θ , geliş açısını (incidence angle) ifade ederken; α ise uydu başucu açısını (satellite heading angle) ifade etmektedir. D_d ve D_y ise düşey ve yatay yöndeki deformasyon bileşenlerini vermektedir.

$$\begin{pmatrix} D_{yük} \\ D_{alç} \end{pmatrix} = \begin{pmatrix} \cos \theta_{yük} & -\cos \alpha_{yük} \sin \theta_{yük} \\ \cos \theta_{alç} & -\cos \alpha_{alç} \sin \theta_{alç} \end{pmatrix} \begin{pmatrix} D_d \\ D_y \end{pmatrix} \quad (2.9)$$




Şekil 2.5 : Uydu yörüngeleri ile deformasyon bileşenlerinin gösterimi.

3. UYDU GÖRÜNTÜLERİNİN SINIFLANDIRILMASI VE DEĞİŞİM ANALİZİ

3.1 Kontrollü Sınıflandırma

İstanbul Havalimanı inşaatı öncesinde insan faaliyetlerinden kaynaklı olarak sürekli bir değişim içerisinde olan çalışma alanının zamansal değişimi, kontrollü sınıflandırma ile tespit edilmiştir. Kontrollü sınıflandırma yöntemi olarak Rastgele Orman (Random Forest-RF) sınıflandırma algoritması kullanılmıştır. RF, Breiman (2001) tarafından sınıflandırma ve regresyon problemlerini çözmek amacıyla geliştirilen bir topluluk öğrenme (ensemble learning) yaklaşımıdır. Topluluk öğrenimi, aynı sorunu çözmek için birden fazla modeli entegre ederek doğruluğu artıran bir makine öğrenimi şemasıdır (Sheykhmousa ve diğ., 2020). RF gibi topluluk öğrenme algoritmaları, tek sınıflandırıcılara göre daha yüksek doğruluğa sahip olmaları ve gürültüye karşı daha güçlü olmaları sayesinde artan bir ilgiye sahiptirler (Breiman, 1996; Dietterich, 2000). RF sınıflandırma algoritması, her sınıflandırıcının girdi vektöründen bağımsız olarak örneklenen rastgele bir vektör kullanılarak üretildiği ve her ağacın bir girdi vektörünü sınıflandırmak için en popüler sınıf için bir birim oy kullandığı ağaç sınıflandırıcılarının bir kombinasyonundan oluşur. Her bir piksel, ormandaki tüm ağaç tahmincilerinden en popüler oylanan sınıf alınarak sınıflandırılır (Breiman, 1999). Şekil 3.1’de RF algoritmasının genel yapısı verilmiştir.

RF; biyoinformatik (Dittman ve diğ., 2015), tıp (Donos ve diğ., 2015), arazi örtüsü ve kullanımının sınıflandırılması (Mahdianpari ve diğ., 2020) gibi birçok farklı alanda yapılan çalışmalarda sıkça kullanılmaktadır. Ancak, açık ve anlaşılır karar verme süreci ve mükemmel sınıflandırma sonuçlarının yanı sıra yersel büyük veri hesaplama hızının artması için RF'nin paralel bir yapıda kolay uygulanabilmesi sayesinde arazi örtüsü sınıflandırmasında popülerlik kazanmıştır (Belgiu ve Drăguț, 2016; Wright ve Ziegler, 2017).



Şekil 3.1 : RF algoritmasının çalışma prensibi.

Optik uydu görüntülerinin sınıflandırılmasında, Google Earth Engine (GEE) platformundan yararlanılmıştır. GEE, birçok petabayt uydu görüntülerini ve coğrafi veri kümelerini global ölçekli analiz yetenekleriyle birleştirir. Araştırmacı ve geliştiricilerin; değişimleri, harita eğilimlerini belirlemesini ve dünya yüzeyindeki farklılıkları belirlemesine olanak sağlar. GEE, uydu görüntülerini depolar, düzenler ve global ölçekte veri madenciliği için kullanılabilir hale getirir. Kamusal veri arşivi ile kırk yıldan fazla süren tarihi dünya imgelerini içerir ve her gün yeni görüntüler toplanarak veri tabanına eklenir. Büyük veri kümelerinin analizini mümkün kılmak için ise diğer araçların yanı sıra JavaScript ve Python'da da uygulama programı arayüzleri (Application Program Interface - API) sağlar (URL-3).

GEE, çok büyük coğrafi veri kümelerini işlemek için yüksek performanslı, bilgi işlem kaynaklarına erişmeyi kolaylaştıran bulut tabanlı bir platformdur. Bu platform sayesinde uydu görüntüleri indirilmeden, platform üzerinde analiz edilebilmektedir. Ayrıca araştırmacıların sonuçlarını diğer araştırmacılar, karar alıcılar, sivil toplum kuruluşları, saha çalışanları ve hatta genel kamuoyu ile kolayca paylaşmaları için tasarlanmıştır (Gorelick ve diğ., 2017).

3.2 Tematik Doğruluk Değerlendirmesi

Yapılan sınıflandırmanın başarılı olup olmadığının tespiti için tematik doğruluk analizi gerçekleştirilir. Doğruluk değerlendirmeleri genellikle bir hata matrisi olarak sunulur ve test verilerindeki performansa odaklanır (Lyons ve diğ., 2018). Doğruluk değerlendirmesinin temel amacı, üretilen sınıflandırma haritalarının hata matrisi ile niceliksel doğruluğunun belirlenmesidir (Foody, 2002). Hata matrisi ile kullanıcı doğruluğu, üretici doğruluğu, genel doğruluk ve Kappa katsayıları hesaplanabilmektedir. Şekil 3.2’de hata matrisi ve doğruluk değerlendirmesi için hesaplanan parametrelerin formülleri verilmiştir. Genel Doğruluk, toplam sınıflandırma doğruluğunu temsil eder. Kullanıcı Doğruluğu, haritanın gerçekten yerde olanı ne kadar iyi temsil ettiğini bildirirken, Üretici Doğruluğu, referans piksellerin ne kadar iyi sınıflandırıldığını ölçer. Kappa katsayısının bire yakın olması yapılan sınıflandırmanın doğruluğunun sonuçlarının tesadüfi olmadığı ve yüksek olduğu anlamını taşımaktadır.

		Referans Veri				
		A	B	C	D	Σ
Sınıflandırma Sonucu	A	n_{AA}	n_{AB}	n_{AC}	n_{AD}	n_{A+}
	B	n_{BA}	n_{BB}	n_{BC}	n_{BD}	n_{B+}
	C	n_{CA}	n_{CB}	n_{CC}	n_{CD}	n_{C+}
	D	n_{DA}	n_{DB}	n_{DC}	n_{DD}	n_{D+}
	Σ	n_{+A}	n_{+B}	n_{+C}	n_{+D}	n

$$\text{Genel Doğruluk} = \frac{\sum_{k=1}^q n_{kk}}{n} \times 100$$

$$\text{Kullanıcı Doğruluğu} = \frac{n_{ii}}{n_{i+}}$$

$$\text{Üretici Doğruluğu} = \frac{n_{ii}}{n_{+i}}$$

$$\text{Kappa} = \frac{n \sum_{k=1}^q n_{kk} - \sum_{k=1}^q n_{k+} n_{+k}}{n^2 - \sum_{k=1}^q n_{k+} n_{+k}}$$

Şekil 3.2 : Hata matrisi ve elemanları (Foody, 2002).




4. STEREO GÖRÜNTÜ ÇİFTİ KULLANILARAK SAYISAL YÜKSEKLİK MODELİ ÜRETİMİ

SYM, her noktanın enlem, boylam ve yüksekliğinin temsil edildiği dijital veridir (Lee ve diğ., 2003). Yüksek doğrulukta SYM'lerin üretilmesi; harita üretimi, üç boyutlu coğrafi bilgi sistemleri, çevresel izleme vb. için önemlidir. SYM, geleneksel olarak topografik haritalardan, arazi ölçmelerinden ve fotogrametrik çalışmalardan üretilmektedir.

Gelişmekte olan ülkelerde ulaşımı zor birçok bölge için yeterli veya güvenilir topografik veri bulunmamaktadır. Yeterince ölçeklendirilmiş bir SYM üretmek için topografik verilerin sayısallaştırılması, zaman alıcı ve pahalı olabilmektedir. Bu durum, araştırmacıları uzaktan algılanan verilerden SYM üretmeye yöneltmiştir. SYM üretimi için kullanılabilecek birçok olası kaynak arasında, uydu görüntüleri potansiyel olarak avantajları ile ön plana çıkmaktadır. Bu avantajlar; sınırlı bir alan yerine geniş kapsama alanına sahip olması, otomasyon sürecini kolaylaştıran dijital veriler ve uydu sensörlerinin belirli zamansal çözünürlükte düzenli kapsama aralıklarına sahip olması olarak sıralanabilmektedir (Krupnik, 2000). Buna ek olarak topografik değişkenliklerin izlenmesi ihtiyacında uzaktan algılama verilerinden uyduların zamansal çözünürlüğüne bağlı olarak istenilen periyotlarda SYM üretilebilir olması bir diğer önemli avantajı oluşturmaktadır.

SYM üretimi; geometrik yöneltme, stereo eşleştirme, düzenleme ve enterpolasyon gibi birçok işlem adımı gerektirir. Tüm bu adımlar, SYM'lerin kalitesine katkıda bulunur; ancak stereo eşleştirme bir SYM'nin doğruluğu ve bütünlüğü için oldukça önemlidir. Stereo eşleştirme, bir stereo görüntü çiftinde eşlenik noktaların bulunması ve eşleştirilmesi işlemidir (Lee ve diğ., 2003). Şekil 4.1'de bir stereo görüntü çifti, arazi ve SYM üzerinde eşlenik noktalar gösterilmektedir. Uydu stereo görüntülerini kullanarak SYM elde etmenin temel teorisi, özellik noktalarını üst üste binen görüntülere göre senkronize etmek ve bu noktaların 3B koordinatlarını üretmektir.


Daha sonra uzay koordinat sisteminde tanımlı stereo model yeniden yapılandırılır ve yerdeki gerçek konumuna göre 3B bilgi elde edilir (Wang ve diğ., 2019).



Şekil 4.1 : Stereo görüntü çiftinden SYM oluşturma (URL-4).

Uydu görüntüsü sağlayıcılarından olan Pleiades uydularının yüksek mekânsal çözünürlüğü, SYM oluşturmak için Pleiades'i bir alternatif haline getirmektedir ve literatürde de yaygın olarak kullanılmaktadır (Almeida ve diğ., 2019; Nurtyawan ve Fiscarina, 2021; Melis ve diğ., 2021). Pleiades uydusu, obje ve görüntü koordinatları arasındaki ilişkiyi temsil eden bir rasyonel fonksiyon modeli için rasyonel polinom katsayısı (Rational Polynomial Coefficient-RPC) dosyasını kullanıcılara sunar ve bu sayede yer koordinatları hesaplanabilir (Dolloff ve Theiss, 2014). Tez çalışması kapsamında da havalimanının inşaatına başladıktan sonra oluşan topoğrafyasını temsil eden SYM, stereo Pleiades görüntü çifti kullanılarak üretilmiştir. SYM üretiminde izlenen adımlar Şekil 4.2'de verilen akış şemasında gösterilmektedir. Başlangıçta, stereo çift görüntülerin seçimi hem kapsama alanını eşleştirmek hem de doğruluk için temel bir adımdır. Görüntü çifti İTÜ Uydu Haberleşme ve Uzaktan Algılama Merkezi (UHUZAM) tarafından temin edilmiştir. Görüntü çifti üzerinde bağlama (tie) noktaları belirlenerek görüntüler koordinatlı bir düzlemle eşleştirilmektedir. Bu işlemin ardından epipolar geometri oluşturularak epipolar görüntüler oluşturulur.

Kameraları, 3B noktaları ve karşılık gelen gözlemleri ilişkilendiren geometri, bir stereo çiftinin epipolar geometrisi olarak adlandırılır. Epipolar görüntüler oluşturulduktan sonra SYM'nin üretileceği projeksiyon vb. çıktı üretme parametreleri belirlenerek SYM üretilir. Son aşamada ise, triangülasyon algoritmalarından, eksik veriden veya uyumsuz değerlerden kaynaklanan anomaliler varsa belirlenerek SYM üzerinde düzenlemeler gerçekleştirilir ve böylece bölgeye ait yüksek çözünürlüklü SYM elde edilir.



Şekil 4.2 : SYM üretiminde izlenen akış şeması.



5. DEFORMASYON ZAMAN SERİLERİNİN GELECEK TAHMİN ANALİZİ

Zaman serisi InSAR deformasyon yöntemlerinden elde edilen deformasyon zaman serileri kullanılarak, birçok yöntem ile tahmin analizleri gerçekleştirilmiş ve hata metrikleri ile model performansları test edilmiştir. Başarılı sonuç veren modeller ile gelecek tahmin analizleri gerçekleştirilmiştir. Gelecek tahminlerinde zaman serilerinin ayrıştırılması ile elde edilen bileşenler ve meteorolojik parametreler regresyonlara dahil edilerek tahmin analizlerinde önem dereceleri belirlenmiştir. Bu bölümde, uygulanan yöntemler geleneksel yöntemler, regresyon tabanlı yöntemler ve derin öğrenme yöntemleri olarak üç grupta verilmiştir.

5.1 Zaman Serilerini Bileşenlerine Ayrıştırma

Ayrıştırma prosedürleri, bir zaman serisindeki eğilimi ve mevsimsel faktörleri tanımlamak için zaman serilerinde kullanılır. Ayrıştırmanın ana hedeflerinden biri, mevsimsellikten arındırılmış değerleri oluşturmak ve sunmak için kullanılabilecek mevsimsel etkileri tahmin etmektir. Trendlerin daha net görülebilmesi için bir değerden mevsimsel etkiyi kaldırır ve mevsimsellikten arındırılmış değerler elde edilir. Temel ayrıştırma modelleri toplamsal ve çarpımsal olmak üzere iki yapıyı kullanır. Toplamsal ayrıştırma modeli, trend, mevsimsel etki ve artık parametrelerinin toplamından oluşurken; çarpımsal ayrıştırma modeli bu üç bileşenin çarpımından oluşmaktadır. Toplamsal ayrıştırma modeli, mevsimsel değişimin zaman içinde nispeten sabit olduğu durumlarda kullanılırken, çarpımsal ayrıştırma modeli mevsimsel değişimin zamanla arttığı durumlarda kullanılmaktadır. Çalışma bölgesinde mevsimsel hareketlilik sabit bir periyotta devam ettiğinden ve çarpımsal model negatif değerlerle işlem gerçekleştirmediğinden, tez çalışması kapsamında toplamsal ayrıştırma modeli kullanılmıştır.

5.2 Geleneksel Yöntemler

5.2.1 ARIMA (AutoRegressive Integrated Moving Average)

Box ve Jenkins (1970) tarafından geliştirilen Otoregresif Entegre Hareketli Ortalama (AutoRegressive Integrated Moving Average - ARIMA), zaman serisi verileri içindeki zamansal yapıları modellemek için otokorelasyon ölçümlerini içeren bir zaman serisi tahmin modelidir. Modelin otoregresyon kısmı, geçmiş gözlem verileri ile belirli bir örneğin bağımlılığını ölçer. Bu farklılıklar, veri modellerini durağan hale getirmek veya geçmiş verilerle bariz korelasyonu en aza indirmek için ölçülür ve entegre edilir.

3 parametre (p, d, q), ARIMA modelini ifade etmektedir. Bu parametreler sırasıyla; p otoregresyon için dikkate alınması gereken geçmiş gözlemlerin sayısını; d ham gözlemlerin kaç kez farklılaştırıldığını ve q ise hareketli ortalama penceresinin boyutunu ifade eder.

Denklem 5.1 tipik bir otoregresif modeli göstermektedir. Adından da anlaşılacağı gibi, bu modelin yeni değerleri, tamamen geçmiş değerlerinin ağırlıklı doğrusal bir kombinasyonuna bağlıdır. p'nin geçmiş değer olduğu göz önüne alındığında, bu AR(p) veya p mertebesinden bir otoregresif model olarak gösterilir. Epsilon (ϵ) ise beyaz gürültüyü ifade eder.

$$Y_t = \alpha + \beta_1 Y_{t-1} + \beta_2 Y_{t-2} + \dots + \beta_p Y_{t-p} + \epsilon_t \quad (5.1)$$

Ardından, hareketli ortalama Denklem 5.2'de gösterildiği gibi tanımlanır:

$$y_t = c + \epsilon_t + \theta_1 \epsilon_{t-1} + \theta_2 \epsilon_{t-2} + \dots + \theta_q \epsilon_{t-q} \quad (5.2)$$

Tahmin edilen y_t değeri, önceki model tarafından yapılan ϵ_t hatalarına dayalı olarak hesaplanır. Bu nedenle, birbirini izleyen her terim, o model tarafından yapılan hataları mevcut hesaplamaya dahil etmek için geçmişe bir adım daha bakar. Geriye dönük bakılan pencereye göre q değeri belirlenir. Bu nedenle, model bağımsız olarak hareketli bir ortalama düzeni q veya basitçe MA(q) olarak gösterilebilir.

5.2.2 Hızlı fourier dönüşümü (Fast Fourier Transform-FFT)

Fourier analizi, bir fonksiyonu periyodik bileşenlerin toplamı olarak ifade etmek ve bu bileşenlerden sinyali kurtarmak için kullanılan bir yöntemdir. Hem fonksiyon hem de onun Fourier dönüşümü, ayrıklaştırılmış karşılıklarıyla değiştirildiğinde, buna Ayrık

Fourier Dönüşümü (Discrete Fourier Transform-DFT) denir. Hızlı Fourier Dönüşümü (Fast Fourier Transform - FFT), DFT'yi diğer algoritmalarından çok daha hızlı hesaplayan bir algoritmadır. FFT, bilgisayarlar aracılığıyla güç spektrum analizi ve filtre simülasyonu gibi sinyal analizini kolaylaştıran bir hesaplama aracıdır. Zaman serisi olarak adlandırılan bir dizi veri örneğinin, DFT hesabını verimli bir şekilde yapmak için kullanılan bir yöntemdir (Cochran ve diğ., 1967).


Tez çalışması kapsamında, Darts kütüphanesinin FFT tahmin modülü kullanılmıştır. Darts, zaman serilerinde kullanıcı dostu tahmin ve anomali tespiti için oluşturulan bir Python kütüphanesidir. Bu model, FFT, müteakip frekans filtreleme ve ters FFT'yi kullanarak bir zaman serisi örneğinde tahmin gerçekleştirir ve verileri trendden çıkarma ve eğitim dizisini tam mevsimlik dönemlere kırma seçeneğiyle birlikte kullanır. Kullanılan FFT modülü, tahmin analizini sırasıyla aşağıdaki adımları uygulayarak gerçekleştirir:

- Zaman serisinin trendi belirlenir. Kullanıcı tarafından trend fonksiyonunun polinom veya eksponansiyel gibi türü de girdi olarak belirtilebilmektedir.
- Trend verisi zaman serisinden çıkarılarak trendsizleştirme işlemi gerçekleştirilir.
- İlk tahmin noktasından mevsimselliğe uyacak şekilde eğitim verisinin kırılma işlemi gerçekleştirilir. Kullanıcı mevsimsel periyodu kendi de girdi olarak belirleyebilir. Bu adımda, trendsizleştirilmiş zaman serisi üzerinden işlemler gerçekleştirilir.
- DFT uygulanır ve tahmin için frekanslar sıralanarak zaman serisinin en önemli frekansları belirlenir. Kullanıcılar en önemli frekans sayısını girdi olarak da ayrıca verebilmektedir.
- Frekans alanındaki diğer tüm değerler sıfır olarak ayarlanır ve ters DFT kullanılarak olası tüm tahmin edilen değerler önceden hesaplanır.
- Tahmin analizinde ise hem trend hem de ters DFT ile belirlenen verilerin toplamı ile kullanıcının belirlediği adım sayısı kadar tahmin analizi gerçekleştirilir.

5.3 Regresyon Tabanlı Yöntemler

Regresyon tabanlı makine öğrenmesi algoritmaları, Skforecast kütüphanesi kullanılarak uygulanmıştır. Skforecast, Python programlama dili kullanılarak bütün Scikit-learn regresyon modellerini uygulamak amacıyla geliştirilmiştir. Skforecast tahmin analizlerinde Özyinelemeli çok adımlı tahmin (Recursive multi-step forecasting - RMF) modeli kullanılmıştır.


RMF yaklaşımında, t_n anındaki değerini tahmin etmek için t_{n-1} anındaki zaman serisi değeri gerekli olduğundan ve t_{n-1} bilinmediğinden, her yeni tahminin bir öncekine dayandığı özyinelemeli bir süreç uygulanır. Her tahmin edilen değer bir sonraki adımı tahmin etmek için kullanılarak ilerler. Lags parametresi, tahmin analizinde geriye yönelik bakılacak veri sayısını ifade etmektedir. RMF için makine öğrenimi modellerini kullanırken karşılaşılan en büyük zorluk, zaman serisini, serinin her değerinin kendisinden önceki zaman penceresiyle (Lags) ilişkili olduğu bir matrise dönüştürmektir. Şekil 5.1’de örnek bir RMF yaklaşımı gösterilmektedir (Url-5).



Şekil 5.1 : Serinin son 4 verisini tahmin edici olarak kullanarak geleceğe yönelik 3 adımı tahmin eden RMF diyagramı (URL-5).

RMF modeli baz alınarak modelin daha iyi öğrenmesini ve tahmin gücünü arttırmak amacıyla geriye dönük test (backtesting, GDT) uygulanmıştır. Geriye dönük test, zaman serisi verileri üzerinde tahmine dayalı bir modelin test edilmesini ifade etmek için modellemede kullanılan bir terimdir. Geriye dönük test, zamanda adım adım, gerektiği kadar çok aşamada geriye gitmeyi içerir. Bu nedenle, önceki dönemlere

uygulanan özel bir çapraz doğrulama türüdür (URL-6). Şekil 5.2’de tezde kullanılan geriye dönük test modelinin işleyiş şeması gösterilmiştir. Görülmeyen veri, modelin görmediği veridir, ancak sonraki adımlarda adım boyutuna göre dahil edilerek model eğitilmektedir.




Şekil 5.2 : Artan eğitim seti ve geriye dönük test prensibi (URL-6).

RMF modeli baz alınarak Rastgele Orman Regresyon (Random Forest Regression-RFR), Destek Vektör Regresyon (Support Vector Regression - SVR), XGBoost Regresyon (XGBR) ve CatBoost Regresyon (CBR) makine öğrenmesi algoritmaları kullanılmıştır.

5.3.1 Rastgele orman regresyon

RFR, Breiman (2001) tarafından geliştirilen regresyon ağacı analizine benzerdir. RFR, tahmin edicileri yinelemeli olarak bir dizi ikili bölmeye ayırır (Şekil 5.3) (Graw ve diğ., 2021). Regresyon ağaçları bağımsız olarak eğitilir ve tahminleri üretmek için ağaçların çıktısının ortalaması alınır (Yoon, 2021).




Şekil 5.3 : RFR adımlarının gösterimi (Graw ve diğ., 2021).

5.3.2 Destek vektör regresyon

SVR, istatistiksel/makine öğrenimi teorisine dayalı sınıflandırma paradigması olan destek vektör makinelerinin bir uyarlamasıdır. SVR metodu, yapılandırılmış risk minimizasyon ilkesine dayanmaktadır ve empirik hataları bulmak yerine, genelleştirme hatasının üst sınırını en aza indirmeyi amaçlar (Pai ve diğ., 2010).


SVR modeli, Şekil 5.4'te gösterildiği gibi gerçekleşir. Hiper düzlem için genelleştirilmiş denklem $y = wX + b$ şeklinde gösterilebilir, burada w , ağırlıklar ve b , $X = 0$ 'daki kesişme noktasıdır. Tolerans payı ise, epsilon (ϵ) ile temsil edilir (Parbat ve Chakraborty, 2020).



Şekil 5.4 : Lineer regresyon için SVR modelinin gösterimi (Parbat ve Chakraborty, 2020).

5.3.3 Aşırı gradyan arttırma (XGBoost) regresyon

XGBoost, Gradyan Arttırma Karar Ağacı'na (Gradient Boosting Decision Tree - GBDT) dayalı bir sınıflandırma ve regresyon algoritmasıdır ve gösterdiği yüksek performans sayesinde son yıllarda oldukça sık kullanılan yeni nesil bir algoritmadır (Chen ve Guestrin, 2016). XGBoost, sütun örnekleme ile aşırı öğrenmeyi (overfitting) önler ve hesaplama miktarını azaltır. XGBoost, Şekil 5.5'te gösterildiği gibi güçlendirilmiş bir ağaç modelidir; yani, bir başlangıç ağacı bir değeri tahmin eder, ardından değer gerçeğe göre sapmasını alır ve sapmayı öğrenmek için bir ağaç ekler (Li ve diğ., 2022).



Şekil 5.5 : XGBoost çalışma prensibi (Li ve diğ., 2022).

5.3.4 CatBoost regresyon metodu


CatBoost, Yandex tarafından geliştirilen ve karar ağaçlarında gradyan artırmayı kullanan bir makine öğrenimi algoritmasıdır (Dorogush ve diğ., 2018). Öğrenmek için büyük miktarda veriye ihtiyaç duyan derin öğrenme modellerine göre nispeten daha az veri ile çok iyi sonuçlar üretebilmektedir (Kuanr ve diğ., 2022). CatBoost, aynı bölme kriterinin ağacın tüm seviyesinde kullanıldığı habersiz karar ağaçlarını kullanır. Bu tür ağaçlar dengelidir, aşırı öğrenmeye daha az eğilimlidir ve test süresinde tahmini önemli ölçüde hızlandırmaya olanak tanır.

5.4 Derin Öğrenme Yöntemleri

Derin öğrenme, büyük veri analizinde en hızlı büyüyen ve 2013'ün on çığır açan teknolojilerinden biri olarak kabul edilmiştir (MIT, 2013). Genellikle ikiden fazla gizli katman içeren sinir ağları ile karakterize edilir ve bu nedenle derin öğrenme olarak adlandırılır. Derin öğrenme yöntemleri, insan beyninden ilham alan veri odaklı makine öğrenimi yöntemleridir. Bu sinir ağları, çoklu işleme katmanlarıyla uyarlanabilir ve otomatik bir şekilde öğrenme ve çıkarma yeteneğine sahiptir. Son yıllarda görüntü sınıflandırma, tanıma ve bölütleme gibi çeşitli alanlarda gerçekleştirilen uygulamalarda üstün performans göstermektedir (Zhu ve diğ., 2017).

InSAR zaman serisi tahmin analizlerinde de özellikle LSTM metodu uygulanmaya başlanmıştır (Li ve diğ., 2020; Radman ve diğ., 2021; Chen ve diğ., 2021; Hill ve diğ., 2021). LSTM, Hochreiter ve Schmidhuber (1997) tarafından geliştirilen Tekrarlayan Sinir Ağları (Recurrent Neural Network - RNN)'nin özel bir çeşididir. RNN dinamik zaman serisi problemlerinde aktif bir şekilde kullanılmaktadır. RNN'nin türü olarak

LSTM ağı ise geleneksel RNN nöronlarını geliştirerek, gradyan kaybolması sorununu ele alarak uzun süreli diziler üzerinde öğrenmeye ve hafızayı korumaya izin verir (Xing ve diğ., 2019). LSTM ağ mimarisi Şekil 5.6’da verilmiştir.



Şekil 5.6 : LSTM mimarisi (Xu ve Niu, 2018).

LSTM, kendisinin uzun vadeli bağımlılığa sahip olmasını sağlayan ve kapı adı verilen üç özel yapı sunar. Kapı, aktivasyon fonksiyonu sigmoid fonksiyon olarak tasarlanmış bir sinir hücresidir (Liu ve diğ., 2020). LSTM, üç işlevsel kapı içerir: giriş, çıkış ve unut. Giriş kapısı, dışarıdan hangi bilgilerin depolanacağına karar verirken, çıkış kapısı ağ içindeki önemli bilgilerin çıkışını düzenler. Unut kapısı, bazı gereksiz bilgileri atabilir. Üç kapı, veri işlemeyi gerçekleştirmek için birbirleriyle iş birliği yapar (Xing ve diğ., 2019). Bu işlem dizisi matematiksel olarak aşağıdaki şekilde tanımlanabilir (Xu ve Niu, 2018; Xie ve diğ., 2019):

$$f_t = \text{sig}(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (5.3)$$

$$i_t = \text{sig}(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (5.4)$$

$$C_t = f_t \times C_{t-1} + i_t \times \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (5.5)$$

$$o_t = \text{sig}(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (5.6)$$

$$h_t = o_t \times \tanh(C_t) \quad (5.7)$$

x_t ve h_t giriş ve çıkış şimdiki zaman dilimindeki adımı; h_{t-1} ve C_{t-1} bir önceki zaman dilimindeki çıkış ve hücre hafızası; (W_f , W_i , W_c , W_o) ve (b_f , b_i , b_c , b_o) sırasıyla unut kapısı, giriş kapısı, hücre durumu katmanı ve çıkış kapısının ağırlık matrisi ve bias vektörü; f_t , i_t ve o_t unut, giriş ve çıkış kapılarının aktivasyon vektörlerini ifade etmektedir.

5.5 Tahmin Modellerinin Doğruluk Değerlendirmesi

Modellerin tahmin doğruluğunu belirlemek üzere istatistiksel metrikler kullanılmaktadır. Bu metriklerden karesel ortalama hata (Root Mean Square Error - RMSE), ortalama mutlak hata (Mean Absolute Error - MAE) ve Pearson's korelasyon katsayısı (R) tez çalışması kapsamında kullanılmıştır. Kullanılan metriklerin formülleri Çizelge 5.1'de verilmektedir.

Çizelge 5.1 : Tahmin doğruluklarının belirlenmesinde kullanılan hata metrikleri.

Metrik	Formül	Açıklama
RMSE	$\sqrt{\sum_{i=1}^n \frac{(y_i - \hat{y}_i)^2}{n}}$	n: örnek sayısı y: gerçek değer $\hat{y}$: tahmin edilen değer
MAE	$\sqrt{\sum_{i=1}^n \frac{(y_i - \hat{y}_i)}{n}}$	m_y : gerçek değer ortalaması $m_{\hat{y}}$: tahmin edilen değerin ortalaması
R	$\frac{\sum (y - m_y)(\hat{y} - m_{\hat{y}})}{\sqrt{\sum (y - m_y)^2 \sum (\hat{y} - m_{\hat{y}})^2}}$	

5.6 Özniteliklerin Önem Derecelerinin Belirlenmesi

Bir tahmin modelinin çıktısını doğru bir şekilde yorumlamak son derece önemlidir. Bu doğrultuda regresyonlara dahil edilen özniteliklerin regresyon modelinde sağladığı katkı düzeylerinin belirlenmesi için regresyon modelinde önem derecelerini belirleyen yöntemler geliştirilmiştir. Permütasyon Öznitelik Önemi ve literatürde oldukça popüler hale gelen SHAP (SHapley Additive exPlanations) yöntemleri tez çalışması kapsamında uygulanmıştır.

5.6.1 Permütasyon öznitelik önemi


Breiman (2001) tarafından ilk olarak RF algoritması için geliştirilen Permütasyon Öznitelik Önemi, öznitelik ile hedef değişken arasındaki ilişkiyi bozan özelliğin değerlerini değiştirdikten sonra modelin tahmin hatasındaki artışı ölçer. Bir özelliğin değerlerinin karıştırılması model hatasını artırıyorsa bu öznitelik "önemlidir" çünkü bu durumda model, tahmin için bu özelliğe dayanır.

5.6.2 SHAP (SHapley Additive exPlanations)

Lundberg ve Lee (2017) tarafından geliştirilen SHAP metodu, bireysel tahminleri açıklamaya yönelik bir yöntemdir. SHAP metodunun amacı, her bir özelliğin tahmine katkısını hesaplayarak bir x örneğinin tahminini açıklamaktır. SHAP açıklama yöntemi, Shapley değerlerini koalisyon oyun teorisinden hesaplar. Shapley değerleri tüm olası permütasyonları göz önünde bulundurur, bu nedenle SHAP, küresel ve yerel tutarlılık ve yorumlanabilirlik sağlayan birleşik bir yaklaşımdır. SHAP, grafikler çizerek hangi özelliğin önemli hangi özelliğin gereksiz olduğunu seçmeye yardımcı olur. Büyük mutlak Shapley değerlerine sahip öznitelikler önemli olarak nitelendirilir.

SHAP öznitelik önemi, permütasyon öznitelik önemine bir alternatiftir. Her iki önem ölçüsü arasında büyük bir fark vardır. Permütasyon öznitelik önemi, model performansındaki düşüşe bağlıken; SHAP, özniteliklerinin büyüklüğüne dayalıdır.

aşaması tamamlanan havalimanının 2029 yılında tamamlanması planlanmaktadır (URL-7). 6 adet pistten oluşan İstanbul Havalimanı, tamamlanan A ve B pistleri ile 29 Ekim 2018 tarihinde kullanıma açılmıştır. Son olarak da C pisti Haziran 2020’de tamamlanarak yolcuların kullanımına açılmıştır.



Şekil 6.2 : İstanbul Havalimanı'nın yapım aşamaları.

Havalimanı inşaatından önce, çalışma bölgesinde 19. yy.'ın sonlarına kadar açık kömür ocakları ve endüstriyel nitelikli kum ve kil yatakları işletilmekteydi. Karadeniz'e paralel konumda yer alan ormanlık alanlardan kömür çıkarılırken, 1988 yılından sonra karada yer alan rezervler tükendiğinden şirketler kuzeye denize doğru yönelmiştir. Önceki alanlardan çıkarılan hafriyat malzemesi kullanılarak kıyıya inşa edilen bentler vasıtasıyla denizin sığ olan alanları doldurularak maden çıkarmaya devam etmişlerdir (Gazioğlu ve diğ., 1997). Kum ve maden ocaklarından çıkarılan hafriyat malzemeleri gelişigüzel çukurlara doldurulduğundan bölgede 20-140 m arasında yüksekliklere sahip tepelerle, yer yer engebeli bir topoğrafya oluşmuştur. Bu tür insan faaliyetleri ile ekosistemlerin topoğrafik yapısı ve doğal dengesi bozulmuştur (Kaya ve diğ., 2008).

1992’de gaz tüketiminin başlamasıyla, ısıtma amaçlı kullanılan kömür tüketimi azalmış ve açık maden ocakları terkedilmiştir. Maden ocaklarının akarsular, yer altı

suları ve yağmur suları ile doldurulması sonucunda farklı büyüklük ve derinliklerde çok sayıda sulak alan oluşmuştur (Köse ve Kul, 2020). Madencilik faaliyetlerinin sona ermesiyle kazılan alanlar sulak alanlara dönüşmüş, tepeler ise ağaçlandırılmıştır. Zamanla sulak alanlar ve çevresinde kendine özgü bir ekosistem oluşmuş ve doğal bir denge kurulmuştur. Ancak sulak alanların bir kısmı İstanbul Havalimanı inşaatı sınırları içerisinde kalarak tahrip olmuştur. 2015 yılında hafriyatla doldurulan sulak alanların üzerine havalimanı inşaatına başlanmıştır.

Bölgede bulunan sulak alanlardan sadece biri doğal oluşumlu olup irili ufaklı birçok sulak alan mevcuttu. Büyük göllerin tabanında 6,5 m kalınlığı bulan balçık, suya doymuş sedimentler ve gevşek yapıda olan maden atık yığınları zemin açısından tehlikeli durumlar olarak listelenmektedir. Tehlikeli durumlar bunlarla sınırlı olmayıp;

- Engeli hale getirilen topoğrafya üzerine inşa edilmesi için aşırı miktarda kazı/dolgu gerektirmesi,
- Sulak alanların tabanında yer alan zeminin suya doymuş sedimentlerden oluşması,
- Yüzeysel ve derin heyelanlar,
- Birincil (ani) ve ikincil (uzun süreli) zemin oturmaları,
- Sıvılaşma,
- Yeraltı su seviyesindeki değişkenlik,
- Terkedilmiş kömür ve kil ocaklarının rehabilite edilmemesi,
- Zemin yapısının proje yükünü karşılayamayacak yapıda olması gibi durumlar Türk Mühendis ve Mimar Odaları Birliği (TMMOB)'nin 2014 yılında yayınladığı teknik raporda tehlikeli durumlar olarak sıralanmıştır (TMMOB, 2014).

İlk etapta Pist, Apron ve Taksirut (PAT) alanlarının ortalama 105 m kotunda planlanarak 2.500.000.000 m³ dolgu ile çok az miktarda kazı ile gerçekleştirileceği Çevresel Etki Değerlendirmesi (ÇED) Raporu'nda belirtilirken (UDHB, 2013) havalimanının inşaat esnasında 70 m'ye düşürüldüğü ifade edilmektedir (Tolunay, 2015). 105 m derinlikte sulak alanların olduğu göz önüne alındığında, 105 m dolgu ile

oturma toleransının oldukça düşük olduğu Jeoloji Mühendisleri Odası (JMO)’nın hazırlamış olduğu raporda belirtilmiştir (JMO, 2014).

6.2 Kullanılan Veriler

Tez çalışması kapsamında hem optik hem de SAR uydu görüntülerinin yanı sıra yardımcı veri olarak meteorolojik veriler kullanılmıştır. Kullanılan verilerin listesi Çizelge 6.1’de kullanım amaçlarıyla birlikte verilmiştir.

Çizelge 6.1 : Kullanılan veriler ve kullanım amaçları.

Veri Adı	Kullanım Amacı
Landsat-5 TM Landsat-8 OLI	Arazi örtüsü/arazi kullanımı
Pleiades SRTM	Kazı/dolgu alanlarının belirlenmesi
Sentinel-1 SLC	Yapısal hareketlerin belirlenmesi
Meteorolojik parametreler	Mevsimsel analiz Tahmin analizleri

6.2.1 Optik uydu verileri

Tez çalışması kapsamında, iki farklı optik uydu görüntüsü, farklı amaçlarla kullanılmıştır. İlk olarak havalimanının inşa edildiği bölgenin zamansal ve mekânsal değişiminin analizinde kullanılmak üzere Landsat uydu görüntüleri kullanılmıştır. NASA tarafından fırlatılan Landsat uyduları 50 yılı aşkın bir süredir optik uydu görüntülerinin teminini sağlamaktadır ve geriye dönük uzun dönem analizlerinde sıkça kullanılmaktadır (URL-8). 2022 yılında 50. yılını kutlayan Landsat uydu serileri, multispektral tarayıcı sistemi (Multispectral Scanner System-MSS) algılayıcısına sahip Landsat-1 uydusunun 23 Temmuz 1972 tarihinde fırlatılmasıyla beraber orta mekânsal çözünürlükte uydu verisi temin etmeye başlamıştır. Landsat-2 MSS, Landsat-3 MSS ve Landsat-4 MSS uyduları ile 60 m çözünürlükte veri temin etmeye devam etmiştir. Tematik Haritalayıcı (Thematic Mapper-TM) sensörünün Landsat-4 uydusuna entegre edilmesiyle beraber 30 m çözünürlükte veri elde edilmeye başlanmıştır. Landsat-5 TM, Landsat-7 Gelişmiş TM+ (Enhanced Thematic Mapper Plus-ETM+) uydularıyla 2011 yılına kadar veri temin etmiştir. Son olarak, Operasyonel Arazi Görüntüleyici (Operational Land Imager-OLI) algılayıcısının

entegre edilmesiyle Landsat-8 OLI ve Landsat-9 OLI ile veri teminine devam edilmektedir.

Çalışma alanının geçmişten günümüze AÖ/AK haritalarının üretilmesi amacıyla 30 m mekânsal çözünürlüğe sahip Landsat-5 TM ve Landsat-8 OLI optik uydu görüntüleri kullanılmıştır. 1984 yılından 2020 yılına kadar beşer yıllık periyotlarla çalışma gerçekleştirilmiştir. 1985 yılında hava koşullarından dolayı uygun görüntü bulunamadığından 1984 yılına ait uydu görüntüsü kullanılmıştır. Uydu görüntü tarihlerinin seçiminde aynı mevsimde yer almalarına özen gösterilmiştir ancak optik uydu görüntülerinin hava şartlarından ve özellikle bulut probleminden etkilenmesi sebebiyle uygun görüntü bulunamadığında, en yakın tarih dikkate alınmıştır. Kullanılan Landsat uydu verilerinin teknik özellikleri Çizelge 6.2’de verilmiştir.

Çizelge 6.2 : Landsat uydu görüntülerinin teknik bilgileri.

Çözünürlük Türü	Landsat-5 TM	Landsat-8 OLI
Spektral Çözünürlük (µm)	B1-Mavi: 0,45-0,52	B1-Kıyısal: 0,43-0,45
	B2-Yeşil: 0,52-0,60	B2-Mavi: 0,45-0,52
	B3-Kırmızı: 0,63-0,69	B3-Yeşil: 0,52-0,60
	B4-Yakın Kızılötesi: 0,76-0,90	B4-Kırmızı: 0,63-0,69
	B5-Kısa Dalga Kızılötesi: 1,55-1,75	B5-Yakın Kızılötesi: 0,85-0,89
	B6-Termal: 10,40-12,50	B6-Kısa Dalga Kızılötesi: 1,56- 1,66
	B7-Kısa Dalga Kızılötesi: 2,08-2,35	B7-Kısa Dalga Kızılötesi: 2,10- 2,30
		B8-Pankromatik: 0,50-0,68
		B9-Cirrus: 1,36-1,39
		B10- Termal: 10,30-11,30
		B10-Termal: 11,50-12,50
Mekânsal Çözünürlük (m)	B1-B5, B7: 30 m B6: 120 m	B8: 15 m B1-B7, B9: 30 m B10-B11: 100 m
Radyometrik Çözünürlük	8 bit	12 bit
Zamansal Çözünürlük	16 gün	16 gün
Kullanılan Uydu Görüntüsü Tarihleri	27.05.1984 12.05.1990 10.05.1995 07.05.2000 18.03.2005 06.07.2010	06.09.2015 28.04.2020

Havalimanı inşaatı esnasında kazı ve dolgu bölgelerinin belirlenmesi amacıyla Pleiades uydusundan temin edilmiş yüksek çözünürlüklü stereo Pleiades görüntü çifti kullanılarak SYM üretilmiştir. Pleiades görüntü çifti, havalimanı inşaatının devam etmekte olduğu 2016 yılına ait olup, teknik bilgileri Çizelge 6.3'te verilmektedir.

Çizelge 6.3 : Pleiades uydu görüntülerinin teknik bilgileri.

Çözünürlük Türü	Pleiades
Spektral Çözünürlük (µm)	B1 – Mavi: 0,45-0,53
	B2 – Yeşil: 0,51-0,59
	B3 – Kırmızı: 0,62-0,70
	B4 – Yakın Kızılötesi: 0,775-0,915
	Pan: 0,48-0,82
Mekansal Çözünürlük (m)	Pan: 0,5 m B1-4: 2 m
Radyometrik Çözünürlük	12 bit
Zamansal Çözünürlük	26 gün
Kullanılan Uydu Görüntüsü Tarihleri	24.07.2016 görüntü çifti

6.2.2 SAR uydu verileri

ESA tarafından fırlatılan Sentinel-1 uydusu, 2014 yılından beri ücretsiz olarak SAR görüntüsü servis etmektedir. Servis edildiği günden beri InSAR analizlerinde oldukça popüler olan ve kullanım sıklığı gün geçtikçe artan Sentinel-1 verileri, orta mekânsal çözünürlükteki C banda sahiptir ve 12 günde bir veri sağlamaktadır. Avrupa üzerinde veri sıklığı 6 günde bir olurken, Sentinel-1B verisinin Aralık 2021'de hasar görmesi ve veri temin etmemesi sebebiyle veri sıklığı 12 günde bir düşmüştür. Sentinel-1 uydu verilerinin teknik detayları Çizelge 6.4'te verilmektedir.

Çizelge 6.4 : Sentinel-1 SAR uydu görüntülerinin teknik bilgileri.

Veri	Mekansal Çözünürlük	Polarizasyon	Geliş Açısı (°)	Zamansal Çözünürlük
Sentinel-1 SLC (C bandı)	5×20 m (azimut×menzil)	VV, VH	29,1-46	12 gün

Sentinel-1, Türkiye üzerinde Interferometric Wide Swath (IW) modunda yaklaşık olarak 700 km yörünge yüksekliğinde ve 29,1° ile 46° bakış açılarıyla algılama yapmaktadır. Algılayıcı şerit genişliği 250 km ve 5×20 m (menzil×azimut) mekânsal çözünürlüğe sahiptir (URL-9). Sentinel-1, Türkiye üzerinde düşey-düşey (vertical-vertical - VV) ve düşey-yatay (vertical-horizontal - VH) olmak üzere iki

polarizasyonda ve hem alçalan (descending) hem de yükselen (ascending) yörüngede görüntü almaktadır.

6.2.3 Meteorolojik veriler

Çalışma alanı olan İstanbul Havalimanı'nda bir adet meteorolojik istasyon mevcuttur. Bu istasyonda ortalama sıcaklık, buharlaşma ve yağış parametreleri ölçülerek araştırmacıların ve kurumların kullanımına sunulmaktadır. Ancak yağış ve sıcaklık ölçmeleri 2019 yılı itibariyle ölçülmeye başlarken, buharlaşma parametresi 2020 yılı itibariyle ölçülmektedir. Bu kapsamda bölgede buharlaşma parametresini ölçen başka istasyon bulunmamakla birlikte, bütün parametreleri sürekli olarak ölçen İstanbul Bölge Meteoroloji İstasyonu'ndan veri alınabilmektedir. Toprak sıcaklığı parametresi ise yine İstanbul Havalimanı istasyonunda ölçülmediğinden en yakın istasyon olan Sarıyer İTÜ İstasyonu'ndan alınabilmektedir. Meteorolojik parametreler ve istasyon bilgileri Çizelge 6.5'te verilmektedir.

Çizelge 6.5 : Meteorolojik parametreler ve temin edilen istasyon bilgileri.

Parametre	İstasyon	Veri aralığı
Ortalama sıcaklık (°C)	İstanbul Havalimanı	Ocak 2019 – Eylül 2022
Toplam yağış (mm)	İstanbul Havalimanı	Ocak 2019 – Eylül 2022
Toplam açık yüzey buharlaşması (mm)	İstanbul Bölge	Kasım 2018 – Eylül 2022
Toprak sıcaklığı – 5 cm (°C)	Sarıyer/İTÜ	Kasım 2018 – Eylül 2022

Çizelge 6.5'te verilen istasyonlardan sadece belirli parametreler temin edilebilmektedir. Çalışma alanına olan mesafeleri göz önüne alındığında her ne kadar Sarıyer/İTÜ istasyonu yakın olsa da İstanbul Bölge istasyonu Anadolu yakasında yer almakta ve çalışma alanına oldukça uzak bir konumda yer almaktadır. Toplam açık yüzey buharlaşması parametresi diğer istasyonlarda çalışmanın gerçekleştirildiği süre zarfında ölçülmemesi ve meteorolojik parametrelerin birbirinden uzak ve farklı istasyonlardan temin edilmesi, sonuçlarda anlamlı bir değerlendirme yapmaya olanak sağlamayacaktır. Tüm meteorolojik parametrelerin tek bir kaynaktan ve sürekli elde edilebilmesi sebebiyle, tahmin analizlerinde günlük ERA5-Land verisi kullanılmıştır. ERA5, çok sayıda atmosferik, kara ve okyanus iklimi değişkenlerinin saatlik

tahminlerini sağlar. ERA5-Land verisi ise ERA5 iklim verilerinin kara bileşeninin tekrar analizi ile üretilmiştir. Yeniden analiz işleminde, fizik yasaları kullanılarak model verileri dünyanın dört bir yanından gözlemlerle eksiksiz ve tutarlı bir veri kümesinde birleştirilir. ERA5-Land verisi 1950'den günümüze 2-3 ay öncesine kadar olan verileri sunmaktadır (URL-10). Yaklaşık olarak 11 km çözünürlükte 50 banda sahiptir. Tez çalışması kapsamında, 2 m yükseklikte hava sıcaklığı, 0-7 cm için toprak sıcaklığı, toplam yağış ve toplam buharlaşma parametreleri kullanılmıştır. Veriler GEE kullanılarak zaman serisi halinde elde edilmiştir ve çalışmalara dahil edilmiştir.



7. YÜZEY HAREKETLERİNİN SEBEP-SONUÇ İLİŞKİLERİ ÇERÇEVESİNDE BELİRLENEREK ZAMAN SERİLERİ İLE MODELLENMESİ

Tez çalışması kapsamında öncelikle çalışma bölgesi sınırlarında arazi örtüsü/arazi kullanımı alanlarının değişim analizi gerçekleştirilmiştir. Daha sonra iki farklı TS-InSAR yöntemi kullanılarak yüzey deformasyon hareketleri elde edilmiş ve sonuçlar birlikte değerlendirilmiştir. Bölgede inşaat öncesi ve sonrası kazı/dolgu bölgelerini belirlemek amacıyla inşaat sonrası alınan stereo uydu görüntüleri ile SYM üretilmiştir. İnşaat öncesi SYM ile farkları alınarak kazı/dolgu bölgeleri belirlenmiş, deformasyon sonuçlarıyla birlikte irdelenerek sebep sonuç ilişkileri çerçevesinde değerlendirilmiştir. Son olarak, seçilen 6 bölge için geleneksel, makine öğrenmesi ve derin öğrenme yöntemleri ile tahmin analizleri yapılmış olup gelecek tahmin analizleri gerçekleştirilmiştir. Yardımcı veriler (özellikler) eklenerek, bu verilerin zaman serilerinin gelecek tahminine katkısı ve önem dereceleri iki farklı yöntem ile belirlenerek sonuçlar irdelenmiştir.

7.1 Çalışma Alanının Sınıflandırılması ve Değişim Analizi

Çalışma alanında meydana gelen değişimlerin ortaya konması için RF algoritması ile 1984-2020 zaman periyodunda beşer yıllık aralıklarla kontrollü sınıflandırma işlemi gerçekleştirilmiştir. Sınıflandırma çalışmalarında 50 yıldan fazla süredir uydu görüntüsü sağlayan Landsat uydu verilerinden yararlanılmıştır. Sınıflandırma işlemi gerçekleştirilmeden önce oldukça az sayıda olan köy tipi yerleşim alanları, köy yerleşim dağılımını ifade edecek şekilde genel hatları ile görüntü üzerinde sayısallaştırılarak sınıflandırma işlemleri öncesinde görüntülerden çıkarılmıştır. Aynı şekilde havalimanı inşaatı sonrası yapılan yol ve pistler de vektör veriler yardımıyla 2020 tarihli uydu görüntüsünden çıkarılarak sınıflandırma işlemi gerçekleştirilmiştir.


Sınıflandırma işleminde su kütlesi, vejetasyon, açık alan ve bina sınıfları için eğitim verileri toplanmış, veriler 10 farklı şekilde eğitilerek tematik doğruluk analizi gerçekleştirilmiş ve elde edilen doğruluk değerlendirmesi metriklerinin (genel

doğruluk, Kappa) ortalaması alınarak Çizelge 7.1’de verilmiştir. Çizelge incelendiğinde genel doğrulukların yüksek Kappa katsayılarının da bu durumu doğrular nitelikte olduğu görülmektedir

Çizelge 7.1 : Tematik doğruluk değerlendirme sonuçları.

Tarih	Genel Doğruluk (%)	Kappa
1984	95,0	0,93
1990	96,3	0,95
1995	95,7	0,94
2000	91,3	0,88
2005	93,3	0,91
2010	94,3	0,92
2015	90,3	0,87
2020	95,8	0,94


Üretilen sınıflandırma sonucu tematik haritaları Şekil 7.1’de verilmiştir. Su kütlesi sınıfında, sulak alanlar ve deniz bölgesi ayrılarak, havalimanı inşaatı öncesinde bölgede yer alan sulak alanların zamansal değişimi gösterilmiştir.



Şekil 7.1 : Çalışma bölgesine ait kontrollü sınıflandırma sonuçları.

Şekil 7.1 incelendiğinde, 2000 yılından itibaren yol yapımının başladığı, havalimanı inşaatıyla beraber hız kazandığı görülmektedir. Ayrıca sulak alanların oluşumunda

artış olduğu, ancak büyük su kütlelerinin olduğu bölgede havalimanı inşaatı sebebiyle tahribatın olduğu da 2015 yılı sonuçlarında görülmektedir. Sınıflandırma ile sınıfların alansal değişimleri belirlenmiş olup Şekil 7.2’de 1984 yılına göre artış/azalış oranlarıyla birlikte verilmiştir.



Şekil 7.2 : Arazi örtüsü/arazi kullanımının alansal olarak zamansal değişimi.

Şekil 7.2 incelendiğinde, sulak alanlarda 1984 yılına göre artış olduğu görülse de havalimanı inşaatı başlamadan önceki 2010 yılında 727,5 ha olan sulak alanların yüzey alanı ciddi bir azalma yaşayarak 2020 yılında 217 ha olmuştur. 1984 yılına göre bitki örtüsünün değişimi incelendiğinde %24’lük bir azalma olurken açık alan sınıfında ise %7 artış görülmüştür. Kırsal yerleşimin de yıllar içerisinde artış gösterdiği elden edilen bir diğer sonuçtur.


7.2 INSAR Zaman Serisi Analiz Sonuçları

InSAR zaman serisi analizlerinde SBAS ve PSI olmak üzere iki yöntemin sonuçları hem yükselen hem de alçalan yörüngede elde edilmiştir. Elde edilen sonuçlar sırasıyla incelenmiştir.


7.2.1 SBAS zaman serisi analizi

SBAS yöntemi ile deformasyon zaman serilerinin elde edilmesinde LiCSBAS uygulama paketi kullanılmıştır. Uygulama paketinin yaklaşık olarak 100 m çözünürlükte sonuçlar üretmesi, çalışma alanında meydana gelen deformasyonlar ile ilgili genel değerlendirme yapılmasına olanak sağlamaktadır. Deformasyon analizi havalimanının kullanıma açıldığı Kasım 2018 ile Eylül 2022 tarih aralığını

kapsamaktadır. SBAS ile kurulan yükselen ve alçalan yörüngedeki interferogram ağı Şekil 7.3'te verilmiştir.




(a)




(b)

Şekil 7.3 : Yükselen (a) ve alçalan (b) yörüngede LiCSBAS ile gerçekleştirilen interferogram ağları.

Şekil 7.3'te verilen interferogram ağı doğrultusunda yükselen ve alçalan yörüngede elde edilen SBAS zaman serisi kümülatif deformasyon sonuçları Şekil 7.4'te verilmiştir. Şekilde kırmızı ile gösterilen alanlar çökme yönünde hareketleri ifade ederken, mavi alanlar kabarma yönünde hareketleri ifade etmektedir. Bölüm 7.1'de verilen sınıflandırma sonuçlarından havalimanı yapılmadan öncesini ifade eden 2010 yılında elde edilen sulak alan sınırları ile havalimanına ait vektör veriler, sonuçların irdelenmesi açısından deformasyon sonuçları üzerine bindirilmiştir.



(a)




(b)

Şekil 7.4 : LiCSBAS (a) yükselen ve (b) alçalan zaman serisi deformasyon sonuçları.


Şekil 7.4 incelendiğinde yükselen ve alçalan geometride elde edilen sonuçların birbirleriyle benzerlik gösterdiği tespit edilmiştir. B ve C pistlerinin ortasında yer alan

bölgede hem yükselen hem de alçalan geometride çökme eğiliminde negatif yönlü hareket tespit edilmiştir. Sınıflandırma sonucu elde edilen sulak alan sınırları incelendiğinde bölgede yer alan yaklaşık 88,6 ha alana sahip olan sulak alanın ıslah edildiği ve B ile C pisti arasında kalan bu alana karşılık geldiği görülmektedir. Bu durumdan B ve C pistleri ile terminal binasının kuzey kesimlerinin de etkilendiği görülmektedir. B pistinin güney kesimlerinde ise kabarma eğilimli pozitif yönde hareket görülmektedir. Bu bölgeler için yükselen yörüngede elde edilen deformasyon zaman serileri Şekil 7.5'te verilmektedir. Sulak alanın ıslah edildiği D bölgesinde kümülatif deformasyon miktarı 250 mm'ye kadar varmaktadır. A ve C pist bölgelerinden alınan zaman serilerinde ise deformasyonun 100 mm'ye vardığı görülmektedir. B pistinin güney kesiminden alınan zaman serisi ise kabarma eğiliminde 100 mm kümülatif deformasyon olduğunu göstermektedir.



Şekil 7.5 : Yükselen yörüngede üretilen LiCSBAS zaman serisi üzerinde gösterilen (a) bölgelerin zaman serisi grafikleri (b).

LiCSBAS ile elde edilen deformasyon hızının standart sapması Şekil 7.6’da yükselen ve alçalan geometri için verilmiştir. Yükselen yörüngede standart sapma 0 ile 1,05 mm/yıl aralığında değişirken, alçalan yörüngede 0 ile 0,81 mm/yıl aralığında değişmektedir.



Şekil 7.6 : Yükselen (a) ve alçalan (b) yörüngede üretilen LiCSBAS deformasyon hızı standart sapma haritası.


7.2.2 PSInSAR zaman serisi analizi

LiCSBAS yönteminin uygulandığı zaman aralığı ile aynı periyotta PSInSAR zaman serisi metodu uygulanmıştır. Hem alçalan hem de yükselen geometride elde edilen sonuçların zaman aralığı, görüntü sayısı ve öncül görüntü tarihi Çizelge 7.2’de verilmiştir.

Çizelge 7.2 : Kullanılan Sentinel-1 uydu görüntülerinin tarih aralığı ve görüntü sayıları.

Bölge	Yörünge	Tarih aralığı	Görüntü Sayısı	Öncül görüntü
Havalimanı	Yükselen	Kasım 2018 – Eylül 2022	211	15.07.2020
	Alçalan	Kasım 2018 – Eylül 2022	210	31.08.2020
C pisti	Yükselen	Temmuz 2020 – Eylül 2022	110	29.05.2021
	Alçalan	Temmuz 2020 – Eylül 2022	111	22.05.2021

Havaalanının kullanıma açıldığı Kasım 2018 ve Ekim 2022 zaman periyodu için hem alçalan hem de yükselen zaman serileri sırasıyla 211 ve 210 SAR uydu görüntüsüyle gerçekleştirilmiştir. Yükselen yörünge ile gerçekleştirilen analizde öncül görüntü tarihi 15 Temmuz 2020, alçalan görüntü ile gerçekleştirilen analizde ise 31 Ağustos 2020 olarak belirlenmiştir. Görüntülerin her iki analiz için baz uzaklığı grafikleri Şekil 7.7’de verilmiştir.




Şekil 7.7 : Kasım 2018-Eylül 2022 zaman aralığı için üretilen (a) yükselen ve (b) alçalan zaman serilerinin baz uzaklığı grafikleri.

Şekil 7.7’de öncül görüntüye göre baz uzunlukları verilen SAR görüntüleri kullanılarak PSInSAR metodu ile analiz gerçekleştirilmiştir. Elde edilen PS noktalarından tutarlılık değeri 0,6’nın altında olan noktalar elenerek, 0,6’nın üzerinde tutarlılık seviyesine sahip noktalar ile analiz sonucu değerlendirilmiştir. Analiz sonucunda elde edilen PS noktaları yüzey deformasyon hızlarına göre Şekil 7.8’de verilmiştir.


Kırmızı noktalar deformasyon hızının negatif yönde arttığı, yani çökme, alanları temsil ederken, sarı noktalar daha stabil olduğu bölgeleri ve mavi noktalar ise deformasyonun artı yönde gerçekleştiği bölgeleri temsil etmektedir. Deformasyonlar LOS yönünde hareketi ifade etmektedir. Hem yükselen hem de alçalan yörüngede elde edilen sonuçların birbirine benzer olduğu tespit edilmiştir. Yükselen yörüngede elde edilen hareketler -18,4 mm/yıl ile 11,3 mm/yıl aralığında değişirken, alçalan yörüngede -11,5 mm/yıl ile 9,2 mm/yıl aralığında değişmektedir. Alçalan ve yükselen yörüngelerin beraber değerlendirilebilmesi adına, lejantları aynı olacak şekilde düzenlenerek Şekil 7.8’de verilmiştir.

LiCSBAS sonuçlarında olduğu gibi, PSInSAR sonuçları da 2010 yılı sınıflandırma sonuçları ve pistlerin vektörel sınırları ile karşılaştırılmıştır. PSInSAR metodu arazi yüzeylerinde ve inşaat halinde olan sahalarda PS noktalarını bulamadığından, B ve C pistlerinin ortasında yer alan ıslah edilmiş sulak alan bölgesinde PS noktalarının bölgeyi karakterize edecek sayıda olmadığı görülmektedir. Bölgenin hafriyat alanı olması da bu durumu güçlendirmektedir. Ancak bölgeye kıyısı olan B ve C pistleri ile terminal binasının kuzey kesimlerinde çökme eğilimli negatif yönde hareket olduğu belirlenmiştir. Ayrıca A pistinin kuzey kesimlerinde benzer hareket görülürken, B pistinin güney kesimleri ile terminal binasının üzerinde kabarma eğilimli pozitif yönde hareket tespit edilmiştir. Elde edilen sonuçlar LiCSBAS sonuçlarıyla örtüşürken, daha yüksek çözünürlükte yapıların incelenmesine olanak sağlamıştır.

Şekil 7.8’de verilen deformasyon hızlarının standart sapma değerleri hem yükselen hem alçalan geometri için Şekil 7.9’da verilmiştir. Yükselen yörüngede standart sapma değerleri 0,13-1,18 mm/yıl aralığında değişirken, alçalan yörüngede 0,13-1,26 mm/yıl aralığında değişmektedir.




Şekil 7.8 : Yükselen (a) ve alçalan (b) yörüngelerde elde edilen PSInSAR deformasyon hızı sonuçları.



Şekil 7.9 : Yükselen (a) ve alçalan (b) yörüngelerde elde edilen PSInSAR deformasyon hızı standart sapma sonuçları.

Temmuz 2020’de inşaatı tamamlanarak kullanıma açılan C pisti, Kasım 2018-Eylül 2022 zaman aralığında inşaat halinde olduğundan Şekil 7.8’de verilen deformasyon analizi sonuçlarında PS noktası tespit edilememiştir. Bu sebeple, C pistinde meydana gelen yüzey hareketlerini belirlemek için Temmuz 2020-Eylül 2022 zaman aralığı için Çizelge 7.2’de bilgileri verilen uydu görüntüleriyle analiz tekrarlanmıştır. Yükselen ve alçalan yörüngelerde sırasıyla 110 ve 111 görüntü kullanılmış olup öncül görüntü tarihleri de 29 Mayıs 2021 ve 22 Mayıs 2021 olarak belirlenmiştir. Şekil 7.10’da öncül görüntüye göre görüntülerin baz uzunlukları verilmiştir.




Şekil 7.10 : Temmuz 2020-Eylül 2022 zaman aralığı için üretilen (a) yükselen ve (b) alçalan zaman serilerinin baz uzaklığı grafikleri.


Şekil 7.10’da öncül görüntüye göre baz uzunlukları verilen SAR görüntüleri kullanılarak PSInSAR metodu ile analiz gerçekleştirilmiştir. Elde edilen sonuçlar Şekil 7.11’de verilmiştir. C pistinin tamamlanması ile beraber planda belirtilen pist uzunluğundan daha kısa inşa edildiği belirlenmiştir. Elde edilen PS noktaları tutarlılık değerlerine göre filtrelenmiş ve tutarlılık değeri 0,60’ın üzerinde olan PS noktaları şekilde gösterilmiştir. Yükselen yörüngede elde edilen hareketler -23 mm/yıl ile 14,7 mm/yıl aralığında değişirken, alçalan yörüngede -25,5 mm/yıl ile 13,5 mm/yıl

aralığında değişmektedir. Alçalan ve yükselen yörüngelerin beraber değerlendirilebilmesi adına, lejantları aynı olacak şekilde düzenlenerek Şekil 7.9'da verilmiştir. Hem yükselen hem de alçalan geometride elde edilen sonuçların birbiriyle benzer hareket gösterdiği belirlenmiştir.

Elde edilen sonuçlara göre C pistinin uç kısımlarında çökme eğilimli negatif yönde hareket olduğu belirlenmiştir. 2010 yılı sınıflandırma sonuçlarında elde edilen sulak alan sınırları ile beraber incelendiğinde yine aynı bölgede ıslah edilen bir sulak alan üzerine C pistinin inşa edildiği belirlenmiştir. Son iki yıllık süre zarfını kapsayan bu analiz sonucunda, B pisti ile terminal binasının kuzeyinde çökme yönündeki hareketlerin devam ettiği, ayrıca A pistinin uç bölgesinde de çökme eğilimli PS noktalarının da artış gösterdiği tespit edilmiştir. B pistinin güneyinde de benzer şekilde kabarma eğilimli pozitif yönde hareket devam etmektedir.




Şekil 7.11 : C pisti için PSInSAR yöntemiyle yükselen (a) ve alçalan (b) yörüngede gerçekleştirilen analiz sonuçları.




Şekil 7.11 (devam) : C pisti için PSInSAR yöntemiyle yükselen (a) ve alçalan (b) yörüngede gerçekleştirilen analiz sonuçları.

Şekil 7.11’de verilen deformasyon hızlarının standart sapma değerleri hem yükselen hem alçalan geometri için Şekil 7.12’de verilmiştir. Yükselen yörüngede standart sapma değerleri 0,29-2,64 mm/yıl aralığında değişirken, alçalan yörüngede 0,27-2,75 mm/yıl aralığında değişmektedir.

Şekil 7.8a’da verilen Kasım 2018-Eylül 2022 aralığında yükselen yörüngede elde edilen uzun dönem deformasyon sonuçları ile Şekil 7.11a’da verilen Temmuz 2020-Eylül 2022 yükselen yörüngede elde edilen deformasyon sonuçlarından zaman serisi grafikleri çıkarılarak Şekil 7.13’te deformasyonların seyri gösterilmiştir. Yaklaşık olarak dört senelik süre zarfını kapsayan Kasım 2018-Eylül 2022 deformasyon analizinde A ve B pistleri ile terminal binasının kuzeyi için verilen zaman serisi hareketlerinde -30 mm’ye kadar düşey hareket olduğu görülmektedir. Son 2 yılı kapsayan Temmuz 2020-Eylül 2022 zaman serilerinde ise bu değer 15 mm’yi bulurken deformasyon hızının yavaşladığı görülmektedir.



Şekil 7.12 : C pisti için PSInSAR yöntemiyle üretilen deformasyon hız sonuçlarının yükselen (a) ve alçalan (b) yörüngede standart sapmaları.




Şekil 7.13 : Farklı dönemlerde elde edilen deformasyon sonuçlarının bölgelere göre zaman serisi gösterimleri: a) Kasım 2018-Eylül 2022, b) Temmuz 2020-Eylül 2022.

Uzun dönem yükselen ve alçalan deformasyon sonuçları kullanılarak LOS yönünde elde edilen deformasyonlar yatay ve düşey bileşenlerine ayrılmıştır. Bu doğrultuda Bölüm 2.3'te verilen Eşitlik 2.9 uygulanmıştır. Eşitlikte kullanılan parametrelerin Sentinel-1 uydusu için değerleri Çizelge 7.3'te verilmiştir.


Çizelge 7.3 : Kullanılan Sentinel-1 uydu yörüngelerinin geliş ve uydu başucu açıları.

Yörünge	Yörünge Numarası	Geliş Açısı (θ)	Uydu Başucu Açısı (α)
Yükselen	58	39,32	-13,57
Alçalan	36	33,77	-166,46

Yatay ve düşey bileşenlerine ayırma işlemi gerçekleştirilmeden önce hem uzun dönemde elde edilen sonuçlar hem de C pisti için tekrarlanan her iki yörüngedeki PSInSAR deformasyon sonuçlarının örtüşmesi için 200 metrelik gridler oluşturulmuş ve her iki deformasyon sonucu gridler aracılığıyla raster verilere dönüştürülmüştür. Elde edilen görüntüler aracılığıyla Eşitlik 2.9 uygulanmış ve yatay-düşey bileşenler elde edilmiştir. Elde edilen bileşenlerden düşey hız bileşeni Şekil 7.14'te verilmiştir. Yatay hız bileşeni anlamlı sonuç vermediğinden eklenmemiştir.




Şekil 7.14 : Kasım 2018-Eylül 2022 düşey hız bileşeni (a) ve Temmuz 2020-Eylül 2022 düşey hız bileşeni (b).



Şekil 7.14 (devam) : Kasım 2018-Eylül 2022 düşey hız bileşeni (a) ve Temmuz 2020-Eylül 2022 düşey hız bileşeni (b).


Elde edilen deformasyon sonuçları her iki yörüngede de aynı karakteristikte (çökme/kabarma) sonuç veriyorsa düşey yönde, farklı ise yatay yönde hareket olduğu söylenebilmektedir (Bayık, 2019). Havaalanı için iki yörüngede elde edilen sonuçların oldukça benzer olması yüzey hareketlerinin düşey yönde olduğunun da bir göstergesidir. Üretilen Temmuz 2020-Eylül 2022 düşey hız bileşeni verisi üzerinden halihazırda kullanılan üç pistin vektör sınırları kullanılarak kesilmiştir ve pist eksenleri boyunca düşey hız profilleri elde edilmiştir (Şekil 7.15). A pisti genelinde kabarma hareketi mevcut iken B pistinin güneyinde kabarma, kuzeyinde çökme hareketi mevcuttur. C pistinde ise güneyde kabarma hareketi mevcutken kuzey kesimleri çökme hareketinin etkisindedir.



Şekil 7.15 : A, B ve C pistlerinin düşey deformasyon hızı üzerinden alınan profilleri.


7.2.3 PSInSAR zaman serilerinin bileşenlerine ayrılması

Zaman serilerinde bileşenlerine ayırma işlemi mevsimsel değişimin zaman içinde nispeten sabit olduğu durumlarda kullanılan, toplamsal ayrıştırma yöntemiyle gerçekleştirilmiştir. Toplamsal ayrıştırma yöntemi, zaman serisinin trend, mevsimsel ve artık bileşenlerinin toplamından oluştuğunu ifade etmektedir. Birçok zaman serisi çalışmalarında sıklıkla kullanılmaktadır. Ancak, InSAR verilerinin zaman serisi analizlerinde tek bir zaman serisi olmamakla beraber birçok sabit saçıcı noktası için zaman serileri mevcuttur. Bu amaçla, benzer deformasyon karakteristiğine sahip sabit saçıcı kümesi seçilmiştir. Mevsimsel etkilere maruz kaldığı düşünülen ve terminal binası üzerinde Şekil 7.8a'da yeşil renkle gösterilen PS noktaları seçilerek tutarlılık değerlerine göre ağırlıklı ortalaması ile bölgeye ait zaman serisi elde edilmiştir. Elde edilen zaman serisine toplamsal ayrıştırma yöntemi uygulanarak bileşenler elde edilmiş ve Şekil 7.16'da verilmiştir.



Şekil 7.16 : Belirlenen zaman serisinin toplamsal ayrıştırma yöntemiyle elde edilen bileşenleri.

Şekil 7.16’da elde edilen bileşenler incelendiğinde trend bileşeninin mevsimsel etkilere göre hareket ettiği görülmektedir. Trend bileşeni, Meteoroloji Genel Müdürlüğü (MGM)’nden temin edilen ve İstanbul Havalimanı meteoroloji istasyonunda ölçülen günlük ortalama sıcaklık verisiyle ilişkilendirilerek Şekil 7.17’de verilmiştir. İki veri arasında korelasyon katsayına (R^2) bakıldığında 0,76 ile yüksek korelasyona sahip olduğu görülmüştür. Bu durum terminal binasının çatısındaki yapı malzemesinin sıcaklığın da artmasıyla beraber yer yer genleşme etkisini gösterdiği açıkça görülmektedir. Ancak genleşmenin yanı sıra kabarma yönünde bir trend gösterdiği de belirlenebilmektedir.




Şekil 7.17 : Trend bileşeni ve MGM'den alınan günlük ortalama sıcaklık verilerinin gösterimi.

7.3 SYM Üretimi ve Kazı-Dolgu Alanlarının Belirlenmesi

İstanbul Havaalanı inşaatı esnasında dolgu yapılan veya kazılan bölgelerin tespiti, deformasyon analizi ile elde edilen sonuçların anlamlandırılması açısından önemlidir. Bu amaçla, bölgeye ait SYM'ler incelenmiştir. Ücretsiz servis edilen modeller incelendiğinde ASTER GDEM (Advanced Spaceborne Thermal Emission and Reflection Radiometer Global Digital Elevation Map) ve SRTM (Shuttle Radar Topography Mission) verilerinin çalışma alanında mevcut olduğu tespit edilmiştir. Her iki veri de yaklaşık olarak 30 metre mekânsal çözünürlüğe sahiptir. Ancak, ASTER GDEM verisi 2000 ve 2013 yılları arasında alınan ASTER optik görüntülerinin stereo analizi ile üretilmiştir ve verinin bu aralıkta hangi yıla ait olduğu bilgisi bulunmamaktadır. SRTM ise radar teknolojisinden faydalanılarak üretilen yükseklik modelidir ve çalışma bölgesinde 2000 yılında 11 günlük bir misyonda kaydedilen SRTM verisinin düzenlenmiş 2014 yılı versiyonu alanın kazı/dolgu analizinde kullanılmıştır.


Kazı/dolgu analizinin gerçekleştirilebilmesi için havaalanı inşa edilmeden öncesi ve sonrası SYM'nin mevcut olması gerekir. SRTM, 2015 yılında inşaatına başlanan havaalanının inşaat öncesi topoğrafyasını yansıtmaktadır (Şekil 7.18a). Şekil 7.18b'de ise inşaat öncesi bölgenin durumu aynı tarihli Google Earth uydu görüntüsü ile

gösterilmiştir. Bölgede bulunan göletler sebebiyle Şekil 7.18a'da verilen SYM'de negatif değerler mevcuttur. İnşaat sonrası için ücretsiz veri bulunamadığından İTÜ UHUZAM'dan temin edilen Pleiades stereo görüntü çiftinden SYM üretilmiştir. SYM, aynı bölgeyi kapsayan iki farklı bakış açısıyla alınmış stereo görüntüler üzerinden üretilmektedir. Stereo görüntülerden SYM Envi yazılımı kullanılarak, 2 m mekânsal çözünürlükte üretilmiştir ve üretilen SYM Şekil 7.19a'da verilmiştir. Şekil 7.19b'de ise bölgenin inşaat başladıktan sonrası SYM ile aynı tarihte alınan Google Earth uydu görüntüsü ile gösterilmektedir. SYM üretiminin gerçekleştirildiği bölge sınırlarında topoğrafyanın inşaat başladıktan sonra ciddi oranda değiştiği görülmektedir.




Şekil 7.18 : SRTM verisi (a) ve bölgenin durumunu gösteren 2014 yılı Google Earth görüntüsü (b).

SYM'ler stereo görüntü sınırlarından kesilerek aynı çalışma sınırı üzerinden kazı/dolgu analizi gerçekleştirilmiştir. SRTM yaklaşık olarak 30 m mekânsal çözünürlüğe sahipken, üretilen model 2 m çözünürlüğe sahiptir. Kazı dolgu analizinin gerçekleştirilebilmesi için her iki SYM'nin aynı mekânsal çözünürlüğe sahip olması gerekmektedir. Bu doğrultuda, Üretilen SYM, SRTM verisi ile eş çözünürlüğe yani 30 m mekânsal çözünürlüğe yeniden örneklenmiştir. İnşaat sonrası ve öncesi iki SYM'nin birbirinden farkı alınarak kazı/dolgu alanları tespit edilmiştir ve Şekil 7.20'de verilmiştir. Kırmızı alanlar kazı bölgelerini temsil ederken mavi alanlar dolguyu temsil etmektedir.



Şekil 7.19 : 2016 yılına ait Pleiades stereo görüntü çiftinden üretilen SYM ve bölgenin durumunu gösteren Google Earth görüntüsü (b).



Şekil 7.20 : Sayısal yükseklik modellerinin farkından üretilen kazı dolgu haritası.


Havaalanının planı üzerine kazı/dolgu haritası eklendiğinde terminal binasının kuzey kesimlerinde yer alan ve sınıflandırma sonuçlarında da önceden sulak alan olduğu tespit edilen bölge kazı/dolgu haritasında da dolgu alanı olarak öne çıkmaktadır. Ortalama 60 m dolgu yapıldığı tespit edilen bölge hem LiCSBAS hem de PSInSAR sonuçlarına göre çökme eğiliminde yoğun deformasyonun olduğu bölgedir. Ayrıca A ve B pistlerinin kuzey uçlarında da dolgu alanlarının olduğu ve aynı zamanda deformasyon sonuçlarında da çökme eğiliminde hareketle eşleştiği görülmektedir. C pistinin ise güney kesiminde ufak bir sulak alanın ıslah edilerek dolgu yapıldığı görülürken, deformasyon sonuçlarında da yine çökme eğilimli hareket olduğu belirlenmiştir. Kazı olan bölgeler ise, deformasyon analizinde kabarma olan bölgelerle uyumlu görülmektedir. Örneğin terminal binası ve binanın güneydoğu kesimleri ile A ve B pistlerinin güney kesimleri deformasyon analizi sonuçlarında kabarma eğilimli hareket gösterirken, bu bölgelerin kazı yapılan bölgeler olduğu dikkat çekmektedir.

7.4 Deformasyon Zaman Serilerinin Tahmin Analizi

Bölgede hem alçalan hem de yükselen yörüngeden elde edilen deformasyonların benzerlik göstermesi ve bölgenin topoğrafyası göz önünde bulundurularak deformasyon zaman serilerinin tahmin analizi yükselen yörüngede elde edilen uzun dönem (Kasım 2018-Eylül 2022) zaman serisi ile gerçekleştirilmiştir. PSInSAR yöntemi ile elde edilen deformasyon sonuçları, LiCSBAS ile elde edilen sonuçlardan daha yüksek mekânsal çözünürlük sağladığından tahmin analizlerinde kullanımının uygun olduğuna karar verilmiştir. Tahmin analizi için farklı zaman serisi karakteristiğine (kabarma, çökme, stabil) ve yüzey tipine (pist ve terminal çatı) sahip 6 pilot bölge seçilmiştir. Seçilen pilot bölgeler Şekil 7.20’de verilmiştir.

Şekil 7.21’de siyah kutu içerisinde bulunan PS noktalarının tutarlılık değerlerine göre ağırlıklı ortalaması alınarak zaman serileri elde edilmiştir. Sentinel-1B uydusunun Aralık 2021’den beri uydu görüntüsü sağlayamaması sebebiyle zaman serisinde son 9 aylık kısımda zamansal çözünürlük 6 günden 12 güne çıkmaktadır. Bütün zaman serisinin aynı zamansal çözünürlükte olmasını sağlamak amacıyla veri aralığı tüm zaman serisi boyunca 6 gün olacak şekilde interpolasyon yapılarak tahmin analizlerine hazır hale getirilmiştir. Veri; eğitim (%70), validasyon (%15) ve test (%15) olmak üzere üç kısma ayrılmış ve regresyon tabanlı modellerde geriye dönük test ile eğitim ve validasyon veri seti kullanılarak modeller eğitilmiş, test verisi ile modelin tahmin

doğruluğu belirlenmiştir. Ancak ARIMA, FFT ve LSTM modellerinde eğitim ve validasyon verisi beraber model eğitiminde kullanılmıştır ve modelin tahmin doğruluğu yine test verisi ile belirlenmiştir. Pilot bölgelerde bulunan PS noktalarının sayısı, ortalama tutarlılık ve deformasyon hız değerlerinin ortalama standart sapması değerleri Çizelge 7.4’te verilmiştir.




Şekil 7.21 : Belirlenen pilot bölgeler ve konumları.

Çizelge 7.4 : Pilot bölgelerde bulunan PS noktalarının detayları.

Bölge	Zaman Serisi Karakteristiği	Yapı Türü	Nokta Sayısı	Ortalama Tutarlılık	Ortalama Standart Sapma [mm/yıl]
1	Çökme	Pist	60	0,76	0,39
2	Çökme	Bina	49	0,83	0,37
3	Kabarma	Pist	24	0,76	0,33
4	Kabarma	Bina	28	0,84	0,21
5	Stabil	Bina	90	0,89	0,21
6	Mevsimsel Kabarma	Bina	37	0,80	0,40

7.4.1 ARIMA ile tahmin analizi

ARIMA ile tahmin modelleri kurulmadan önce en uygun model parametreleri (p, d, q) belirlenir. ARIMA otoregresif bir modeldir ve bu modeller kavramsal olarak lineer regresyona benzer. Bu yüzden lineer regresyonda geçerli varsayımlar, ARIMA için de geçerlidir. Geçmiş verilerle olan korelasyon model sonuçlarını doğrudan etkileyeceğinden öncelikle verinin otokorelasyonuna bakılır. Şekil 7.22’de 1. bölge için otokorelasyon grafiği verilmiştir.




Şekil 7.22 : 1. Bölgenin otokorelasyon grafiği.

Geçmiş verilerle herhangi bir açık korelasyonu ve doğrusallığı ortadan kaldırmak için zaman serisi verileri durağan hale getirilmelidir. Durağan zaman serisi verilerinde, bir örnek gözlemin özellikleri veya değeri, gözlemlendiği zaman dilimine bağlı değildir. Geçmiş verilerle olan bu korelasyonu ortadan kaldırmak için ARIMA, verileri durağan hale getirmek için farkları kullanır. Fark alma, en basit haliyle, iki bitişik veri noktasının farkının alınmasını içerir. Bu sebeple, zaman serisi deformasyon verisine 1. ve 2. derece fark alma işlemi uygulanmıştır ve elde edilen sonuçlar Şekil 7.23’te gösterilmiştir.

Ancak sadece görsel olarak değil matematiksel olarak da 1.derece fark alma işleminin yeterli olup olmadığının test edilmesi için Augmented Dickey-Fuller (ADF) testi uygulanmıştır. ADF testi, verilen zaman serisi verilerinin durağan olmadığı şeklindeki boş hipotezi reddetmeyi amaçlar. Bu amaçla, p değerini hesaplar ve bunu 0,05’lik bir eşik değeri veya anlamlılık düzeyi ile karşılaştırır. p değeri bu seviyeden küçükse veri durağandır; aksi takdirde, fark sırası bir artırılır. Elde edilen sonuçlar Çizelge 7.5’te

verilmektedir. Sonuçlara göre matematiksel olarak da 1. ve 2. derece fark işlemi veriyi durağan hale getirmektedir.



Şekil 7.23 : Zaman serisinin 1. ve 2. derece fark grafiği ve farkın otokorelasyonu.

Çizelge 7.5 : ADF test sonuçları.


Veri	p-değeri
Orijinal veri	0,64
1. Derece Farkı Alınmış Veri	5,2e-18
2. Derece Farkı Alınmış Veri	1,7e-10

ARIMA modellerinde eğitim ve validasyon verisi ile her pilot bölge için model parametreleri belirlenmiştir. Model parametreleri belirlenirken her parametre kombinasyonu için tahmin edilen veri ile test verisi arasında RMSE değerleri hesaplanmış ve en düşük RMSE değerini veren parametre, tahmin analizinde kullanılmıştır. Altı bölge için de parametreler belirlenerek modeller kurulmuş ve tahmin analizleri gerçekleştirilmiştir. Çizelge 7.6’da model bilgileri, hata metrikleri ve tahmin görselleri verilmiştir.


Çizelge 7.6’da doğruluk değerlendirme sonuçları verilen ARIMA modellerinin tahmin sonuçları Şekil 7.24’te gösterilmektedir. Çizelgede verilen grafiklerde yeşil çizgi modelin eğitim verisini, kırmızı çizgi test verisini ve kesikli çizgi de ARIMA model tahmin sonucunu ifade etmektedir.

Çizelge 7.6 : Altı bölgenin seçilen ARIMA modellerine göre doğruluk değerlendirmesi sonuçları.

Bölge	Model (p, d, q)	RMSE (mm)	MAE (mm)	R
1.Bölge (Pist çökme)	(1, 2, 1)	2,57	2,25	0,561
2.Bölge (Bina çökme)	(3, 1, 7)	2,97	2,44	0,417
3.Bölge (Pist kabarma)	(1, 3, 3)	2,81	2,34	-0,202
4.Bölge (Terminal kabarma)	(1, 2, 3)	2,72	2,27	0,260
5.Bölge (Stabil)	(11, 2, 1)	1,02	0,86	0,496
6.Bölge (Mevsimsel kabarma)	(4, 3, 1)	3,74	2,96	0,854



Şekil 7.24 : Sırasıyla altı pilot bölgeye uygulanan ARIMA ile tahmin analizi sonuçları.



Şekil 7.24 (devam) : Sırasıyla altı pilot bölgeye uygulanan ARIMA ile tahmin analizi sonuçları.

Çizelge 7.6’da verilen hata değerlerinin 4 mm’yi geçmediği görülmektedir. Ancak Şekil 7.24’te verilen tahmin görselleri incelendiğinde, ARIMA’nın tahmin analizlerinde lineer bir yaklaşım sunduğu görülmektedir.


7.4.2 FFT ile tahmin analizi

Darts kütüphanesinin FFT modülü ile tahmin analizleri gerçekleştirilmiştir. Her bölge için parametre seçimi, en düşük RMSE değeri veren parametre kombinasyonu ile belirlenmiştir. Altı bölge için belirlenen parametreler ve elde edilen hata değerleri Çizelge 7.7’de verilmiştir.





Çizelge 7.7 : Altı bölgenin seçilen FFT modellerine göre doğruluk değerlendirme sonuçları.

Bölge	Model parametreleri (frekans sayısı, polinom derecesi)	RMSE (mm)	MAE (mm)	R
1.Bölge (Pist çökme)	(16, 1)	1,60	1,37	0,695
2.Bölge (Bina çökme)	(2, 2)	2,96	2,33	0,397
3.Bölge (Pist kabarma)	(1, 1)	3,14	2,51	-0,046
4.Bölge (Terminal kabarma)	(1, 1)	2,55	2,04	0,232
5.Bölge (Stabil)	(1, 1)	1,73	1,45	-0,087
6.Bölge (Mevsimsel kabarma)	(2, 1)	2,01	1,58	0,897


Çizelge 7.7’de doğruluk değerlendirme sonuçları verilen FFT modellerinin tahmin sonuçları Şekil 7.25’te gösterilmektedir. Çizelgede verilen grafiklerde yeşil çizgi modelin eğitim verisini, kırmızı çizgi test verisini ve kesikli çizgi de FFT model tahmin sonucunu ifade etmektedir. Çizelge 7.7’de verilen hata değerlerinin 3,5 mm’yi geçmediği görülmekte ve Şekil 7.25’te verilen tahmin görsellerinde de FFT tahmin modelinin veriyi öğrenme sürecinde başarılı sonuçlar verdiği görülmektedir.



Şekil 7.25 : Sırasıyla altı pilot bölgeye uygulanan ARIMA ile tahmin analizi sonuçları.



Şekil 7.25 (devam) : Sırasıyla altı pilot bölgeye uygulanan FFT ile tahmin analizi sonuçları.



Şekil 7.25 (devam) : Sırasıyla altı pilot bölgeye uygulanan FFT ile tahmin analizi sonuçları.

7.4.3 Regresyon tabanlı yöntemler ile tahmin analizi

Regresyon tabanlı modellerin eğitiminde eğitim ve validasyon veri setleri kullanılmıştır. GDT analizinde, validasyon veri seti adım adım geriye bakılarak tahmin edilmiştir ve tahmin edilen ile validasyon veri seti arasında doğruluk metrikleri ile hata miktarları hesaplanmıştır. Model öğrenmeyi bu şekilde gerçekleştirdikten sonra hiç görmediği test verisi için tahmin analizi yapılmış ve modellerin tahmin doğruluğu Şekil 7.20’de verilen altı bölgede dört algoritma için ayrı ayrı belirlenmiştir. Algoritmaların parametre seçiminde GridSearch algoritmasından yararlanılmıştır. Catboost regresyon CBR, XGBoost regresyon XGBR, Rastgele Orman regresyon RFR ve destek vektör regresyon SVR olarak grafik ve tablolarda gösterilmiştir. Grafiklerde yeşil renk eğitim verisini, turuncu renk validasyon verisini ve kırmızı renk ise test verisini ifade etmektedir. Tahmin verileri kesikli çizgilerle gösterilmiştir. GDT tahmin sonu mavi renk ile gösterilirken, modelin tahmin sonucu siyah renk ile gösterilmiştir.


7.4.3.1 1. bölge analiz sonuçları

B pistinin kuzey kesimlerinde çökme eğilimli hareket gösteren bölgeden alınan 1. bölgede 4 algoritma için elde edilen RMSE, MAE ve R metrik değerleri Çizelge 7.8’de verilmiştir. No. estimators, tahmin edici ağaç sayısını ifade ederken, max depth, karar ağaçlarının boyutunu, learning rate ise öğrenme oranı yani algoritmanın model ağırlıklarında güncellemeler yaptığı adım boyutunu kontrol eden parametredir.


Çizelge 7.8 : 1. Bölge için regresyon tabanlı algoritmaların doğruluk değerlendirmesi sonuçları.

Algoritma	Model parametreleri	GDT			Tahmin Analizi		
		RMSE (mm)	MAE (mm)	R	RMSE (mm)	MAE (mm)	R
CBR	No. estimators: 10 Max depth: 5 Learning rate: 0.5 Lags: 28	3,41	2,66	-0,247	5,26	5,07	0,353
XGBR	No. estimators: 5 Max depth: 10 Learning rate: 1 Lags: 58	4,28	3,57	-0,115	3,58	3,10	0,546
RFR	No. estimators: 5 Max depth: 100 Lags: 56	3,71	2,80	-0,238	6,26	6,03	0,127
SVR	C: 1 Epsilon: 0.1 Kernel: linear Lags: 66	4,35	3,47	-0,047	3,15	2,61	0,423

Çizelge 7.8 incelendiğinde modellerin GDT aşamasında doğruluklarının birbirine yakın olduğu ve 5 mm'nin altında olduğu görülmektedir. Bu aşamada en iyi öğrenmeyi CBR gerçekleştirmesine rağmen, SVR ve XGBR en yüksek tahmin doğruluğunu sağlamıştır. Tahmin metrikleri verilen modellerin görsel sonuçları da Şekil 7.26'da verilmiştir. Trend olarak incelendiğinde, CBR ve RFR modellerinin zaman serisindeki ani düşüşü yakalayamadığı görülmektedir. Sırasıyla SVR ve XGBR algoritmalarının ise bu anlamda daha iyi sonuç verdiği söylenebilmektedir.



Şekil 7.26 : Sırasıyla altı pilot bölgeye uygulanan FFT ile tahmin analizi sonuçları.



Şekil 7.26 (devam) : 1. bölgeye uygulanan regresyon tabanlı algoritmalar ile tahmin analizi sonuçları, sırasıyla a) CBR, b) XGBR, c) RFR ve d) SVR.


7.4.3.2 2. bölge analiz sonuçları

İstanbul Havalimanı'nın doğu kesimlerinde bulunan ve çökme eğilimli hareket gösteren yapıların bulunduğu 2. Bölgede, dört algoritma için elde edilen RMSE, MAE ve R metrik değerleri Çizelge 7.9'da verilmiştir.

Çizelge 7.9 : 2. Bölge için regresyon tabanlı algoritmaların doğruluk değerlendirmesi sonuçları.

Algoritma	Model parametreleri	GDT			Tahmin Analizi		
		RMSE (mm)	MAE (mm)	R	RMSE (mm)	MAE (mm)	R
CBR	No. estimators: 10 Max depth: 5 Learning rate: 0.5 Lags: 28	4,08	3,13	0,552	2,94	2.19	0,307
XGBR	No. estimators: 20 Max depth: 1 Learning rate: 0.5 Lags: 68	3,82	2,92	0,561	3,02	2.39	0,244
RFR	No. estimators: 25 Max depth: 10 Lags: 8	3,35	2,61	0,706	3,20	2.71	0,304
SVR	C: 5 Epsilon: 0.5 Kernel: rbf Lags: 12	4,70	3,80	0,608	3,42	2.57	0,236

Çizelge 7.9 incelendiğinde modellerin GDT aşamasında doğruluklarının yine birbirine yakın olduğu ve 5 mm'nin altında olduğu görülmektedir. Bu aşamada en iyi öğrenmeyi RFR algoritması gerçekleştirmesine rağmen, CBR ve XGBR algoritmaları en düşük hatayı vermiştir. Tahmin metrikleri verilen modellerin görsel sonuçları da Şekil 7.27'de verilmiştir. Trend olarak incelendiğinde, tahmin analizinde en düşük hatayı veren CBR algoritması ile GDT aşamasında en düşük hatayı veren RFR modellerinin tahmin analizinde başarılı olmadığı ve birkaç adım sonra tahmini başarılı bir şekilde gerçekleştiremediği görülmektedir. Tahmini başarılı bir şekilde gerçekleştiremeyen CBR ve RFR algoritmalarında R metriğinin diğer algoritmalara göre yüksek çıkması ise bu metriğin değerlendirmede tek başına kullanılmaması gerektiğinin bir örneği niteliğindedir. Bu doğrultuda, CBR'den sonra en düşük hatayı vermesi ve anlamlı bir tahmin sonucu vermesi sebebiyle, XGBR algoritmasının başarılı bir sonuç verdiği söylenebilmektedir.



Şekil 7.27 : 2. bölgeye uygulanan regresyon tabanlı algoritmalar ile tahmin analizi sonuçları, sırasıyla a) CBR, b) XGBR, c) RFR ve d) SVR.


7.4.3.3 3. bölge analiz sonuçları

3. bölge B pistinin güney kesimlerindeki kabarma eğilimli hareket gösteren bölgeden alınmıştır. 3. Bölgede uygulanan dört algoritmanın RMSE, MAE ve R metrik değerleri Çizelge 7.10’da verilmiştir.

Çizelge 7.10 : 3. Bölge için regresyon tabanlı algoritmaların doğruluk değerlendirmesi sonuçları.

Algoritma	Model parametreleri	GDT			Tahmin Analizi		
		RMSE (mm)	MAE (mm)	R	RMSE (mm)	MAE (mm)	R
CBR	No. estimators: 25 Max depth: 10 Learning rate: 1 Lags: 16	4,26	3,31	-0,292	4,05	3,46	0,059
XGBR	No. estimators: 10 Max depth: 10 Learning rate: 0.5 Lags: 16	3,73	2,98	-0,122	3,83	3,39	0,356
RFR	No. estimators: 10 Max depth: 25 Lags: 10	2,73	2,22	0,293	4,89	4,40	0,291
SVR	C: 3 Epsilon: 0.1 Kernel: linear Lags: 64	2,82	2,07	0,375	3,95	3,31	-0,008

Çizelge 7.10 incelendiğinde modellerin GDT aşamasında doğruluklarının birbirine yakın olduğu ve 4.5 mm’nin altında olduğu görülmektedir. Bu aşamada hata metriklerine göre en iyi öğrenmeyi RFR algoritması gerçekleştirmesine rağmen, XGBR ve SVR algoritmaları sırasıyla en düşük hatayı vermiştir. Tahmin metrikleri verilen modellerin görsel sonuçları da Şekil 7.28’de verilmiştir. Trend olarak incelendiğinde de tahmin analizinde en düşük hatayı veren XGBR algoritmasının R değeri diğer algoritmalara göre en yüksek değere sahipken, SVR algoritmasında korelasyonun çok düşük olduğu görülmektedir.



Şekil 7.28 : 3. bölgeye uygulanan regresyon tabanlı algoritmalar ile tahmin analizi sonuçları, sırasıyla a) CBR, b) XGBR, c) RFR ve d) SVR.


7.4.3.4 4. bölge analiz sonuçları

4. bölge terminal binasının çatısı üzerinde kabarma eğilimli hareket gösteren bölgeden alınmıştır. 4. Bölgede uygulanan dört algoritmanın RMSE, MAE ve R metrik değerleri Çizelge 7.11’de verilmiştir.

Çizelge 7.11 : 4. Bölge için regresyon tabanlı algoritmaların doğruluk değerlendirmesi sonuçları.

Algoritma	Model parametreleri	RMSE (mm)	GDT MAE (mm)	R	Tahmin Analizi		
					RMSE (mm)	MAE (mm)	R
CBR	No. estimators: 10 Max depth: 5 Learning rate: 0.5 Lags: 20	2,54	2,09	0,122	3,55	2,89	0,306
XGBR	No. estimators: 20 Max depth: 1 Learning rate: 1 Lags: 66	3,28	2,43	0,062	2,77	2,25	0,331
RFR	No. estimators: 20 Max depth: 5 Lags: 56	2,66	2,11	-0,036	3,66	3,02	-0,098
SVR	C: 3 Epsilon: 0.5 Kernel: linear Lags: 12	2,79	2,16	0,034	3,49	2,72	0,146

Çizelge 7.11 incelendiğinde modellerin GDT aşamasında doğruluklarının birbirine yakın olduğu ve 3.5 mm’nin altında olduğu görülmektedir. Bu aşamada hata metriklerine göre en iyi öğrenmeyi CBR algoritması gerçekleştirmesine rağmen, XGBR algoritması en düşük hatayı vermiştir. Tahmin metrikleri verilen modellerin görsel sonuçları da Şekil 7.29’da verilmiştir. Trend olarak incelendiğinde de tahmin analizinde en düşük hatayı veren XGBR algoritmasının R değeri diğer algoritmalara göre en yüksek değere sahipken, RFR algoritmasının en düşük korelasyon değerine sahip olduğu görülmektedir.



Şekil 7.29 : 4. bölgeye uygulanan regresyon tabanlı algoritmalar ile tahmin analizi sonuçları, sırasıyla a) CBR, b) XGBR, c) RFR ve d) SVR.


7.4.3.5 5. bölge analiz sonuçları

5. bölge terminal binasının çatısı üzerinde stabil harekete sahip bölgeden alınmıştır. 5. bölgede uygulanan dört algoritmanın RMSE, MAE ve R metrik değerleri Çizelge 7.12’de verilmiştir.

Çizelge 7.12 : 5. Bölge için regresyon tabanlı algoritmaların doğruluk değerlendirmesi sonuçları.

Algoritma	Model parametreleri	RMSE (mm)	GDT MAE (mm)	R	Tahmin Analizi		
					RMSE (mm)	MAE (mm)	R
CBR	No. estimators: 20 Max depth: 5 Learning rate: 0.5 Lags: 16	2,22	1,81	- 0,089	1,55	1,20	0,146
XGBR	No. estimators: 30 Max depth: 1 Learning rate: 0.5 Lags: 20	1,98	1,66	0,223	1,77	1,38	0,129
RFR	No. estimators: 20 Max depth: 30 Lags: 14	2,11	1,73	0,022	1,92	1,58	0,015
SVR	C: 3 Epsilon: 0.1 Kernel: rbf Lags: 14	2,18	1,74	- 0,040	2,13	1,76	0,331

Çizelge 7.12 incelendiğinde modellerin GDT aşamasında doğruluklarının birbirine oldukça yakın olduğu ve 2 mm civarında olduğu görülmektedir. Tahmin doğruluklarında da hatalar yine birbirine oldukça yakın olmakla beraber 2 mm civarındadır. GDT aşamasında hata metriklerine göre en iyi öğrenmeyi nispeten XGBR algoritması sağlamaktadır. Tahmin doğruluğunda ise en düşük hatayı sırasıyla CBR ve XGBR algoritmaları vermiştir. Tahmin metrikleri verilen modellerin görsel sonuçları da Şekil 7.30’da verilmiştir. Trend olarak incelendiğinde de tahmin analizinde en düşük hatayı veren CBR algoritmasının R değeri diğer algoritmalara göre nispeten yüksek bir değere sahiptir.



Şekil 7.30 : 5. bölgeye uygulanan regresyon tabanlı algoritmalar ile tahmin analizi sonuçları, sırasıyla a) CBR, b) XGBR, c) RFR ve d) SVR.


7.4.3.6 6. bölge analiz sonuçları

6. bölge terminal binasının çatısı üzerinde mevsimsel kabarma hareketine sahip bölgeden alınmıştır. 6. bölgede uygulanan dört algoritmanın RMSE, MAE ve R metrik değerleri Çizelge 7.13'te verilmiştir.

Çizelge 7.13 : 6. bölge için regresyon tabanlı algoritmaların doğruluk değerlendirmesi sonuçları.

Algoritma	Model parametreleri	GDT			Tahmin Analizi		
		RMSE (mm)	MAE (mm)	R	RMSE (mm)	MAE (mm)	R
CBR	No. estimators: 20 Max depth: 5 Learning rate: 1 Lags: 26	3,52	2,74	0,662	3,92	3,26	0,589
XGBR	No. estimators: 100 Max depth: 1 Learning rate: 0.1 Lags: 54	2,83	2,30	0,768	2,70	2,27	0,868
RFR	No. estimators: 10 Max depth: 75 Lags: 66	2,48	2,00	0,836	3,14	2,72	0,730
SVR	C: 1 Epsilon: 0.1 Kernel: rbf Lags: 54	2,42	1,93	0,863	2,38	1,82	0,873

Çizelge 7.13 incelendiğinde modellerin GDT aşamasında doğruluklarının birbirine çoğunlukla yakın olduğu ve 3.5 mm civarında olduğu görülmektedir. Tahmin doğruluklarında da hatalar yine birbirine nispeten yakın olmakla beraber 4 mm'nin altındadır. GDT aşamasında hata metriklerine göre en iyi öğrenmeyi SVR algoritması gerçekleştirirken, tahmin doğruluğunda da yine en düşük hatayı sırasıyla SVR ve XGBR algoritmaları vermiştir. Tahmin metrikleri verilen modellerin görsel sonuçları da Şekil 7.31'de verilmiştir. Trend olarak incelendiğinde de tahmin analizinde en düşük hatayı veren SVR ve XGBR algoritmalarının R değeri diğer algoritmalara göre en yüksek değere sahiptir. Ayrıca, sürekli bir yapıya sahip olan mevsimsel hareketin varlığı modelin tahminini kolaylaştırmanın yanı sıra yüksek R değerinde sonuçların elde edilmesini de sağlamıştır.



Şekil 7.31 : 6. bölgeye uygulanan regresyon tabanlı algoritmalar ile tahmin analizi sonuçları, sırasıyla a) CBR, b) XGBR, c) RFR ve d) SVR.

7.4.4 LSTM ile tahmin analizi

Şekil 7.21’de verilen altı bölge için LSTM tahmin analizleri gerçekleştirilmiştir. İki tip LSTM modeli kurulmuştur. Birinci tipte, iki LSTM katmanı ile bir seyreltme (drop out) katmanından oluşurken, bütünleşik LSTM denilen ikinci tipte dört LSTM katmanı ve bölgeye göre iki ya da üç seyreltme katmanından oluşmaktadır. Bütün modellerde kayıp (loss) fonksiyonu olarak ortalama karesel hata, optimize edici olarak ise adam fonksiyonu kullanılmıştır ve her bölge için 100 epokta gerçekleştirilmiştir. Unit ise çıktı uzayının boyutunu, batch size ise paket boyutunu ifade etmektedir. Modellerin tahmin metrikleri ile değerlendirme sonuçları Çizelge 7.14’te verilmiştir.



Çizelge 7.14 : Altı bölgenin LSTM modellerine göre doğruluk değerlendirmesi sonuçları.

Bölge	Model	RMSE (mm)	MAE (mm)	R
1.Bölge (Pist çökme)	LSTM Katmanı: 2 Unit: 50 Seyreltme: 0.2 Paket boyutu: 64	1,84	1,36	0,448
	LSTM Katmanı: 4 Unit: 50 Seyreltme: 0.2 Paket boyutu: 32	1,25	0,97	0,576
2.Bölge (Bina çökme)	LSTM Katmanı: 2 Unit: 50 Seyreltme: 0.5 Paket boyutu: 32	3,68	2,73	0,044
	LSTM Katmanı: 4 Unit: 50 Seyreltme: 0.75 Paket boyutu: 32	3,12	2,36	0,133
3.Bölge	LSTM Katmanı: 2 Unit: 50 Seyreltme: 0.2 Paket boyutu: 32	3,90	3,41	0,292
	LSTM Katmanı: 4 Unit: 50 Seyreltme: 0.5 Paket boyutu: 32	3,21	2,77	0,068


Çizelge 7.14 (devam) : Altı bölgenin LSTM modellerine göre doğruluk değerlendirmesi sonuçları.

Bölge	Model	RMSE (mm)	MAE (mm)	R
4.Bölge	LSTM Katmanı: 2 Unit: 50 Seyreltme: 0.2 Paket boyutu: 32	3,58	2,94	0,021
	LSTM Katmanı: 4 Unit: 250 Seyreltme: 0.1 Paket boyutu: 64	3,17	2,69	0,085
	LSTM Katmanı: 2 Unit: 250 Seyreltme: 0.1 Paket boyutu: 64	2,18	1,89	0,220
	LSTM Katmanı: 4 Unit: 50 Seyreltme: 0.75 Paket boyutu: 64	1,35	1,11	-0,459
5.Bölge	LSTM Katmanı: 2 Unit: 50 Seyreltme: 0.2 Paket boyutu: 64	3,92	3,25	0,588
	LSTM Katmanı: 4 Unit: 250 Seyreltme: 0.5 Paket boyutu: 64	2,60	2,16	0,843
	LSTM Katmanı: 2 Unit: 50 Seyreltme: 0.2 Paket boyutu: 64	3,92	3,25	0,588
	LSTM Katmanı: 4 Unit: 250 Seyreltme: 0.5 Paket boyutu: 64	2,60	2,16	0,843
6. Bölge	LSTM Katmanı: 2 Unit: 50 Seyreltme: 0.2 Paket boyutu: 64	3,92	3,25	0,588
	LSTM Katmanı: 4 Unit: 250 Seyreltme: 0.5 Paket boyutu: 64	2,60	2,16	0,843
	LSTM Katmanı: 2 Unit: 50 Seyreltme: 0.2 Paket boyutu: 64	3,92	3,25	0,588
	LSTM Katmanı: 4 Unit: 250 Seyreltme: 0.5 Paket boyutu: 64	2,60	2,16	0,843


Çizelge 7.14 incelendiğinde hata değerlerinin 4 mm'nin altında olduğu görülmektedir. LSTM katman sayısının arttırılmasının doğruluk değerlerinde iyileşme sağladığı görülmüştür. Modellerin görsel sonuçları 1. Bölge için Şekil 7.32'de, 2. Bölge için Şekil 7.33'te, 3. Bölge için Şekil 7.34'te, 4. Bölge için Şekil 7.35'te, 5. Bölge için Şekil 7.36'da ve 6. Bölge için Şekil 7.37'de verilmiştir.





Şekil 7.32 : 1. bölgeye uygulanan regresyon tabanlı algoritmalar ile tahmin analizi sonuçları, sırasıyla a) LSTM ve b) Bütünleşik LSTM.





Şekil 7.33 : 2. bölgeye uygulanan regresyon tabanlı algoritmalar ile tahmin analizi sonuçları, sırasıyla a) LSTM ve b) Bütünleşik LSTM.




Şekil 7.33 (devam) : 2. bölgeye uygulanan regresyon tabanlı algoritmalar ile tahmin analizi sonuçları, sırasıyla a) LSTM ve b) Bütünleşik LSTM.




Şekil 7.34 : 3. bölgeye uygulanan regresyon tabanlı algoritmalar ile tahmin analizi sonuçları, sırasıyla a) LSTM ve b) Bütünleşik LSTM.





Şekil 7.35 : 4. bölgeye uygulanan regresyon tabanlı algoritmalar ile tahmin analizi sonuçları, sırasıyla a) LSTM ve b) Bütünleşik LSTM.



Şekil 7.36 : 5. bölgeye uygulanan regresyon tabanlı algoritmalar ile tahmin analizi sonuçları, sırasıyla a) LSTM ve b) Bütünleşik LSTM.



Şekil 7.36 (devam) : 5. bölgeye uygulanan regresyon tabanlı algoritmalar ile tahmin analizi sonuçları, sırasıyla a) LSTM ve b) Bütünleşik LSTM.



Şekil 7.37 : 6. bölgeye uygulanan regresyon tabanlı algoritmalar ile tahmin analizi sonuçları, sırasıyla a) LSTM ve b) Bütünleşik LSTM.

7.4.5 Tüm bölgelerde en uygun modelin seçilmesi

Geleneksel, regresyon tabanlı ve derin öğrenme yöntemleri ile sırasıyla modeller kurularak analizler gerçekleştirilmiştir. Analizler sonucunda doğruluk değerlendirme metrikleri ile hata miktarları hesaplanmış ve modellerin tahmin doğrulukları belirlenmiştir. Çizelge 7.15'te altı bölgenin model doğrulukları verilmiştir. Aynı zamanda test verisinin %95 güven aralığında üst ve alt değerleri belirlenerek arada kalan bölgeyle tahmin sonuçlarının örtüşme oranları hesaplanmıştır.

Çizelge 7.15 : Uygulanan bütün modellerin doğruluk değerlendirme sonuçlarının özet tablosu.

Bölge	Model	RMSE (mm)	MAE (mm)	R	Örtüşme Oranı (%)
1.Bölge	ARIMA	2,57	2,25	0,561	8,57
	FFT	1,60	1,37	0,695	17,14
	CBR	5,26	5,07	0,353	0,00
	XGBR	3,58	3,10	0,546	2,86
	RFR	6,26	6,03	0,127	0,00
	SVR	3,15	2,61	0,423	22,86
	LSTM	1,84	1,36	0,448	31,43
	Bütünleşik LSTM	1,25	0,97	0,576	37,14
2.Bölge	ARIMA	2,97	2,44	0,417	25,71
	FFT	2,96	2,33	0,397	37,14
	CBR	2,94	2,19	0,307	20,00
	XGBR	3,02	2,39	0,244	5,71
	RFR	3,20	2,71	0,304	5,71
	SVR	3,42	2,57	0,236	20,00
	LSTM	3,68	2,73	0,044	8,57
	Bütünleşik LSTM	3,12	2,36	0,133	17,14
3.Bölge	ARIMA	2,81	2,34	-0,202	25,71
	FFT	3,14	2,51	-0,046	22,86

Çizelge 7.15 (devam) : Uygulanan bütün modellerin doğruluk değerlendirme sonuçlarının özet tablosu.

Bölge	Model	RMSE (mm)	MAE (mm)	R	Örtüşme Oranı (%)
3.Bölge	CBR	4,05	3,46	0,059	34,29
	XGBR	3,83	3,39	0,356	31,43
	RFR	4,89	4,40	0,291	20,00
	SVR	3,95	3,31	-0,008	34,29
	LSTM	3,90	3,41	0,292	34,29
	Bütünleşik LSTM	3,21	2,77	0,068	31,43
4.Bölge	ARIMA	2,72	2,27	0,260	14,29
	FFT	2,55	2,04	0,232	31,43
	CBR	3,55	2,89	0,306	28,57
	XGBR	2,77	2,25	0,331	22,86
	RFR	3,66	3,02	-0,098	14,29
	SVR	3,49	2,72	0,146	14,29
	LSTM	3,58	2,94	0,021	8,57
	Bütünleşik LSTM	3,17	2,69	0,085	17,14
5.Bölge	ARIMA	1,02	0,86	0,496	25,71
	FFT	1,73	1,45	-0,087	17,14
	CBR	1,55	1,20	0,146	20,00
	XGBR	1,77	1,38	0,129	25,71
	RFR	1,92	1,58	0,015	17,14
	SVR	2,13	1,76	0,331	20,00
	LSTM	2,18	1,89	0,220	17,14
	Bütünleşik LSTM	1,35	1,11	-0,459	14,29
6.Bölge	ARIMA	3,74	2,96	0,854	40,00
	FFT	2,01	1,58	0,897	62,86
	CBR	3,92	3,26	0,589	17,14
	XGBR	2,70	2,27	0,868	37,14
	RFR	3,14	2,72	0,730	25,71
	SVR	2,38	1,82	0,873	54,29
	LSTM	3,92	3,25	0,588	25,71
	Bütünleşik LSTM	2,60	2,16	0,843	42,86

Çizelge 7.15 incelendiğinde yöntemler arasında ARIMA, FFT ve bütünleşik LSTM yöntemlerinin neredeyse bütün bölgelerde başarılı sonuç verdiği ve en iyi ilk üç yöntem arasında olduğu söylenebilmektedir. Her yöntem grubundan en iyi sonuç veren algoritma Çizelge 7.15'te koyu renkle gösterilmiştir. Regresyon tabanlı algoritma sonuçları incelendiğinde, bölgelere göre en yüksek tahmin doğruluğunu sağlayan yöntemler değişmektedir. Ancak, XGBR yöntemi her bölgede en düşük hatayı vermese de ikinci en iyi sonucu veren yöntem olarak karşımıza çıkmaktadır. İlk iki sırada yer alan yöntemlerin hata miktarlarının birbirine yakın olması ve XGBR yönteminin her bölgede başarılı performans sergilemesi, bu yöntemin farklı karakteristiğe sahip deformasyon zaman serilerinin tahmin analizlerinde kullanılabileceğinin bir göstergesidir. Bütün yöntemlerde ortak olarak en iyi sonucu veren XGBR ve Bütünleşik LSTM algoritmaları üzerinden yardımcı verilerin etkisi araştırılmıştır.


7.4.6 Özniteliklerin tahmin analizlerine katkısı ve önem derecelerinin belirlenmesi

Özniteliklerin tahmin analizlerine etkisinin araştırılması amacıyla zaman serileri; trend, mevsimsel etki ve artık parametrelerine ayrılmıştır. Bu üç parametreye ek olarak ERA5-Land yüzeyden 2 m yükseklikteki hava sıcaklığı, toprak sıcaklığı (0-7 cm), günlük toplam yağış ve günlük toplam buharlaşma parametreleriyle beraber yedi öznitelik tahmin analizlerine eklenerek katkısı incelenmiştir. Altı pilot bölge için analizler sırasıyla gerçekleştirilmiştir.

7.4.6.1 1. bölgede yardımcı verilerin etkisi

Pilot bölgelerden ilki olan 1. bölgede analizler gerçekleştirilmeden önce öznitelikler ile deformasyon zaman serisinin korelasyon analizi gerçekleştirilerek Şekil 7.38'de verilmiştir.

Şekil 7.38'de verilen korelasyonlar incelendiğinde, verinin trend verisi ile yüksek korelasyon gösterdiği ancak diğer parametrelerle korelasyonun olmadığı görülmektedir. Yedi öznitelik tahmin analizlerine eklenerek elde edilen hata değerleri Çizelge 7.16'da verilmiştir. Çizelgede verilen parametreler çok değişkenli modelin parametreleridir. Yardımcı veriler eklendikten sonra GridSearch algoritmasıyla model parametreleri tekrar belirlenmiştir.





Şekil 7.38 : Özniteliklerin 1. bölgede elde edilen deformasyon zaman serisi ile korelasyon grafiği.

Çizelge 7.16 : 1. bölgede tek değişkenli ve çok değişkenli tahmin analizi sonuçları.


Bölge	Model	Tek Değişkenli			Çok Değişkenli		
		RMSE (mm)	MAE (mm)	R	RMSE (mm)	MAE (mm)	R
1.Bölge	XGBR						
	No. estimator: 75						
	Max depth: 1	3,58	3,10	0,546	3,52	3,08	0,369
	Learning rate: 1						
	Lags: 68						
	Bütünleşik LSTM						
	Unit: 50	1,25	0,97	0,576	1,19	0,93	0,625
	Seyreltme: 0,2						
	Paket boyutu: 32						

Elde edilen sonuçlara göre her iki yöntemde de özniteliklerin eklenmesi RMSE ve MAE hata metriklerinde pozitif bir etki yaratmıştır. Ancak R değeri XGBR algoritmasında düşerken, Bütünleşik LSTM yönteminde artış göstermiştir. Tahmin analizlerinin görsel sonuçları Şekil 7.39’da verilmiştir.

XGBR yöntemine SHAP ve Permütasyon Öznitelik Önemi yöntemleri uygulanmıştır ve XGBR algoritmasının ağaç yapısını oluştururken ürettiği öznitelik ağırlıkları ile elde edilen sonuçlar Şekil 7.40’ta verilmiştir. Elde edilen sonuçlara göre, üç yöntemde de en önemli ilk üç bileşen sırasıyla artık bileşeni, trend bileşeni ve buharlaşma olarak belirlenmiştir. SHAP metoduna göre mevsimsel etki ve yağış da etkili olmaktadır.




Şekil 7.39 : Yardımcı veriler ile 1. bölgede tahmin analizi sonuçları a) XGBR ve b) Bütünleşik LSTM.



Şekil 7.40 : XGBR yöntemi üzerinden SHAP, Permütasyon Öznitelik Önemi ve XGBoost ağırlıklarının karşılaştırılması.


Bütünleşik LSTM yöntemi üzerinden sadece Permütasyon Öznitelik Önemi yöntemi uygulanmıştır ve elde edilen sonuçlar Şekil 7.41’de verilmiştir. Elde edilen sonuçlara göre en önemli üç öznitelik sırasıyla trend, artık ve yağış olarak belirlenmiştir.



Şekil 7.41 : Bütünleşik LSTM yöntemi üzerinden Permütasyon Öznitelik Önemi ile belirlenen öznitelik ağırlıkları.

7.4.6.2 2. bölgede yardımcı verilerin etkisi

2. bölgede analizler gerçekleştirilmeden önce öznitelikler ile deformasyon zaman serisinin korelasyon analizi gerçekleştirilerek Şekil 7.42’de verilmiştir.




Şekil 7.42 : Özniteliklerin 2. bölgede elde edilen deformasyon zaman serisi ile korelasyon grafiği.

Şekil 7.42’de verilen korelasyonlar incelendiğinde, verinin 1. bölgede olduğu gibi trend verisi ile yüksek korelasyon gösterdiği ancak diğer parametrelerle korelasyonunun olmadığı görülmektedir. Yedi öznitelik tahmin analizlerine eklenerek elde edilen hata değerleri Çizelge 7.17’de verilmiştir. Çizelgede verilen parametreler çok değişkenli modelin parametreleridir. Yardımcı veriler eklendikten sonra GridSearch algoritmasıyla model parametreleri tekrar belirlenmiştir.


Çizelge 7.17 : 2. bölgede tek değişkenli ve çok değişkenli tahmin analizi sonuçları.

Bölge	Model	Tek Değişkenli			Çok Değişkenli		
		RMSE (mm)	MAE (mm)	R	RMSE (mm)	MAE (mm)	R
2.Bölge	XGBR						
	No. estimator: 20						
	Max depth: 1	3,02	2,39	0,244	2,17	1,69	0,724
	Learning rate: 1						
	Lags: 26						
	Bütünleşik LSTM						
	Unit: 50	3,12	2,36	0,133	3,09	2,46	0,156
	Seyreltme: 0,5						
	Paket boyutu: 32						

Çizelge 7.17 incelendiğinde özniteliklerin eklenmesi model sonuçlarına katkı sağlamıştır ve bütün doğruluk metriklerinde pozitif yönde etkisi olmuştur. Korelasyon değerlerinde de artış görülmüştür. Elde edilen görsel sonuçlar Şekil 7.43’te verilmiştir.




Şekil 7.43 : Yardımcı veriler ile 2. bölgede tahmin analizi sonuçları a) XGBR ve b) Bütünleşik LSTM.



Şekil 7.43 (devam) : Yardımcı veriler ile 2. bölgede tahmin analizi sonuçları a) XGBR ve b) Bütünleşik LSTM.


XGBR yöntemine SHAP ve Permütasyon Öznitelik Önemi yöntemleri uygulanmıştır ve XGBR algoritmasının ağaç yapısını oluştururken ürettiği öznitelik ağırlıkları ile elde edilen sonuçlar Şekil 7.44'te verilmiştir. Bulgular neticesinde, üç yöntemde de en önemli ilk üç bileşen sırasıyla trend bileşeni, artık bileşeni ve hava sıcaklığı olarak belirlenmiştir. SHAP metoduna göre mevsimsel etki dışında diğer özniteliklerin de etkisi görülürken, diğer iki yöntemde buharlaşma ve toprak sıcaklığının da etkili olduğu görülmektedir.



Şekil 7.44 : XGBR yöntemi üzerinden 2. bölge için SHAP, Permütasyon Öznitelik Önemi ve XGBoost ağırlıklarının karşılaştırılması.

Bütünleşik LSTM yöntemi üzerinden sadece Permütasyon Öznitelik Önemi yöntemi uygulanmıştır ve elde edilen sonuçlar Şekil 7.45'te verilmiştir. Elde edilen sonuçlara


göre en önemli üç öznitelik sırasıyla trend, artık ve hava sıcaklığı olarak belirlenmiştir ve XGBR algoritması üzerinden gerçekleştirilen üç yöntem ile uyumlu olduğu görülmektedir.



Şekil 7.45 : Bütünleşik LSTM yöntemi üzerinden 2. bölge Permütasyon Öznitelik Önemi ile belirlenen ağırlıklar.

7.4.6.3 3. bölgede yardımcı verilerin etkisi

3. bölgede analizler gerçekleştirilmeden önce öznitelikler ile deformasyon zaman serisinin korelasyon analizi gerçekleştirilerek Şekil 7.46’da verilmiştir.




Şekil 7.46 : Özniteliklerin 3. bölgede elde edilen deformasyon zaman serisi ile korelasyon grafiği.

Trend bileşeniyle korelasyonun yüksek olmasının yanı sıra diğer parametrelerde de ilk iki bölgedeki korelasyon değerlerinden fazla olduğu görülmektedir. Yedi öznitelik tahmin analizlerine eklenerek elde edilen hata değerleri Çizelge 7.18’de verilmiştir. Çizelgede verilen parametreler çok değişkenli modelin parametreleridir. Yardımcı veriler eklendikten sonra GridSearch algoritmasıyla model parametreleri tekrar belirlenmiştir.


Çizelge 7.18 : 3. bölgede tek değişkenli ve çok değişkenli tahmin analizi sonuçları.

Bölge	Model	Tek Değişkenli			Çok Değişkenli		
		RMSE (mm)	MAE (mm)	R	RMSE (mm)	MAE (mm)	R
3.Bölge	XGBR						
	No. estimator: 50						
	Max depth: 1	3,83	3,39	0,356	1,84	1,45	0,744
	Learning rate: 1						
	Lags: 38						
	Bütünleşik LSTM						
	Unit: 50	3,21	2,77	0,068	3,20	2,76	0,088
	Seyreltme: 0,5						
	Paket boyutu: 32						

Çizelge 7.18 incelendiğinde özniteliklerin eklenmesi model sonuçlarına katkı sağlamıştır ve bütün doğruluk metriklerinde pozitif yönde etkisi olmuştur. Bütünleşik LSTM yönteminde XGBR yöntemine göre nispeten daha az gelişme olmuştur. Korelasyon değerlerinde de artış görülmüştür. Elde edilen görsel sonuçlar Şekil 7.47’de verilmiştir.




Şekil 7.47 : Yardımcı veriler ile 3. bölgede tahmin analizi sonuçları a) XGBR ve b) Bütünleşik LSTM.



Şekil 7.47 (devam) : Yardımcı veriler ile 3. bölgede tahmin analizi sonuçları a) XGBR ve b) Bütünleşik LSTM.


XGBR yöntemine SHAP ve Permütasyon Öznitelik Önemi yöntemleri uygulanmıştır ve XGBR algoritmasının ağaç yapısını oluştururken ürettiği öznitelik ağırlıkları ile elde edilen sonuçlar Şekil 7.48’de verilmiştir. Üç yöntemde de en önemli bileşenler sırasıyla trend bileşeni, artık bileşeni, buharlaşma ve toprak sıcaklığı olarak belirlenmiştir.



Şekil 7.48 : XGBR yöntemi üzerinden 3. bölge için SHAP, Permütasyon Öznitelik Önemi ve XGBoost ağırlıklarının karşılaştırılması.

Bütünleşik LSTM yöntemi üzerinden sadece Permütasyon Öznitelik Önemi yöntemi uygulanmıştır ve elde edilen sonuçlar Şekil 7.49’da gösterilmektedir. Elde edilen


sonuçlara göre en önemli üç öznitelik sırasıyla trend bileşeni, buharlaşma ve yağış olarak belirlenmiştir. Trend bileşeni ve buharlaşma özniteliklerinin önem derecelerinin yüksek çıkması, XGBR algoritması üzerinden gerçekleştirilen üç yöntem ile de uyumlu bir sonuç vermiştir. Ancak yağış Bütünleşik LSTM yönteminde ilk üç sırada yer alsa da sadece XGBR üzerinde uygulanan SHAP yönteminde ve ayrıca önem derecesi olarak son sıralarda yer aldığı görülmektedir.



Şekil 7.49 : Bütünleşik LSTM yöntemi üzerinden 3. bölge Permütasyon Öznitelik Önemi ile belirlenen ağırlıklar.

7.4.6.4 4. bölgede yardımcı verilerin etkisi

4. bölgede analizler gerçekleştirilmeden önce öznitelikler ile deformasyon zaman serisinin korelasyon analizi gerçekleştirilerek Şekil 7.50’de verilmiştir.




Şekil 7.50 : Özniteliklerin 4. bölgede elde edilen deformasyon zaman serisi ile korelasyon grafiği.

Trend bileşeniyle korelasyonun yüksek olmasının yanı sıra artık bileşeninde de korelasyonun olduğu görülmektedir. Yedi öznitelik tahmin analizlerine eklenerek elde edilen hata değerleri Çizelge 7.19’da verilmiştir. Çizelgede verilen parametreler çok değişkenli modelin parametreleridir. Yardımcı veriler eklendikten sonra GridSearch algoritmasıyla model parametreleri tekrar belirlenmiştir.


Çizelge 7.19 : 4. bölgede tek değişkenli ve çok değişkenli tahmin analizi sonuçları.

Bölge	Model	Tek Değişkenli			Çok Değişkenli		
		RMSE (mm)	MAE (mm)	R	RMSE (mm)	MAE (mm)	R
4.Bölge	XGBR						
	No. estimator: 75						
	Max depth: 1	2,77	2,25	0,331	1,52	1,14	0,819
	Learning rate: 1						
	Lags: 32						
	Bütünleşik LSTM						
	Unit: 250	3,17	2,69	0,085	2,87	2,39	0,155
	Seyreltme: 0,1						
	Paket boyutu: 32						

Çizelge 7.19 incelendiğinde özniteliklerin eklenmesi model sonuçlarına katkı sağlamıştır ve bütün doğruluk metriklerinde pozitif yönde etkisi olmuştur. Bütünleşik LSTM yönteminde XGBR yöntemine göre nispeten daha az gelişme olmuştur. Korelasyon değerlerinde de artış görülmüştür. Elde edilen görsel sonuçlar Şekil 7.51’de verilmiştir.




Şekil 7.51 : Yardımcı veriler ile 4. bölgede tahmin analizi sonuçları a) XGBR ve b) Bütünleşik LSTM.



Şekil 7.51 (devam) : Yardımcı veriler ile 4. bölgede tahmin analizi sonuçları a) XGBR ve b) Bütünleşik LSTM.


XGBR yöntemine SHAP ve Permütasyon Öznitelik Önemi yöntemleri uygulanmıştır ve XGBR algoritmasının ağaç yapısını oluştururken ürettiği öznitelik ağırlıkları ile elde edilen sonuçlar Şekil 7.52’de verilmiştir. Üç yöntemde de en önemli bileşenler sırasıyla trend bileşeni, artık bileşeni, mevsimsel etki olarak öne çıkmaktadır. Toprak sıcaklığının hiç etkisi görülmezken, sırasıyla yağış, buharlaşma ve hava sıcaklığının da etkisi görülmektedir.



Şekil 7.52 : XGBR yöntemi üzerinden 4. bölge için SHAP, Permütasyon Öznitelik Önemi ve XGBoost ağırlıklarının karşılaştırılması.

Bütünleşik LSTM yöntemi üzerinden sadece Permütasyon Öznitelik Önemi yöntemi uygulanmıştır ve elde edilen sonuçlar Şekil 7.53’te gösterilmektedir. Elde edilen sonuçlara göre en önemli üç öznitelik sırasıyla toprak sıcaklığı, trend bileşeni ve buharlaşma olarak belirlenmiştir. XGBR ile uygulanan yöntemlerin aksine toprak


sıcaklığı LSTM ile permütasyon öznitelik öneminde en önemli parametre olarak öne çıkmaktadır.



Şekil 7.53 : Bütünleşik LSTM yöntemi üzerinden 4. bölge Permütasyon Öznitelik Önemi ile belirlenen ağırlıklar.

7.4.6.5 5. bölgede yardımcı verilerin etkisi

5. bölgede analizler gerçekleştirilmeden önce öznitelikler ile deformasyon zaman serisinin korelasyon analizi gerçekleştirilerek Şekil 7.54’te verilmiştir.



Şekil 7.54 : Özniteliklerin 5. bölgede elde edilen deformasyon zaman serisi ile korelasyon grafiği.


Stabil hareket gösteren 5. bölgede, artık bileşeni ile korelasyon yüksek iken trend bileşeniyle de korelasyonun olduğu görülmektedir. Yedi öznitelik tahmin analizlerine

eklenerek elde edilen hata değerleri Çizelge 7.20’de verilmiştir. Çizelgede verilen parametreler çok değişkenli modelin parametreleridir. Yardımcı veriler eklendikten sonra GridSearch algoritmasıyla model parametreleri tekrar belirlenmiştir.


Çizelge 7.20 : 5. bölgede tek değişkenli ve çok değişkenli tahmin analizi sonuçları.

Bölge	Model	Tek Değişkenli			Çok Değişkenli		
		RMSE (mm)	MAE (mm)	R	RMSE (mm)	MAE (mm)	R
5.Bölge	XGBR						
	No. estimator: 100						
	Max depth: 1	1,77	1,38	0,129	0,48	0,37	0,949
	Learning rate: 1						
	Lags: 2						
	Bütünleşik LSTM						
	Unit: 50	1,35	1,11	-0,459	1,23	1,04	-0,157
	Seyreltme: 0,75						
	Paket boyutu: 64						

Çizelge 7.20 incelendiğinde özniteliklerin eklenmesi model sonuçlarına katkı sağlamıştır ve bütün doğruluk metriklerinde pozitif yönde etkisi olmuştur. Bütünleşik LSTM yönteminde XGBR yöntemine göre nispeten daha az gelişme olmuştur. Korelasyon değerlerinde de artış görülmüştür. Elde edilen görsel sonuçlar Şekil 7.55’te verilmiştir.




Şekil 7.55 : Yardımcı veriler ile 5. bölgede tahmin analizi sonuçları a) XGBR ve b) Bütünleşik LSTM.



Şekil 7.55 (devam) : Yardımcı veriler ile 5. bölgede tahmin analizi sonuçları a) XGBR ve b) Bütünleşik LSTM.


XGBR yöntemine SHAP ve Permütasyon Öznitelik Önemi yöntemleri uygulanmıştır ve XGBR algoritmasının ağaç yapısını oluştururken ürettiği öznitelik ağırlıkları ile elde edilen sonuçlar Şekil 7.56’da verilmiştir. Üç yöntemde de en önemli bileşenler sırasıyla artık bileşeni, trend bileşeni ve mevsimsel etki olarak öne çıkmaktadır. Diğer parametrelerin de az da olsa etkisinin olduğu görülmektedir.



Şekil 7.56 : XGBR yöntemi üzerinden 5. bölge için SHAP, Permütasyon Öznitelik Önemi ve XGBoost ağırlıklarının karşılaştırılması.

Bütünleşik LSTM yöntemi üzerinden sadece Permütasyon Öznitelik Önemi yöntemi uygulanmıştır ve elde edilen sonuçlar Şekil 7.57’de gösterilmektedir. Elde edilen sonuçlara göre en önemli üç öznitelik sırasıyla toprak sıcaklığı, trend bileşeni ve hava sıcaklığı olarak belirlenmiştir. Bu parametreleri, yağış, buharlaşma ve artık bileşeni takip etmektedir. XGBR ile uygulanan yöntemlerin aksine toprak sıcaklığı LSTM ile


permütasyon öznitelik öneminde en önemli parametre olarak ve artık ve mevsimsel etki ise en düşük etkiye sahip bileşenler olarak öne çıkmaktadır.



Şekil 7.57 : Bütünleşik LSTM yöntemi üzerinden 5. bölge Permütasyon Öznitelik Önemi ile belirlenen ağırlıklar.

7.4.6.6 6. bölgede yardımcı verilerin etkisi

6. bölgede analizler gerçekleştirilmeden önce öznitelikler ile deformasyon zaman serisinin korelasyon analizi gerçekleştirilerek Şekil 7.58’te verilmiştir.




Şekil 7.58 : Özniteliklerin 6. bölgede elde edilen deformasyon zaman serisi ile korelasyon grafiği.

Mevsimsel kabarma hareketi gösteren 6. bölgede, trend bileşeninin yanı sıra mevsimsel hareket gösterdiği için hava ve toprak sıcaklığı ile de yüksek korelasyona sahiptir. Tahmin analizlerinde aşırı öğrenme (overtraining) oluşumuna sebep olduğundan trend parametresi eklenmeden altı öz nitelik ile gerçekleştirilen tahmin analizi hata değerleri Çizelge 7.21’de verilmiştir. Çizelgede verilen parametreler çok değişkenli modelin parametreleridir. Yardımcı veriler eklendikten sonra GridSearch algoritmasıyla model parametreleri tekrar belirlenmiştir.


Çizelge 7.21 incelendiğinde öz niteliklerin eklenmesi model sonuçlarına nispeten katkı sağlamıştır ve bütün doğruluk metriklerinde pozitif yönde etkisi olmuştur. Elde edilen görsel sonuçlar Şekil 7.59’da verilmiştir.

Çizelge 7.21 : 6. bölgede tek değişkenli ve çok değişkenli tahmin analizi sonuçları.

Bölge	Model	Tek Değişkenli			Çok Değişkenli		
		RMSE (mm)	MAE (mm)	R	RMSE (mm)	MAE (mm)	R
6.Bölge	XGBR						
	No. estimator: 100						
	Max depth: 1	2,70	2,27	0,868	2,00	1,75	0,896
	Learning rate: 0,5						
	Lags: 62						
	Bütünleşik LSTM						
	Unit: 500	2,60	2,16	0,843	2,12	1,73	0,884
	Seyreltme: 0,5						
	Paket boyutu: 64						




Şekil 7.59 : Yardımcı veriler ile 6. bölgede tahmin analizi sonuçları a) XGBR ve b) Bütünleşik LSTM.



Şekil 7.59 (devam) : Yardımcı veriler ile 6. bölgede tahmin analizi sonuçları a) XGBR ve b) Bütünleşik LSTM.


XGBR yöntemine SHAP ve Permütasyon Öznitelik Önemi yöntemleri uygulanmıştır ve XGBR algoritmasının ağaç yapısını oluştururken ürettiği öznitelik ağırlıkları ile elde edilen sonuçlar Şekil 7.60'ta verilmiştir. Üç yöntemde de en önemli bileşenler sırasıyla toprak sıcaklığı, artık bileşeni, hava sıcaklığı ve mevsimsel etki olarak öne çıkmaktadır. Yağış ve buharlaşma parametrelerinin etkisinin olmadığı görülmektedir.



Şekil 7.60 : XGBR yöntemi üzerinden 6. bölge için SHAP, Permütasyon Öznitelik Önemi ve XGBoost ağırlıklarının karşılaştırılması.

Bütünleşik LSTM yöntemi üzerinden sadece Permütasyon Öznitelik Önemi yöntemi uygulanmıştır ve elde edilen sonuçlar Şekil 7.61'de gösterilmektedir. Elde edilen sonuçlara göre en önemli üç öznitelik sırasıyla buharlaşma, toprak sıcaklığı ve hava sıcaklığı olarak öne çıkmaktadır. Bu parametreleri yağış, artık ve trend bileşenleri


takip etmektedir. XGBR ile uygulanan yöntemlerin aksine buharlaşma LSTM ile permütasyon öznelik öneminde en önemli parametre olarak öne çıkmaktadır.






Şekil 7.61 : Bütünleşik LSTM yöntemi üzerinden 6. bölge Permütasyon Öznelik Önemi ile belirlenen ağırlıklar.

7.4.7 Pilot bölgelerin gelecek tahmin analizi

Üç farklı yöntemden (geleneksel, regresyon tabanlı ve derin öğrenme yöntemleri) başarılı sonuç veren algoritmalar ile gelecek tahmin analizleri gerçekleştirilmiştir. ARIMA ve FFT yöntemleri tek değişkenli analiz sonuçlarında başarılı doğruluk değerleri verdiğinden gelecek tahmininde de sonuçları değerlendirilmiştir. XGBR ve Bütünleşik LSTM yöntemlerinde ise çok değişkenli analiz sonuçları daha yüksek doğruluk sağladığından gelecek tahmininde çok değişkenli analiz uygulanmıştır. Dört modelin sonuçları altı pilot bölgede de uygulanarak gelecek tahmin değerlendirmeleri yapılmıştır. İlk olarak 1. bölgede uygulanan model sonuçları Çizelge 7.31’de verilmiştir.







Şekil 7.62 : 1. pilot bölge için a) ARIMA, b) FFT, c) XGBR ve d) Bütünleşik LSTM yöntemleriyle gelecek tahmin analizi.




Şekil 7.62 (devam) : 1. pilot bölge için a) ARIMA, b) FFT, c) XGBR ve d) Bütünleşik LSTM yöntemleriyle gelecek tahmin analizi.

Elde edilen sonuçlar doğrultusunda, dört yöntem de 1. bölgede düşey hareket trendinin devam edeceğini gösteren sonuçlar vermiştir. FFT ve Bütünleşik LSTM yöntemlerinin birbirine yakın sonuçlar vermesi de dikkat çekmektedir. ARIMA lineer bir hareket gösterirken, XGBR ise gelgitli bir sonuç vermiştir. Bu dört yöntem 2. bölgede de uygulanarak model sonuçları Şekil 7.63'te verilmiştir.




Şekil 7.63 : 2. pilot bölge için a) ARIMA, b) FFT, c) XGBR ve d) Bütünleşik LSTM yöntemleriyle gelecek tahmin analizi.

Şekil 7.63 incelendiğinde FFT ve Bütünleşik LSTM model sonuçlarının benzerlik gösterdiği görülmektedir. ARIMA stabil bir hareket gösterirken, XGBR da gelgitler ile beraber hafif düşüş meyilli bir hareket göstermektedir. Dört model 3. pilot bölgeye uygulanarak sonuçlar Şekil 7.64’te verilmiştir.




Şekil 7.64 : 3. pilot bölge için a) ARIMA, b) FFT, c) XGBR ve d) Bütünleşik LSTM yöntemleriyle gelecek tahmin analizi.





Şekil 7.64 (devam) : 3. pilot bölge için a) ARIMA, b) FFT, c) XGBR ve d) Bütünleşik LSTM yöntemleriyle gelecek tahmin analizi.

Şekil 7.64 incelendiğinde ARIMA, FFT ve Bütünleşik LSTM model sonuçlarının benzerlik gösterdiği ve kabarma hareketinin lineer olarak devam edeceği görülmektedir. XGBR da ise hareketin daha stabil seyredeceği görülmektedir. Dört model 4. pilot bölgeye uygulanarak sonuçlar Şekil 7.65'te verilmiştir.




Şekil 7.65 : 4. pilot bölge için a) ARIMA, b) FFT, c) XGBR ve d) Bütünleşik LSTM yöntemleriyle gelecek tahmin analizi.






Şekil 7.65 (devam) : 4. pilot bölge için a) ARIMA, b) FFT, c) XGBR ve d) Bütünleşik LSTM yöntemleriyle gelecek tahmin analizi.

Şekil 7.65 incelendiğinde ARIMA, FFT ve Bütünleşik LSTM model sonuçlarının benzerlik gösterdiği ve kabarma hareketinin lineer olarak devam edeceği görülmektedir. XGBR da ise hareketin hafif kabarma meyilli seyredeceği görülmektedir. Dört model 5. pilot bölgeye uygulanarak sonuçlar Şekil 7.66'da verilmiştir.







Şekil 7.66 : 5. pilot bölge için a) ARIMA, b) FFT, c) XGBR ve d) Bütünleşik LSTM yöntemleriyle gelecek tahmin analizi.



Şekil 7.66 (devam) : 5. pilot bölge için a) ARIMA, b) FFT, c) XGBR ve d) Bütünleşik LSTM yöntemleriyle gelecek tahmin analizi.

Şekil 7.66 incelendiğinde ARIMA, FFT ve Bütünleşik LSTM model sonuçlarının benzer yaklaşımda sonuç gösterdiği ve stabil hareketin trendde de olduğu gibi hafif eğimli bir şekilde devam edeceği görülmektedir. Dört model 6. pilot bölgeye uygulanarak sonuçlar Şekil 7.67’de verilmiştir.



Şekil 7.67 : 6. pilot bölge için a) ARIMA, b) FFT, c) XGBR ve d) Bütünleşik LSTM yöntemleriyle gelecek tahmin analizi.

Şekil 7.67 incelendiğinde FFT ve XGBR sonuçlarının nispeten benzer bir trend gösterdiği görülmektedir. Bütünleşik LSTM model sonucunun ise yine zaman serisinin trendine uygun olarak hareket edeceği ama daha yavaş bir salınımında ilerlediği görülmektedir. ARIMA ise başarılı bir sonuç göstermemiştir.

Elde edilen sonuçlar neticesinde zaman serilerinin tahmin analizinde, yardımcı veri olmadan da başarılı sonuç gösteren algoritmalar geleneksel yöntemlerden FFT, derin öğrenme yöntemlerinden Bütünleşik LSTM ve regresyon tabanlı yöntemlerden XGBR olarak gösterilebilmektedir. Ancak XGBR algoritması aşırı öğrenmeye meyilli olmakla beraber, Bütünleşik LSTM algoritmasında seyreltme katmanları ile bu durum engellenebilmektedir.





8. SONUÇLAR

İstanbul'un üçüncü havalimanı olan İstanbul Havalimanı, İstanbul'un hem ulusal hem de uluslararası hava trafiğine bir çözüm niteliğinde geliştirilmiştir. Kullanıma açılmasından sonra kısa sürede hava trafiğinde önemli bir konuma gelmesi de bu durumun göstergesi niteliğindedir. Ancak, İstanbul Havalimanı terkedilmiş kömür ve kum ocaklarının zamanla sulak alanlara dönüştüğü ve rehabilite çalışmalarının uzun yıllar devam ettiği Karadeniz'e kıyısı olan bir bölge üzerine inşa edilmiştir. Bölge ıslah edilerek yüksek oranda dolgu yapılmıştır ve yapılan dolguların etkilerinin havalimanı yapıları (pist, terminal vb.) üzerinde de görülmesi kaçınılmaz olmaktadır. Bu sebeple, havalimanında deformasyonların belirlenmesi, geniş alan ölçeğinde sürekli olarak takip edilmesi ve deformasyonların nasıl seyredebileceğinin kestirilerek önlemlerin alınması önemli bir husustur.

Uzaktan algılama teknolojileri, hızlı, efektif ve yüksek doğrulukta sonuçlar üretmeye olanak sağlamaktadır. Nokta tabanlı GNSS, inklonometre ve nivelman vb. gibi ölçme yöntemlerinin aksine geniş ölçekte alanları görüntülemeye ve uzaktan algılanmış görüntüler yardımıyla birçok analizi gerçekleştirmeye olanak sağlamaktadır. Aynı zamanda, yersel ölçme yöntemlerinde referans alınan ölçme noktaları da deforme olarak hatalı sonuçlar alınmasına sebebiyet verebilmektedir. Uydu görüntü arşivlerinin ve orta mekânsal çözünürlükte güncel uydu görüntülerinin ücretsiz olarak servis edilmesi, havalimanı gibi büyük ulaşım altyapılarının geçmişten günümüze değişim analizinin yanı sıra yapısal veya inşa edildiği bölge kaynaklı yüzey hareketlerinin belirlenmesine olanak sağlamaktadır. Landsat optik uydu görüntüleri geçmişten günümüze arazi örtüsü/kullanımındaki değişimin analizine olanak sağlarken, ESA tarafından ücretsiz olarak servis edilen Sentinel-1 SAR uydu görüntüleri ise yüzey hareketlerinin belirlenmesine olanak sağlamaktadır.

İstanbul Havalimanı örneği üzerinde gerçekleştirilen çalışma, bu bölge üzerinde gerçekleştirilen ilk çalışma olmasının yanı sıra, büyük havalimanlarının kapsamlı olarak birçok yönden incelendiği ilk tez çalışmasıdır. Bölgede optik uydu

görüntüleriyle değişim analizlerinin belirlenmesinin yanı sıra SBAS ve PSInSAR yöntemleriyle yüzey hareketleri genel ve özel detayda belirlenmiştir. 3B modeller yardımıyla kazı/dolgu alanları belirlenmiştir ve deformasyon sonuçları ile ilişkilendirilmiştir. Deformasyonların belirlenmesinin yanı sıra elde edilen deformasyonların gelecek tahmin analizleri birçok farklı yöntem kullanılarak gerçekleştirilmiştir. Çalışmalar neticesinde elde edilen sonuçlar maddeler halinde aşağıda sıralanmıştır.

- Çalışma alanı havalimanı inşaatından önce kömür ve kum ocaklarına ev sahipliği yapmıştır. 1990'lardan sonra terkedilen ocaklar zamanla yer altı suyu ve yağmur suyu ile dolarak sulak alan haline gelmiş ve rehabilitasyon çalışmaları yapılmıştır. Landsat-5 TM ve Landsat-8 OLI uydu görüntüleri RF sınıflandırma algoritması ile sınıflandırılarak çalışma alanının 1984-2020 yılları arasındaki beşer yıllık değişimi ortaya konmuştur. Elde edilen sonuçlara göre, sulak alanların yüzey alanlarında 36 yıl içerisinde %12'lik bir artış görülse de 1984 yılından havalimanı inşaatı öncesi 2010 yılına kadar sulak alanların 10 kat arttığı ve inşaat sonrası büyük bir kısmının yok edildiği tespit edilmiştir. 2010 ve 2020 yılları baz alındığında, su yüzey alanının 727,5 hektardan 217 hektara düşmesiyle ciddi bir kayıp yaşandığı görülmüştür. Yeşil alanlarda %24 azalma, açık alan sınıfında ise %7 artış görülürken, son 20 yıl içerisinde yol ağının inşa edildiği tespit edilen diğer hususlardır. Aynı zamanda bölgedeki kıyı çizgisi değişimleri de dikkat çeken bir diğer husustur.
- Havalimanında meydana gelen yüzey deformasyonlarının belirlenmesi için öncelikle LiCSBAS uygulama paketi kullanılarak Sentinel-1 uydu görüntülerinden üretilen LiCSAR ürünleri ile SBAS analizi gerçekleştirilmiştir. Sonuç ürünler yaklaşık olarak 100 m mekânsal çözünürlüğe sahip olduğundan, havalimanındaki genel durumu ortaya koyması adına tercih edilmiştir. Havalimanının kullanıma açıldığı Kasım 2018 ile Eylül 2022 tarihleri arasında hem yükselen hem de alçalan geometride gerçekleştirilen analizler sonucunda, her iki geometride de benzer sonuç alındığı görülmektedir. B ve C pistlerinin arasında ve terminal binasının yukarısında kalan havalimanı inşaatı için ıslah edilmiş 88,6 ha alana sahip sulak alanın bulunduğu bölgede her iki yörüngede de çökme eğilimli hareket olduğu tespit edilmiştir. Yükselen yörüngeden alınan zaman serilerinde, bu

alandaki kümülatif deformasyonun 250 mm'ye ulaştığı belirlenmiştir. B ve C pistleri ile terminal binasının kuzeyinin de bu bölgeden etkilendiği de analiz sonuçlarında görülmüştür. Zaman serileri incelendiğinde, A pistinin kuzey üst kesimlerinde ve C pisti üzerinde 100 mm'ye varan çökme eğiliminde negatif yönde hareket tespit edilirken, B pistinin güneyinde de 100 mm'ye varan kabarma eğilimli pozitif yönde hareket tespit edilmiştir.

- Detaylı deformasyon analizlerinin gerçekleştirilmesi için Sentinel-1 SAR uydu görüntülerine SNAP ve StaMPS yazılımları yardımıyla PSInSAR yöntemi yine aynı periyotta, Kasım 2018-Eylül 2022 zaman aralığında, uygulanmıştır. Hem yükselen hem de alçalan geometride elde edilen sonuçların, LiCSBAS sonuçlarında da olduğu gibi birbirine benzer olduğu tespit edilmiştir. Elde edilen PS noktaları filtrelenerek tutarlılık değeri 0.60'ın üzerinde olan PS noktaları incelenmiştir. PSInSAR sonuçları doğrultusunda, B ve C pistleri arasında yer alan ve ıslah edilen dolgu alana yakın kesimlerde örneğin B pisti ile terminal binasının kuzey kesimlerinde çökme eğilimli negatif hareket olduğu görülmüştür. Aynı şekilde A pistinin kuzeyinde de çökme eğilimli hareket görülmüştür. B pistinin güneyi ile terminal binasının çatısı üzerinden elde edilen PS noktaları ise kabarma eğilimli pozitif yönde hareket göstermiştir.
- Kasım 2018-Eylül 2022 zaman aralığında üretilen PSInSAR sonuçlarında, C pistine ait bilgi elde edilememiştir. Bu durumun temel sebebi, C pistinin bu tarihler arasında inşaat halinde olması ve PSInSAR yönteminin inşaat bölgelerinde kararlı saçıcıları tespit edememesinden kaynaklanmaktadır. Bu doğrultuda, C pistinin durum tespiti için Temmuz 2020-Eylül 2022 zaman aralığı için PSInSAR analizleri hem yükselen hem de alçalan geometride tekrarlanmıştır. Elde edilen sonuçlardan ilki, pistin projede planlanandan daha kısa inşa edildiğidir. Deformasyon sonuçları incelendiğinde, yükselen ve alçalan geometri sonuçları benzerlik göstermekte ve uzun dönem deformasyon sonuçlarıyla benzer bölgeler çökme veya kabarma eğilimli hareket göstermeye devam etmiştir. Ancak, C pisti üzerindeki PS noktaları incelendiğinde C pistinin kuzey kesimlerinde yine ufak bir sulak alanın ıslah edilerek üzerine pistin inşa edildiği belirlenmiş ve bu bölgede çökme eğilimli negatif yönde hareketin olduğu tespit edilmiştir. Sulak alanlarda suyun tahliyesi

gerçekleştirilerek zemin iyileştirmesi üzerine dolgu malzemesi serilse de yapı ve kullanım yükleri ile beraber dolgu malzemesinde oturma gerçekleşir. Deformasyon zaman serileri incelendiğinde de çökme ve kabarma hareketlerinin zaman içerisinde yavaşlayarak stabil konuma gelmeye başladığı söylenebilmektedir.

- Yükselen ve alçalan yörüngede elde edilen deformasyon sonuçları kullanılarak yüzey deformasyonu yatay ve düşey bileşenlerine ayrılmıştır. Bu amaçla, 200 metrelik gridler oluşturulmuş ve PS noktaları bu gridlerle eşleştirilerek raster veriler elde edilmiştir. Elde edilen raster veriler ile Bölüm 2.3'te verilen eşitlik kullanılarak yatay ve düşey bileşenler oluşturulmuştur. Yükselen ve alçalan yörüngede elde edilen deformasyonların benzer olması, hareketin düşey yönde olduğunun göstergesi olup, elde edilen sonuçlar da bu durumu doğrulamaktadır.
- Meteorolojik parametrelerin PS noktaları üzerindeki etkilerini incelemek amacıyla, terminal binasının çatısında mevsimsel hareket gösteren PS noktasının deformasyon zaman serisi, toplamsal ayrıştırma yöntemi ile bileşenlerine ayrılmış ve trend parametresi İstanbul Havalimanı Meteoroloji İstasyonu'ndan temin edilen sıcaklık parametresiyle ilişkilendirilmiştir. İki veri arasında korelasyon katsayısının (R^2) 0,76 ile yüksek olduğu belirlenmiştir. Bu durum, terminal binasının çatı malzemesinin mevsimsel olarak genişlemeye duyarlı olduğunu da göstermektedir.
- Havalimanının inşa edildiği bölge ıslah edilen sulak alanlardan oluşmaktadır ve bu sulak alanların dolgu malzemesiyle doldurularak havalimanının inşa edildiği bilinmektedir. Bu durumun tespiti amacıyla, havalimanı inşaatı öncesi ve sonrası SYM'ler kullanılarak kazı ve dolgu alanları tespit edilmiştir. Havalimanı inşaatı öncesi için 2014 yılında servis edilen ücretsiz SRTM verisi kullanılırken, inşaat başladıktan sonrası içinse ücretsiz SYM verisi bulunmadığından İTÜ UHUZAM'dan temin edilen stereo Pleiades uydu verileri ile 2 m mekânsal çözünürlüğe sahip SYM üretilmiştir. SYM'lerin eş mekânsal çözünürlükte değerlendirilmesi için üretilen SYM 30 metreye örneklenmiştir. SYM'lerin farkı ile kazı ve dolgu alanları tespit edilmiş ve 88,6 ha alana sahip büyük sulak alanın ıslah edildikten sonra dolgu malzemesi ile ortalama 60 m doldurulduğu tespit edilmiştir. Ayrıca, deformasyon

sonuçlarında elde edilen çökme eğilimli hareket gösteren bölgelerin dolgu alanlarıyla örtüştüğü, kabarma eğilimli hareket gösteren bölgelerin ise kazı alanlarıyla örtüştüğü belirlenmiştir.

- Deformasyonların seyrinin belirlenebilmesi adına tahmin analizi çalışmaları gerçekleştirilmiştir. Bu amaçla 6 farklı pilot bölge seçilmiştir. Pilot bölgeler seçilirken farklı yapı türü (pist ve bina) ve farklı deformasyon davranışlarına (çökme, kabarma, stabil ve mevsimsel hareket) sahip olmalarına dikkat edilmiştir. Belirlenen bölgelerin içerisinde kalan PS noktalarının tutarlılık değerlerine göre ağırlıklı ortalaması alınmış ve deformasyon zaman serileri elde edilmiştir. Geleneksel yöntemler (ARIMA, FFT), regresyon tabanlı yöntemler (CBR, XGBR, RFR ve SVR) ve derin öğrenme yöntemleri (LSTM ve Bütünleşik LSTM) kullanılarak tahmin analizleri gerçekleştirilmiş ve hata metrikleri ile test edilmiştir. Bütün zaman serisi tiplerinde en iyi sonucu veren algoritmalar, XGBR ve Bütünleşik LSTM olarak belirlenmiştir. Bu algoritmalar kullanılarak yardımcı verilerin eklenmesinin regresyona katkısı ve önemliliklerin önem dereceleri iki farklı metot kullanılarak bölgelere göre incelenmiştir. Yardımcı veriler, zaman serisinin trend, mevsimsel etki ve artık bileşenleri ile ERA5-Land verisinden temin edilen hava sıcaklığı, toprak sıcaklığı, yağış ve buharlaşma parametrelerinden oluşmaktadır. Bu yedi önemliliğin eklenmesinin, tahmin analizlerine katkı sağladığı görülmüştür. Ancak XGBR gibi regresyon tabanlı algoritmaların aşırı öğrenmeye meyilli olduğu belirlenmiştir. LSTM gibi derin öğrenme yöntemlerinde ise seyreltme katmanı sayesinde aşırı öğrenme engellenebilmektedir.
- Özniteliklerin önem dereceleri SHAP ve Permütasyon Öznitelik Önemi yöntemleri ile XGBR algoritması üzerinde test edilmiştir. Elde edilen sonuçlar doğrultusunda SHAP, Permütasyon Öznitelik Önemi ve XGBR algoritmasının kendi ağaç yapısını oluştururken ürettiği önem dereceleri karşılaştırılmış ve üç yöntemin de benzer sonuçlar verdiği tespit edilmiştir. Yapı ve deformasyon karakteristiği açısından incelendiğinde, trend ve artık bileşenlerinin bütün zaman serisi türlerinde tahmin doğruluğunu arttırdığı ancak mevsimsel kabarmada olduğu gibi kontrol edilmediği takdirde aşırı öğrenmeye de sebebiyet verebileceği belirlenmiştir. Pist üzerinden alınan kabarma ve çökme zaman serilerinde buharlaşma parametresinin öne çıktığı, bina üzerinden alınan

kabarma ve çökme zaman serilerinde ise buharlaşmanın yanı sıra hava sıcaklığının etkili olduğu tespit edilmiştir. Terminal binası üzerinden alınan üç farklı zaman serisinde de mevsimsel etki ve hava sıcaklığının etkili olduğu belirlenmiş olup, terminal binasının yapı malzemesinin zaman serilerinde etkisinin olduğu söylenebilmektedir.

- Bütünleşik LSTM yöntemi üzerinde sadece Permütasyon Öznitelik Önemi yöntemiyle öznitelik önemleri belirlenmiştir. Elde edilen sonuçlara göre trend bileşeni mevsimsel kabarma hareketi hariç diğer zaman serilerinde en önemli üç bileşen arasında yer almaktadır. Çökme ve kabarma hareketlerinde yapı türü bazında inceleme yapıldığında, pistte yağış parametresi öne çıkarken, binada buharlaşma parametresi öne çıkmaktadır. Pist üzerinde yağış parametresinin hem çökme hem de kabarma bölgelerinde öne çıkmasının olası sebebi olarak zeminin yağışa karşı hassas olması gösterilebilmektedir. 88,6 ha alana sahip sulak alanın kurutulması bölgenin yeraltı su seviyesini de düşürmektedir. Yeraltı su seviyesi azalan bölgeler yağışa karşı hassas konuma gelmekte ve bu durum zeminde çökme hareketini tetiklemektedir. Kabarma bölgesinde ise dolgu yapılan alanlarda dolgu malzemesinin yağış ile şişmesinden dolayı yağışın etkili olabileceği düşünülmektedir. Terminal binası üzerinden alınan farklı zaman serileri incelendiğinde ise, terminal binasında toprak sıcaklığı parametresinin önem derecesinin fazla olduğu görülmektedir. Toprak sıcaklığının yüzey sıcaklığını temsil ettiği göz önüne alındığında metalik çatı ve cephe kaplamalarına sahip yapıların termal etkilere karşı hassas olması bu parametrenin öne çıkmasının olası sebebi olarak gösterilebilmektedir. Zaman serisinin karakteristiğine göre değerlendirme yapıldığında ise kabarma karakteristiğine sahip zaman serilerinde buharlaşmanın önem derecesinin fazla olduğu görülürken, çökme karakteristiğine sahip zaman serilerinde yağış, hava sıcaklığı ve buharlaşmanın etkili olduğu ancak en etkili üç parametrenin sıralamasında yapı türüne göre değişkenlik olduğu görülmektedir.
- Tez çalışması 2029 yılında tamamlanması planlanan İstanbul Havalimanı'nın inşa edilen kısımlarında gerçekleştirilmiş olup, diğer pist ve yapılar tamamlandıktan sonra yapılan çalışmalar bu yapılar için de uygulanabilecektir. Çalışmanın zaman aralıkları C pistinde olduğu gibi kullanıma açıldığı tarih aralığından itibaren başlatılabileceği gibi, var olan yapıların durumu da veri

eklendikçe sürekli olarak kontrol edilebilmektedir. Ancak yersel ölçme verileri mevcut olmadığından, yüzey hareketleri uydu bazlı tekniklerle belirlenmiş olup elde edilen deformasyon sonuçları rölatif deformasyonları ifade etmektedir. Bu sebeple belirlenen periyotta elde edilen rölatif deformasyon sonuçlarının olası sebepleri belirlenmiş ve zaman serisi analizleri ile değerlendirilmiştir. Çalışmada yaklaşık 5 km kritik baz uzunluğuna ve orta mekânsal çözünürlüğe (C bant) sahip Kasım 2018-Eylül 2022 zaman aralığında temin edilen Sentinel-1 SAR uydu görüntüleri ile analizler gerçekleştirilmiş olup tutarlılık değeri 0,60'ın üzerinde olan ve standart sapması 0,13-1,18 mm/yıl aralığında değişen PS noktaları ile elde edilen sonuçlar sunulmuştur.

- TS-InSAR analizleri ve elde edilen sonuçların yine uzaktan algılama verileriyle değerlendirilmesi ile İstanbul Havalimanı gibi büyük ulaşım altyapılarında yapı sağlığının izlenmesinin sadece noktasal olarak değil alansal bazda gerçekleştirilebilmesinin yanı sıra yapı bütünlüğünün kontrolü de rölatif olarak sağlanabilmektedir.



KAYNAKLAR

- Abdessaemed, M., Kenai, S., & Bali, A.** (2015). Experimental and numerical analysis of the behavior of an airport pavement reinforced by geogrids. *Construction and Building Materials*, 94, 547-554. <https://doi.org/10.1016/j.conbuildmat.2015.07.037>
- Abidin, H. Z., Andreas, H., Gamal, M., Djaja, R., Subarya, C., Hirose, K., ... & Rajiyowiryo, H.** (2005). Monitoring land subsidence of Jakarta (Indonesia) using leveling, GPS survey and InSAR techniques. *In A Window on the Future of Geodesy* (pp. 561-566). Berlin, Heidelberg: Springer. https://doi.org/10.1007/3-540-27432-4_95
- Abidin, H. Z., Andreas, H., Gumilar, I., Yuwono, B. D., Murdohardono, D., & Supriyadi, S.** (2015). On integration of geodetic observation results for assessment of land subsidence hazard risk in urban areas of Indonesia. *In IAG 150 Years* (pp. 435-442). Springer, Cham. https://doi.org/10.1007/1345_2015_82
- Almeida, L. P., Almar, R., Bergsma, E. W., Berthier, E., Baptista, P., Garel, E., Alves, B.** (2019). Deriving high spatial-resolution coastal topography from sub-meter satellite stereo imagery. *Remote Sensing*, 11(5), 590. <https://doi.org/10.3390/rs11050590>
- Aobpaet, A., Cuenca, M. C., Hooper, A., & Trisirisatayawong, I.** (2013). InSAR time-series analysis of land subsidence in Bangkok, Thailand. *International Journal of Remote Sensing*, 34(8), 2969-2982. <https://doi.org/10.1080/01431161.2012.756596>
- Bao, X., Zhang, R., Shama, A., Li, S., Xie, L., Lv, J., Liu, G.** (2022). Ground Deformation Pattern Analysis and Evolution Prediction of Shanghai Pudong International Airport based on PSI Long Time Series Observations. *Remote Sensing*, 14(3), 610. <https://doi.org/10.3390/rs14030610>
- Bayik, C., & Abdikan, S.** (2021). Monitoring of small-scale deformation at sea-filled Ordu-Giresun Airport, Turkey from multi-temporal SAR data. *Engineering Failure Analysis*, 130, 105738. <https://doi.org/10.1016/j.engfailanal.2021.105738>
- Belgiu, M. & Drăguț, L.** (2016). Random forest in remote sensing: A review of applications and future directions. *ISPRS Journal of Photogrammetry and Remote Sensing*, 114, 24-31. <https://doi.org/10.1016/j.isprsjprs.2016.01.011>

- 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(11), 2375-2383. <https://doi.org/10.1109/TGRS.2002.803792>
- Bianchini Ciampoli, L., Gagliardi, V., Ferrante, C., Calvi, A., D'Amico, F., & Tosti, F.** (2020). Displacement monitoring in airport runways by persistent scatterers SAR interferometry. *Remote Sensing*, 12(21), 3564. <https://doi.org/10.3390/rs12213564>
- Bingjun, W., Dong-hai, L., Yuan-ze, S., & You, W.** (2016). Pavement roughness calculation of entire road surface based on automatic road elevation measuring. *China Journal of Highway and Transport*, 29(11), 10-17.
- Breiman, L.** (1996). Bagging predictors. *Machine Learning*, 24, 123–140. <https://doi.org/10.1007/BF00058655>
- Breiman, L.** (1999). *Random forests—random features*. Technical Report 567, Statistics
- Breiman, L.** (2001). ST4_Method_Random_Forest, *Machine Learning*, 45(1), 5–32. Department, University of California, Berkeley, <ftp://ftp.stat.berkeley.edu/pub/users/breiman>.
- Castellazzi, P., Arroyo-Domínguez, N., Martel, R., Calderhead, A. I., Normand, J. C., Gárfias, J., & Rivera, A.** (2016). Land subsidence in major cities of Central Mexico: Interpreting InSAR-derived land subsidence mapping with hydrogeological data. *International Journal of Applied Earth Observation and Geoinformation*, 47, 102-111. <https://doi.org/10.1016/j.jag.2015.12.002>
- Casu, F., Manzo, M., & Lanari, R.** (2006). A quantitative assessment of the SBAS algorithm performance for surface deformation retrieval from DInSAR data. *Remote Sensing of Environment*, 102(3-4), 195-210. <https://doi.org/10.1016/j.rse.2006.01.023>
- Cavalié, O., Sladen, A., & Kelner, M.** (2015). Detailed quantification of delta subsidence, compaction and interaction with man-made structures: the case of the NCA airport, France. *Natural Hazards and Earth System Sciences*, 15(9), 1973-1984. <https://doi.org/10.5194/nhess-15-1973-2015>
- Chen, H., Wang, Y., Zhang, Y., & Yan, Y.** (2018). Surface Deformation of Kangding Airport, Qinghai-Tibet Plateau, China Using Insar Techniques and Multi-Temporal Sentinel-1 Datasets. In *IGARSS 2018 IEEE International Geoscience and Remote Sensing Symposium*. Valencia, Spain: July 22-27. <https://doi.org/10.1109/IGARSS.2018.8518320>
- Chen, H., Yang, T., Wang, Y., & Yan, Y.** (2018). Assessing Deformation of and Impact of Earthquakes on Jiuzhai-Huanglong Airport, China with InSAR Techniques. In *EUSAR 2018; 12th European Conference on Synthetic Aperture Radar*, Eurogress Aachen, Germany: June 04-07.

- Chen, T., Guestrin, C.** (2016). Xgboost: A scalable tree boosting system. *In Proceedings of the 22nd ACM SIGKDD International Conference On Knowledge Discovery And Data Mining*, San Francisco California: August 13 – 17. <https://doi.org/10.1145/2939672.2939785>
- Chen, Y., He, Y., Zhang, L., Chen, Y., Pu, H., Chen, B., & Gao, L.** (2021). Prediction of InSAR deformation time-series using a long short-term memory neural network. *International Journal of Remote Sensing*, 42(18), 6919-6942. <https://doi.org/10.1080/01431161.2021.1947540>
- Cochran, W. T., Cooley, J. W., Favin, D. L., Helms, H. D., Kaenel, R. A., Lang, W. W., Welch, P. D.** (1967). What is the fast Fourier transform?. *Proceedings of the IEEE*, 55(10), 1664-1674. <https://doi.org/10.1109/PROC.1967.5957>
- Colesanti, C., Ferretti, A., Prati, C., & Rocca, F.** (2003). Monitoring landslides and tectonic motions with the Permanent Scatterers Technique. *Engineering Geology*, 68(1-2), 3-14. [https://doi.org/10.1016/S0013-7952\(02\)00195-3](https://doi.org/10.1016/S0013-7952(02)00195-3)
- Comerci, V., Vittori, E., Cipolloni, C., Di Manna, P., Guerrieri, L., Nisio, S., Bertolotti, E.** (2015). Geohazards monitoring in Roma from InSAR and in situ data: Outcomes of the PanGeo project. *Pure and Applied Geophysics*, 172, 2997-3028. <https://doi.org/10.1007/s00024-015-1066-1>
- 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. <https://doi.org/10.1016/j.isprsjprs.2015.10.011>
- Dai, K., Shi, X., Gou, J., Hu, L., Chen, M., Zhao, L., Li, Z.** (2020). Diagnosing subsidence geohazard at Beijing Capital International Airport, from high-resolution SAR interferometry. *Sustainability*, 12(6), 2269. <https://doi.org/10.3390/su12062269>
- Dewanto, B. G., Haryanto, Y., & Purnomo, S. N.** (2021). Land Subsidence Potential Detection in Yogyakarta International Airport using Sentinel-1 Insar Data. *Civil Engineering Dimension*, 23(2), 91-99. <https://doi.org/10.9744/ced.23.2.91-99>
- Dietterich, T. G.** (2000). An experimental comparison of three methods for constructing ensembles of decision trees: Bagging, boosting, and randomization. *Machine Learning*, 40, 139–157. <https://doi.org/10.1023/A:1007607513941>
- Dittman, D. J., Khoshgoftaar, T. M., & Napolitano, A.** (2015). The effect of data sampling when using random forest on imbalanced bioinformatics data. *In 2015 IEEE international conference on information reuse and integration*. San Francisco, CA, USA: August 13-15. <https://doi.org/10.1109/IRI.2015.76>
- Doler, D., & Kovačič, B.** (2019). Improved decision-making geo-information system for continuous monitoring of deformations on airport infrastructure. *ISPRS International Journal of Geo-Information*, 8(1), 1. <https://doi.org/10.3390/ijgi8010001>

- Dolloff, J. T., & Theiss, H. J.** (2014). The specification and validation of predicted accuracy capabilities for commercial satellite imagery. In *ASPRS 2014 Annual Conference*. Kentucky, USA: March 23-28.
- Dong, J., Guo, S., Wang, N., Zhang, L., Ge, D., Liao, M., & Gong, J.** (2023). Tri-decadal evolution of land subsidence in the Beijing Plain revealed by multi-epoch satellite InSAR observations. *Remote Sensing of Environment*, 286, 113446. <https://doi.org/10.1016/j.rse.2022.113446>
- Dong, S., Samsonov, S., Yin, H., Ye, S., & Cao, Y.** (2014). Time-series analysis of subsidence associated with rapid urbanization in Shanghai, China measured with SBAS InSAR method. *Environmental Earth Sciences*, 72, 677-691. <https://doi.org/10.1007/s12665-013-2990-y>
- Donos, C., Dümpelmann, M., & Schulze-Bonhage, A.** (2015). Early seizure detection algorithm based on intracranial EEG and random forest classification. *International Journal of Neural Systems*, 25(05), 1550023. <https://doi.org/10.1142/S0129065715500239>
- Dorogush, A. V., Ershov, V., Gulin, A.** (2018). CatBoost: gradient boosting with categorical features support. arXiv preprint arXiv:1810.11363. <https://doi.org/10.48550/arXiv.1810.11363>
- 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(5), 2202-2212. <https://doi.org/10.1109/36.868878>
- Foody, G. M.** (2002). Status of land cover classification accuracy assessment. *Remote Sensing of Environment*, 80(1), 185-201. [https://doi.org/10.1016/S0034-4257\(01\)00295-4](https://doi.org/10.1016/S0034-4257(01)00295-4)
- 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(B7), 9183-9191. <https://doi.org/10.1029/JB094iB07p09183>
- Gagliardi, V., Bianchini Ciampoli, L., Trevisani, S., D'Amico, F., Alani, A. M., Benedetto, A., & Tosti, F.** (2021). Testing Sentinel-1 SAR interferometry data for airport runway monitoring: a geostatistical analysis. *Sensors*, 21(17), 5769. <https://doi.org/10.3390/s21175769>
- Gao, M., Gong, H., Chen, B., Zhou, C., Chen, W., Liang, Y., Si, Y.** (2016). InSAR time-series investigation of long-term ground displacement at Beijing Capital International Airport, China. *Tectonophysics*, 691, 271-281. <https://doi.org/10.1016/j.tecto.2016.10.016>
- Gao, M., Gong, H., Li, X., Chen, B., Zhou, C., Shi, M., ... & Duan, G.** (2019). Land subsidence and ground fissures in Beijing capital international airport (bcia): Evidence from quasi-ps insar analysis. *Remote Sensing*, 11(12), 1466. <https://doi.org/10.3390/rs11121466>
- Gazioglu, C., Yücel, Z. Y., Burak, S., Okus, E., Alpar, B.** (1997). Coastline changes and inadequate management between Kilyos and Karaburun shoreline. *Journal of Black Sea/Mediterranean Environment*, 3(2).

- Gorelick, N., Hancher, M., Dixon, M., Ilyushchenko, S., Thau, D., & Moore, R.** (2017). Google Earth Engine: Planetary-scale geospatial analysis for everyone. *Remote Sensing of Environment*, 202, 18-27. <https://doi.org/10.1016/j.rse.2017.06.031>
- Graw, J. H., Wood, W. T., Phrampus, B. J.** (2021). Predicting global marine sediment density using the random forest regressor machine learning algorithm. *Journal of Geophysical Research: Solid Earth*, 126(1), e2020JB020135. <https://doi.org/10.1029/2020JB020135>
- Haghighi, M. H., & Motagh, M.** (2019). Ground surface response to continuous compaction of aquifer system in Tehran, Iran: Results from a long-term multi-sensor InSAR analysis. *Remote Sensing of Environment*, 221, 534-550. <https://doi.org/10.1016/j.rse.2018.11.003>
- Haikun, C., Lihua, Z., Qin, Z., Wei, Q., Jianliang, N.** (2018). Ascending and Descending Orbits InSAR-GPS Data Fusion Method with Additional Systematic Parameters for Three-Dimensional Deformation Field, *Geomatics and Information Science of Wuhan University*, 43(09), 1362–1368. <https://doi.org/10.13203/j.whugis20160461>
- Hill, P., Biggs, J., Ponce-López, V., & Bull, D.** (2021). Time-Series Prediction Approaches to Forecasting Deformation in Sentinel-1 InSAR Data. *Journal of Geophysical Research: Solid Earth*, 126(3), e2020JB020176. <https://doi.org/10.1029/2020JB020176>
- Hochreiter, S., Schmidhuber, J.** (1997). Long short-term memory. *Neural Computation*, 9(8), 1735-1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- Hu, F., Wu, J., Chang, L., & Hanssen, R. F.** (2019). Incorporating temporary coherent scatterers in multi-temporal InSAR using adaptive temporal subsets. *IEEE Transactions on Geoscience and Remote Sensing*, 57(10), 7658-7670. <https://doi.org/10.1109/TGRS.2019.2915658>
- Hu, J., Li, Z. W., Ding, X. L., Zhu, J. J., Zhang, L., & Sun, Q.** (2014). Resolving three-dimensional surface displacements from InSAR measurements: A review. *Earth-Science Reviews*, 133, 1-17. <https://doi.org/10.1016/j.earscirev.2014.02.005>
- Hu, L., Dai, K., Xing, C., Li, Z., Tomás, R., Clark, B., Lu, Y.** (2019). Land subsidence in Beijing and its relationship with geological faults revealed by Sentinel-1 InSAR observations. *International Journal of Applied Earth Observation and Geoinformation*, 82, 101886. <https://doi.org/10.1016/j.jag.2019.05.019>
- Jeoloji Mühendisleri Odası (JMO)** (2014). *Çevre Jeolojisi Açısından 3. Havaalanı*. https://www.jmo.org.tr/resimler/ekler/7c4e57139a05e51_ek.pdf
- Jiang, L., & Lin, H.** (2010). Integrated analysis of SAR interferometric and geological data for investigating long-term reclamation settlement of Chek Lap Kok Airport, Hong Kong. *Engineering Geology*, 110(3-4), 77-92. <https://doi.org/10.1016/j.enggeo.2009.11.005>

- Jiang, L., Lin, H., & Zhao, Q.** (2010). Spatial and temporal deformation characteristics of marine alluvial deposits due to land reclamation: implications from InSAR observation and geotechnical estimate. *Earth Surface Processes and Landforms: The Journal of the British Geomorphological Research Group*, 35(3), 331-343. <https://doi.org/10.1002/esp.1922>
- Jiang, Y., Liao, M., Wang, H., Zhang, L., & Balz, T.** (2016). Deformation monitoring and analysis of the geological environment of Pudong international airport with persistent scatterer SAR interferometry. *Remote Sensing*, 8(12), 1021. <https://doi.org/10.3390/rs8121021>
- Kantarci, M.D.** (1980). *Belgrad Ormanı Toprak Tipleri ve Orman Yetiştirme Ortamı Birimlerinin Haritalanması Üzerine Araştırmalar (Almanca özeti ile)*. İstanbul: Matbaa Teknisyenleri Basımevi,
- Kaya, S., Sertel, E., Seker, D. Z., Tanik, A.** (2008). Multi-temporal analysis and mapping of coastal erosion caused by open-mining areas. *Environmental Forensics*, 9(2-3), 271-276. <https://doi.org/10.1080/15275920802123963>
- Kim, J. W., Lu, Z., Jia, Y., & Shum, C. K.** (2015). Ground subsidence in Tucson, Arizona, monitored by time-series analysis using multi-sensor InSAR datasets from 1993 to 2011. *ISPRS Journal of Photogrammetry and Remote Sensing*, 107, 126-141. <https://doi.org/10.1016/j.isprsjprs.2015.03.013>
- Köse, M. ve Kul, A.** (2020). Terkedilmiş maden sahalarındaki sulak alanlar ve yakın çevrelerinden sürdürülebilir faydalanmanın incelenmesi: İstanbul örneği. *Türkiye Ormanlık Dergisi*, 21(3), 243-253. <https://doi.org/10.18182/tjf.710561>
- Krupnik, A.** (2000). Accuracy assessment of automatically derived digital elevation models from SPOT images. *Photogrammetric Engineering and Remote Sensing*, 66(8), 1017-1023.
- Kuanr, M., Mohapatra, P., & Yesubabu, M.** (2022, March). Feature Selection Based Approach for Handling Cold Start Problem in Collaborative Recommender Systems. In *2022 First International Conference on Artificial Intelligence Trends and Pattern Recognition (ICAITPR)*. Hyderabad, India: March 10-12. <https://doi.org/10.1109/ICAITPR51569.2022.9844218>
- LeBlanc, A. M., Short, N., Oldenborger, G. A., Mathon-Dufour, V., & Allard, M.** (2012). Geophysical investigation and InSAR mapping of permafrost and ground movement at the Iqaluit airport. In *Cold Regions Engineering 2012: Sustainable Infrastructure Development in a Changing Cold Environment*. Quebec City, Canada: August 19-22. <https://doi.org/10.1061/9780784412473.064>
- Lee, H. Y., Kim, T., Park, W., & Lee, H. K.** (2003). Extraction of digital elevation models from satellite stereo images through stereo matching based on epipolarity and scene geometry. *Image and Vision Computing*, 21(9), 789-796. [https://doi.org/10.1016/S0262-8856\(03\)00092-1](https://doi.org/10.1016/S0262-8856(03)00092-1)

- Li, G., Zhao, C., Wang, B., Liu, X., & Chen, H.** (2022). Land Subsidence Monitoring and Dynamic Prediction of Reclaimed Islands with Multi-Temporal InSAR Techniques in Xiamen and Zhangzhou Cities, China. *Remote Sensing*, 14(12), 2930. <https://doi.org/10.3390/rs14122930>
- Li, H., Zhu, L., Gong, H., Sun, H., & Yu, J.** (2020). Land subsidence modelling using a long short-term memory algorithm based on time-series datasets. *Proceedings of the International Association of Hydrological Sciences*, 382, 505-510. <https://doi.org/10.5194/piahs-382-505-2020>
- Li, X., Ma, L., Chen, P., Xu, H., Xing, Q., Yan, J., ... Cheng, Y.** (2022). Probabilistic solar irradiance forecasting based on XGBoost. *Energy Reports*, 8, 1087-1095. <https://doi.org/10.1016/j.egyr.2022.02.251>
- Liu, G., Ding, X., Chen, Y., Li, Z., & Li, Z.** (2001). Ground settlement of Chek Lap Kok Airport, Hong Kong, detected by satellite synthetic aperture radar interferometry. *Chinese Science Bulletin*, 46, 1778-1782. <https://doi.org/10.1007/BF02900548>
- Liu, G., Jia, H., Zhang, R., Zhang, H., Jia, H., Yu, B., & Sang, M.** (2010). Exploration of subsidence estimation by persistent scatterer InSAR on time series of high resolution TerraSAR-X images. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 4(1), 159-170. <https://doi.org/10.1109/JSTARS.2010.2067446>
- Liu, M., Frangopol, D. M., & Kim, S.** (2009). Bridge system performance assessment from structural health monitoring: A case study. *Journal of Structural Engineering*, 135(6), 733-742. [https://doi.org/10.1061/\(ASCE\)ST.1943-541X.0000014](https://doi.org/10.1061/(ASCE)ST.1943-541X.0000014)
- Liu, P., Chen, X., Li, Z., Zhang, Z., Xu, J., Feng, W., ... & Li, H.** (2018). Resolving surface displacements in Shenzhen of China from time series InSAR. *Remote Sensing*, 10(7), 1162. <https://doi.org/10.3390/rs10071162>
- Liu, P., Chen, X., Xu, J., Wang, C., & Hu, Z.** (2019). ALOS-2 Observations of Subsidence in Shenzhen. In *IGARSS 2019 IEEE International Geoscience and Remote Sensing Symposium*. Yokohama, Japan: July 28 - August 2. <https://doi.org/10.1109/IGARSS.2019.8900487>
- Liu, W., Pan, J., Ren, Y., Wu, Z., & Wang, J.** (2020). Coupling prediction model for long-term displacements of arch dams based on long short-term memory network. *Structural Control and Health Monitoring*, 27(7), e2548. <https://doi.org/10.1002/stc.2548>
- Liu, X., Zhao, C., Zhang, Q., Yang, C., & Zhang, J.** (2019). Characterizing and Monitoring Ground Settlement of Marine Reclamation Land of Xiamen New Airport, China with Sentinel-1 SAR Datasets. *Remote Sensing*, 11(5), 585. <https://doi.org/10.3390/rs11050585>
- Lundberg, S. M., & Lee, S. I.** (2017). A unified approach to interpreting model predictions. *Advances in neural information processing systems*, 30.
- Lyons, M. B., Keith, D. A., Phinn, S. R., Mason, T. J., & Elith, J.** (2018). A comparison of resampling methods for remote sensing classification and accuracy assessment. *Remote Sensing of Environment*, 208, 145-153. <https://doi.org/10.1016/j.rse.2018.02.026>

- Ma, D., Motagh, M., Liu, G., Zhang, R., Wang, X., Zhang, B., ... & Yu, B.** (2022). Thaw Settlement Monitoring and Active Layer Thickness Retrieval Using Time Series COSMO-SkyMed Imagery in Iqaluit Airport. *Remote Sensing*, 14(9), 2156. <https://doi.org/10.3390/rs14092156>
- Ma, G., Zhao, Q., Wang, Q., & Liu, M.** (2018). On the effects of InSAR temporal decorrelation and its implications for land cover classification: The case of the ocean-reclaimed lands of the Shanghai megacity. *Sensors*, 18(9), 2939. <https://doi.org/10.3390/s18092939>
- Ma, P., Wang, W., Zhang, B., Wang, J., Shi, G., Huang, G., ... & Lin, H.** (2019). Remotely sensing large-and small-scale ground subsidence: A case study of the Guangdong–Hong Kong–Macao Greater Bay Area of China. *Remote Sensing of Environment*, 232, 111282. <https://doi.org/10.1016/j.rse.2019.111282>
- Ma, P., Zhang, F., & Lin, H.** (2020). Prediction of InSAR time-series deformation using deep convolutional neural networks. *Remote Sensing Letters*, 11(2), 137-145. <https://doi.org/10.1080/2150704X.2019.1692390>
- Mahdianpari, M., Salehi, B., Mohammadimanesh, F., Brisco, B., Homayouni, S., Gill, E., Bourgeau-Chavez, L.** (2020). Big data for a big country: the first generation of Canadian wetland inventory map at a spatial resolution of 10-m using Sentinel-1 and Sentinel-2 data on the Google Earth Engine cloud computing platform. *Canadian Journal of Remote Sensing*, 46(1), 15-33. <https://doi.org/10.1080/07038992.2019.1711366>
- Malik, K., Kumar, D., Perissin, D., & Pradhan, B.** (2022). Estimation of ground subsidence of New Delhi, India using PS-InSAR technique and Multi-sensor Radar data. *Advances in Space Research*, 69(4), 1863-1882. <https://doi.org/10.1016/j.asr.2021.08.032>
- Marshall, C., Large, D. J., Athab, A., Evers, S. L., Sowter, A., Marsh, S., & Sjögersten, S.** (2018). Monitoring tropical peat related settlement using isbas insar, kuala lumpur international airport (klia). *Engineering Geology*, 244, 57-65. <https://doi.org/10.1016/j.enggeo.2018.07.015>
- Martín Antón, M., Negro, V., del Campo, J. M., López-Gutiérrez, J. S., Esteban, M. D.** (2016). Review of coastal land reclamation situation in the world. *Journal of Coastal Research*, 75(10075), 667-671. <https://doi.org/10.2112/SI75-133.1>
- Melis, M. T., Pisani, L., & De Waele, J.** (2021). On the Use of Tri-Stereo Pleiades Images for the Morphometric Measurement of Dolines in the Basaltic Plateau of Azrou (Middle Atlas, Morocco). *Remote Sensing*, 13(20), 4087. <https://doi.org/10.3390/rs13204087>
- MIT Technology Review** (2013). 10 Breakthrough Technologies 2013. Retrieved January 7, 2023 from <https://www.technologyreview.com/lists/technologies/2013/>

- Mirzadeh, S. M. J., Jin, S., Parizi, E., Chaussard, E., Bürgmann, R., Delgado Blasco, J. M., Mirzadeh, S. H.** (2021). Characterization of Irreversible Land Subsidence in the Yazd-Ardakan Plain, Iran From 2003 to 2020 InSAR Time Series. *Journal of Geophysical Research: Solid Earth*, 126(11), e2021JB022258. <https://doi.org/10.1029/2021JB022258>
- Mohammadimanesh, F., Salehi, B., Mahdianpari, M., English, J., Chamberland, J., & Alasset, P. J.** (2019). Monitoring surface changes in discontinuous permafrost terrain using small baseline SAR interferometry, object-based classification, and geological features: a case study from Mayo, Yukon Territory, Canada. *GIScience & Remote Sensing*, 56(4), 485-510. <https://doi.org/10.1080/15481603.2018.1513444>
- Mora, O., Mallorqui, J. J., & Broquetas, A.** (2003). Linear and nonlinear terrain deformation maps from a reduced set of interferometric SAR images. *IEEE Transactions on Geoscience and Remote Sensing*, 41(10), 2243-2253. <https://doi.org/10.1109/TGRS.2003.814657>
- Nurtyawan, R., Fiscarina, N.** (2021). Assessment of the Accuracy of Dem from Panchromatic Pleiades Imagery (Case Study: Bandung City. West Java). *International Journal of Remote Sensing and Earth Sciences (IJReSES)*, 17(1), 34-44.
- Pai, P. F., Lin, K. P., Lin, C. S., & Chang, P. T.** (2010). Time series forecasting by a seasonal support vector regression model. *Expert Systems with Applications*, 37(6), 4261-4265. <https://doi.org/10.1016/j.eswa.2009.11.076>
- Parbat, D., Chakraborty, M.** (2020). A python based support vector regression model for prediction of COVID19 cases in India. *Chaos, Solitons & Fractals*, 138, 109942. <https://doi.org/10.1016/j.chaos.2020.109942>
- Pepe, A., Bonano, M., Zhao, Q., Yang, T., & Wang, H.** (2016). The use of C-/X-band time-gapped SAR data and geotechnical models for the study of Shanghai's ocean-reclaimed lands through the SBAS-DInSAR technique. *Remote Sensing*, 8(11), 911. <https://doi.org/10.3390/rs8110911>
- Pooja, B., Oommen, T., Sajinkumar, K. S., Nair, A. G., Rajaneesh, A., Aswathi, J., Thrivikramji, K. P.** (2021). Correspondence of PSInSAR monitoring and Settle3 modelling at Cochin International Airport, SW India. *Applied Geomatics*, 13, 735-746. <https://doi.org/10.1007/s12518-021-00387-y>
- Qin, X., Ding, X., Liao, M., Zhang, L., & Wang, C.** (2019). A bridge-tailored multi-temporal DInSAR approach for remote exploration of deformation characteristics and mechanisms of complexly structured bridges. *ISPRS Journal of Photogrammetry and Remote Sensing*, 156, 27-50. <https://doi.org/10.1016/j.isprsjprs.2019.08.003>

- Radman, A., Akhoondzadeh, M., & Hosseiny, B.** (2021). Integrating InSAR and deep-learning for modeling and predicting subsidence over the adjacent area of Lake Urmia, Iran. *GIScience & Remote Sensing*, 58(8), 1413-1433. <https://doi.org/10.1080/15481603.2021.1991689>
- Raspini, F., Loupasakis, C., Rozos, D., & Moretti, S.** (2013). Advanced interpretation of land subsidence by validating multi-interferometric SAR data: the case study of the Anthemountas basin (Northern Greece). *Natural Hazards and Earth System Sciences*, 13(10), 2425-2440. <https://doi.org/10.5194/nhess-13-2425-2013>
- Ruiz-Armenteros, A. M., Lazecky, M., Ruiz-Constán, A., Bakoň, M., Delgado, J. M., Sousa, J. J., Perissin, D.** (2018). Monitoring continuous subsidence in the Costa del Sol (Málaga province, southern Spanish coast) using ERS-1/2, Envisat, and Sentinel-1A/B SAR interferometry. *Procedia Computer Science*, 138, 354-361. <https://doi.org/10.1016/j.procs.2018.10.050>
- Sato, H. P., & Une, H.** (2016). Detection of the 2015 Gorkha earthquake-induced landslide surface deformation in Kathmandu using InSAR images from PALSAR-2 data. *Earth, Planets and Space*, 68, 1-13. <https://doi.org/10.1186/s40623-016-0425-1>
- Scuro, C., Sciammarella, P. F., Lamonaca, F., Olivito, R. S., & Carni, D. L.** (2018). IoT for structural health monitoring. *IEEE Instrumentation & Measurement Magazine*, 21(6), 4-14. <https://doi.org/10.1109/MIM.2018.8573586>
- Sengupta, D., Chen, R., Meadows & M. E.** (2018). Building beyond land: An overview of coastal land reclamation in 16 global megacities. *Applied Geography*, 90, 229-238. <https://doi.org/10.1016/j.apgeog.2017.12.015>
- Sengur, F. K.** (2020). Public-private partnerships in airports: the Turkish experience. *World Review of Intermodal Transportation Research*, 9(3), 217-244. <https://doi.org/10.1504/WRITR.2020.108211>
- Shanker, P., Casu, F., Zebker, H. A., & Lanari, R.** (2011). Comparison of persistent scatterers and small baseline time-series InSAR results: A case study of the San Francisco bay area. *IEEE Geoscience and Remote Sensing Letters*, 8(4), 592-596. <https://doi.org/10.1109/LGRS.2010.2095829>
- Sharma, J., Eppler, J., & Busler, J.** (2015). Urban infrastructure monitoring with a spatially adaptive multi-looking InSAR technique. *In Fringe*. Frascati, Italy: March 23-27.
- Sheykhmousa, M., Mahdianpari, M., Ghanbari, H., Mohammadimanesh, F., Ghamisi, P., & Homayouni, S.** (2020). Support vector machine vs. random forest for remote sensing image classification: A meta-analysis and systematic review. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 13, 6308-6325. <https://doi.org/10.1109/JSTARS.2020.3026724>
- SHGM (Sivil Havacılık Genel Müdürlüğü) Havaalanları Daire Başkanlığı.** (2016). *Havaalanı Pistleri* (Yayın No: HAD/T-28). Ankara: Sivil Havacılık Genel Müdürlüğü.

- Shi, X., Chen, C., Dai, K., Deng, J., Wen, N., Yin, Y., & Dong, X.** (2022). Monitoring and Predicting the Subsidence of Dalian Jinzhou Bay International Airport, China by Integrating InSAR Observation and Terzaghi Consolidation Theory. *Remote Sensing*, 14(10), 2332. <https://doi.org/10.3390/rs14102332>
- Short, N., LeBlanc, A. M., Sladen, W., & Brisco, B.** (2013). RADARSAT-2 InSAR for monitoring permafrost environments: Pangnirtung and Iqaluit. In *2013 IEEE Radar Conference (RadarCon13)*. Ottawa, Ontario, Canada: April 29 - May 3. <https://doi.org/10.1109/RADAR.2013.6586149>
- Short, N., LeBlanc, A. M., Sladen, W., Oldenborger, G., Mathon-Dufour, V., & Brisco, B.** (2014). RADARSAT-2 D-InSAR for ground displacement in permafrost terrain, validation from Iqaluit Airport, Baffin Island, Canada. *Remote Sensing of Environment*, 141, 40-51. <https://doi.org/10.1016/j.rse.2013.10.016>
- Sun, Q., Jiang, L., Jiang, M., Lin, H., Ma, P., & Wang, H.** (2018). Monitoring coastal reclamation subsidence in Hong Kong with distributed scatterer interferometry. *Remote Sensing*, 10(11), 1738. <https://doi.org/10.3390/rs10111738>
- Sun, Q., Jiang, L., Sun, Y., Bai, L., & Wang, H.** (2016). Monitoring ground deformation in Hong Kong international airport with NL-InSAR filtering. In *2016 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*. Beijing, China: July 10-15. <https://doi.org/10.1109/IGARSS.2016.7730562>
- Susaki, J., Kusakabe, T., & Anahara, T.** (2020). Estimating 3d Land Subsidence from Multi-Temporal SAR Images and Gns Data Using Weighted Least Squares. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 3, 165-172. <https://doi.org/10.5194/isprs-annals-V-3-2020-165-2020>
- Svigkas, N., Loupasakis, C., Papoutsis, I., Kontoes, C., Alatza, S., Tzampoglou, P., Spachos, T.** (2020). InSAR campaign reveals ongoing displacement trends at high impact sites of Thessaloniki and Chalkidiki, Greece. *Remote Sensing*, 12(15), 2396. <https://doi.org/10.3390/rs12152396>
- Svigkas, N., Loupasakis, C., Tsangaratos, P., Papoutsis, I., Kiratzi, A., & Kontoes, C.** (2020). A deformation study of Anthemountas graben (northern Greece) based on in situ data and new InSAR results. *Arabian Journal of Geosciences*, 13(13), 518. <https://doi.org/10.1007/s12517-020-05393-9>
- T.C. Ulaştırma Denizcilik ve Haberleşme Bakanlığı (UDHB)** (2013). *İstanbul Bölgesi 3. Havalimanı Nihai ÇED Raporu*. Ankara: T.C. Ulaştırma Denizcilik ve Haberleşme Bakanlığı (UDHB) Altyapı Yatırımları Genel Müdürlüğü
- Tolunay, D.** (2015). İstanbul'daki Üçüncü Havalimanı ÇED Raporunun Değerlendirilmesi. 6. *Ulusal Hava Kirliliği ve Kontrolü Sempozyumu*. İzmir, Türkiye: 7-9 Ekim.

- URL-1**<<https://github.com/yumorishita/LiCSBAS>>, erişim tarihi 29.01.2023.
- URL-2**<<https://site.tre-altamira.com/insar/>>, erişim tarihi 29.01.2023.
- URL-3**<<https://earthengine.google.com/>>, erişim tarihi 29.01.2023.
- URL-4**<https://catalyst.earth/catalyst-system-files/help/COMMON/concepts/DEM_buildfromstereo.html>, erişim tarihi 29.01.2023.
- URL-5**<<https://www.cienciadedatos.net/documentos/py27-time-series-forecasting-python-scikitlearn.html>>, erişim tarihi 29.01.2023.
- URL-6**<https://joaquinamatrodriago.github.io/skforecast/0.6.0/user_guides/backtesting.html>, erişim tarihi 29.01.2023.
- URL-7**<<http://iga.phtools.net/insaat-asamalar.html>>, erişim tarihi 29.01.2023.
- URL-8**<<https://www.usgs.gov/landsat-missions/landsat-satellite-missions>>, erişim tarihi 29.01.2023.
- URL-9**<<https://sentinels.copernicus.eu/web/sentinel/missions/sentinel-1>>, erişim tarihi 29.01.2023.
- URL-10**<<https://cds.climate.copernicus.eu/cdsapp#!/dataset/reanalysis-era5-land?tab=overview>>, erişim tarihi 29.01.2023.
- Wang, K. C., Li, Q. J., Yang, G., Zhan, Y., & Qiu, Y. (2015).** Network level pavement evaluation with 1 mm 3D survey system. *Journal of Traffic and Transportation Engineering (English edition)*, 2(6), 391-398. <https://doi.org/10.1016/j.jtte.2015.10.005>
- Wang, S., Ren, Z., Wu, C., Lei, Q., Gong, W., Ou, Q., ... & Li, C. (2019).** DEM generation from Worldview-2 stereo imagery and vertical accuracy assessment for its application in active tectonics. *Geomorphology*, 336, 107-118. <https://doi.org/10.1016/j.geomorph.2019.03.016>
- Wang, T., Zhang, R., Zhan, R., Shama, A., Liao, M., Bao, X., Zhan, J. (2022).** Subsidence Monitoring and Mechanism Analysis of Anju Airport in Suining Based on InSAR and Numerical Simulation. *Remote Sensing*, 14(15), 3759. <https://doi.org/10.3390/rs14153759>
- Wright, M. N. & Ziegler, A. (2017).** Ranger: A fast implementation of random forests for high dimensional data in C++ and R. *Journal of Statistical Software*. 77(1), 1–17. <https://doi.org/10.18637/jss.v077.i01>
- Wu, Q., Jia, C., Chen, S., & Li, H. (2019).** SBAS-InSAR based deformation detection of urban land, created from mega-scale mountain excavating and valley filling in the Loess Plateau: The case study of Yan'an City. *Remote Sensing*, 11(14), 1673. <https://doi.org/10.3390/rs11141673>
- Wu, S., Yang, Z., Ding, X., Zhang, B., Zhang, L. & Lu, Z. (2020).** Two decades of settlement of hong kong international airport measured with multi-temporal InSAR. *Remote Sensing of Environment*, 248, 111976. <https://doi.org/10.1016/j.rse.2020.111976>
- Xie, P., Zhou, A., & Chai, B. (2019).** The application of long short-term memory (LSTM) method on displacement prediction of multifactor-induced landslides. *IEEE Access*, 7, 54305-54311. <https://doi.org/10.1109/ACCESS.2019.2912419>

- Xing, X., Zhu, L., Liu, B., Peng, W., Zhang, R., & Ma, X. (2022).** Measuring land surface deformation over soft clay area based on an fipr sar interferometry algorithm—A case study of beijing capital international airport (China). *Remote Sensing*, 14(17), 4253. <https://doi.org/10.3390/rs14174253>
- Xing, Y., Yue, J., Chen, C., Cong, K., Zhu, S., & Bian, Y. (2019).** Dynamic displacement forecasting of dashuitian landslide in china using variational mode decomposition and stack long short-term memory network. *Applied Sciences*, 9(15), 2951. <https://doi.org/10.3390/app9152951>
- Xiong, Z., Deng, K., Feng, G., Miao, L., Li, K., He, C., & He, Y. (2022).** Settlement Prediction of Reclaimed Coastal Airports with InSAR Observation: A Case Study of the Xiamen Xiang'an International Airport, China. *Remote Sensing*, 14(13), 3081. <https://doi.org/10.3390/rs14133081>
- Xu, B., Feng, G., Li, Z., Wang, Q., Wang, C., & Xie, R. (2016).** Coastal subsidence monitoring associated with land reclamation using the point target based SBAS-InSAR method: A case study of Shenzhen, China. *Remote Sensing*, 8(8), 652. <https://doi.org/10.3390/rs8080652>
- Xu, S., & Niu, R. (2018).** Displacement prediction of Baijiabao landslide based on empirical mode decomposition and long short-term memory neural network in Three Gorges area, China. *Computers & Geosciences*, 111, 87-96. <https://doi.org/10.1016/j.cageo.2017.10.013>
- Xue, F., Lv, X., Dou, F., & Yun, Y. (2020).** A Review of Time-Series Interferometric SAR Techniques: A Tutorial for Surface Deformation Analysis. *IEEE Geoscience and Remote Sensing Magazine*, 8(1), 22-42. <https://doi.org/10.1109/MGRS.2019.2956165>
- Yagmur, N., Erten, E., Musaoglu, N., & Safak, E. (2022).** Assessing spatio-temporal dynamics of large airport's surface stability. *Geocarto International*, 37(26), 13734-13747. <https://doi.org/10.1080/10106049.2022.2082554>
- Yanbin, G., Song-bo, Z., & Yong-fa, G. (2017).** Deformation Rates and Stability Control of Soft Foundation. *China Journal of Highway and Transport*, 30(2), 11.
- Yang, B., Xu, H., Liu, W., Ge, J., Li, C., & Li, J. (2019).** An improved stanford method for persistent scatterers applied to 3D building reconstruction and monitoring. *Remote Sensing*, 11(15), 1807. <https://doi.org/10.3390/rs11151807>
- Yang, C., Qiuxiang, T., Guolin, L., LuYao, W., FengYun, W., Ke, W. (2021).** Detailed Mining Subsidence Monitoring Combined with InSAR and Probability Integral Method, *Chinese Journal of Geophysics*, 64(10), 3554-3566. <https://doi.org/10.6038/cjg2021O0421>
- Yang, M., Yang, T., Zhang, L., Lin, J., Qin, X., & Liao, M. (2018).** Spatio-temporal characterization of a reclamation settlement in the Shanghai coastal area with time series analyses of X-, C-, and L-band SAR datasets. *Remote Sensing*, 10(2), 329. <https://doi.org/10.3390/rs10020329>

- Yoon, J.** (2021). Forecasting of real GDP growth using machine learning models: Gradient boosting and random forest approach. *Computational Economics*, 57(1), 247-265. <https://doi.org/10.1007/s10614-020-10054-w>
- Yu, L., Yang, T., Zhao, Q., Pepe, A., Dong, H. & Sun, Z.** (2017). Residual settlements detection of ocean reclaimed lands with multi-platform SAR time series and SBAS technique: A case study of Shanghai Pudong International Airport. In *Proceedings of the Remote Sensing and Modeling of Ecosystems for Sustainability XIV*, San Diego, CA, USA: August 9. <https://doi.org/10.1117/12.2273107>
- Zhang, R., Zhang, W., Huang, W., Ma, T., Wang, Q., Fang, K., & Wang, K.** (2023). High-precision monitoring method for airport deformation based on time-series InSAR technology. *Construction and Building Materials*, 366, 130144. <https://doi.org/10.1016/j.conbuildmat.2022.130144>
- Zhang, S., Si, J., Niu, Y., Zhu, W., Fan, Q., Hu, X., Li, Z.** (2022). Surface Deformation of Expansive Soil at Ankang Airport, China, Revealed by InSAR Observations. *Remote Sensing*, 14(9), 2217. <https://doi.org/10.3390/rs14092217>
- Zhang, Z., Ding, X. L., Wu, S., & Kang, Q.** (2022). The Settlement of Hong Kong International Airport Based on the Interferometric Point Target Analysis. *The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, 43, 1267-1272.
- Zhao, Q., Lin, H., Gao, W., Zebker, H. A., Chen, A., & Yeung, K.** (2011). InSAR detection of residual settlement of an ocean reclamation engineering project: a case study of Hong Kong International Airport. *Journal of Oceanography*, 67, 415-426. <https://doi.org/10.1007/s10872-011-0034-3>
- Zhe, C., Boping, W., Xia, Z., Zhixing, P., Tao, H., Chang, L., ... & Ye, P.** (2020). Monitoring and Analysis of Surface Subsidence Based on Sentinel-1A: a Case Study in a Loess Plateau Airport. In *Proceedings of the 2020 International Conference on Aviation Safety and Information Technology*, Weihai City China: October 14 – 16. <https://doi.org/10.1145/3434581.3434592>
- Zheng, L., Zhu, L., Wang, W., Guo, L., & Chen, B.** (2020). Land subsidence related to coal mining in China revealed by L-band InSAR analysis. *International Journal of Environmental Research and Public Health*, 17(4), 1170. <https://doi.org/10.3390/ijerph17041170>
- Zhou, C. F., Liu, K. S., & Shi, M.** (2015). Mapping and characterization of land subsidence in Beijing Plain caused by groundwater pumping using the Small Baseline Subset (SBAS) InSAR technique. *Proceedings of the International Association of Hydrological Sciences*, 372(372), 347-349. <https://doi.org/10.5194/piahs-372-347-2015>

- Zhou, C., Lan, H., Gong, H., Zhang, Y., Warner, T. A., Clague, J. J., & Wu, Y.** (2020). Reduced rate of land subsidence since 2016 in Beijing, China: Evidence from Tomo-PSInSAR using RadarSAT-2 and Sentinel-1 datasets. *International Journal of Remote Sensing*, 41(4), 1259-1285. <https://doi.org/10.1080/01431161.2019.1662967>
- Zhou, Z., Yao, X., Ren, K., & Liu, H.** (2022). Formation mechanism of ground fissure at Beijing Capital International Airport revealed by high-resolution InSAR and numerical modelling. *Engineering Geology*, 306, 106775. <https://doi.org/10.1016/j.enggeo.2022.106775>
- Zhu, X. X., Tuia, D., Mou, L., Xia, G. S., Zhang, L., Xu, F., & Fraundorfer, F.** (2017). Deep learning in remote sensing: A comprehensive review and list of resources. *IEEE Geoscience and Remote Sensing Magazine*, 5(4), 8-36. <https://doi.org/10.1109/MGRS.2017.2762307>
- Zhuo, G., Dai, K., Huang, H., Li, S., Shi, X., Feng, Y., ... & Deng, J.** (2020). Evaluating potential ground subsidence geo-hazard of Xiamen Xiang'an new airport on reclaimed land by SAR interferometry. *Sustainability*, 12(17), 6991. <https://doi.org/10.3390/su12176991>
- Zhuo, G., Dai, K., Shi, X., Li, S., Ran, P., & Huang, H.** (2019). Monitoring Reclaimed Land Subsidence on Xiamen New Airport with Sentinel-1 Datasets. In *2019 6th Asia-Pacific Conference on Synthetic Aperture Radar (APSAR)*. Xiamen, China: November 26-29. <https://doi.org/10.1109/APSAR46974.2019.9048570>



ÖZGEÇMİŞ

Ad-Soyad : NUR YAĞMUR

ÖĞRENİM DURUMU:

- **Lisans** : 2016, İstanbul Teknik Üniversitesi, İnşaat Fakültesi, Geomatik Mühendisliği Bölümü
- **Lisans** : 2017, İstanbul Teknik Üniversitesi, İnşaat Fakültesi, İnşaat Mühendisliği Bölümü
- **Yüksek lisans** : 2018, İstanbul Teknik Üniversitesi, Geomatik Mühendisliği, Geomatik Mühendisliği Doktora Programı

MESLEKİ DENEYİM VE ÖDÜLLER:

- 2017-2021 yılları arasında İstanbul Teknik Üniversitesi Geomatik Mühendisliği Bölümü'nde Araştırma Görevlisi olarak çalıştı.
- 2021 yılından beri Gebze Teknik Üniversitesi Harita Mühendisliği Bölümü'nde Öğretim Görevlisi olarak çalışmaktadır.

DOKTORA TEZİNDEN TÜRETİLEN YAYINLAR, SUNUMLAR VE PATENTLER:

- **Yagmur, N., Erten, E., Musaoglu, N., Safak, E.** 2022. Assessing Spatio-Temporal Dynamics Of Large Airport's Surface Stability. *Geocarto International*, 37(26), 13734-13747.
- **Yağmur, N., Musaoğlu N.** 2022. Havalimanlarında Yapısal Değişimlerin PSInSAR Tekniği ile Belirlenmesi. *Harita Dergisi*, 168, 28-37.
- **Yagmur, N., Musaoglu, N.** 2022. The Prediction of Surface Movements Based on Long-Term InSAR Time Series Observations. *International Symposium on Applied Geoinformatics (ISAG) 2022*, October 12-14, 2022 Chania, Greece. (Özet)
- **Yağmur, N., Musaoğlu, N.** 2022. Uzaktan Algılama Yöntemleri ile Havalimanlarında Deformasyonların Belirlenmesi. *11. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu*, 12-14 Mayıs 2022 Mersin, Türkiye. (Özet)

DİĞER YAYINLAR, SUNUMLAR VE PATENTLER:

- **Sunar, A.F., Dervişoğlu, A., Yağmur, N.** 2023. Sentinel-2 Uydu Görüntüleri ile Klorofil-a Parametresi Tahmininde Güneş Parıltısının Etkisi. *Harita Dergisi*, 169, 1-12.

- **Avci, C., Budak, M., Yagmur, N., Balcik, F.B.** 2023. Comparison between random forest and support vector machine algorithms for LULC classification . *International Journal of Engineering and Geosciences*, 8(1), 1-10.
- **Albarqouni, M.M.Y., Yagmur, N., Bektas Balcik, F., Sekertekin, A.** 2022. Assessment of Spatio-Temporal Changes in Water Surface Extents and Lake Surface Temperatures Using Google Earth Engine for Lakes Region, Türkiye. *ISPRS International Journal of Geo-Information*, 11(7), 407.
- **Firatli, E., Dervisoglu, A., Yagmur, N., Musaoglu, N., Tanik, A.** 2022. Spatio-temporal assessment of natural lakes in Turkey. *Earth Science Informatics*, 15, 951–964.
- **Dervisoglu, A., Yagmur, N., Firatli, E., Musaoglu, N., Tanik, A.** 2022. Spatio-Temporal Assessment of the Shrinking Lake Burdur, Turkey. *International Journal of Environment and Geoinformatics*, 9(2), 169-176.
- **Karaca, M., Yağmur, N., Balçık, F.** 2022. İstanbul Terkos Gölü zamansal değişiminin Google Earth Engine kullanılarak belirlenmesi, *Geomatik*, 7(3), 235-242.
- **Yagmur N., Dervisoglu A., Bilgilioglu B.B.** 2022. Assessment of Rapid Urbanization Effects with Remote Sensing Techniques. In: Ben Ahmed M., Boudhir A.A., Karaş İ.R., Jain V., Mellouli S. (eds) *Innovations in Smart Cities Applications Volume 5*. SCA 2021. Lecture Notes in Networks and Systems, vol 393. Springer, Cham.
- **Yagmur, N., Dervisoglu, A., Sunar, F.** 2022. Evaluation of Atmospheric Correction Processors Applied to the Sentinel-2 Image in the Gulf of Izmit. *10th International Symposium on Atmospheric Sciences*, October 18-21, 2022 Istanbul, Turkey.
- **Sunar, F., Dervisoglu, A., Yagmur, N., Colak, E., Kuzyaka, E., Mutlu, S.** 2022. How Efficient Can Sentinel-2 Data Help Spatial Mapping Of Mucilage Event in the Marmara Sea?. *The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, 43, 181-186.
- **Dervisoglu, A., Yagmur, N., Bilgilioglu, B.B.** 2021. Satellite-derived shallow wetland bathymetry using different classification algorithms and datasets. *Desalination and Water Treatment*, 243, 231-241.
- **Yagmur, N., Bilgilioglu, B. B., Dervisoglu, A., Musaoglu, N., Tanik, A.** 2021. Long and Short-Term Assessment of Surface Area Changes in Saline and Freshwater Lakes Via Remote Sensing. *Water and Environment Journal*, 35(1), 107-122.
- **Yagmur, N., Balcik, F. B., Sekertekin, A.** 2021. COVID-19 Lockdown Effects on The Air Quality: A Case Study of Istanbul. *International Symposium on Applied Geoinformatics 2021*.
- **Yagmur, N., Erten, E., Musaoglu, N.** 2021. How to Start Gentrification Process Using Interferometric Stack of SENTINEL-1. *ISPRS-International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 43, 183-188.
- **Yagmur, N., Tanik, A., Tuzcu, A., Musaoglu, N., Erten, E., Bilgilioglu, B.** 2020. Opportunities Provided by Remote Sensing Data for Watershed Management: Example of Konya Closed Basin. *International Journal of Engineering and Geosciences*, 5(3), 120-129.
- **Dervisoglu, A., Bilgilioglu, B. B., Yagmur, N.** 2020. Comparison of Pixel-Based and Object-Based Classification Methods in Determination of Wetland Coastline, *International Journal of Environment and Geoinformatics*, 7(2), 213-220.

- **Musaoglu, N., Dervisoglu, A., Yagmur, N., Bilgilioglu, B., Tuzcu, A., Tanik, A.** 2020. Assessing Contribution of Climate Change on Wetlands by Using Multi-temporal Satellite Data. In *Climate Change, Hazards and Adaptation Options* (pp. 77-87). Springer, Cham.
- **Yagmur, N., Musaoglu, N.** 2020. Temporal Analysis of Ramsar Sites via Remote Sensing Techniques—A Case Study of Meke Maar. *IOP Conf. Series: Materials Science and Engineering*, 737, 012248.
- **Dervisoglu, A., Bilgilioglu, B.B., Yagmur, N., Musaoglu, N., Tanik, A.** 2019. Temporal Assessment of Natural Wetlands via Remotely Sensed Data: A Case Study from Turkey, *Feb-Fresenius Environmental Bulletin*, 1005.
- **Basaran, A., Haymana, S., Kuscü, N.B., Yagmur, N., Tuzcu, A., Musaoglu, N., Tanik, A.** 2019. Temporal Assessment of Water Surfaces via Satellite Images: A Case Study from Konya Closed Basin of Turkey. *4th Eurasian Conference on Civil and Environmental Engineering (ECOCEE)*, June 17-18, 2019 Istanbul, Turkey.
- **Senol, A., Alpyurur, M., Yagmur, N., Dervisoglu, A., Bilgilioglu, B.B., Musaoglu, N., Tanik, A.** 2019. Geotechnical Investigation of The Dike Built for Rehabilitation of Akgol Wetland- Turkey. *International Civil Engineering and Architecture Conference 2019*, 17-20 April 2019 Trabzon, Turkey.
- **Yagmur, N., Kaya, A., Keles, S., Musaoglu, N., Tanik, A.** 2019. Detecting Areal Surface Water Changes via Landsat and Sentinel Data. *International Symposium on Applied Geoinformatics (ISAG 2019)*, November 7-9, 2019 Istanbul, Turkey.
- **Sunar, A. F., Yagmur, N., Dervisoglu, A.** 2019. Flood Analysis with Remote Sensing Data—A Case Study: Maritsa River, Edirne. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*.
- **Yagmur, N., Musaoglu, N., Taskin, G.** 2019. Detection of Shallow Water Area With Machine Learning Algorithms. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*.
- **Yagmur, N., Bilgilioglu, B.B., Musaoglu, N., Erten, E., Tanik, A.** 2018. Temporal Changes of Lentic System Surfaces in Konya Closed Basin, Turkey. 3. *International Conference on Civil and Environmental Engineering (ICOCEE 2018)*, April 24-27, 2018, Izmir, Turkey.
- **Tanik, A., Musaoglu, N., Altas, L., Baran, D., Dervisoglu, A., Bilgilioglu, B.B., Yagmur, N., Celebi, H., Simsek, İ., Tulun, S., Ekercin, S.** 2018. Degradation of Ecological Functions of Akgol Wetland in Turkey: Effects and Causes. 3. *International Conference on Civil and Environmental Engineering (ICOCEE 2018)*, April 24-27, 2018, Izmir, Turkey.
- **Musaoglu, N., Tanik, A., Gumusay, M.U., Dervisoglu, A., Bilgilioglu, B.B., Yagmur, N., Bakirman, T., Baran, D., Gokdag, M.F.** 2018. Long-term Monitoring of Wetlands via Remote Sensing and GIS: A Case Study from Turkey. 2. *International Conference on Climate Change (ICCC 2018)*, February 15-16, 2018, Sri Lanka.
- **Goksel, C., Balcik, FB., Keskin, M., Celik, B., Cihan, C., Yagmur, N.** 2016. Evaluation of Classification Methods for Detection of Greenhouses from Spot 5 Satellite Imagery. *6th International Conference Cartography and GIS*, June 13-17, 2016 Albena, Bulgaria.