

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

**ORMAN YANGINLARININ MEKÂNSAL DAĞILIMI VE HAVA KALİTESİNE
ETKİLERİNİN UYDU VERİLERİ VE MAKİNE ÖĞRENME YÖNTEMLERİ
İLE ANALİZİ: 2025 TÜRKİYE VE KALİFORNİYA (LA) YANGINLARI**

YÜKSEK LİSANS TEZİ

İlay Nur TÜMER

Geomatik Mühendisliği Anabilim Dalı

Geomatik Mühendisliği Programı

OCAK 2026

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

**ORMAN YANGINLARININ MEKÂNSAL DAĞILIMI VE HAVA KALİTESİNE
ETKİLERİNİN UYDU VERİLERİ VE MAKİNE ÖĞRENME YÖNTEMLERİ
İLE ANALİZİ: 2025 TÜRKİYE VE KALİFORNİYA (LA) YANGINLARI**

YÜKSEK LİSANS TEZİ

**İlay Nur TÜMER
(501221646)**

Geomatik Mühendisliği Anabilim Dalı

Geomatik Mühendisliği Programı

Tez Danışmanı: Prof. Dr. Elif SERTEL

OCAK 2026

ISTANBUL TECHNICAL UNIVERSITY ★ GRADUATE SCHOOL

**ANALYSIS OF SPATIAL DISTRIBUTION OF FOREST FIRES AND THEIR
IMPACTS ON AIR QUALITY USING SATELLITE DATA AND MACHINE
LEARNING METHODS: 2025 TURKEY AND CALIFORNIA (LA) FIRES**

M.Sc. THESIS

**İlay Nur TÜMER
(501221646)**

Department of Geomatics Engineering

Geomatics Engineering Programme

Thesis Advisor: Prof. Dr. Elif SERTEL

JANUARY 2026

İTÜ, Lisansüstü Eğitim Enstitüsü'nün 501221646 numaralı Yüksek Lisans Öğrencisi İlay Nur TÜMER, ilgili yönetmeliklerin belirlediği gerekli tüm şartları yerine getirdikten sonra hazırladığı “ORMAN YANGINLARININ MEKÂNSAL DAĞILIMI VE HAVA KALİTESİNE ETKİLERİNİN UYDU VERİLERİ VE MAKİNE ÖĞRENME YÖNTEMLERİ İLE ANALİZİ: 2025 TÜRKİYE VE KALİFORNİYA (LA) YANGINLARI” başlıklı tezini aşağıda imzaları olan jüri önünde başarı ile sunmuştur.

Tez Danışmanı : **Prof. Dr. Elif SERTEL**
İstanbul Teknik Üniversitesi

Jüri Üyeleri : **Prof. Dr. Şinasi KAYA**
İstanbul Teknik Üniversitesi

Prof. Dr. Beyza USTAOĞLU
Sakarya Üniversitesi

Teslim Tarihi : 1 Ocak 2026
Savunma Tarihi : 19 Ocak 2026





Canım aileme ve yeğenim Ege'ye,



ÖNSÖZ

Bu yüksek lisans tezimin hazırlanma sürecinde her zaman yanımda olan, akademik yolculuğum boyunca bilgi ve deneyimleriyle bana yol gösteren değerli danışman hocam Prof. Dr. Elif SERTEL'e içten teşekkürlerimi sunarım. Kendisinin vizyonu, yol gösterici fikirleri, sabrı ve desteği bu çalışmanın tamamlanmasında en önemli güç kaynağım olmuştur.

Bugüne kadar eğitim hayatım boyunca yanımda olan, her koşulda fedakârlıklarını ve desteklerini esirgemeyen sevgili ailem Asuman TÜMER, Erdoğan TÜMER, Eray TÜMER ve Eda TÜMER'e minnettarlığımı ifade etmek isterim. Onların varlığı ve desteği, bu çalışmanın tamamlanmasında en büyük motivasyon kaynağım olmuştur.

Tez çalışmam sırasında her zaman yanımda olan, manevi desteklerini esirgemeyen tüm arkadaşlarıma gönülden teşekkür ederim.

Son olarak yüksek lisans eğitimim boyunca TÜBİTAK Bilim İnsanı Destek Programları Başkanlığı (BİDEB) 2210-A Yurt İçi Genel Yüksek Lisans Burs Programı ile bana sağlanan değerli destek için teşekkür ederim.

Ocak 2026

İlay Nur TÜMER
(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	5
1.2.1 Orman yangınlarının uzaktan algılama görüntüleri ile tespiti	6
1.2.2 Makine öğrenmesi yöntemleriyle NO ₂ , CO tespiti	8
1.2.3 Orman yangınlarının hava kalitesi ile ilişkisi	13
1.2.4 Açıklanabilir yapay zeka yaklaşımları ile modellerin incelenmesi.....	15
2. ÇALIŞMA ALANI VE VERİ	19
2.1 Çalışma Alanı.....	19
2.1.1 Türkiye'deki çalışma bölgesi	20
2.1.2 Kaliforniya eyaleti.....	21
2.2 Veri.....	22
2.2.1 Uydu verileri	22
2.2.1.1 Sentinel 2 ve Landsat 8/9	22
2.2.1.2 ECOSTRESS	26
2.2.1.3 Sentinel-5P.....	27
2.2.1.4 ERA-5 Land Reanalysis	30
2.2.1.5 GRIDMET	31
2.2.1.6 TanDEM-X EDEM	33
2.2.2 Yersel veriler.....	34
3. YÖNTEMLER	37
3.1 Orman Yangını Tespiti.....	38
3.1.1 İndisler	38
3.1.1.1 Normalize edilmiş fark bitki örtüsü indeksi (dNDVI)	39
3.1.1.2 Normalize edilmiş fark nem indeksi (dNDMI).....	39
3.1.1.3 Normalize edilmiş fark yanıklık oranı (dNBR)	39
3.1.2 Yanma şiddeti sınıflandırma	40
3.2 Veriseti hazırlama	41
3.2.1 Ortam	41
3.2.2 Kullanılan özellikler.....	42
3.2.3 Ön işleme	42
3.3 Makine öğrenmesi yöntemleri.....	45

3.3.1 Rastgele orman (Random Forest).....	45
3.3.2 Destek vektör makinesi (Support Vector Machine).....	46
3.3.3 Gradyan artırma makinesi (Gradient Boosting Machine).....	46
3.3.4 Aşırı gradyan artırma (Extreme Gradient Boosting).....	47
3.3.5 Kategorik Güçlendirme (Categorical Boosting)	47
3.3.6 Hafif gradyan artırma makinesi (Light Gradient Boosting Machine).....	48
3.3.7 Uzun kısa süreli bellek (Long Short-Term Memory).....	49
3.4 Shapley Katkı Değerleri (SHAP) ile Açıklanabilirlik	49
3.4.1 Özellik önem grafiği.....	50
3.4.2 Özet grafiği.....	51
3.4.3 Kuvvet grafiği	51
3.5 Doğruluk Analizi	52
4. BULGULAR VE TARTIŞMA	55
4.1 Türkiye Çalışma Alanı	55
4.1.1 Orman yangınlarının spektral indisler kullanılarak tespiti.....	55
4.1.2 Makine öğrenmesi modellerinin NO ₂ ve CO tahmin performansları.....	60
4.1.3 SHAP analizi ile tahminlerdeki etkili değişkenlerin belirlenmesi	67
4.2 Kaliforniya Çalışma Alanı.....	89
4.2.1 Orman yangınlarının spektral indisler kullanılarak tespiti.....	89
4.2.2 Makine öğrenmesi modellerinin NO ₂ ve CO tahmin performansları.....	93
4.2.3 SHAP analizi ile tahminlerdeki etkili değişkenlerin belirlenmesi	98
4.3 Aktarımlı Öğrenme.....	119
4.3.1 Kaliforniyadaki eğitilmiş modellerin Bursa yangınına uygulanması.....	119
4.3.2 Kaliforniyadaki eğitilmiş modellerin İzmir yangınına uygulanması	120
4.4 ERA-5 Land ve GRIDMET Karşılaştırma	121
5. SONUÇ VE ÖNERİLER.....	129
KAYNAKLAR.....	133
ÖZGEÇMİŞ.....	143

KISALTMALAR

GEE	: Google Earth Engine
RMSE	: Karesel Ortalama Hata
SHAP	: Shapley katkı açıklamaları
XAI	: Açıklanabilir Yapay Zekâ
dNBR	: Normalize Edilmiş Fark Yanma Oranı
dNDMI	: Normalize Edilmiş Fark Nem İndeksi
dNDVI	: Normalize Edilmiş Fark Bitki Örtüsü İndeksi
GBR	: Gradyan Artırma Regresyonu
RF	: Rastgele Orman
SVR	: Destek Vektör Regresyonu
XGBoost	: Aşırı gradyan artırma
LightGBM	: Hafif gradyan artırma makinesi
CatBoost	: Kategorik Güçlendirme
LSTM	: Uzun-kısa süreli bellek
NO₂	: Azot Dioksit
CO	: Karbon Monoksit



SEMBOLLER

$\mu\text{mol/m}^2$: Mikromol / metrekare

$\mu\text{g/m}^3$: Mikrogram / metreküp

R^2 :Determinasyon katsayısı

x_i : i'inci gözlem için gerçek (yersel ölçüm) değer

y_i : i'inci gözlem için model tarafından tahmin edilen değer

k : Toplam gözlem sayısı



ÇİZELGE LİSTESİ

Sayfa

Çizelge 1.1 : Literatürde NO ₂ & CO tahminine yönelik çalışmaların karşılaştırılması.	11
Çizelge 2.1 : Sentinel 2 A/B ve Landsat8/9 uydularının bant özellikleri.	23
Çizelge 3.1 : Yangın şiddeti sınıfları.	40
Çizelge 3.2 : Makine öğrenmesi modellerine giren değişkenler.	42
Çizelge 4.1 : Türkiye çalışma alanı için geliştirilen NO ₂ parametresi makine öğrenmesi modellerinin performans karşılaştırması...	61
Çizelge 4.2 : Türkiye çalışma alanı için geliştirilen CO parametresi makine öğrenmesi modellerinin performans karşılaştırması.	62
Çizelge 4.3 : SHAP analizinde kullanılan değişkenler.	67
Çizelge 4.4 : Türkiye çalışma alanı için yükseklik (DEM) yardımcı verisi kullanılmadan geliştirilen NO ₂ makine öğrenmesi modellerinin performans karşılaştırması.....	68
Çizelge 4.5 : Türkiye çalışma alanı için SHAP analizine göre en düşük katkıya sahip değişkenler (D2M, TE ve SSRD) dışlanarak oluşturulan NO ₂ makine öğrenmesi modellerinin performans sonuçları.	68
Çizelge 4.6 : Kaliforniya Los Angeles yanan orman alanları 2025.....	90
Çizelge 4.7 : Kaliforniya çalışma alanı için geliştirilen NO ₂ modellerinin performans karşılaştırması.	94
Çizelge 4.8 : Kaliforniya çalışma alanı için geliştirilen CO parametresi modellerinin performans karşılaştırması.	95
Çizelge 4.9 : Kaliforniya çalışma alanı için yükseklik (DEM) yardımcı verisi kullanılmadan geliştirilen modellerinin performans karşılaştırması. .	101
Çizelge 4.10 : Türkiye çalışma alanı için SHAP analizine göre en düşük katkıya sahip değişkenler (Wd, TE ve Ws) dışlanarak oluşturulan modellerinin performans sonuçları.....	101
Çizelge 4.11 : GRIDMET ve NDVI kullanılarak eğitilen model performansları. ..	123
Çizelge 4.12 : ERA-5 Land ve NDVI kullanılarak eğitilen model performansları.	123



ŞEKİL LİSTESİ

Sayfa

Şekil 2.1	: 2025 yılında Türkiye'de gerçekleşen orman yangınlarının konumları..	20
Şekil 2.2	: (a) Genel görünüm, (b) Kaliforniya, (c) Türkiye çalışma alanı.	22
Şekil 2.3	: İzmir/Seferihisar orman yangını için oluşturulan RGB görüntüler. (a) Sentinel-2 yangın öncesi görüntüsü (22 Haziran 2025), (b) Sentinel-2 yangın sonrası görüntüsü (2 Temmuz 2025), (c) Landsat 8/9 yangın öncesi görüntüsü (20 Haziran 2025) ve (d) Landsat 8/9 yangın sonrası görüntüsü (6 Temmuz 2025).....	24
Şekil 2.4	: İzmir/Seferihisar orman yangını için oluşturulan yanlış renkli bileşik (SWIR–NIR–RED) görüntüler. (a) Sentinel-2 yangın öncesi görüntüsü (22 Haziran 2025), (b) Sentinel-2 yangın sonrası görüntüsü (2 Temmuz 2025), (c) Landsat 8/9 yangın öncesi görüntüsü (20 Haziran 2025) ve (d) Landsat 8/9 yangın sonrası görüntüsü (6 Temmuz 2025).....	24
Şekil 2.5	: Kaliforniya/Los Angeles bölgesine ait Sentinel-2 görüntüleri. (a) ve (b) RGB bant kombinasyonunu, (c) ve (d) ise yanlış renkli bileşik (SWIR–NIR–RED) görüntüleri göstermektedir. (a) ve (c) yangın öncesi durumu (2 Ocak 2025), (b) ve (d) ise yangın sonrası durumu (12 Ocak 2025) temsil etmektedir.....	25
Şekil 2.6	: Kaliforniya/Los Angeles bölgesine ait Landsat 8/9 görüntülerinin yangın öncesi ve sonrası karşılaştırılması. (a,b) RGB bant kombinasyonu, (c,d) yanlış renkli bileşik (SWIR–NIR–RED) görüntülerdir. Yangın öncesi ve sonrası tarihler sırasıyla 6 Ocak 2025 ve 14 Ocak 2025'tir.....	26
Şekil 2.7	: (a) Palisades, (b) Eaton, Kaliforniya, Los Angeles yangınlarına ait ECOSTRESS veri örnekleri.....	27
Şekil 2.8	: Los Angeles yangın (7 Ocak 2025) öncesi ve sonrasına ait Sentinel-5P Troposferik NO ₂ görüntüleri.....	29
Şekil 2.9	: Seferihisar/İzmir yangın (29 Haziran 2025) öncesi ve sonrasına ait Sentinel-5P toplam sütun yoğunluğu CO görüntüleri.....	29
Şekil 2.10	: Türkiye'de 1 Haziran-30 Ağustos 2025 tarihleri arasında günlük ortalama 2m hava sıcaklığı.	31
Şekil 2.11	: Kaliforniya'da 1 Ocak-1 Şubat 2025 tarihleri arasında saatlik ortalama yüzey sıcaklığı.	31
Şekil 2.12	: Kaliforniya'da Ocak ayı ortalama rüzgar hızı parametresi.	32
Şekil 2.13	: Kaliforniya ve Türkiye çalışma alanlarına ait DEM verisi.	34
Şekil 2.14	: Türkiye çalışma alanındaki yersel istasyonların veri kapsama analiz örnekleri.	35
Şekil 2.15	: Türkiye çalışma alanındaki NO ₂ ve CO istasyonlarının dağılımı.	35
Şekil 2.16	: Kaliforniya çalışma alanındaki NO ₂ ve CO istasyonlarının dağılımı. ..	36
Şekil 3.1	: İş akış diyagramı.	37
Şekil 3.2	: Türkiye çalışma alanındaki uydu ve yersel veriler arasındaki korelasyon analizi.....	44

Şekil 3.3 : Kaliforniya çalışma alanındaki uydu ve yersel veriler arasındaki korelasyon analizi.	45
Şekil 3.4 : Rastgele Orman yöntemi.	46
Şekil 3.5 : XGBoost yöntemi.	47
Şekil 3.6 : CatBoost yöntemi.	48
Şekil 3.7 : SHAP özellik önem grafiği.	50
Şekil 3.8 : SHAP özet grafiği.	51
Şekil 3.9 : SHAP kuvvet grafiği.	52
Şekil 4.1 : 2025 yılında Türkiye'de gerçekleşen en büyük orman yangınları.	56
Şekil 4.2 : 2025'te Türkiye'de gerçekleşen en büyük 15 orman yangını.	56
Şekil 4.3 : Sakarya ve Bursa yangınlarına ait ECOSTRESS verisi & Sentinel 2A/B SWIR/NIR/RED kombinasyonu.	57
Şekil 4.4 : İzmir/Seferihisar yangın alanı; (a) Sentinel-2 tabanlı dNDVI, (b) Landsat 8/9 tabanlı dNDVI fark haritası, (c) Sentinel-2 tabanlı dNDMI, (d) Landsat 8/9 tabanlı dNDMI fark haritası, (e) Sentinel-2 dNBR indeksine dayalı yanma şiddeti sınıfları ve (f) Landsat 8/9 dNBR indeksine dayalı yanma şiddeti sınıfları.	58
Şekil 4.5 : Sakarya/ Bilecik yangın alanı; (a) Sentinel-2 tabanlı dNDVI, (b) Landsat 8/9 tabanlı dNDVI fark haritası, (c) Sentinel-2 tabanlı dNDMI, (d) Landsat 8/9 tabanlı dNDMI fark haritası, (e) Sentinel-2 dNBR indeksine dayalı yanma şiddeti sınıfları ve (f) Landsat 8/9 dNBR indeksine dayalı yanma şiddeti sınıfları.	59
Şekil 4.6 : Türkiye çalışma alanında yer alan Sakarya yangın dönemi (21 Temmuz 2025) sırasında farklı makine öğrenmesi modelleri kullanılarak üretilen yersel NO ₂ tahmin haritaları. İlk harita, Sentinel-5P TROPOMI verisinin troposferik NO ₂ sütun yoğunluğunu göstermektedir.	64
Şekil 4.7 : Türkiye çalışma alanında yer alan Bursa yangın dönemi (27 Temmuz 2025) sırasında farklı makine öğrenmesi modelleri kullanılarak üretilen yersel NO ₂ tahmin haritaları. İlk harita, Sentinel-5P TROPOMI verisinin troposferik NO ₂ sütun yoğunluğunu göstermektedir.	65
Şekil 4.8 : Türkiye çalışma alanında yer alan Bursa yangın dönemi sırasında farklı makine öğrenmesi modelleri kullanılarak üretilen yersel CO tahmin haritaları. İlk harita, Sentinel-5P TROPOMI verisinin CO sütun yoğunluğunu göstermektedir.	66
Şekil 4.9 : Türkiye çalışma alanı NO ₂ SHAP özellik önem grafikleri (a) RF, (b) XGBoost, (c) LightGBM, (d) GBR, (e) CatBoost.	69
Şekil 4.10 : Türkiye çalışma alanı CO SHAP özellik önem grafikleri (a) RF, (b) XGBoost, (c) LightGBM, (d) GBR, (e) CatBoost.	70
Şekil 4.11 : Türkiye çalışma alanı NO ₂ SHAP özet grafikleri (a) RF, (b) XGBoost, (c) LightGBM, (d) GBR, (e) CatBoost.	73
Şekil 4.12 : Türkiye çalışma alanı CO SHAP özet grafikleri (a) RF, (b) XGBoost, (c) LightGBM, (d) GBR, (e) CatBoost.	74
Şekil 4.13 : Türkiye çalışma alanı NO ₂ 1. test örneği (18 Temmuz 2025) için SHAP kuvvet grafikleri.	76
Şekil 4.14 : Türkiye çalışma alanı NO ₂ 2. test örneği (24 Haziran 2025) için SHAP kuvvet grafikleri.	77
Şekil 4.15 : Türkiye çalışma alanı NO ₂ 3. test örneği (23 Mayıs 2025) için SHAP kuvvet grafikleri.	78
Şekil 4.16 : Türkiye çalışma alanı NO ₂ 4. test örneği (21 Temmuz 2025) için SHAP kuvvet grafikleri.	80

Şekil 4.17 : Türkiye çalışma alanı NO ₂ 5. test örneği (23 Temmuz 2025) için SHAP kuvvet grafikleri.....	81
Şekil 4.18 : Türkiye çalışma alanı CO 1. test örneği (20 Haziran 2025) için SHAP kuvvet grafikleri.....	83
Şekil 4.19 : Türkiye çalışma alanı CO 2. test örneği (20 Haziran 2025) için SHAP kuvvet grafikleri.....	84
Şekil 4.20 : Türkiye çalışma alanı CO 3. test örneği (20 Mayıs 2025) için SHAP kuvvet grafikleri.....	85
Şekil 4.21 : Türkiye çalışma alanı CO 4. test örneği (21 Mayıs 2025) için SHAP kuvvet grafikleri.....	87
Şekil 4.22 : Türkiye çalışma alanı CO 5. test örneği (10 Haziran 2025) için SHAP kuvvet grafikleri.....	88
Şekil 4.23 : Kaliforniya Los Angeles yangınları 2025.	89
Şekil 4.24 : LA yangınları dNBR yangın şiddeti haritaları (a) Sentinel 2A/B, (b) Landsat 8/9.....	90
Şekil 4.25 : (a) Eaton yangın alanı ve (b) Palisades yangın alanı için Sentinel 2 görüntüleri. (c) Eaton yangın alanı ve (d) Palisades yangın alanı için ECOSTRESS tabanlı ortalama LST (K) değerlerinin 1 Aralık 2024-28 Şubat 2025 tarihleri arasındaki zaman serisi.	91
Şekil 4.26 : 7 Ocak 2025 Kaliforniya/Palisades yangın alanı için ECOSTRESS LST haritaları. (a) 1 Ocak 2025, (b) 5 Ocak 2025, (c) 8 Ocak 2025, (d) 9 Ocak 2025, (e) 11 Ocak 2025 ve (f) 13 Ocak 2025 tarihlerine aittir.	92
Şekil 4.27 : 7 Ocak 2025 Kaliforniya/Eaton yangın alanı için ECOSTRESS LST haritaları. (a) 5 Ocak 2025, (b) 8 Ocak 2025, (c) 9 Ocak 2025, ve (d) 13 Ocak 2025.	93
Şekil 4.28 : Kaliforniya çalışma alanında yer alan Los Angeles yangın dönemi (10 Ocak 2025) sırasında farklı makine öğrenmesi modelleri kullanılarak üretilen yersel NO ₂ tahmin haritaları. İlk harita, Sentinel-5P TROPOMI verisinin troposferik NO ₂ sütun yoğunluğunu göstermektedir.	96
Şekil 4.29 : Kaliforniya çalışma alanında yer alan Los Angeles yangın dönemi (10 Ocak 2025) sırasında farklı makine öğrenmesi modelleri kullanılarak üretilen yersel CO tahmin haritaları. İlk harita, Sentinel-5P TROPOMI verisinin CO sütun yoğunluğunu göstermektedir.	97
Şekil 4.30 : Kaliforniya çalışma alanı NO ₂ SHAP özellik önem grafikleri (a) RF, (b) CatBoost, (c) XGBoost, (d) LightGBM, (e) GBM, (f) SVR, (g) LSTM.	99
Şekil 4.31 : Kaliforniya çalışma alanı CO SHAP özellik önem grafikleri (a) RF, (b) CatBoost, (c) XGBoost, (d) LightGBM, (e) GBM.	100
Şekil 4.32 : Kaliforniya çalışma alanı NO ₂ SHAP özet grafikleri (a) RF, (b) CatBoost, (c) XGBoost, (d) LightGBM, (e) GBM, (f) SVR, (g) LSTM.....	103
Şekil 4.33 : Kaliforniya çalışma alanı CO SHAP özet grafikleri (a) RF, (b) CatBoost, (c) XGBoost, (d) LightGBM, (e) GBM.	104
Şekil 4.34 : Kaliforniya çalışma alanı NO ₂ 1. test örneği (4 Mart 2025) için SHAP kuvvet grafikleri.....	106
Şekil 4.35 : Kaliforniya çalışma alanı NO ₂ 2. test örneği (9 Mart 2025) için SHAP kuvvet grafikleri.....	107
Şekil 4.36 : Kaliforniya çalışma alanı NO ₂ 3. test örneği (23 Mayıs 2025) için SHAP kuvvet grafikleri.....	108
Şekil 4.37 : Kaliforniya çalışma alanı NO ₂ 4. test örneği (23 Şubat 2025) için SHAP kuvvet grafikleri.....	110

Şekil 4.38 : Kaliforniya çalışma alanı NO ₂ 5. test örneği (24 Mart 2025) için SHAP kuvvet grafikleri.....	111
Şekil 4.39 : Kaliforniya çalışma alanı CO 1. test örneği (26 Mayıs 2025) için SHAP kuvvet grafikleri.....	113
Şekil 4.40 : Kaliforniya çalışma alanı CO 2. test örneği (7 Mayıs 2025) için SHAP kuvvet grafikleri.....	114
Şekil 4.41 : Kaliforniya çalışma alanı CO 3. test örneği (20 Ocak 2025) için SHAP kuvvet grafikleri.....	115
Şekil 4.42 : Kaliforniya çalışma alanı CO 4. test örneği (17 Şubat 2025) için SHAP kuvvet grafikleri.....	117
Şekil 4.43 : Kaliforniya çalışma alanı CO 5. test örneği (1 Şubat 2025) için SHAP kuvvet grafikleri.....	118
Şekil 4.44 : Sakarya yangını için Kaliforniya’da üretilen CatBoost ile NO ₂ tahmin haritası.....	120
Şekil 4.45 : İzmir yangını için Kaliforniya’da üretilen CatBoost ile NO ₂ tahmin haritası.....	121
Şekil 4.46 : SHAP özellik önem grafikleri GRIDMET için (a) RF, (b) CatBoost, (c) LightGBM, ERA-5 Land için (d) RF, (e) CatBoost, (f)LightGBM....	125
Şekil 4.47 : SHAP özet grafikleri GRIDMET için (a) RF, (b) CatBoost, (c) LightGBM, ERA-5 Land için (d) RF, (e) CatBoost, (f) LightGBM.	126
Şekil 4.48 : Kaliforniya çalışma alanında ERA-5 Land ile GRIDMET veri setlerinden alınan yardımcı değişkenler ile üretilen NO ₂ tahmin haritaları.	127

ORMAN YANGINLARININ MEKÂNSAL DAĞILIMI VE HAVA KALİTESİNE ETKİLERİNİN UYDU VERİLERİ VE MAKİNE ÖĞRENME YÖNTEMLERİ İLE ANALİZİ: 2025 TÜRKİYE VE KALİFORNİYA (LA) YANGINLARI

ÖZET

Orman yangınları, küresel ölçekte artan sıklıkları ve şiddetleri nedeniyle ekosistemler, atmosferik süreçler ve insan sağlığı üzerinde giderek daha belirgin etkiler oluşturmaktadır. Yangınlar sırasında açığa çıkan gazlar ve partikül maddeler, özellikle NO₂ ve CO gibi iz gazların atmosferik konsantrasyonlarını önemli ölçüde artırmaktadır. Bu kirleticiler, kısa ve orta vadede hava kalitesini düşürerek solunum sistemi hastalıkları başta olmak üzere çeşitli sağlık risklerini beraberinde getirmektedir. Bu nedenle yangın kaynaklı hava kirliliğinin doğru biçimde izlenmesi ve değerlendirilmesi çevresel ve toplumsal açıdan kritik bir gereklilik haline gelmiştir.

Yangınların hava kalitesi üzerindeki etkilerinin güvenilir biçimde analiz edilebilmesi, öncelikle yangın alanlarının doğru ve zamanında tespit edilmesine bağlıdır. Yanmış alanların konumu, büyüklüğü ve şiddeti, atmosfere salınan kirletici miktarlarının mekânsal ve zamansal dağılımını doğrudan etkilemektedir. Yersel hava kalitesi istasyonları yüksek doğruluklu ölçümler sunsa da mekânsal kapsama alanları sınırlıdır ve geniş ölçekli yangın olaylarını temsil etmekte yetersiz kalabilmektedir. Bu bağlamda, uydu görüntülerine dayalı yangın alanı tespiti, yangın sonrası hava kalitesi analizleri için temel bir girdi oluşturmaktadır. Uydu verileri, yangın alanlarının geniş ölçekte haritalanmasını sağlarken, makine öğrenmesi yöntemleri bu bilgiler ile atmosferik ve meteorolojik değişkenler arasındaki karmaşık ilişkilerin modellenmesine olanak tanımaktadır.

Bu çalışmada, yangın dönemlerinde yersel NO₂ ve CO konsantrasyonlarının tahmin edilmesi amacıyla uydu tabanlı gözlemler, meteorolojik yardımcı veriler ve makine öğrenmesi modelleri birlikte kullanılmıştır. Ayrıca geliştirilen modellerin yalnızca doğruluk açısından değil, fiziksel tutarlılık açısından da değerlendirilmesi hedeflenmiştir. Bu kapsamda açıklanabilir yapay zekâ yöntemlerinden SHAP analizi kullanılarak model davranışları incelenmiştir.

Çalışma alanı olarak 2025 yangınları nedeniyle Türkiye çalışma alanı ve Kaliforniya eyaleti seçilmiş ve modellerin farklı coğrafi ve iklimsel koşullardaki performansları karşılaştırılmıştır. Çalışmada Sentinel 2A/B ile Landsat 8/9 verileri kullanılarak yangın alanları tespit edilmiştir. 2025 yangın sezonu boyunca Türkiye genelinde tespit edilen toplam yanmış alan büyüklüğü, Sentinel 2A/B verileri kullanılarak 101503.99 hektar, Landsat 8/9 verileri kullanılarak ise 100058.78 hektar olarak hesaplanmıştır.

Kaliforniya çalışma alanında, yangınların yüzey sıcaklığı üzerindeki etkilerinin değerlendirilmesi amacıyla ECOSTRESS verileri kullanılmıştır. ECOSTRESS tabanlı kara yüzey sıcaklığı (LST) verileri, özellikle Los Angeles çevresinde meydana gelen büyük ölçekli yangınlar sırasında oluşan termal anomalilerin mekânsal dağılımını

ortaya koymak için değerlendirilmiştir. Bu veriler, yangın alanlarında gözlenen yüksek sıcaklık değerlerinin belirlenmesine olanak sağlamış ve yangın şiddetinin termal bileşeninin yorumlanmasına destek olmuştur. Sentinel 2A/B verilerine göre Palisades, Eaton, Kenneth, Hurst, Lidia, Sunset ve Archer yangınları sonucunda oluşan toplam yanmış alan yaklaşık 41000 dönüm olarak hesaplanmıştır. Bu alanın önemli bir bölümü Palisades ve Eaton yangınları tarafından oluşturulmuş olup, Palisades yangını yaklaşık 24280 dönüm, Eaton yangını ise yaklaşık 14489 dönüm ile en büyük yanmış alanlara sahip iki olay olarak öne çıkmaktadır.

Makine öğrenmesi aşamasında Random Forest, Gradient Boosting, XGBoost, LightGBM, CatBoost, SVR ve LSTM modelleri uygulanmıştır. Modeller beş katlı çapraz doğrulama ile değerlendirilmiştir. Performans ölçütleri olarak R^2 ve RMSE kullanılmıştır.

NO_2 parametresi için Türkiye çalışma alanında en iyi performans CatBoost modeli ile elde edilmiştir. Bu model için test R^2 değeri 0.808, test RMSE değeri $6.644 \mu g/m^3$ olarak hesaplanmıştır. LightGBM modeli benzer doğruluk seviyeleri sunarken, LSTM modeli ise en düşük değerleri alarak anlamlı bir sonuç vermemiştir. Kaliforniya çalışma alanında da CatBoost ($0.863 R^2$ ve $4.249 \mu g/m^3$ RMSE) ve LightGBM ($0.85 R^2$ ve $4.411 \mu g/m^3$ RMSE) modelleri öne çıkmış ve karmaşık, doğrusal olmayan ilişkilerin bu modeller tarafından başarılı biçimde temsil edildiği görülmüştür. LSTM modeli Kaliforniya çalışma alanında daha iyi gözükse de halen diğer modellere göre düşük kalmaktadır. Ayrıca görsel olarak ta bakıldığında anlamlı sonuç vermediği gözükmemektedir.

CO parametresi için Türkiye çalışma alanında en iyi performans Gradient Boosting modeli ile elde edilmiştir. Bu model için test R^2 değeri 0.833, test RMSE değeri ise $168.851 \mu g/m^3$ olarak hesaplanmıştır. LightGBM modeli 0.820 test R^2 ve $175.328 \mu g/m^3$ RMSE değeri ile benzer sonuçlar sunmuştur. Kaliforniya çalışma alanında CO için en yüksek performans LightGBM modeli ile elde edilmiştir. Bu modelin test R^2 değeri 0.792, test RMSE değeri ise $55.938 \mu g/m^3$ olarak gözükmemektedir. CatBoost ve Gradient Boosting modelleri her iki çalışma alanında da tutarlı sonuçlar üretmiştir.

Model sonuçlarının yorumlanması için SHAP analizi uygulanmıştır. Hem Türkiye hem de Kaliforniya çalışma alanlarında uydu tabanlı NO_2 değişkeninin en baskın açıklayıcı parametre olduğu görülmüştür. Bu değişken tüm modellerde en yüksek SHAP değerlerine sahiptir. Yükselti değişkeni her iki çalışma alanında da önemli bir katkı sunmuştur. Bu bulgu topografyanın NO_2 dağılımı üzerindeki etkisinin farklı coğrafyalarda tutarlı olduğunu göstermektedir. Bitki örtüsünü temsil eden LAI değişkenleri orta düzeyde katkı sağlamıştır. Meteorolojik değişkenlerin katkısı ise genel olarak ikincil düzeyde kalmıştır.

Çalışmada ayrıca aktarımlı öğrenme (transfer learning) yaklaşımı kapsamında, Kaliforniya çalışma alanında eğitilen modeller Türkiye'deki büyük yangınlara uygulanmıştır. Kaliforniya'da eğitilen CatBoost modeli, Bursa ve İzmir yangınları için yersel NO_2 tahminlerinde kullanılmış ve modellerin genellenebilirliği test edilmiştir.

Buna ek olarak, çalışmada GRIDMET ve ERA5-Land meteorolojik veri setleri karşılaştırmalı olarak değerlendirilmiştir. Her iki veri seti kullanılarak geliştirilen makine öğrenmesi modellerinin performansları ve SHAP tabanlı açıklanabilirlik sonuçları incelenmiştir. Elde edilen bulgular, R^2 ve RMSE gibi temel performans metrikleri açısından iki veri seti arasında ciddi bir fark bulunmadığını göstermektedir. Bununla birlikte, üretilen mekânsal tahmin haritaları incelendiğinde, GRIDMET veri seti kullanılarak elde edilen sonuçların, daha yüksek mekânsal çözünürlüğü nedeniyle

daha ayrıntılı ve pürüzsüz desenler sunduğu görülmüştür. SHAP sonuçlarına göre ise iki veri seti kullanıldığında da modellerin benzer değişkenleri daha etkin kullanarak sonuçlara vardığı tespit edilmiştir.

Sonuç olarak bu çalışma, uydu verileri ve makine öğrenmesi yöntemlerinin birlikte kullanılmasıyla yangın dönemlerinde yersel hava kalitesi tahminlerinin başarılı biçimde gerçekleştirilebileceğini göstermiştir. Ağaç tabanlı gradyan artırma modelleri hem doğruluk hem de kararlılık açısından öne çıkmıştır. SHAP analizleri, geliştirilen modellerin karar mekanizmalarının fiziksel olarak anlamlı olduğunu desteklemiştir. Elde edilen bulgular, farklı coğrafi bölgelerde benzer süreçlerin yakalanabildiğini göstermekte ve yöntemin genellenebilirliğini ortaya koymaktadır.





ANALYSIS OF SPATIAL DISTRIBUTION OF FOREST FIRES AND THEIR IMPACTS ON AIR QUALITY USING SATELLITE DATA AND MACHINE LEARNING METHODS: 2025 TURKEY AND CALIFORNIA (LA) FIRES

SUMMARY

Forests are natural ecosystems covers approximately 31% of the Earth's land surface and play a critical role in maintaining the continuity of the global ecosystem. They are indispensable for ecological balance due to their capacity to sequester atmospheric carbon dioxide, contribute to oxygen production, and provide habitats for biodiversity. Forests also play an important role in sustaining the hydrological cycle, mitigating soil erosion, and regulating local climatic conditions.

In recent years, a significant increase has been observed in both the frequency and intensity of forest fires. This increase is primarily attributed to rising temperatures, prolonged drought conditions, strong wind events, and human activities. The escalation of wildfire activity has been particularly pronounced in fire-prone regions such as the Mediterranean Basin. Large-scale fires cause the loss of forest resources and accelerate climate change by releasing greenhouse gases into the atmosphere.

During forest fires, large amounts of gases and particles are released into the atmosphere. Among these emissions, nitrogen dioxide and carbon monoxide are prominent trace gases. Nitrogen dioxide is a reactive compound closely associated with combustion processes and can promote ozone formation through photochemical reactions, thereby degrading air quality. Carbon monoxide, on the other hand, is a major product of incomplete combustion and influences ozone formation and methane lifetime through its interaction with hydroxyl radicals in the troposphere.

Exposure to these pollutants is directly linked to respiratory and cardiovascular diseases, leading to serious health impacts, especially among vulnerable populations. Hence, reliable analysis of the spatial and temporal patterns of fire related air pollution is important for environmental management and public health protection.

Accurate assessment of wildfire impacts on air quality depends primarily on the timely and precise detection of burned areas. The location, extent, and burn severity of fire-affected areas directly determine the distribution of emitted pollutants. Ground-based air quality monitoring stations provide high accuracy measurements; however, their limited spatial coverage constrains the representation of large-scale and spatially heterogeneous wildfire events.

Remote sensing satellite data offer a strong alternative in this context. Their ability to cover large areas and provide regular, continuous observations represents a major advantage. Multispectral sensors such as Sentinel-2A/B and Landsat-8/9 enable the comparison of pre- and post-fire conditions, allowing burned areas to be delineated using spectral indices such as dNBR, dNDVI, and dNDMI. These indices also support the classification of burn severity.

For monitoring atmospheric components, the TROPOMI sensor aboard the Sentinel-5P satellite plays a key role by providing daily observations of tropospheric column densities of pollutants such as nitrogen dioxide and carbon monoxide. However, satellite derived column measurements do not directly represent ground level concentrations, and their relationship with ground observations is influenced by various environmental factors, including meteorological conditions, topography, and land cover.

ERA5-Land reanalysis products contribute to modeling this complex relationship by providing meteorological variables such as air temperature, wind speed and direction, surface pressure, and solar radiation at high temporal resolution. These variables play a significant role in explaining the linkage between satellite observations and ground-based air quality measurements.

In this context, machine learning methods provide an effective framework for capturing nonlinear relationships between satellite observations, meteorological variables, and environmental factors to estimate ground level air quality. However, their black-box nature often limits interpretability. Explainable artificial intelligence techniques, particularly SHAP, address this limitation by quantifying the contribution of individual variables to model predictions.

This thesis investigates the impacts of forest fires on ground-level air quality using an explainable modeling framework. Burned areas are identified through spectral indices, and ground-level concentrations of nitrogen dioxide and carbon monoxide during fire periods are estimated using integrated satellite and meteorological data. The generalizability and physical consistency of the developed models are evaluated through SHAP based analysis.

Two study areas are defined: Western and Southwestern Anatolia in Türkiye, and the state of California in the United States. The Türkiye study area includes the provinces of İzmir, Aydın, Muğla, Antalya, Burdur, Isparta, Denizli, Afyonkarahisar, Uşak, Manisa, Balıkesir, Bilecik, Bursa, Çanakkale, Yalova, Kocaeli, Sakarya, Tekirdağ, Kırklareli, and Edirne. This region was selected based on the continuity and spatial distribution of ground monitoring stations and is characterized by coastal meteorological influences, diverse vegetation cover, and pronounced topographic variability, allowing for representative analysis of fire dynamics and pollutant dispersion.

California was selected due to its frequent large-scale wildfires and well-established air quality monitoring infrastructure, providing an appropriate second study area for testing the proposed methods under different environmental conditions.

Burned area detection was performed using Sentinel-2 and Landsat-8/9 imagery. Cloud and water masking were applied during preprocessing, followed by the creation of pre- and post-fire mosaics. dNBR classification was conducted based on USGS threshold values, while dNDVI and dNDMI were used as supporting indicators of vegetation and moisture loss. During the 2025 fire season in Türkiye, the total burned area was estimated as 101,503.99 hectares using Sentinel-2 data and 100,058.78 hectares using Landsat-8/9 data.

In the Los Angeles region of California, the Palisades, Eaton, Kenneth, Hurst, Lidia, Sunset, and Archer fires were analyzed. Sentinel-2 data indicated a total burned area of approximately 41000 acres, with the Palisades fire accounting for about 24280 acres and the Eaton fire for approximately 14489 acres.

Air quality variables were obtained from Sentinel-5P TROPOMI OFFL products via Google Earth Engine. Tropospheric column densities of nitrogen dioxide and carbon monoxide were converted from mol/m² to μ mol/m². Meteorological auxiliary variables were extracted from the ERA5-Land Hourly dataset and included air temperature, dew point temperature, surface solar radiation, wind speed, wind direction, surface pressure, total precipitation, total evaporation, surface albedo, high and low vegetation leaf area index. Topographic effects were represented using the 30-m resolution TanDEM-X digital elevation model.

Ground-based air quality data were obtained from the National Air Quality Monitoring Network for Türkiye and from the EPA AirData database for California. In the Türkiye study area, 98 stations were used for the period 15 May–30 July 2025, with 90 stations measuring nitrogen dioxide and 55 measuring carbon monoxide. Measurements were matched to satellite overpass times using the 09:00–12:00 local time window.

For California, data from 1 January–30 July 2025 were analyzed, including 52 nitrogen dioxide stations and 30 carbon monoxide stations. Measurements from 19:00–22:00 UTC were used to represent satellite overpass conditions.

Datasets were filtered to remove missing values and physically implausible negative observations. The Türkiye nitrogen dioxide dataset was structured to capture both background conditions and fire-related peaks, retaining observations within the 10th and 90th percentiles. The final dataset consisted of 3,135 observations, with a Pearson correlation of 0.637 between satellite-based and ground-based nitrogen dioxide. For carbon monoxide, 1,728 observations were retained, yielding a correlation of 0.411.

The California nitrogen dioxide dataset consisted of 5,055 observations, with a correlation of 0.709, while the carbon monoxide dataset included 2,498 observations with a correlation of 0.252. The California nitrogen dioxide dataset was split into 80% training (4,169 observations) and 20% testing (1,043 observations).

To assess the thermal effects of fires in California, ECOSTRESS land surface temperature data with 70-m spatial resolution were used. These data supported the spatial characterization of thermal anomalies during major fires in the Los Angeles region and were treated as a complementary layer representing the thermal component of burn severity.

For the NO₂ parameter, the best performance in the Türkiye study area was achieved using the CatBoost model, with a test R² value of 0.808 and a test RMSE of 6.644 μ g/m³. The LightGBM model provided comparable accuracy, whereas the LSTM model yielded the lowest performance and did not produce meaningful results. In the California study area, the CatBoost (R² = 0.863, RMSE = 4.249 μ g/m³) and LightGBM (R² = 0.850, RMSE = 4.411 μ g/m³) models also outperformed the other approaches, indicating their strong capability to represent complex and nonlinear relationships. Although the LSTM model showed relatively improved performance in California, it remained inferior to the other models, and visual inspection of the prediction maps further suggested that it did not produce meaningful spatial patterns.

For the CO parameter, the highest performance in the Türkiye study area was obtained with the Gradient Boosting model, achieving a test R² of 0.833 and a test RMSE of 168.851 μ g/m³. The LightGBM model yielded comparable results with a test R² of 0.820 and an RMSE of 175.328 μ g/m³. In the California study area, the LightGBM model demonstrated the best performance for CO, with a test R² of 0.792 and an RMSE

of 55.938 $\mu\text{g}/\text{m}^3$. The CatBoost and Gradient Boosting models produced consistent results across both study areas.

SHAP analysis revealed that satellite derived nitrogen dioxide was the most influential explanatory variable in both study areas. Elevation consistently showed a significant contribution, while leaf area index variables exhibited moderate effects. Meteorological variables generally played a secondary role, with contributions varying depending on conditions. Local SHAP explanations indicated that satellite nitrogen dioxide and topography strongly increased predictions in certain cases, while some meteorological variables exerted balancing effects. These findings indicate that the models capture relationships consistent with underlying physical processes.

In addition, within the scope of the transfer learning approach, models trained in the California study area were applied to major wildfire events in Türkiye. The CatBoost model trained in California was used to estimate ground-level NO_2 concentrations for the Bursa and İzmir fires, and the generalizability of the developed models was evaluated.

Furthermore, the GRIDMET and ERA5-Land meteorological datasets were comparatively assessed in this study. The performance of machine learning models developed using both datasets, along with their SHAP-based explainability results, were analyzed. The findings indicate that there were no substantial differences between the two datasets in terms of key performance metrics such as R^2 and RMSE. However, an examination of the spatial prediction maps revealed that the results obtained using the GRIDMET dataset exhibited more detailed and smoother spatial patterns due to its higher spatial resolution. SHAP analysis further showed that, regardless of the meteorological dataset used, the models relied on similar explanatory variables to generate predictions.

In conclusion, this study demonstrates that surface-level nitrogen dioxide and carbon monoxide concentrations during wildfire periods can be effectively estimated by integrating satellite observations, meteorological auxiliary data, and machine learning methods. Tree-based boosting models showed superior accuracy and robustness, while SHAP analysis enhanced model interpretability. The ability to capture similar processes across distinct geographic regions such as Türkiye and California indicates the generalizability of the proposed approach and highlights the value of multi-source data integration for analyzing wildfire air quality interactions.

1. GİRİŞ

Ormanlar, dünya yüzeyinin yaklaşık %31'ini kaplayan ve küresel ekosistemin en kritik bileşenlerinden biri olarak kabul edilen doğal alanlardır (International Institute for Sustainable Development (IISD), 2025). Atmosferdeki karbondioksiti tutarak oksijen üretmeleri, iklim düzenleyici rolleri ve biyoçeşitlilik için barınma alanı sağlamaları nedeniyle ormanlar ekolojik denge açısından vazgeçilmez olmasını sağlamaktadır (Nzabarinda vd., 2025). Aynı zamanda su döngüsünün devamlılığında, toprak erozyonunun önlenmesinde (Elliot, 2002), yerel iklim koşullarının düzenlenmesinde (Jones vd., 2024) ve milyonlarca insan için ekonomik değer yaratılmasında önemli katkılar sunmaktadırlar (FAO, 2024). Bu nedenle ormanlar hem doğanın sürdürülebilirliği hem de insan yaşamının devamlılığı açısından korunması gereken temel ekosistemler arasında yer almaktadır. Ancak son yıllarda küresel ısınmanın yol açtığı yüksek sıcaklıklar, yağışların azalması, rüzgar paternlerindeki değişimler ve insan faaliyetleri nedeniyle orman yangınlarında ciddi bir artış gözlenmektedir. Artan sıcaklıklar, kuraklık ve yangın sırasındaki hava koşulları (rüzgâr hızı vb.) yangınların hızlı bir şekilde ilerleyerek büyük ölçeklere yayılmasına ve şiddetinin artmasına neden olmaktadır. Özellikle Akdeniz Havzası'nda bu etkiler belirgin şekilde görülmektedir (Costa-Saura vd., 2025). Büyük ölçekli yangınlar yalnızca orman varlığının ve biyolojik çeşitliliği tehdit etmekle kalmamakta, aynı zamanda açığa çıkan sera gazları atmosfere salınarak iklim değişikliğini hızlandıran bir geri besleme döngüsü yaratmaktadır ve hava kalitesini de olumsuz olarak etkilemektedir (Future Earth, The Earth League, & WCRP, 2021). Yangınlardan salınan duman ve gazlar, özellikle azot dioksit (NO₂) ve karbon monoksit (CO), insan sağlığı üzerinde ciddi solunum yolu sorunlarına yol açmakta ve çevresel etkileri daha da artırmaktadır (WHO, 2021). Bu nedenle orman yangınlarının izlenmesi, çevresel ve insanlara olan etkilerinin ortaya konması önemli bir araştırma konusudur.

Azot dioksit (NO₂) ve karbon monoksit (CO), orman yangınları sırasında atmosfere salınan gazlar arasında yer almakta olup, yanma süreçlerinin bir göstergesi olarak hava kalitesi ve insan sağlığı üzerinde önemli etkilere neden olmaktadır. NO₂, azot

oksitlerin (NO_x) bir bileşeni olarak özellikle yanma süreçlerinde ortaya çıkan reaktif bir gazdır; atmosferde fotokimyasal reaksiyonlarla ozon (O_3) oluşumunu tetiklemekte ve hava kalitesini etkilemektedir (Di Carlo vd., 2015; Shen vd., 2025). Böylece, maruziyet düzeyine bağlı olarak solunum yolu hastalıkları ve kardiyovasküler risklerde artışa neden olabilmektedir (Wang vd., 2023). Ayrıca, CO, biyokütle yanması ve fosil yakıt kullanımına bağlı eksik yanma süreçlerinden kaynaklanan başlıca emisyonlardan biridir. Troposferik fotokimya içinde hidroksil radikalleri (OH) ile tepkimeye girerek O_3 oluşumunu ve atmosferin oksidatif kapasitesi üzerinden metan (CH_4) ömrünü etkilemektedir (Fiore vd., 2024). Dolayısıyla, yangın kaynaklı bu gazlar atmosferin kimyasal dengesini değiştirerek bölgesel hava kalitesini düşürmekte ve çevresel etkilerin yanı sıra halk sağlığı (Manisalidis vd., 2020) açısından da ciddi bir tehdit oluşturmaktadır.

Orman yangınlarının çevresel ve atmosferik etkilerinin doğru biçimde analiz edilebilmesi, öncelikle bu olayların mekânsal ve zamansal olarak doğru şekilde saptanmasına bağlıdır. Bu alanda uzaktan algılama sistemleri ön plana çıkmaktadır. Özellikle arazi çalışmalarının kısıtlı olduğu geniş ölçekli yangınlarda, uydu tabanlı sistemler büyük avantaj sağlamaktadır. Teknolojideki ilerlemelerle birlikte kullanımı giderek artan uydu verileri, geniş alanları kapsaması ve düzenli aralıklarla sürekli gözlem imkânı sunması nedeniyle yangın tespiti ve izlenmesinde yaygın olarak tercih edilmektedir (Castro-Melgar vd., 2025). Çok bantlı (multispektral) algılayıcı aracılığıyla elde edilen veriler, yangın öncesi ve sonrası koşulların karşılaştırılmasına olanak tanımakta ve bu sayede yanmış alanların sınırlarının belirlenmesi ve yangın şiddetinin belirlenmesi mümkün olmaktadır. Bu amaçla en yaygın kullanılan uydu sistemleri bazıları Landsat 8/9 (Masek vd., 2020; Roy vd., 2014) ve Sentinel-2A/B (Spoto vd., 2012) misyonlarıdır. Elektromanyetik spektrumun görünür, yakın kızılötesi (NIR) ve kısa dalga kızılötesi (SWIR) bölgelerinde bantlara sahip olmaları ve kısa tekrar ziyaret süreleri, bu sistemleri yangın tespiti çalışmalarında öne çıkarmaktadır. Çok bantlı yapıları, dNBR (Fark Normalize Edilmiş Yanma Oranı), dNDVI (Fark Normalize Edilmiş Bitki Örtüsü İndeksi) ve dNDMI (Fark Normalize Edilmiş Nem İndeksi) gibi uzaktan algılama indekslerinin kullanılmasına imkân tanımaktadır. Bu indeksler yangın alanlarının tespiti, yangın şiddet sınıflarının belirlenmesi ve yangın etkilerinin analiz edilmesinde etkin bir şekilde kullanılmaktadır.

Yangın tespitindeki doğruluk, yangınların hava kalitesi üzerindeki etkilerinin modellenmesinde doğrudan belirleyici olmaktadır. Uzaktan algılama sistemleri, yalnızca optik algılayıcılarla elde edilen yeryüzü görüntülerinin değil, aynı zamanda atmosferik parametrelerin izlenmesinde de yaygın olarak kullanılan veri kaynağıdır. Gelişmiş uydu sistemleri sayesinde azot dioksit (NO_2), karbon monoksit (CO), kükürt dioksit (SO_2), ozon (O_3) ve aerosol optik derinliği (AOD) gibi hava kalitesiyle ilişkili parametreler küresel ölçekte sürekli olarak gözlemlenebilmektedir. Bu kapsamda Sentinel-5P, MODIS (Moderate Resolution Imaging Spectroradiometer) ve OMI (Ozone Monitoring Instrument) gibi uydular, atmosferin farklı katmanlarındaki gaz yoğunluklarını gözlemleyerek hava kirletici parametrelerin değerlendirilmesine olanak tanımaktadır (Qin vd., 2024). Uydu tabanlı atmosferik ölçümler, yersel istasyonu verilerinden farklı olarak atmosferin belirli bir sütunu boyunca toplam değerleri temsil ettiğinden dolayı yüzey seviyesinde ölçülen konsantrasyonlarla doğrudan karşılaştırılamamaktadır. Özellikle troposferik NO_2 konsantrasyonları, yalnızca emisyon şiddetine değil, aynı zamanda hava sıcaklığı rüzgâr hızı ve yönü, atmosferik taşıyım süreçleri ve bitki örtüsü yoğunluğu gibi çevresel faktörlerin etkileşimine de güçlü biçimde bağlıdır (Griffin vd., 2025). Bu çevresel ve meteorolojik değişkenler, ERA5 yeniden analiz veri seti gibi yüksek zamansal çözünürlüklü ürünler aracılığıyla tutarlı bir şekilde elde edilebilmektedir (Hersbach vd., 2020). Yeniden analiz ve uydu tabanlı veri setlerinin sınırlı mekânsal çözünürlüğü, özellikle yerel emisyon kaynaklarının baskın olduğu bölgelerde troposferik NO_2 dağılımının ayrıntılı biçimde temsil edilmesini güçleştirmektedir. Bu durum, makine öğrenmesi tabanlı yaklaşımlara olan gereksinimi artırmaktadır. Makine öğrenmesi yaklaşımları, uydu kaynaklı gözlemler ile yersel hava kalitesi ölçümleri arasındaki karmaşık ve doğrusal olmayan ilişkileri, yardımcı değişkenler aracılığıyla modelleme konusunda önemli bir avantaj sunmaktadır. Yersel NO_2 derişimlerinin tahmininde en yaygın kullanılan yöntemler arasında Çoklu Doğrusal Regresyon (MLR), Destek Vektör Regresyonu (SVR), Rastgele Orman (RF) ve Gradyan Artırmalı Karar Ağaçları (GBDT) gibi makine öğrenmesi modelleri ile Evrişimli Sinir Ağları (CNN) ve Uzun Kısa Süreli Bellek ağları (LSTM) gibi derin öğrenme yaklaşımları yer almaktadır. Bu modeller genellikle uydu gözlemleri meteorolojik ve çevresel yardımcı değişkenlerle birlikte kullanılmaktadır (Siddique vd., 2024). Bu yaklaşım, istasyonların seyrek olduğu bölgelerde uydu tabanlı tahminler yoluyla hava kalitesinin değerlendirilmesine olanak sağlamaktadır.

Makine öğrenmesi ve derin öğrenme tabanlı yaklaşımların yaygınlaşmasıyla birlikte, bu modellerin karar verme süreçlerinde hangi girdilerin ne ölçüde etkili olduğu daha fazla sorgulanmaya başlanmıştır. Yüksek doğruluk sunan bu modeller, çoğu zaman “kara kutu” yapıları nedeniyle karar verme süreçlerinin doğrudan anlaşılmasını zorlaştırmaktadır (Höhl vd., 2024). Bu durum, model çıktılarının yalnızca doğruluk açısından değil, yorumlanabilirlik açısından da değerlendirilmesini gerekli kılmıştır. Bu kapsamda geliştirilen açıklanabilir yapay zekâ yaklaşımları, karmaşık modellerin iç işleyişinin anlaşılmasına olanak sağlamaktadır. Özellikle açıklanabilir yapay zekâ yöntemleri arasında Shapley Additive Explanations (SHAP), modelden bağımsız yapısı ve tutarlı açıklamalar sunması nedeniyle yaygın olarak tercih edilmektedir (Aksoy vd., 2024).

1.1 Tezin Amacı

Bu tez çalışmasının temel amacı, 2025 yılında Türkiye ve Kaliforniya’da meydana gelmiş olan orman yangınlarının mekânsal dağılımını belirlemek ve orman yangınlarının yersel hava kalitesi üzerindeki etkilerini uzaktan algılama verileri ve makine öğrenmesi yöntemleri kullanarak açıklanabilir bir çerçevede ortaya koymaktır. Bu kapsamda, uydu verileri aracılığıyla yangın alanlarının tespiti ve şiddetinin belirlenmesi, yangın sonrası atmosferik kirleticilerde (NO_2 ve CO) meydana gelen değişimlerin analiz edilmesi ve bu kirleticilerin yersel düzeyde tahmin edilmesi hedeflenmiştir.

Bu genel amaç doğrultusunda çalışmanın özel amaçları aşağıda sıralanmaktadır:

- **Orman yangınından etkilenen alanların spektral indeksler kullanılarak tespiti ve karşılaştırılması**

Landsat ve Sentinel uydu verileri kullanılarak yanmış alanların belirlenmesi ve mekânsal dağılımlarının ortaya konması amaçlanmıştır. Bu kapsamda, dNBR, dNDVI ve benzeri spektral indeksler aracılığıyla yangın şiddeti sınıflandırılmakta ve farklı sensörler ile indeks tabanlı yöntemlerin yangın alanı tespit performansları karşılaştırılmıştır. Aynı zamanda mekânsal çözünürlüğün sonuçlara etkisi de incelenmiştir.

- **Makine öğrenmesi ile yangın öncesi ve sonrası yersel hava kalitesi tahmini**

Yangınlardan etkilenen alan ve dönemleri kapsayacak şekilde, Random Forest, LightGBM, XGBoost, CatBoost, Boosting yöntemleri ve SVR gibi makine öğrenmesi modelleri ile LSTM gibi derin öğrenme tabanlı modeller kullanılarak yersel NO₂ ve CO konsantrasyonları tahmin edilmiştir ve modellerin performansları karşılaştırılmıştır.

- **Model genellenebilirliğinin test edilmesi**

Eğitilen modelle farklı bir coğrafi bölgede uygulanarak test edilmiş ve model performansları mekânsal aktarılabilirlik açısından değerlendirilmiştir.

- **Açıklanabilir yapay zekâ ile model kararlarının yorumlanması**

SHAP gibi açıklanabilir yapay zekâ yöntemleri kullanılarak, farklı orman yangınları için makine öğrenmesi modellerine giren çevresel ve meteorolojik değişkenlerin emisyon tahminleri üzerindeki etkileri analiz edilmiştir. Bu sayede, modele en fazla katkı sağlayan ve tahminlerde belirleyici olan parametreler açık bir biçimde ortaya konulmuştur.

Bu amaçlar doğrultusunda, uzaktan algılama, yersel ölçümler ve makine öğrenmesi tabanlı yaklaşımlar bütüncül bir çerçevede ele alınarak, orman yangınlarının hava kalitesi üzerindeki etkilerinin hem mekânsal hem de zamansal boyutta değerlendirilmesi hedeflenmiştir. Çalışma kapsamında uygulanan yöntemler sayesinde, yangın kaynaklı hava kirliliği artışlarının daha doğru, genellenebilir ve açıklanabilir bir şekilde ortaya konması amaçlanmıştır. Elde edilen bulguların, hem akademik literatüre katkı sağlaması hem de hava kalitesi ve yangın yönetimi çalışmalarında karar destek süreçlerine bilimsel bir temel oluşturması beklenmektedir.

1.2 Literatür Araştırması

Literatürde orman yangınlarının tespiti ve etkilerinin analizi, uzaktan algılama verileri kullanılarak farklı yaklaşımlarla ele alınmaktadır. Makine öğrenmesi tabanlı yöntemler yaygınlaşmakla birlikte, optik uydu görüntülerinden türetilen spektral indisler yanmış alanların belirlenmesi ve yanma şiddetinin sınıflandırılmasında temel bir girdi olarak öne çıkmaktadır. Bu indisler, fiziksel olarak yorumlanabilir olmaları ve farklı veri setleri arasında karşılaştırılabilir sonuçlar sunmaları nedeniyle sıklıkla

tercih edilmektedir. Bulut tabanlı platformların kullanımıyla birlikte, indis temelli analizler geniş alanlar ve farklı zaman dilimleri için hızlı ve tekrarlanabilir hâle gelmiştir. Yangınların karasal etkilerinin yanı sıra, atmosfere salınan kirleticiler nedeniyle hava kalitesi üzerindeki sonuçları literatürde giderek daha fazla incelenmektedir. Uydu tabanlı atmosferik gözlemler kullanılarak yangın dönemlerinde NO₂, CO ve partikül madde konsantrasyonlarındaki değişimler çoğunlukla günlük zaman ölçeğinde ve sınırlı çalışma alanları için analiz edilmektedir. Bu çalışmalar, yangınların hava kalitesi üzerinde belirgin etkiler oluşturduğunu göstermektedir. Ancak yangın şiddeti ile hava kalitesi değişimlerinin daha geniş alanlarda ve farklı yangın bölgelerini kapsayacak şekilde birlikte değerlendirildiği çalışmalar sınırlı kalmaktadır. Son yıllarda uydu verilerinin meteorolojik ve çevresel değişkenlerle bütünleştirilmesiyle geliştirilen makine öğrenmesi tabanlı modeller, yüzey hava kirleticilerinin tahmininde yaygın olarak kullanılmaktadır. Bununla birlikte, yangın dönemlerine özgü kısa süreli ve ani kirlilik artışlarının modellenmesi, atmosferin dinamik yapısı ve yüksek zamansal çözünürlük gereksinimi nedeniyle zorluklar içermektedir. Özellikle bu tür olayları temsil edebilecek uygun zamansal çözünürlükte veri setlerinin oluşturulması, literatürde önemli bir sınırlayıcı unsur olarak öne çıkmaktadır. Makine öğrenmesi modellerinin yorumlanabilirliği, son yıllarda artan biçimde ele alınan bir araştırma alanıdır. Açıklanabilir yapay zekâ yaklaşımları, model çıktılarının hangi değişkenler tarafından ve hangi yönde etkilendiğini ortaya koymayı amaçlamaktadır. Ancak bu yaklaşımların sunduğu açıklamalar, kullanılan veri seti, çalışma alanı ve çevresel koşullara bağlı olarak farklılık gösterebilmektedir. Bu durum, orman yangınları gibi karmaşık ve dinamik süreçlerde hava kalitesi üzerindeki etkilerin açıklanabilirliği konusunda literatürde önemli boşluklar bulunduğunu göstermektedir.

Sonuç olarak, literatür araştırması tezin amaçları kapsamında dört ana başlıkta incelenmiştir.

1.2.1 Orman yangınlarının uzaktan algılama görüntüleri ile tespiti

Uzaktan algılama teknolojilerinin gelişmesiyle birlikte, orman yangınlarının mekânsal etkilerinin belirlenmesi ve şiddetinin analiz edilmesi alanında yapılan çalışmalar son yıllarda artış göstermiştir. Yüksek çözünürlüklü optik uydular, termal sensörler ve

atmosferik gözlem uyduları sayesinde yangın öncesi ve sonrası ekosistem değişimlerinin ayrıntılı biçimde incelenmesi mümkün hâle gelmiştir.

Özellikle Sentinel-2 görüntüleri, zamansal, spektral ve mekânsal çözünürlükleri sayesinde en yaygın tercih edilen uydu verileri arasında yer almaktadır. Arıkan ve diğ. (2022) tarafından gerçekleştirilen çalışmada da Sentinel 2A kullanılarak, 2021 yılında Antalya/Manavgat bölgesinde meydana gelen en büyük orman yangınlarından birinin makine öğrenmesi tabanlı yöntemler kullanılarak belirlenmesi amaçlanmıştır. Elde edilen dNBR, RdNBR, RBR, NDVI, BAI, SAVI ve MSAVI indisleri yanma şiddetine göre sınıflandırılmıştır. Üretilen bu indisler, görüntünün RGB bantları ile birlikte makine öğrenmesi modellerine dâhil edilerek GEE ortamında RF, SVM ve Classification and Regression Tree (CART) algoritmaları uygulanmıştır. Elde edilen sonuçlar, %98,57 genel doğruluk oranı ile en başarılı sınıflandırmanın RF algoritması tarafından indis destekli kompozit görüntüler kullanıldığında sağlandığını göstermiştir (Arıkan vd., 2022). Bu bulgular, yanmış alanların otomatik tespitinde spektral indisler ve makine öğrenmesi yöntemlerinin güçlü bir alternatif sunduğunu ortaya koymaktadır.

Sentinel-2 kullanılarak yapılan çalışmalardan biri de Japonya'da 2017 yılında meydana gelen ülkenin en büyük orman yangınında, ağaç tepe örtüsü (crown) hasarını belirlemek amacıyla yapılmıştır (Emang vd., 2020). Çalışmada NDVI, NDMI, NBR, NBR2 fark indisleri karşılaştırılmış ve dNDMI indisinin yanmamış ve yanmış alanları ayırmada en yüksek duyarlılığa (Separability Index = 0.9) sahip olduğu belirlenmiştir. NDMI'ye dayalı eşik değerler kullanılarak oluşturulan yangın şiddeti haritasına göre, yüksek şiddetli yanık alanları toplamın %33,1'ini oluşturmaktadır. Çalışma, özellikle taç yangınlarında oluşan yapısal ve nem kaynaklı değişimlerin NDMI tarafından daha etkin yakalandığını göstermektedir.

Başka bir çalışmada ise, Bosco Difesa Grande ormanında 2017 ve 2021 yıllarında meydana gelen yangınların bitki örtüsü üzerindeki etkileri uzaktan algılama yöntemleriyle analiz edilmiştir (Zahabnazouri vd., 2025). Sentinel-2 verileri GEE ortamında işlenerek NBR ve NDVI indeksleri hesaplanmış, yanma şiddeti dNBR, bitki örtüsü kaybı ve toparlanma süreci ise dNDVI ve çok yıllık NDVI zaman serileri kullanılarak değerlendirilmiştir. Çalışma alanı, yangın geçmişine göre yanmamış, tek kez yanan ve iki kez yanan bölgeler olarak sınıflandırılmıştır. Analiz sonuçları, düşük şiddetli yangın alanlarında daha hızlı bir toparlanma gözlenirken, yüksek şiddetli ve

tekrarlayan yangınların bitki örtüsü toparlanmasını belirgin biçimde yavaşlattığını göstermiştir.

Uzaktan algılama verileri kullanılan başka bir çalışmada (Yilgan vd., 2025) ise Bohemian Switzerland Ulusal Parkı'nda 2022 yılında gerçekleşen orman yangınının çevresel etkileri analiz edilmiştir. Landsat-8 OLI/TIRS ve Sentinel-5P TROPOMI verileri GEE ortamında işlenerek NDVI, NDMI, NBR, LST ve SMI indisleri hesaplanmış; yangın sonrası bitki örtüsü, toprak nemi ve yüzey sıcaklığındaki değişimler analiz edilmiştir. Sonuçlar, yangın sonrası dönemde NDVI ve NDMI değerlerinde belirgin azalma, yüzey sıcaklığında ise ortalama 2.5 °C'lik artış olduğunu göstermiştir. Ayrıca Sentinel-5P NO₂ verileri, yangın sonrasında atmosferik azot dioksit konsantrasyonunun yaklaşık iki katına çıktığını ortaya koymuştur. Yaklaşık 13.2 km²'lik yanmış alan belirlenmiş ve Landsat tabanlı tahminlerin Avrupa Orman Yangını Bilgi Sistemi (EFFIS) raporlarıyla tutarlı sonuçlar verdiği tespit edilmiştir.

Literatürde yer alan bu çalışmalar, uzaktan algılama verilerinin yangın sonrası bitki örtüsü, toprak nemi, yüzey sıcaklığı ve atmosfer bileşenlerindeki değişimlerin analizinde etkin biçimde kullanılabildiğini göstermektedir. Özellikle NDVI, NBR, NDMI gibi spektral indislerin GEE platformunda uygulanması, geniş alanlarda hızlı, maliyetsiz ve tekrarlanabilir yangın tespiti sağlamaktadır.

1.2.2 Makine öğrenmesi yöntemleriyle NO₂, CO tespiti

Uydu tabanlı uzaktan algılama verilerinin yüksek mekânsal ve zamansal çözünürlüğe ulaşmasıyla birlikte, atmosferik kirleticilerin makine öğrenmesi yöntemleriyle tahmin edilmesine yönelik çalışmalar hız kazanmıştır. NO₂ ve CO gibi kısa ömürlü gazlar, orman yangınları sırasında atmosfere yoğun biçimde salınmaları ve yüzey seviyesinde hızlı değişimler göstermeleri nedeniyle yangın kaynaklı hava kalitesi etkilerinin izlenmesinde önemli göstergeler olarak değerlendirilmektedir. Sabit ölçüm istasyonlarının sınırlı olduğu bölgelerde, makine öğrenmesi modelleri uzaktan algılama, meteorolojik ve topografik verilerle birleştirilerek geniş alanlarda güvenilir tahminler üretmektedir.

Çin genelinde 2007-2020 yılları arasını kapsayan bir çalışmada (Shao vd., 2023), yüzey NO₂ konsantrasyonlarını tahmin etmek amacıyla XGBoost algoritmasını kullanmıştır. Girdi olarak OMI ve GOME-2 uydularından elde edilen troposferik NO₂ kolon yoğunlukları, ERA5 meteorolojik parametreleri (sıcaklık, bağıl nem, rüzgâr hızı,

sınır tabaka yüksekliği vb.) ve arazi kullanım verileri modele dahil edilmiştir. Günlük bazda $0.1^{\circ} \times 0.1^{\circ}$ çözünürlükte yapılan test veriseti üzerindeki tahminlerde $R^2 = 0.75$ ve $RMSE = 9.11 \mu g/m^3$ elde edilmiştir.

Bilgiç & Elbir (2025) tarafından Türkiye’de gerçekleştirilen bir çalışmada, Sentinel-5P TROPOMI ve ERA5-Land verilerini kullanarak İzmir ilinde 2022-2023 yıllarına ait saatlik NO_2 konsantrasyonlarını tahmin etmiştir. Çalışmada RF modeli uygulanmış, bağımsız değişkenler olarak troposferik NO_2 kolon yoğunluğu, yüzey sıcaklığı, rüzgâr bileşenleri, albedo, yaprak alanı indeksi (LAI) ve sayısal yükselti modeli (DEM) kullanılmıştır. Model 10 katlı çapraz doğrulama ile test edilmiş ve $R^2=0.71$, $RMSE=14.52 \mu g/m^3$, $MAE=8.88 \mu g/m^3$ olarak hesaplanmıştır.

Başka bir çalışma (Cedeno Jimenez & Brovelli, 2023), kentsel ölçekte yersel NO_2 konsantrasyonlarının uydu ve meteorolojik veriler kullanılarak tahmin edilmesini amaçlamaktadır. Sentinel-5P TROPOMI NO_2 troposferik sütun verileri ile ERA5 meteorolojik değişkenleri entegre edilerek, Milano’daki 13 ARPA (Regional Environment Protection Agency) istasyonunun ölçümleri referans alınmıştır. Farklı makine öğrenmesi ve doğrusal modelleri karşılaştırarak Random Forest özellik seçimi ile birleştirilmiş SVR ve MLPR (Multi Layer Perceptron Regressor) modelinde en iyi sonucu elde etmişlerdir. Günlük NO_2 tahminlerinde ortalama $R^2 = 0.76$ ve $NRMSE \approx \%56$ elde edilmiştir. Sonuçlar, yer istasyonlarının sınırlı olduğu bölgelerde uydu tabanlı, düşük maliyetli hava kalitesi izleme için güçlü bir alternatif sunduğunu göstermektedir.

Ngo ve arkadaşları (2023) Vietnam genelinde günlük yersel NO_2 konsantrasyonlarının 1×1 km mekânsal çözünürlükte tahmin edilmesini amaçlamıştır. Analizde OMI ve Sentinel-5P TROPOMI troposferik NO_2 verilerini kullanmışlardır. Bu verileri, ERA5 tabanlı meteorolojik değişkenler ile arazi örtüsü ve yol yoğunluğu bilgileriyle bütünleştirerek farklı Karma Etki Modelleri (MEM), Sinir ağları ve LightGBM gibi yöntemleri karşılaştırmışlardır. Sonuçlar, LightGBM modelinin en yüksek performansı sağladığını ve Pearson korelasyon katsayısı $r = 0.77$, $RMSE = 7.93 \mu g/m^3$ ve ortalama bağıl hata (MRE) = $\%42.6$ değerlerine ulaştığını göstermektedir. Üretilen NO_2 haritaları yer istasyonu ölçümleriyle güçlü bir uyum sergilemiştir. Bu yaklaşım, ulusal ölçekte hava kalitesi izleme için güvenilir bir yöntem sunmaktadır.

Siddique ve diğ. (2024) tarafından gerçekleştirilen geniş kapsamlı bir derleme çalışmasında, yüzey NO₂ tahmininde kullanılan makine öğrenmesi ve derin öğrenme yöntemleri sistematik olarak karşılaştırılmıştır. Çalışma, literatürde en sık kullanılan modellerin RF, XGBoost, SVR, Yapay Sinir Ağları (ANN) ve Evrişimsel Sinir Ağları (CNN) olduğunu göstermektedir. Yardımcı değişken olarak ise ERA5 meteorolojik verileri, MODIS AOD, arazi örtüsü sınıfları (LULC), nüfus yoğunluğu, yol ve trafik verileri ile DEM bilgilerinin kullanıldığını rapor etmiştir. Bu derleme çalışması, makine öğrenmesi tabanlı modellerin klasik çoklu doğrusal regresyon (MLR) yaklaşımlarına kıyasla genel olarak daha iyi performans gösterdiğini ortaya koymaktadır. İncelenen çalışmaların büyük bir bölümünde Random Forest ve XGBoost gibi ağaç tabanlı algoritmaların RMSE değerlerinin 10 µg/m³'ün altına düştüğü ve karmaşık, doğrusal olmayan ilişkileri daha iyi temsil edebildiği görülmektedir. Bu modeller, daha güçlü genelleme kabiliyetleri nedeniyle yüzey NO₂ tahmininde öne çıkmaktadır.

Sonuç olarak, literatürde yer alan çalışmalar, makine öğrenmesi tabanlı yöntemlerin özellikle RF, XGBoost ve derin öğrenme modellerinin NO₂ konsantrasyonlarının tahmininde yüksek doğruluk sağladığını göstermektedir. Bu modellerin başarısı, Sentinel-5P, OMI ve GOME-2 gibi yüksek çözünürlüklü uydu sensörlerinden elde edilen troposferik kolon verilerinin ERA5-Land meteorolojik verileri, arazi örtüsü, topografya ve sosyoekonomik değişkenlerle bütünleştirilmesine dayanmaktadır. Böylece, ölçüm istasyonlarının az olduğu bölgelerde bile geniş alanlı hava kalitesi haritalarının oluşturulması mümkün hale gelmiştir.

Literatürde NO₂ ve CO parametresi için makine öğrenmesi yaklaşımlarıyla tahmin eden çalışmalar bulunmaktadır (Çizelge 1.1). Bu çalışmalar farklı amaçlar doğrultusunda yapılmaktadır. Bu nedenle kullanılan veriler, yöntemler ve yardımcı değişkenler farklılık göstermektedir. Çizelge 1.1'de farklı çalışmalar listelenmiş ve sonuçları etkileyebilecek zamansal çözünürlük, yardımcı değişkenler, modeller gibi başlıklar altında karşılaştırılmıştır.

Çizelge 1.1: Literatürde NO₂ & CO tahminine yönelik çalışmaların karşılaştırılması.

Parametre	Çalışma alanı	Amaç	Zaman aralığı & Çözünürlük	Veri	Yöntem	R ²	RMSE	Açıklanabilirlik	Referans
NO ₂	Doğu Asya (Çin, Güney Kore, Japonya)	Hava kalitesi izleme	May 14, 2018 - November 12, 2020 & Günlük	Sentinel-5P NO ₂ & O ₃ VCD, GOCI aerosol, UM RDAPS meteoroloji, MODIS arazi örtüsü	MLR SVR RF XGB LGBM	0.54 0.58 0.66 0.7 0.7	5.86 ppb 5.95 ppb 5.07 ppb 4.75 ppb 4.76 ppb	SHAP (uydu kaynaklı NO ₂ ve sınır tabaka yüksekliği en etkili ilk iki veri)	(Kang vd., 2021)
NO ₂	Çin	Yersel NO ₂ tahmini	2018-2020 & Günlük	Sentinel-5P NO ₂ , ERA5/HRCLDAS meteoroloji, arazi kullanımı, yol ağı, nüfus	XGB	0.73	4.47 µg/m ³	-	(Chi vd., 2022)
NO ₂	Avrupa geneli	Yersel NO ₂ tahmini	2019-2021 & Günlük	Sentinel-5P NO ₂ , VIIRS, MODISAqua, ERA5 Land, MERIT DEM	XGB	0.66	13.07 µg/m ³	SHAP (uydu kaynaklı NO ₂ , VIIRS gece ışıkları ve NDVI sırasıyla en etkili 3 değişken)	(Shetty vd., 2024)
NO ₂	Vietnam	Günlük yersel NO ₂ tahmini	2019-2022 & Günlük	OMI + Sentinel-5P NO ₂ , yersel istasyonlar, WRF meteoroloji, NDVI, yol yoğunluğu	MEM (Mied Effect Model) - 10 fold CV Neural Network - 10 fold CV LightGBM - 10 fold CV	0.56 0.55 0.77	10.46 µg/m ³ 10.43 µg/m ³ 7.93 µg/m ³	-	(Ngo vd., 2023)
NO ₂	Çin	Yersel NO ₂ tahmini ve COVID-19'un NO ₂ üzerindeki etkisini ortaya koymak.	2019 & Günlük	Sentinel-5P, ERA5, MEIC Emissions, MCD12C1 arazi kullanımı, SRTM DEM	ET (Extra Trees) RF GBDT (Gradient Boosting Decision Trees) DT (Decision Trees) LSTM RF SVR	0.802 0.796 0.65 0.614 - - -	3.518 µg/m ³ 3.657 µg/m ³ 4.674 µg/m ³ 4.911 µg/m ³ 6.82 µg/m ³ 7.13 µg/m ³ 6.37 µg/m ³	-	(Long vd., 2022)
NO ₂	Milan / İtalya	Yersel NO ₂ tahmini	1 January 2019 - 28 September 2022 & Günlük	Sentinel-5P NO ₂ , ARPA meteoroloji	Decision Tree Regressor Gradient Tree Boosting MLPR (Multi-Layer Perceptron Regressor)	- - -	9.61 µg/m ³ 6.8 µg/m ³ 6.42 µg/m ³	-	(Cedeno Jimenez & Brovelli, 2023)

Çizelge 1.1 (devam) : Literatürde NO₂ & CO tahminine yönelik çalışmaların karşılaştırılması.

Parametre	Çalışma alanı	Amaç	Zaman aralığı & Çözünürlük	Veri	Yöntem	R ²	RMSE	Açıklanabilirlik	Referans
NO ₂	Çin	Hava kalitesindeki insan etkisini incelemek	2007-2020 & Günlük	OMI + GOME-2 NO ₂ , ERA5 meteoroloji, arazi kullanımı, nüfus	SMOTE XGB	0.75	9.11 µg/m ³	SHAP (uydu kaynaklı NO ₂ sınır tabaka yüksekliği ve Yapılaşmış alan en etkili ilk üç değişken)	(Shao vd., 2023)
NO ₂	Beijing, Tianjin, Hebei / Çin	Hava kalitesini izlemek	2019–2022 & Günlük	Sentinel-5P NO ₂ , ERA5, MODIS/Sentinel-2 NDVI, SRTM DEM, WorldPop nüfus, OpenStreetMap yol ağı	CNN GNNWR GTNNWR RF	0.69 0.76 0.89 0.7	10.1 µg/m ³ 8.72 µg/m ³ 6.11 µg/m ³ 10.06 µg/m ³	-	(C. Liu vd., 2023)
NO ₂	İzmir	Hava kalitesini izlemek	2022-2023 & Saatlik	Sentinel-5P NO ₂ , ERA5 Land, SRTM DEM	RF	0.71	14.52 µg/m ³	Özellik önem analizi (vejetasyon, Sentinel-5P verileri, albedo ve yükselti en etkili veriler)	Bilgiç & Elbir, 2025
NO ₂	Çin / Sichuan Eyaleti	Yersel NO ₂ tahmini	1 Ocak – 31 Aralık, 2021 & günlük	TROPOMI troposferik NO ₂ , ERA5 meteoroloji, nüfus (POP), DEM, arazi kullanımı (LCT), NDVI OMI & TROPOMI NO ₂ sütunları, CAMS NO ₂ (gap-filling), ERA5 / ERA5-Land meteoroloji, yol ağı, yükselti (SRTM)	XGBoost (10-fold cv) RF (10-fold cv)	0.875 0.829	4.774 µg/m ³ 5.591 µg/m ³	SHAP (Sentinel-5P NO ₂ , boylam ve popülasyon en etkili ilk üç değişken)	(Deng vd., 2022)
NO ₂	Mexico City	Yersel NO ₂ tahmini	2005-2019 & günlük		RF+XGBoost+GAM	0.87	3.95 µg/m ³	Özellik önem analizi (uydu NO ₂ , rüzgâr, yol uzunluğu en etkililer)	(He vd., 2023)
NO ₂	Çin	COVID-19 etkilerini değerlendirmek	1 Haziran 2018 – 31 Mart 2020 & günlük	TROPOMI, NDVI, GEOS-FP, arazi örtüsü, yol ağı, nüfus yoğunluğu	LightGBM	0.72	8.448 µg/m ³	Özellik önem analizi (uydu kaynaklı NO ₂)	
CO					LightGBM	0.55	0.325 mg/m ³	Özellik önem analizi (rüzgâr bileşenleri uydu kaynaklı NO ₂ verisine göre daha etkili çıkmıştır.)	(Wang vd., 2021)

1.2.3 Orman yangınlarının hava kalitesi ile ilişkisi

Orman yangınları yalnızca ekosistem üzerinde fiziksel tahribata yol açmakla kalmayıp, aynı zamanda büyük miktarda partikül madde (PM), karbon monoksit (CO), azot dioksit (NO₂), ozon (O₃), uçucu organik bileşikler (VOC) ve diğer sera gazlarının atmosfere salınmasıyla hava kalitesini ciddi biçimde etkilemektedir. Bu kirleticiler, yangın sahasının çevresiyle sınırlı kalmayıp, uzun menzilli taşınım yoluyla yüzlerce kilometre uzağa kadar taşınabilmektedir. Son yıllarda uydu tabanlı uzaktan algılama teknikleri, bu kirleticilerin mekânsal dağılımını ve taşınım yönlerini belirlemede yaygın olarak kullanılmaya başlanmıştır.

Li ve diğ. (2025), Kuzey Amerika yüksek enlemlerinde meydana gelen orman yangınlarının hava kalitesine etkisini GOES-R (ABI), VIIRS ve Sentinel-5P verilerini birleştirerek incelemiştir. Çalışmada, CONUS için geliştirilen RAVE algoritmasının yüksek enlemlere uyarlanmış bir sürümü kullanılarak, ABI ve VIIRS yangın radyatif gücü (FRP) verilerinin füzyonuna dayalı saatlik emisyon tahmin yöntemi uygulanmış ve bu yaklaşım ile PM_{2.5}, CO ve NO₂ gibi kirleticilerin saatlik emisyonları hesaplanmıştır. 2021 ve 2022 yıllarında sırasıyla 0.54 Tg ve 0.40 Tg PM_{2.5} emisyonu tespit edilmiş, bunların %86'sının yaz aylarında meydana gelen boreal orman yangınlarından kaynaklandığı belirlenmiştir. Sentinel-5P gözlemleriyle yapılan karşılaştırmalarda CO emisyonları için $R^2 = 0.94$ korelasyon değeri elde edilmiştir. Bu sonuç, uzaktan algılama temelli yüksek zamansal çözünürlüklü emisyon verilerinin bölgesel hava kalitesi modellerinin doğruluğunu önemli ölçüde artırabileceğini göstermektedir.

Shrestha vd., (2025) Nepal'de 2020-2021 yıllarında meydana gelen orman yangınlarının hava kalitesi üzerindeki etkisini WRF-Chem kimyasal taşınım modeli ve Sentinel-5P verilerini entegre ederek incelemiştir. Araştırma, yangın dönemlerinde NO₂'de %120, PM_{2.5}'te %48, PM₁₀'da %35, CO'da %32, SO₂'de %28 oranında artış meydana geldiğini ortaya koymuştur. Uydu verileriyle model çıktıları arasında $r > 0.8$ düzeyinde yüksek korelasyon saptanmıştır. Çalışma, yangın kaynaklı emisyonların yalnızca yerel değil, aynı zamanda bölgesel hava kalitesi üzerinde de ciddi etkiler yarattığını ve özellikle Himalaya bölgesinde sınır ötesi kirlilik taşınımının önemli bir tehdit olduğunu göstermiştir.

Arjantin'in Paraná Nehri Deltası'nda yapılan bir çalışmada (Binet vd., 2024) ise 2022 yılı Eylül ayında meydana gelen yoğun yangınların TROPOMI verileriyle troposferik NO₂ dağılımı üzerindeki etkilerini incelemiştir. VIIRS tabanlı FRP, AOD ve MAIAC duman enjeksiyon yüksekliği verileriyle birlikte değerlendirilmiştir. Yangın sırasında troposferik NO₂ sütun yoğunluğu 1.66×10^{16} molekül/cm²'ye kadar ulaşmış ve özellikle Rosario kenti çevresinde AOD değerleri 0.9-1.0 aralığında ölçülmüştür. HYSPLIT modeliyle yapılan hava kütlesi analizleri, duman bulutlarının 0-1500 m yükseklik aralığında taşındığını ve şehir merkezlerine ulaştığını göstermiştir. Bu sonuçlar, yangın kaynaklı NO₂ artışlarının kısa sürede kent merkezlerinde hava kalitesini bozduğunu ve solunum yolu rahatsızlıklarını tetikleyebileceğini ortaya koymuştur.

Başka bir çalışmada (Schneider vd., 2021) yersel istasyonu verileri ve Sentinel-5P uydu gözlemlerini, HYSPLIT geri-iz analizi ve uydu tabanlı yangın sıcak nokta verileriyle birleştiren Trajectory–Fire Interception Method (TFIM) yaklaşımını kullanmıştır. Bu yöntem kapsamında, Kanada'nın batı şehirlerinde 2018-2023 yılları arasında meydana gelen büyük orman yangınlarının PM_{2.5}, NO₂, CO ve O₃ üzerindeki etkileri analiz edilmiştir. Sonuçlar, yangın etkili dönemlerde PM_{2.5} konsantrasyonlarının belirgin biçimde arttığını, NO₂ ve CO seviyelerinde ise daha sınırlı ancak istatistiksel olarak anlamlı yükselişler olduğunu göstermiştir. Araştırma, özellikle yaz aylarında atmosferik durağanlık koşullarının kirleticilerin şehirler üzerinde daha uzun süre kalmasına neden olarak hava kalitesi üzerindeki olumsuz etkileri artırdığını ortaya koymaktadır.

Orman yangınlarının hava kalitesi üzerindeki etkileri farklı coğrafyalarda benzer eğilimler göstermektedir. Portekiz'in kuzeyinde yapılan çalışma, yangın sezonunda PM₁₀, PM_{2.5}, O₃ ve NO₂ seviyelerinin belirgin biçimde arttığını, bu artışların acil servis başvuruları, sağlık harcamaları ve erken ölümlerle ilişkili olduğunu ortaya koymaktadır (Barros vd., 2025). Benzer şekilde, Kaliforniya'da yürütülen uydu temelli analizler, kentsel alanlarda NO₂ azalırken ormanlık ve kırsal bölgelerde özellikle yangınlar ve sıcaklığa duyarlı toprak NO_x emisyonları nedeniyle NO₂ seviyelerinin arttığını göstermektedir (Wang vd., 2023). Bu bulgular, iklim değişikliğiyle şiddeti artan yangınların hem hava kalitesi hem de halk sağlığı açısından küresel ölçekte önemli bir risk oluşturduğunu göstermektedir.

Genel olarak, literatürdeki çalışmalar, orman yangınlarının hava kalitesi üzerindeki etkilerinin küresel ölçekte belirgin olduğunu ortaya koymaktadır. Özellikle Sentinel-

5P (TROPOMI), VIIRS, MODIS ve GOES-R gibi uyduların sağladığı yüksek zamansal ve mekânsal çözünürlüklü veriler, yangın kaynaklı kirleticilerin izlenmesinde kritik rol oynamaktadır.

1.2.4 Açıklanabilir yapay zeka yaklaşımları ile modellerin incelenmesi

Makine öğrenmesi tabanlı modeller yüksek doğruluk sağlamalarına rağmen, bu modellerin karar verme süreçleri genellikle “kara kutu” niteliği taşımaktadır. Tahmin sonuçlarının nedenlerini açıklamakta yaşanan zorluk, model güvenilirliği açısından önemli bir dezavantaj oluşturmaktadır. Bu nedenle, son yıllarda Açıklanabilir Yapay Zekâ (Explainable Artificial Intelligence, XAI) yaklaşımları daha yaygın kullanılmaktadır. Bu yaklaşımlar, modellerin karar süreçlerini daha şeffaf hale getirir, değişkenlerin tahminler üzerindeki etkisini ortaya koyar ve tahminlerin fiziksel tutarlılığının değerlendirilmesini sağlar. Bu amaçla geliştirilen SHAP (Shapley Additive Explanations), LIME (Local Interpretable Model-Agnostic Explanations), Deep SHAP, Gradient SHAP ve PDP (Partial Dependence Plot) gibi yöntemler, hava kalitesi tahminlerinde en yaygın kullanılan açıklama teknikleri arasında yer almaktadır.

İtalya genelinde belediye ölçeğinde yapılan bir çalışmada (Fania vd., 2024) günlük yüzey hava kirleticilerinin tahmini için geliştirilen makine öğrenmesi modellerinin karar süreçleri SHAP analizi ile incelenmiştir. SHAP sonuçları, nüfus yoğunluğunun NO₂ tahminlerinde en baskın değişken olduğunu ve uydu kaynaklı gaz kolonlarından daha güçlü bir etkiye sahip bulunduğunu göstermektedir. Partikül maddeler için rüzgâr hızı temel belirleyici faktör olarak öne çıkmış ve konsantrasyonlarla negatif ilişki göstermiştir. Ayrıca yağış ve basınç gibi meteorolojik değişkenlerin etkileri fiziksel süreçlerle uyumlu bulunmuştur. SHAP analizi, model çıktılarının yorumlanabilirliğini artırarak sonuçların çevresel açıdan tutarlı biçimde değerlendirilmesine olanak sağlamıştır.

Vega García & Aznarte, (2020) yaptıkları çalışmada, Madrid’de ölçülen NO₂ konsantrasyonları için geliştirdikleri LSTM modelinin çıktılarını Deep SHAP yöntemiyle yorumlamıştır. SHAP analizleri, model tahminlerinin hangi değişkenler tarafından ve hangi yönde etkilendiğini ortaya koymaktadır. Sonuçlar, rüzgâr hızının NO₂ tahminleri üzerinde en yüksek etki değerine (impact value) sahip değişken olduğunu göstermiştir. Düşük rüzgâr hızları pozitif SHAP değerleriyle

ilişkilendirilirken, yüksek rüzgâr hızları NO₂ konsantrasyonlarını düşürücü yönde etki etmektedir. Gecikmeli NO₂ değerleri, sıcaklık ve basınç değişkenleri de modele anlamlı katkı sağlayan önemli girdiler olarak belirlenmiştir.

Başka bir çalışmada (Shao vd., 2023), Çin genelinde 2007-2020 dönemine ait yüzey NO₂ konsantrasyonları açıklanabilir makine öğrenmesi yaklaşımıyla analiz edilmiştir. XGBoost modeli kullanılarak tahmin edilen NO₂ değerleri, SHAP yöntemiyle yorumlanmıştır. SHAP sonuçları, troposferik kolon NO₂'nin yüzey NO₂ değişiminin en baskın belirleyicisi olduğunu ortaya koymuştur. Özellikle yüksek kirlilik bölgelerinde kolon NO₂, pozitif ve yüksek SHAP etki değerleriyle yüzey konsantrasyonlarını artırmaktadır. Sınır tabakası yüksekliği, sıcaklık, rüzgâr gibi meteorolojik değişkenler ve sosyo-ekonomik faktörler ise ikincil ancak anlamlı katkılar sunarak NO₂'nin mekânsal ve zamansal değişimini şekillendirmektedir.

Shetty ve arkadaşları (2024) tarafından yapılan çalışmada Sentinel-5P TROPOMI verileri ve yardımcı değişkenler kullanılarak Avrupa genelinde 1 km çözünürlükte günlük yüzey NO₂ tahmini üretilmiştir. SHAP analizi, model çıktılarının hangi değişkenler tarafından baskın biçimde yönlendirildiğini açıkça ortaya koymaktadır. En etkili değişken TROPOMI troposferik NO₂ sütun yoğunluğu olup, yüzey NO₂ ile güçlü bir ilişki sergilemektedir. Bunu sırasıyla VIIRS gece ışıkları, sınır tabakası yüksekliği ve NDVI izlemektedir. Bu iki yardımcı değişkenin yüksek SHAP katkıları, bu değişkenlerin modelde anlamlı ve istikrarlı açıklayıcı rol üstlendiğini göstermektedir. Bu sonuçlar, model kararlarının yorumlanabilirliğini desteklemektedir.

Siddique ve diğ. (2024), makine öğrenmesi tabanlı hava kalitesi tahminlerinde açıklanabilir yapay zekâ uygulamalarını inceleyen kapsamlı bir derleme çalışması yürütmüştür. Çalışmada, SHAP, LIME, PDP ve ICE gibi yöntemlerin Random Forest, XGBoost, CNN ve LSTM modellerinde kullanılarak değişken önem sıralamalarının belirlenmesinde ve tahminlerin yorumlanmasında kritik rol oynadığı vurgulanmıştır. Derleme kapsamında, SHAP analizlerinde en baskın değişkenlerin genellikle uydu kaynaklı NO₂ sütun verileri, sınır tabakası yüksekliği (BLH), rüzgâr hızı ve yönü, yüzey sıcaklığı ile yüzey basıncı gibi meteorolojik parametreler olduğu anlaşılmaktadır. Ayrıca, arazi örtüsü ve bitki örtüsü yoğunluğu yüzey ve atmosfer etkileşimleriyle ilişkili olarak öne çıkmaktadır.

Bu beş çalışma birlikte değerlendirildiğinde, açıklanabilir yapay zekâ yaklaşımlarının hava kalitesi modellemelerinde fiziksel anlamda yorumlanabilirliğini güçlendiren önemli bir araç olduğu görülmektedir. SHAP, LIME ve Deep SHAP gibi yöntemler, NO₂ ve PM_{2.5} tahminlerinde hangi değişkenlerin en etkili olduğunu açık biçimde ortaya koymakta, böylece makine öğrenmesi modellerinin “kara kutu” yapısının çözülmesine ve çevresel süreçlerle ilişkilerinin daha iyi anlaşılmasına katkı sağlamaktadır.





2. ÇALIŞMA ALANI VE VERİ

2.1 Çalışma Alanı


Bu çalışma kapsamında iki farklı çalışma alanı belirlenmiştir. Çalışma alanları, özellikle 2025 yılında orman yangınlarının yoğun olarak gözlemlendiği ve yersel hava kalitesi verilerinin düzenli biçimde ölçüldüğü istasyonların bulunduğu bölgeler dikkate alınarak seçilmiştir. Türkiye’de kuraklıkla daha da güçlenen sıcaklık artışları, yağış eksikliği, insan kaynaklı hatalar, kundaklama ve yeterli önleyici tedbirlerin alınmaması gibi nedenler sonucunda son yıllarda orman yangınlarında belirgin bir artış gözlemlenmektedir. Uzun dönemli iklim analizlerine dayanan çalışmalar, Türkiye genelinde sıcak hava dalgalarının sıklığının, süresinin ve şiddetinin istatistiksel olarak anlamlı biçimde arttığını ortaya koymaktadır (Tatlı & Serkendiz, 2025). Özellikle iklim değişikliği kaynaklı yüksek yaz sıcaklıkları Ege, Akdeniz ve Marmara gibi kıyı bölgelerinde yangın oluşumunu kolaylaştırmaktadır. Bu bölgelerde rüzgâr koşulları ve kuraklık yangınların yayılma hızını artırmaktadır. 2025 yaz döneminde Türkiye genelinde meydana gelen geniş ölçekli orman yangınları on binlerce hektar alanın yanmasına neden olmuş ve can kayıplarıyla sonuçlanmıştır. Bu süreçte 50.000’den fazla kişinin güvenli bölgelere tahliye edildiği, yüzlerce konut ve işyerinin zarar gördüğü ve toplamda en az 17 kişinin yaşamını yitirdiği rapor edilmiştir (Anadolu Ajansı, 2025; Echo Flash, 2025; Keeping vd., 2025). Ayrıca yakın bölgelerde eş zamanlı olarak meydana gelen yangınlar söndürme ekiplerinin kapasitesini bölmektedir. Bu durum yangınların kontrol altına alınma ve soğutma süreçlerini uzatmaktadır. Benzer bir durum Ocak ayında ABD’nin Kaliforniya eyaletinde Los Angeles çevresinde aynı zaman aralığında çıkan birden fazla orman yangınında da gözlemlenmiştir. Yerleşim alanlarına yakın bölgelerde başlayan bu yangınlar hızla ilerleyerek 16.255 konutun tamamen yok olmasına, 2.090 konutun ise hasar görmesine neden olmuştur (Wall vd., 2025). Bu yangınlar sırasında en az 29 sivil yaşamını yitirmiş ve yangına maruz kalan nüfusta kardiyovasküler ve solunum sistemiyle ilişkili telesağlık başvurularında ilk hafta içinde yüzde 35’in üzerinde artış gözlemlenmiştir (Casey vd., 2025; Schollaert vd., 2025). Bu nedenle çalışma alanları, artan yangın

sıklığı ve şiddetinin hava kalitesi üzerindeki etkilerinin yersel ve uydu verileriyle birlikte analiz edilebileceği bölgeler arasından belirlenmiştir.

2.1.1 Türkiyede'ki çalışma bölgesi

Bu araştırmada Türkiye genelinde yapılan ön değerlendirmeler sonucunda, hava kalitesi verilerinin mekânsal ve zamansal sürekliliğinin en yüksek olduğu bölge olan Batı ve Güneybatı Anadolu çalışma alanı olarak belirlenmiştir. Bu alan, İzmir, Aydın, Muğla, Antalya, Burdur, Isparta, Denizli, Afyonkarahisar, Uşak, Manisa, Balıkesir, Bilecik, Bursa, Çanakkale, Yalova, Kocaeli, Sakarya, Tekirdağ, Kırklareli ve Edirne illerini kapsamaktadır.

Çalışma alanı, Şekil 2.1'de görüldüğü gibi 2025 yılında orman yangınlarının fazla olduğu bölgeleri içermektedir. Yersel NO₂ ve CO ölçümleri, Çevre, Şehircilik ve İklim Değişikliği Bakanlığı'na bağlı istasyonlardan alınmış, bu istasyonların veri sürekliliği ve konumsal dağılımı esas alınarak nihai alan sınırları belirlenmiştir. Bu bölge, kıyısız meteorolojik etkiler, farklı bitki örtüsü yoğunlukları ve topografik çeşitlilik sayesinde hem yangın dinamiklerinin hem de atmosferik kirleticilerin modellenmesi açısından uygun bir temsiliyet sağlamaktadır.



Şekil 2.1 : 2025 yılında Türkiye'de gerçekleşen orman yangınlarının konumları.


Çalışma alanı büyük kentsel merkezler ile kırsal bölgelerin bir arada bulunduğu heterojen bir yapıya sahiptir. Bu özellik, NO₂ ve CO gibi atmosferik kirleticilerin hem insan kaynaklı faaliyetler hem de doğal süreçler kapsamında birlikte değerlendirilmesine olanak sağlamaktadır. Ayrıca Türkiye'nin farklı iklim kuşaklarının kesiştiği bu alan, farklı çevresel koşulları aynı kapsamda barındırdığı için geliştirilen modellerin genellenebilirliğini ve taşınabilirliğini artırmakta, farklı

ekolojik ortamlarda benzer performans göstermesini sağlamaktadır. Bu durum, hem yangın sonrası NO₂ ve CO değişimlerinin hem de makine öğrenmesi tabanlı tahmin modellerinin güvenilir biçimde test edilmesini mümkün kılmıştır.


2.1.2 Kaliforniya eyaleti

Bir diğer çalışma alanı olarak ABD'nin Kaliforniya Eyaleti seçilmiştir. Kaliforniya, hem sık tekrarlayan büyük ölçekli orman yangınları hem de yoğun endüstriyel ve kentsel kaynaklı hava kirleticileri nedeniyle uzaktan algılama ve makine öğrenmesi tabanlı analizler için ideal bir bölgedir. Çalışma kapsamında 2025 Ocak ayında gerçekleşen Los Angeles yangınları ele alınmıştır. Geniş ölçekli analiz yaklaşımıyla tüm eyalet genelinde gerçekleştirilmiş, özellikle orman yangınlarının ardından NO₂ ve CO konsantrasyonlarındaki değişimler incelenmiştir. Kaliforniya'nın farklı ekosistem tiplerine (orman, chaparral, kentsel) sahip olması modellerin farklı çevresel koşullar altındaki davranışlarının değerlendirilmesine imkân tanımaktadır. Veri yoğunluğunun yüksek olması ise makine öğrenmesi modellerinin daha güvenilir ve ayrıntılı biçimde eğitilmesine olanak sağlamaktadır. Ayrıca Kaliforniya, küresel ölçekte yangın ve hava kalitesi ilişkisini araştıran çalışmaların yoğunlaştığı bir bölge olması nedeniyle model doğrulaması ve yöntemsel kıyaslama açısından önemli bir referans noktası sunmaktadır. Bununla birlikte Kaliforniya, yangınların iklim koşulları, arazi örtüsü ve insan etkileri ile ilişkili olduğu bölgelerden biri olarak öne çıkmaktadır. Bu özellik, farklı coğrafi bağlamlarda geliştirilen modellerin karşılaştırılmasına ve yöntemlerin genellenebilirliğinin değerlendirilmesine olanak sağlamaktadır.

Şekil 2.2'de, çalışmada ele alınan iki farklı coğrafi bölgenin küresel ve bölgesel ölçekteki konumları gösterilmektedir. Bu gösterim, çalışma alanlarının dünya üzerindeki konumunu ve analizlerde dikkate alınan mekânsal sınırları açık biçimde sunmaktadır. Birbirinden farklı iklimsel, topografik ve çevresel özelliklere sahip olan Türkiye ve Kaliforniya çalışma alanlarında, aynı veri setleri ve aynı modelleme yaklaşımının uygulanması, geliştirilen yöntemin farklı coğrafyalarda karşılaştırılabilir ve genellenebilir sonuçlar üretme kapasitesinin değerlendirilmesine olanak sağlamaktadır.



(a)



(b)



(c)

Şekil 2.2 : (a) Genel görünüm, (b) Kaliforniya, (c) Türkiye çalışma alanı.

2.2 Veri

Tez çalışması kapsamında çeşitli veriler kullanılmıştır. Bu veriler uydu ve yersel kaynaklı veriler olarak ikiye ayrılmaktadır. İki farklı ana başlık altında kullanılan tüm veriler açıklanmıştır.

2.2.1 Uydu verileri

2.2.1.1 Sentinel 2 ve Landsat 8/9

Orman yangınlarının tespiti için kullanılan uydu görüntüleri Sentinel-2 (Avrupa Uzay Ajansı-ESA) ve Landsat 8 (ABD Jeoloji Araştırmaları Kurumu-USGS/NASA) uydularına aittir.

Sentinel-2, Avrupa Uzay Ajansı tarafından Copernicus Programı kapsamında geliştirilen, çok bantlı optik gözlem uydusudur. Sistem, Sentinel-2A (23 Haziran 2015)


ve Sentinel-2B (7 Mart 2017) olmak üzere iki uydudan oluşur. Aynı yörünge düzleminde 180° faz farkı ile hareket eden bu iki uydu, birlikte çalıştıklarında aynı noktayı 5 günde bir gözlemleyebilir (Phiri vd., 2020). Bu da yangın gibi kısa süreli olayların izlenmesi açısından zamansal çözünürlük önem taşımaktadır. Güneş eşzamanlı yörüngede bulunan Sentinel-2 uyduları, 13 farklı spektral bantta görüntüleme yapabilen MSI (Multispectral Imager) sensörünü taşımaktadır (Copernicus Data Space, t.y.). Landsat 8 ve Landsat 9 uyduları, NASA ve USGS iş birliğiyle geliştirilmiş olup sırasıyla 11 Şubat 2013 ve 27 Eylül 2021 tarihlerinde fırlatılmıştır ve hâlen operasyonel durumdadır. Her iki uydu da Operational Land Imager (OLI) ve Thermal Infrared Sensor (TIRS) sensörlerini taşımakta ve güneş eşzamanlı yörüngede hareket etmektedir (Earth Resources Observation and Science (EROS) Center, 2020). Uydular tekil olarak aynı noktayı 16 günde bir gözlemlerken, birlikte kullanıldıklarında bu tekrar süresi yaklaşık 8 güne düşmektedir (Mazzeo vd., 2025). Sentinel-2 ve Landsat 8/9 uydularına ait bant isimleri, spektral dalga boyu aralıkları ve mekansal çözünürlükler karşılaştırmalı olarak çizelge 2.1’de sunulmuştur.

Çizelge 2.1 : Sentinel 2 A/B ve Landsat8/9 uydularının bant özellikleri.


Spektral Bölge	Sentinel-2			Landsat 8/9		
	Bant ismi	Dalga Boyu (µm)	Çözünürlük (m)	Bant ismi	Dalga Boyu (µm)	Çözünürlük (m)
Kıyı / Aerosol	B1	0.443	60	B1	0.433–0.453	30
Mavi	B2	0.490	10	B2	0.452–0.512	30
Yeşil	B3	0.560	10	B3	0.533–0.590	30
Kırmızı	B4	0.665	10	B4	0.636–0.673	30
Kırmızı Kenar 1	B5	0.705	20	–	–	–
Kırmızı Kenar 2	B6	0.740	20	–	–	–
Kırmızı Kenar 3	B7	0.783	20	–	–	–
NIR	B8	0.842	10	B5	0.851–0.879	30
NIR (Dar)	B8A	0.865	20	–	–	–
SWIR-1	B11	1.610	20	B6	1.566–1.651	30
SWIR-2	B12	2.190	20	B7	2.107–2.294	30
Pankromatik	–	–	–	B8	0.500–0.680	15
Termal	–	–	–	B10	10.6–11.19	100

Şekil 2.3 ve Şekil 2.4’de Sentinel ve Landsat’a ait farklı yangın alanlarında öncesi ve sonrası örnekler görülmektedir. Yanlış renkli bileşik görüntüler, sağlıklı ve yanmış vejetasyon alanları arasındaki kontrastı artırarak yangın şiddetinin görsel olarak belirginleştirilmesini sağlayan etkili bir görselleştirme tekniğidir. Özellikle SWIR, NIR ve RED bantların birlikte kullanıldığı yanlış renkli bileşikler, yangın sonrası

vejetasyon kaybını ve yüzey özelliklerindeki değişimleri açık bir şekilde ortaya koymaktadır.




Şekil 2.3 : İzmir/Seferihisar orman yangını için oluşturulan RGB görüntüler. (a) Sentinel-2 yangın öncesi görüntüsü (22 Haziran 2025), (b) Sentinel-2 yangın sonrası görüntüsü (2 Temmuz 2025), (c) Landsat 8/9 yangın öncesi görüntüsü (20 Haziran 2025) ve (d) Landsat 8/9 yangın sonrası görüntüsü (6 Temmuz 2025).




Şekil 2.4 : İzmir/Seferihisar orman yangını için oluşturulan yanlış renkli bileşik (SWIR–NIR–RED) görüntüler. (a) Sentinel-2 yangın öncesi görüntüsü (22 Haziran 2025), (b) Sentinel-2 yangın sonrası görüntüsü (2 Temmuz 2025), (c) Landsat 8/9 yangın öncesi görüntüsü (20 Haziran 2025) ve (d) Landsat 8/9 yangın sonrası görüntüsü (6 Temmuz 2025).

Kaliforniya eyaletinde Ocak ayında gerçekleşen Los Angeles yangınları için uydu görüntüleri bulut oranı filtrelenerek temiz görüntüler seçilmiştir. Los Angeles çevresinde birçok yangın noktası gözükmemektedir. Bunlardan en büyükleri Palisades ve Eaton yangınları olarak geçiyor (Armstrong, 2025). Bu alanları kapsayan uygun uydu görüntü tarihleri incelenmiş ve yangın öncesi/yangın sonrası olarak belirlenmiştir. Yangınlar 7 Ocak 2025 tarihinde başlayıp ilerlemiştir. Bu tarih baz alınarak bakıldığında yangından öncesi için 2 Ocak 2025, yangının söndürülmesinden sonra ise 12 Ocak 2025 görüntüleri seçilmiştir. Bu görüntüler hem çalışma alanını kapsamı hem yangın tarihine yakın olması hem de bulut oranının düşük olması nedeniyle analizler için ideal gözükmemektedir. Şekil 2.5 ve Şekil 2.6'da Sentinel ve Landsat uydularına ait farklı yangın alanlarında öncesi ve sonrası örnekler gözükmemektedir. Görüntülerde yangın öncesi dönemde yoğun ve sağlıklı vejetasyon alanları yeşil tonlarda izlenirken, yangın sonrası sahnelerde bu alanların yerini kırmızı ve koyu kahverengi tonların aldığı görülmektedir. Bu tonal değişim, yangından etkilenen bölgelerin mekânsal dağılımını ve yanmış alanların sınırlarını uydu görüntüleri üzerinden açık biçimde ortaya koymaktadır.




Şekil 2.5 : Kaliforniya/Los Angeles bölgesine ait Sentinel-2 görüntüleri. (a) ve (b) RGB bant kombinasyonunu, (c) ve (d) ise yanlış renkli bileşik (SWIR–NIR–RED) görüntüleri göstermektedir. (a) ve (c) yangın öncesi durumu (2 Ocak 2025), (b) ve (d) ise yangın sonrası durumu (12 Ocak 2025) temsil etmektedir.



Şekil 2.6 : Kaliforniya/Los Angeles bölgesine ait Landsat 8/9 görüntülerinin yangın öncesi ve sonrası karşılaştırılması. (a,b) RGB bant kombinasyonu, (c,d) yanlış renkli bileşik (SWIR–NIR–RED) görüntülerdir. Yangın öncesi ve sonrası tarihler sırasıyla 6 Ocak 2025 ve 14 Ocak 2025'tir.

2.2.1.2 ECOSTRESS

Bu çalışmada yangınların yüzey sıcaklığı üzerindeki etkisini değerlendirmek amacıyla, ECOSTRESS (ECOSystem Spaceborne Thermal Radiometer Experiment on Space Station) uydu misyonuna ait kara yüzey sıcaklığı (Land Surface Temperature, LST) verileri kullanılmıştır. ECOSTRESS, NASA tarafından geliştirilen ve 2018 yılından bu yana Uluslararası Uzay İstasyonu (ISS) üzerinde aktif görev yapan bir termal kızılötesi sensördür. Mekansal çözünürlüğü 70 m iken zamansal çözünürlüğü 4-5 gündür (Amici vd., 2022). Ekosistemlerin su stresi, buharlaşma, terleme süreçleri ve yüzey enerji dengesi gibi dinamiklerini yüksek mekânsal ve zamansal çözünürlükte izlemeyi amaçlamaktadır. Termal kızılötesi bantlar bitki örtüsü durumu, toprak nemi ve yüzey özelliklerindeki değişimlere duyarlı bir sıcaklık ölçümü sunmaktadır. Bu özellikleri nedeniyle ECOSTRESS verileri, orman yangınları sonrası bitki stresi ve yüzey koşullarındaki ani değişimlerin izlenmesi ve yangınların çevresel etkilerinin değerlendirilmesi açısından önemli bir veri kaynağı olarak öne çıkmaktadır (Y. Zhu vd., 2025). Şekil 2.7'de gözüktüğü gibi kırmızı kısımlar yüzey sıcaklığının ciddi anlamda arttığı alanlar olarak yangın sınırlarıyla örtüşmektedir.



Şekil 2.7 : (a) Palisades, (b) Eaton, Kaliforniya, Los Angeles yangınlarına ait ECOSTRESS veri örnekleri.

Bu çalışma kapsamında ECOSTRESS LST verileri, yangın öncesi ve yangın sonrası dönemlerde kara yüzey sıcaklığındaki değişimleri incelemek amacıyla kullanılmıştır. Veriler, NASA Earthdata platformu üzerinden temin edilmiş ve yangın olaylarıyla zamansal olarak örtüşecek şekilde seçilmiştir. ECOSTRESS LST ürünleri sistemde sunulduğu şekliyle Kelvin (K) birimindedir ve analiz aşamasında yorumlamayı kolaylaştırmak amacıyla gerekli durumlarda Santigrat dereceye ($^{\circ}\text{C}$) dönüştürülmüştür. Elde edilen LST değerleri, yangın sonrası yüzey koşullarında meydana gelen sıcaklık artışlarını ortaya koymak ve yangınların termal etkilerini mekânsal olarak değerlendirmek amacıyla analiz edilmiştir.

2.2.1.3 Sentinel-5P

Orman yangınları sırasında atmosfere salınan azot dioksit (NO_2) ve karbon monoksit (CO), hava kalitesini doğrudan etkileyen başlıca kirleticiler arasındadır. Bu gazlar, yangınların troposferik kirliliğe olan katkısının değerlendirilmesinde önemli göstergeler sunmaktadır. Bu çalışma kapsamında, yangın kaynaklı gaz salınımlarının mekânsal ve zamansal değişimi, Sentinel-5P (Sentinel-5 Precursor) uydusu üzerinde yer alan TROPOMI (Tropospheric Monitoring Instrument) sensöründen elde edilen uydu verileri kullanılarak incelenmiştir.

Sentinel-5P, Avrupa Uzay Ajansı (ESA) tarafından Copernicus Atmosphere Monitoring Service (CAMS) kapsamında geliştirilmiş ve 13 Ekim 2017 tarihinde fırlatılmıştır (Ialongo vd., 2020). Uydu, güneş eşzamanlı bir yörüngede yaklaşık 824 km yükseklikte hareket etmekte olup Dünya'yı bir günde tamamen tarayarak günlük ölçeğe küresel veri sağlamaktadır (Veefkind vd., 2012). Bu özellik, kısa süreli olayların atmosfer üzerindeki etkilerinin günlük bazda izlenebilmesine olanak tanımaktadır.


TROPOMI sensörü, ultraviyole (UV) ve görünür (VIS) spektral aralıklar başta olmak üzere yakın ve kısa dalga kızılötesi bantlarda ölçüm yapabilmektedir (Reshi vd., 2024). Bu sensör, atmosferik hava kalitesinin önemli göstergelerinden biri olan azot dioksit (NO₂) gazının troposferik ve stratosferik dikey sütun yoğunluklarının izlenmesinde yaygın olarak kullanılmaktadır. TROPOMI sensörünün mekânsal çözünürlüğü, 2022 yılı sonrasında yayımlanan ürünlerde yaklaşık 5.5×3.5 km² seviyesindedir (Henk Eskes vd., 2022). Sensör, 270-2385 nm dalga boyu aralığında çalışmakta ve 12 bit radyometrik çözünürlüğe sahiptir.

Bu çalışmada kullanılan NO₂ ve CO verileri, Google Earth Engine (GEE) platformu üzerinden Sentinel-5P OFFL (Offline) ürün koleksiyonundan elde edilmiştir. OFFL ürünleri, uydu geçişinden 12-36 saat sonra erişime açılan, kalibrasyon ve kalite kontrolü tamamlanmış veri setleridir. Veriler mol/m² biriminde bulunmakta olup, analiz kolaylığı sağlamak amacıyla µmol/m² (mikromol/m²) cinsine dönüştürülmüştür.


Yangın kaynaklı gazların yüzeye yakın atmosfer tabakalarında izlenebilmesi amacıyla troposferik sütun verileri kullanılmıştır. Atmosferik koşullar ve bulutluluk nedeniyle bazı bölgelerde veri eksiklikleri gözlenmiştir. Bu nedenle veriler Google Earth Engine ortamında doğrudan veri koleksiyonlarından alınmış ve yalnızca çalışma alanı ile zaman aralığına göre filtrelenmiştir. Ek bir bulut maskesi ya da kalite filtresi uygulanmamıştır.

Sentinel-5P, her gün aynı yerel saat aralıklarında veri topladığından, geçiş zamanları analizlerde dikkate alınmıştır. Uydu geçişi Türkiye üzerinde genellikle 12.00-14.00 (yerel saat), Kaliforniya üzerinde ise 10.00-12.00 (yerel saat) aralığında gerçekleşmektedir.

Veri tarih aralıkları çalışma alanlarına göre belirlenmiştir. Türkiye için 15 Mayıs-27 Temmuz 2025, Kaliforniya için ise 1 Ocak-30 Temmuz 2025 dönemleri esas alınmıştır. Bu zaman aralıkları, her iki bölgede orman yangınlarının yoğun olarak gözlemlendiği dönemlere karşılık gelmektedir. Belirlenen süre boyunca her iki çalışma alanı için saatlik bazda NO₂ ve CO değerleri elde edilmiştir. Bu veriler kullanılarak atmosferik değişimlerin zamansal eğilimleri incelenmiş ve yangın aktiviteleri ile ilişkileri değerlendirilmiştir. Şekil 2.8 ve Şekil 2.9'da Sentinel-5P NO₂ ve CO parametreleri için örnekler verilmiştir.



Şekil 2.8 : Los Angeles yangın (7 Ocak 2025) öncesi ve sonrasına ait Sentinel-5P Troposferik NO₂ görüntüleri.



Şekil 2.9 : Seferihisar/Izmir yangın (29 Haziran 2025) öncesi ve sonrasına ait Sentinel-5P toplam sütun yoğunluğu CO görüntüleri.

2.2.1.4 ERA-5 Land Reanalysis

Bu çalışmada meteorolojik koşulların yangın kaynaklı gaz yoğunlukları üzerindeki etkilerini değerlendirmek ve model sonuçlarını desteklemek amacıyla ERA5-Land yeniden analiz (reanalysis) verileri kullanılmıştır. ERA5-Land, Avrupa Orta Vadeli Hava Tahminleri Merkezi (European Centre for Medium-Range Weather Forecasts - ECMWF) tarafından geliştirilen ve Copernicus Climate Data Store (CDS) aracılığıyla sağlanan yüksek çözünürlüklü iklim veri setidir (Muñoz-Sabater vd., 2021).


Bu çalışmada meteorolojik değişkenler, Google Earth Engine (GEE) ortamında erişilen ERA5-Land Hourly (ECMWF/ERA5 LAND/HOURLY) veri koleksiyonundan elde edilmiştir. ERA5-Land veri seti, yaklaşık 0.1° (≈ 11 km) mekansal çözünürlüğe ve saatlik zamansal çözünürlüğe sahiptir. ERA5-Land veri seti, kara yüzeyi ve yüzeye yakın atmosfer koşullarını tanımlayan çok sayıda saatlik meteorolojik değişkeni içermektedir. Bu kapsamda veri seti; 2 m hava sıcaklığı (temperature_2m), 2 m çığ noktası sıcaklığı (dewpoint_temperature_2m), 10 m rüzgâr bileşenleri (u_component_of_wind_10m, v_component_of_wind_10m), yüzey basıncı (surface_pressure), toplam yağış (total_precipitation) ve farklı derinliklerdeki toprak nemi (volumetric_soil_water_layer_1–4) gibi temel meteorolojik parametreleri içermektedir. Ayrıca yüzey-atmosfer etkileşimini ve enerji dengesi süreçlerini temsil eden yüzey sıcaklığı (skin_temperature) ile yüzeye gelen kısa dalga güneş radyasyonu (surface_solar_radiation_downwards) ve yüzey duyulur ısı akısı (surface_sensible_heat_flux) gibi değişkenler de veri seti içerisinde yer almaktadır. Şekil 2.10 ve Şekil 2.11’de bu parametrelere ait örnekler gösterilmiştir.

Bu meteorolojik değişkenler, atmosferdeki NO_2 , CO, SO_2 gibi gazların taşınımı, karışımı ve yoğunluk dağılımları üzerinde belirleyici etkiye sahiptir. Rüzgâr hızı ve yönü kirleticilerin yatay taşınımını etkilerken, düşük basınç koşulları veya sıcaklık terselmesi (inversion) durumları kirleticilerin birikmesine yol açabilmektedir (Bilgiç & Elbir, 2025). Bu nedenle ERA5-Land verileri, çalışma kapsamında yardımcı (auxiliary) veri olarak kullanılmış ve modelleme sürecine girdi olarak dâhil edilmiştir.


Çalışmada kullanılan ERA5-Land saatlik verileri, TROPOMI uydu geçiş saatleri ve yersel gözlem verileri ile uyumlu olacak şekilde işlenmiştir. Bu kapsamda, verilerle aynı saatler alınmış ve veri seti günlük formata dönüştürülmüştür. Böylece

meteorolojik parametreler, gaz ölçümleriyle zamansal olarak senkronize hâle getirilmiş ve analizler arasındaki zaman farkı en aza indirilmiştir.

Verilerin modele entegrasyonu, NO₂ ve CO konsantrasyonlarının meteorolojik etkilerle birlikte değerlendirilmesine olanak sağlayarak daha gerçekçi, tutarlı ve fiziksel olarak anlamlı tahminler elde edilmiştir. Böylelikle yalnızca uydu gözlemlerine dayalı değil, atmosferik koşullarla desteklenmiş bütüncül bir analiz yaklaşımı benimsenmiştir.



Şekil 2.10 : Türkiye’de 1 Haziran-30 Ağustos 2025 tarihleri arasında günlük ortalama 2m hava sıcaklığı.



Şekil 2.11 : Kaliforniya’da 1 Ocak-1 Şubat 2025 tarihleri arasında saatlik ortalama yüzey sıcaklığı.


2.2.1.5 GRIDMET

Gridded Surface Meteorological Dataset, 1979 yılından itibaren Amerika Birleşik Devletleri’nin bitişik bölgesi (CONUS) için üretilen bir meteorolojik veri setidir (Schantz vd., 2026). Veri seti yaklaşık 4 km mekânsal çözünürlüğe ve günlük

zamansal çözünürlüğe sahiptir (Jing vd., 2026). Kara yüzeyi ve atmosfer süreçlerini temsil eden temel meteorolojik değişkenleri içermektedir. Veri seti, sıcaklık, yağış, rüzgâr, nem ve yüzey radyasyonu gibi parametreleri kapsamaktadır. Bu değişkenler, çevresel süreçlerin ve arazi yüzeyi ve atmosfer etkileşimlerinin analizinde yaygın olarak kullanılmaktadır. Rüzgâr hızı parametresine ait örnek Şekil 2.12’de görülmektedir.

Verilerin üretiminde iki ana kaynak bir araya getirilmektedir (Avila vd., 2025). PRISM verileri yüksek mekânsal çözünürlük sağlamaktadır. National Land Data Assimilation System (NLDAS) ise yüksek zamansal çözünürlüğe sahip meteorolojik bilgileri sunmaktadır. Bu bütünleştirme yaklaşımı, mekânsal olarak ayrıntılı ve zamansal olarak sürekli meteorolojik alanların elde edilmesine olanak tanımaktadır.

Veriler, üretim süreci ilerledikçe güncellenen farklı sürümler hâlinde yayımlanmaktadır. İlk aşamada sunulan veriler geçici nitelik taşıırken, yapılan kontroller ve düzenlemeler sonucunda zamanla daha kararlı bir yapıya ulaşmaktadır. Nihai sürümler ise uzun dönemli analizler için güvenilir bir veri kaynağı sunmaktadır. Bu çalışma kapsamında söz konusu meteorolojik veriler Google Earth Engine (GEE) ortamı üzerinden temin edilmiştir. Kaliforniya çalışma alanı özelinde, bu veri seti ERA5-Land yeniden analiz verileri ile karşılaştırmalı olarak değerlendirilmiş, böylece farklı meteorolojik veri kaynaklarının model sonuçları üzerindeki etkilerinin incelenmesi amaçlanmıştır.



Şekil 2.12 : Kaliforniya’da Ocak ayı ortalama rüzgar hızı parametresi.

2.2.1.6 TanDEM-X EDEM


Bu çalışmada, topografyanın modelleme sürecine dâhil edilmesi ve arazi yükselti farklarının analizlerde temsil edilmesi amacıyla dijital yükseklik modeli (DEM) verileri kullanılmıştır. Bu amaçla, TanDEM-X 30 m Edited Digital Elevation Model (EDEM) veri setinden yararlanılmıştır. Veri, Alman Uzay Ajansı (DLR) tarafından üretilmiş olup https://download.geoservice.dlr.de/TDM30_EDEM/ web sitesi üzerinden temin edilmiştir.

TanDEM-X EDEM, TerraSAR-X ve TanDEM-X uydularının interferometrik SAR (InSAR) yöntemiyle elde edilen radar görüntülerinden türetilen küresel bir yükseklik modelidir (Krieger vd., 2007). EDEM sürümü, orijinal TanDEM-X verilerinin işlenmiş (edited) versiyonu olup, boşlukların giderildiği, su yüzeylerinin düzeltilip düzgünleştirildiği ve topografik doğruluğun artırıldığı bir veri ürünüdür. Model, yaklaşık 30 m (~1 arc-second) mekansal çözünürlüğe sahiptir ve küresel ölçekte karasal alanları kapsamaktadır (Sefercik & Jacobsen, 2025). Veriler, GeoTIFF formatında ve WGS84 koordinat referans sisteminde sağlanmaktadır.

TanDEM-X EDEM, yüksek mekânsal doğruluğu, boşluksuz veri kapsamı ve radar interferometrisi temelli üretim yöntemi sayesinde diğer küresel DEM ürünlerine göre daha güvenilir bir yükseklik temsili sunmaktadır. Bu nedenle çalışmada, modelleme aşamasında kullanılacak elevation (yükselti) parametresinin elde edilmesinde tercih edilmiştir.

Bu çalışmada EDEM verisi doğrudan modelin giriş verisi (input parameter) olarak kullanılarak yükseklik, meteorolojik ve atmosferik değişkenlerle birlikte değerlendirilmiştir. Böylece arazinin topografik özelliklerinin, yangın sonrası gaz dağılımı ve atmosferik süreçler üzerindeki olası etkilerinin modellenmesinde gerçekçi bir topoğrafik temsil sağlanmıştır.

DEM verileri, çalışma alanlarına göre kesilmiş, uydu verilerinin koordinat sistemleriyle eşleştirilmiş ve modelleme aşamasında kullanılacak biçime dönüştürülmüştür. Her iki bölge için de TanDEM-X EDEM verisi aynı çözünürlükte kullanılarak karşılaştırılabilir bir topografik temel oluşturulmuştur.




Şekil 2.13 : Kaliforniya ve Türkiye çalışma alanlarına ait DEM verisi.

2.2.2 Yersel veriler

Türkiye çalışma alanı için kullanılan yersel hava kalitesi ölçümleri, T.C. Çevre, Şehircilik ve İklim Değişikliği Bakanlığı tarafından işletilen Ulusal Hava Kalitesi İzleme Ağı (UHKİA) üzerinden sağlanan açık erişimli <https://sim.csb.gov.tr/Services/AirQuality> websitesinden elde edilmiştir. UHKİA kapsamında Türkiye genelinde çok sayıda sabit izleme istasyonu bulunmaktadır. İstasyonlara bağlı olarak SO₂, PM₁₀, PM_{2.5}, NO₂, O₃, CO gibi temel kirleticiler ölçülmektedir. Veriler kamuoyu ile paylaşılmakta ve sistemdeki bilgiler sahadan gelen ölçümler doğrultusunda saatlik olarak güncellenen anlık değerler şeklinde sunulmaktadır. Bu çalışma kapsamında, 15 Mayıs - 30 Haziran 2025 tarihleri arasındaki ölçümler dikkate alınmış ve Türkiye çalışma alanı içinde yer alan 98 istasyona ait veriler kullanılmıştır. Şekil 2.14’de gözüktüğü gibi veri bulunma oranları dikkate alınarak istasyonlar seçilmiş ve sürekliliğin sağlanacağı, eksik verinin en aza indirileceği istasyonlar veri setine eklenmiştir. Bu istasyonlar arasında, NO₂ parametresini ölçen 90 istasyon bulunurken, CO parametresi 55 istasyon tarafından ölçülmektedir. Bu istasyonların dağılımları Şekil 2.15’te görülmektedir. Her iki kirletici için de veriler UHKİA sisteminden saatlik konsantrasyonlar olarak alınmıştır. NO₂ ve CO değerleri, sistemde yer aldığı şekilde mikrogram/metreküp (µg/m³) biriminde değerlendirilmiştir. İstasyon verileri, Sentinel-5P (TROPOMI) uydu gözlemleriyle 09:00-12:00 yerel saat (UTC+3) aralığında zaman eşleştirmesi yapılarak kullanılmıştır. Bu yaklaşım, yersel ölçüm değerlerinin uydu geçiş saatleriyle tutarlılığını sağlamış ve veri entegrasyonunda olası zamansal kaymaları en aza indirmiştir.

İstasyon	Parametre	Birim	Min. Değ	Min. Tarih	Max. Değ	Max. Tarih	Ort. Değ	Veri Adeti	Olmasi Gereken V	Veri yüzü
Balıkesir	NO2	µg/m3	8,03	23.07.2025 15:00	125,68	22.07.2025 11:00	46,73	58	1.777	% 3,26
Balıkesir - Bandırma-MTHM	NO2	µg/m3	2,45	26.05.2025 04:00	73,01	17.05.2025 00:00	18,59	1.68	1.777	% 94,54
Balıkesir - Edremit - MTHM	NO2	µg/m3	7,20	19.07.2025 02:00	102,24	28.07.2025 08:00	41,89	233	1.777	% 13,11
Balıkesir - Erdek-MTHM	NO2	µg/m3	0,02	1.06.2025 14:00	49,33	31.05.2025 19:00	5,87	454	1.777	% 25,55
Balıkesir - Merkez - MTHM	CO	µg/m3	677,90	23.07.2025 17:00	2.341,13	28.07.2025 09:00	1.373,66	214	1.777	% 12,04
	NO2	µg/m3	0,88	21.07.2025 16:00	132,94	28.07.2025 09:00	44,64	165	1.777	% 9,29
Bilecik	NO2	µg/m3	6,27	26.07.2025 12:00	47,95	22.07.2025 22:00	21,22	106	1.777	% 5,97
Bilecik - Bozüyük-MTHM	NO2	µg/m3	2,47	2.07.2025 05:00	110,06	28.07.2025 02:00	25,85	1.773	1.777	% 99,77
Bursa	Veri yok									
Bursa - Beyazıt Cad.-MTHM	CO	µg/m3	952,85	5.07.2025 05:00	3.949,76	22.07.2025 23:00	1.432,97	1.111	1.777	% 62,52
	NO2	µg/m3	6,77	29.06.2025 05:00	115,55	22.07.2025 22:00	35,37	1.111	1.777	% 62,52
Bursa - Inegöl-MTHM	NO2	µg/m3	2,40	13.07.2025 11:00	71,14	16.05.2025 12:00	16,80	1.206	1.777	% 67,87
Bursa - Kestel-MTHM	NO2	µg/m3	2,87	2.07.2025 03:00	126,36	26.06.2025 05:00	25,19	1.485	1.777	% 83,57
Bursa - Kültür Park-MTHM	Veri yok									
Bursa - Uludağ Univ.-MTHM	CO	µg/m3	0,00	21.07.2025 13:00	176,73	18.07.2025 01:00	31,34	1.773	1.777	% 99,77
Bursa-Gürsu	NO2	µg/m3	10,64	29.06.2025 12:00	121,73	17.05.2025 00:00	38,20	1.633	1.777	% 91,90
	CO	µg/m3	143,35	10.07.2025 04:00	1.153,58	27.07.2025 23:00	356,12	1.777	1.777	% 100,00
Bursa-Kestel (Hilal Parkı)	NO2	µg/m3	10,11	29.06.2025 15:00	104,55	20.06.2025 12:00	31,38	1.564	1.777	% 88,01
Bursa-Nilüfer	Veri yok									
Çanakkale	Veri yok									
Çanakkale - Biga - MTHM	CO	ppm	203,48	3.07.2025 14:00	947,44	18.06.2025 02:00	443,42	1.192	1.777	% 67,08
Çanakkale - Biga İçdaş	Veri yok									
Çanakkale - Çan-MTHM	NO2	µg/m3	2,03	29.06.2025 10:00	203,23	20.05.2025 09:00	28,89	1.537	1.777	% 86,49
Çanakkale - Lapseki-MTHM	NO2	µg/m3	0,60	20.07.2025 00:00	34,53	15.06.2025 08:00	9,21	1.734	1.777	% 97,58
Edirne	NO2	µg/m3	6,31	11.06.2025 06:00	49,36	19.05.2025 23:00	22,35	1.693	1.777	% 95,27
Edirne - Karaağaç-MTHM	NO2	µg/m3	4,14	15.06.2025 17:00	65,35	4.07.2025 23:00	12,53	1.777	1.777	% 100,00
Edirne - Keşan-MTHM	NO2	µg/m3	3,01	18.05.2025 12:00	36,37	25.06.2025 02:00	10,86	663	1.777	% 37,31
EMEP - Kırklareli Vize	Veri yok									
İstanbul - Arnavutköy	CO	µg/m3	51,70	9.06.2025 11:00	2.363,20	23.07.2025 06:00	567,60	1.77	1.777	% 99,61
	NO2	µg/m3	1,60	24.07.2025 05:00	127,10	23.07.2025 09:00	26,15	1.666	1.777	% 93,75
İstanbul - Bağcılar	CO	µg/m3	106,40	13.07.2025 13:00	2.509,90	23.05.2025 08:00	576,71	1.67	1.777	% 93,98
	NO2	µg/m3	5,90	29.06.2025 06:00	204,70	23.05.2025 08:00	45,18	1.619	1.777	% 91,11
İstanbul - Başakşehir-MTHM	CO	µg/m3	2.103,62	18.05.2025 14:00	2.148,41	17.05.2025 05:00	2.122,87	82	1.777	% 4,61
	NO2	µg/m3	0,83	10.07.2025 04:00	109,28	17.05.2025 04:00	22,74	488	1.777	% 27,46
İstanbul - Çatladıkapı	CO	µg/m3	63,20	28.05.2025 15:00	1.776,00	22.05.2025 05:00	692,77	1.771	1.777	% 99,66
	NO2	µg/m3	8,40	26.05.2025 06:00	116,70	23.05.2025 10:00	46,43	1.771	1.777	% 99,66


Şekil 2.14 : Türkiye çalışma alanındaki yersel istasyonların veri kapsama analiz örnekleri.



Şekil 2.15 : Türkiye çalışma alanındaki NO₂ ve CO istasyonlarının dağılımı.

Kaliforniya çalışma alanı için kullanılan yersel hava kalitesi ölçümleri, Amerika Birleşik Devletleri Çevre Koruma Ajansı (United States Environmental Protection Agency, EPA) tarafından işletilen Hava Kalitesi Sistemi (Air Quality System, AQS) veri tabanı üzerinden sağlanan açık erişimli verilerden elde edilmiştir. Yersel ölçüm verileri, EPA tarafından sunulan AirData platformu aracılığıyla (https://aq5.epa.gov/aqsweb/airdata/download_files.html) temin edilmiş olup, sistem kapsamında eyalet genelinde farklı istasyon tiplerine ait saatlik hava kalitesi ölçümleri bulunmaktadır. Bu çalışma kapsamında, 7 Ocak 2025 tarihinde Los Angeles bölgesinde meydana gelen yangın olayını kapsayacak şekilde, 1 Ocak – 30 Temmuz 2025 tarihleri arasındaki saatlik yersel ölçümler kullanılmıştır. NO₂ parametresini


ölçen 52 istasyon ve CO parametresini ölçen 30 istasyon analizlere dahil edilmiştir. Bu istasyonların dağılımı iki parametre için de Şekil 2.16’da gösterilmiştir. Uydu tabanlı Sentinel-5P (TROPOMI) gözlemlerinin Kaliforniya bölgesi üzerindeki yaklaşık geçiş zamanını temsil edebilmek amacıyla, 19:00-22:00 UTC saat aralığındaki yersel NO₂ ve CO ölçümleri dikkate alınmıştır. Yersel veriler hem yerel saat hem de GMT zaman referansında sunulduğundan, analizlerde herhangi bir saat dönüşümü uygulanmamış ve doğrudan UTC zaman damgaları kullanılmıştır. Bu zaman aralığı, Kaliforniya için 11:00-14:00 yerel saate (UTC-8/UTC-7, mevsimsel saat uygulamasına bağlı olarak) karşılık gelmektedir. Bu yaklaşım, yersel ölçümler ile uydu gözlemleri arasında zamansal uyum sağlanmasını amaçlamaktadır.



Şekil 2.16 : Kaliforniya çalışma alanındaki NO₂ ve CO istasyonlarının dağılımı.

3. YÖNTEMLER

Bu çalışmada izlenen yöntem, orman yangınlarının çevresel ve atmosferik etkilerinin modellenmesine yönelik bütüncül bir iş akışı üzerine kurulmuştur (Şekil 3.1). İlk aşamada yangın öncesi ve sonrası koşulları temsil eden uydu tabanlı çevresel değişkenler ile yersel ölçümler çalışma alanına göre mekânsal ve zamansal olarak uyumlu hâle getirilmiştir. Elde edilen raster ve vektör tabanlı veri katmanları ortak bir grid yapısında birleştirilmiş ve yangın etkilerinin modellenmesi için gerekli öznitelikler oluşturulmuştur.



Şekil 3.1 : İş akış diyagramı.

İkinci aşamada oluşturulan veri seti eğitim ve test kümelerine ayrılmıştır. Eğitim verileri kullanılarak Random Forest, XGBoost, LightGBM, CatBoost, Destek Vektör Regresyonu ve Uzun Kısa Süreli Bellek tabanlı modeller eğitilmiştir. Bu modeller, orman yangınları sonrası çevresel değişimlerin ve ilişkili hava kalitesi bileşenlerinin tahmin edilmesi amacıyla kullanılmıştır. Model performansını artırmak için hiperparametre optimizasyonu uygulanmış ve her model için en uygun yapı

belirlenmiştir. Model çıktılarının yorumlanabilirliğini sağlamak amacıyla SHAP yöntemi kullanılarak yangınla ilişkili değişkenlerin modele olan katkıları analiz edilmiştir. Son aşamada model tahminleri bağımsız test verileri ile karşılaştırılarak doğruluk analizi gerçekleştirilmiştir.

3.1 Orman Yangını Tespiti

Orman yangınlarının tespiti ve etkilerinin değerlendirilmesinde, multispektral ve termal bantlara sahip Sentinel ve Landsat gibi uydu sistemleri yaygın olarak kullanılmaktadır. Sentinel-2 ve Landsat 8/9 verileri, yanmış alanların belirlenmesi ve yangın şiddetinin analiz edilmesinde başarılı sonuçlar sunmakta olup, Sentinel-2'nin daha yüksek mekânsal çözünürlüğü ile Landsat arşivinin uzun dönemli veri sürekliliği bu sensörleri birbirini tamamlayıcı hale getirmektedir (Guo vd., 2024). Bu kapsamda, uydu tabanlı uzaktan algılama verileri, yangın sonrası hasar tespiti, şiddet sınıflandırması ve ekosistem iyileşme süreçlerinin izlenmesinde önemli bir araçtır.

3.1.1 İndisler

İndisler, multispektral görüntülerde yüzeyin farklı dalga boylarındaki yansıtımlarını kullanarak yeryüzü özellikleri hakkında bilgi sunmaktadır. Farklı indisler, bitki örtüsü durumu, nem içeriği ve yanma etkileri gibi farklı yüzey özelliklerini ortaya çıkararak alanların ayrıştırılmasını mümkün kılmaktadır. Multispektral uydu verilerinden türetilen bu spektral indisler, standart ve tekrarlanabilir ölçütler sağlayarak orman yangınlarının tespiti ve değerlendirilmesinde yaygın olarak kullanılmaktadır. Özellikle NDVI, NDMI, NBR ile fark indisleri olan dNDVI ve dNBR, yanmış alanların belirlenmesi ve yangın şiddetinin sınıflandırılmasında öne çıkmaktadır. Literatürdeki çalışmalar, dNBR ve benzeri fark indislerinin, yalın spektral indislerle karşılaştırıldığında yanma şiddetini daha doğru temsil ettiğini ve zemin etkilerini daha etkin bir şekilde ayrıştırabildiğini göstermektedir (Arıkan vd., 2022). Bu doğrultuda, çalışmada farklı spektral indisler karşılaştırmalı olarak kullanılarak orman yangınlarının mekânsal etkileri analiz edilmiştir. Bu tür çalışmalarda, orman yangınlarının etkilerinin belirlenmesi amacıyla spektral indisler genellikle yangın öncesi (pre-fire) ve yangın sonrası (post-fire) uydu görüntülerinden ayrı ayrı hesaplanmaktadır. İki dönem arasındaki fark alınarak (örneğin dNBR, dNDVI) yanma şiddeti ve bitki örtüsündeki değişimler değerlendirilmektedir. Bu yaklaşım, yangın

kaynaklı deęişimlerin zamansal olarak daha net bir biçimde ortaya konmasını sağlamaktadır. Denkem 3.1’de fark indeksinin hesaplanması gözükmektedir.

$$dIndex = Index_{yangın\ öncesi} - Index_{yangın\ sonrası} \quad (3.1)$$

3.1.1.1 Normalize edilmiş fark bitki örtüsü indeksi (dNDVI)

Normalize Edilmiş Fark Bitki Örtüsü İndeksi (dNDVI), yangın öncesi ve sonrası dönemler arasındaki bitki örtüsü deęişimlerinin deęerlendirilmesinde kullanılmaktadır. NDVI, kırmızı (RED) ve yakın kızılötesi (NIR) bantlar kullanılarak hesaplanmakta olup denklem 3.2’de hesaplanması gösterilmektedir. Sağlıklı bitki örtüsünün kırmızı ışığı büyük ölçüde soğurması ve yakın kızılötesi radyasyonu yansıtması ilkesine dayanmaktadır. Bu özellik sayesinde dNDVI, bitki örtüsündeki bozulma ve iyileşme süreçlerinin belirlenmesinde güvenilir bir gösterge olarak kabul edilmektedir (Arıkan vd., 2022; Zahabnazouri vd., 2025).

$$NDVI = \frac{NIR-RED}{NIR+RED} \quad (\text{Huang vd., 2021}) \quad (3.2)$$

3.1.1.2 Normalize edilmiş fark nem indeksi (dNDMI)

Normalize Edilmiş Fark Nem İndeksi (dNDMI), yangın öncesi ve sonrası dönemler arasındaki bitki örtüsü nem içeriğindeki deęişimlerin izlenmesinde kullanılmaktadır. Yangınlar, bitkilerin su içeriğini azaltması nedeniyle yanmış alanlarda dNDMI deęerlerinde belirgin bir düşüşe neden olmaktadır. Denklem 3.3’de gözüktüğü gibi bu indis, sağlıklı bitki örtüsüne duyarlı olan yakın kızılötesi (NIR) bandı ile yaprak ve toprak nemine tepki veren kısa dalga kızılötesi 1 (SWIR1) bandını kullanmaktadır (Hislop vd., 2018). NBR indeksinin daha uzun dalga boyuna sahip SWIR2 bandını kullanmasına kıyasla, NDMI bitki örtüsü tepe tabakası (canopy) su içeriğine karşı daha hassas bir yapı sunmaktadır (Yue vd., 2019).

$$NDMI = \frac{NIR-SWIR1}{NIR+SWIR1} \quad (\text{Emang vd., 2020}) \quad (3.3)$$

3.1.1.3 Normalize edilmiş fark yanıklık oranı (dNBR)

Normalize Edilmiş Fark Yanıklık Oranı (dNBR), yangın kaynaklı deęişimlerin tespit edilmesinde kullanılan yaygın bir spektral indisti olup, yangın sonrası NBR deęerlerinin yangın öncesi deęerlerden çıkarılmasıyla elde edilmektedir. NBR indeksi,

yakın kızılötesi (NIR) ve kısa dalga kızılötesi 2 (SWIR2) bantlarını birleştirerek bitki örtüsü kaybı ve yanmış yüzeylere karşı yüksek duyarlılık göstermektedir. Denklem 3.4’de iki bandı kullanarak indeksin nasıl hesaplandığı görülmektedir. Ayrıca, dNBR için Amerika Birleşik Devletleri Jeoloji Araştırmaları Kurumu (USGS) tarafından geliştirilen ve yaygın olarak kabul gören bir yangın şiddeti sınıflandırma standardı bulunmakta olup, bu sayede yanmış alanlar düşükten yükseğe doğru giden farklı şiddet seviyelerine ayrılabilir (Keeley, 2009).

$$NBR = \frac{NIR-SWIR2}{NIR+SWIR2} \quad (\text{Yılın vd., 2025}) \quad (3.4)$$

3.1.2 Yanma şiddeti sınıflandırma

Yanma şiddeti sınıflandırması, çizelge 3.1’de sunulan ve USGS tarafından önerilen dNBR eşik değerlerine dayalı olarak gerçekleştirilmiştir. dNBR haritalarının oluşturulmasının ardından, elde edilen değerler bu aralıklara göre farklı şiddet seviyelerine ayrılmıştır. Bu standartlaştırılmış yaklaşım, referans verilerin sınırlı olduğu ve arazi doğrulamasının zor olduğu bölgelerde özellikle yararlı olup, geniş alanlarda yangın şiddetinin tutarlı ve nesnel bir biçimde değerlendirilmesine olanak sağlamaktadır.

Çizelge 3.1 : Yangın şiddeti sınıfları.

Yanma şiddeti	dNBR value (x)
Yanmamış	$x < 0.1$
Düşük	$0.1 \leq x < 0.27$
Orta düşük	$0.27 \leq x < 0.44$
Orta yüksek	$0.44 \leq x < 0.66$
Yüksek	$0.66 \leq x$

Ayrıca, yangın sonrası ekosistem tepkisinin daha ayrıntılı biçimde ortaya konabilmesi amacıyla, fark indisleri destekleyici göstergeler olarak kullanılmaktadır. Bu kapsamda, dNDVI değerinin 0.1’i aştığı alanlar bitki örtüsü kaybı olarak, dNDMI değerinin 0.05’i aştığı alanlar ise nem kaybı olarak değerlendirilmiştir. Literatürde, dNBR’nin yangın sonrası bitki örtüsü kaybı ve yüzey değişimlerini etkili biçimde yansıttığı, dNDVI ve dNDMI’nin ise sırasıyla bitki örtüsü ve nem değişimlerine duyarlı olduğu ifade edilmektedir (Zahabnazouri vd., 2025). Bu indislerin birlikte kullanılması, yangın sonrası etkilerin daha kapsamlı bir biçimde değerlendirilmesini sağlamaktadır.

3.2 Veriseti hazırlama

Bu bölümde çalışma boyunca kullanılacak verisetinin nasıl oluşturulduğu özetlenmektedir. Farklı kaynaklardan elde edilen verilerin tek bir yapıda kullanılabilmesi için önce veriler aynı çalışma alanı ve zaman aralığına göre düzenlenmiş, ardından gerekli ön işlemler uygulanarak ortak bir formatta birleştirilmiştir. Bu süreçte amaç, hem verilerin tutarlılığını sağlamak hem de modelleme aşamasına doğrudan aktarılabilir, temiz ve düzenli bir öznitelik tablosu üretmektir. Böylece veri hazırlama adımları netleştirilmiş ve sonraki bölümlerde detaylandırılacak analizler için sağlam bir temel oluşturulmuştur.

3.2.1 Ortam

Bu çalışma kapsamında uzaktan algılama verilerinin elde edilmesi, ön işlenmesi ve spektral indeks hesaplamaları için Google Earth Engine (GEE) platformu kullanılmıştır. GEE'nin bulut tabanlı yapısı sayesinde Sentinel, Landsat ve ERA-5 Land gibi büyük hacimli uydu veri setlerine hızlı erişim sağlanmış, gerekli filtrelemeler ve indeks hesaplamaları doğrudan platform üzerinde gerçekleştirilmiştir.

Ancak Google Earth Engine ortamı, istemci taraflı işlemlerde veri boyutuna ilişkin kısıtlar içermekte ve büyük örneklem setleriyle detaylı makine öğrenmesi uygulamaları açısından sınırlı esneklik sunmaktadır. Ayrıca GEE bünyesinde bulunan makine öğrenmesi algoritmaları, model çeşitliliği, hiperparametre optimizasyonu ve ileri seviye değerlendirme metrikleri bakımından sınırlıdır.

Bu nedenlerle, GEE ortamında elde edilen öznitelik tabloları dışa aktarılmış ve makine öğrenmesi tabanlı analizler Google Colab ortamında gerçekleştirilmiştir. Google Colab, Python tabanlı açık kaynak kütüphaneler (örneğin scikit-learn, XGBoost, LightGBM vb.) sayesinde farklı makine öğrenmesi algoritmalarının uygulanmasına, model karşılaştırmalarının yapılmasına ve hiperparametre optimizasyonunun esnek bir şekilde yürütülmesine olanak sağlamıştır.

Sonuç olarak, bu çalışmada Google Earth Engine ve Google Colab birlikte kullanılarak, her iki platformun güçlü yönlerinden yararlanılan bütüncül ve verimli bir çalışma ortamı oluşturulmuştur.

3.2.2 Kullanılan özellikler

Bu çalışmada makine öğrenmesi modellerinin girdisi olarak, hava kalitesi üzerinde etkili olan meteorolojik ve yüzey özelliklerini temsil eden değişkenler kullanılmıştır. Tüm özellikler çalışma alanı ve zaman aralığına göre eşleştirilmiş ve modelleme aşamasında girdi değişkenleri olarak değerlendirilmiştir.

Meteorolojik değişkenler ERA5-Land veri setinden elde edilmiştir. Bu kapsamda, atmosferin termodinamik durumunu temsil etmek amacıyla 2 m hava sıcaklığı (T2M), 2 m çiğ noktası sıcaklığı (D2M) ve yüzey basıncı (SP) kullanılmıştır. Atmosferik taşınım süreçlerini yansıtmak amacıyla rüzgâr hızı (WS) ve rüzgâr yönü (WD) modele dâhil edilmiştir. Ayrıca enerji dengesi ve atmosferik koşulların etkisini temsil etmek üzere yüzeye ulaşan güneş radyasyonu (SSRD) ve toplam yağış (TP) değişkenleri kullanılmıştır. Toprak buharlaşması/evapotranspirasyon ile ilişkili parametre (TE) ve yüzey albedo bileşeni (FAL) kullanılmıştır. Yüzey koşullarını ve bitki örtüsünün etkisini temsil etmek amacıyla yüksek bitki örtüsü yaprak alan indeksi (LAI_HV) ve düşük bitki örtüsü yaprak alan indeksi (LAI_LV) değişkenleri modele girdi olarak eklenmiştir. Çizelge 3.2’de kullanılan gösterilen ve modellere giren tüm değişkenler, makine öğrenmesi modellerinin performansını artırmak amacıyla birlikte değerlendirilmiş ve analiz edilmiştir.

Çizelge 3.2 : Makine öğrenmesi modellerine giren değişkenler.

İsim	Veri	Birim	Kaynak	Mekânsal çözünürlük	Zamansal çözünürlük
NO2_value	Yersel NO ₂	µg/m ³	İstasyon	-	Saatlik
CO_value	Yersel CO	µg/m ³	İstasyon	-	Saatlik
no2_satellite_umol	Troposferik NO ₂	mol/m ²	Sentinel-5P	1.1 km	Günlük
co_satellite_umol	Sütun sayısal yoğunluğu CO	mol/m ²			
elevation	Yükselti	m	TanDEM-X	30m	-
T2M	2m hava sıcaklığı	K			
D2M	2m çiğ noktası sıcaklığı	K			
WS_calc	10m rüzgâr hızı	m/s			
WD_calc	10m rüzgâr yönü	Derece (°)			
SP	Yüzey basıncı	Pa			
LAI_HV	Yüksek bitki örtüsü yaprak alan indeksi	Area fraction	ERA-5 Land	11km	Saatlik
LAI_LV	Düşük bitki örtüsü yaprak alan indeksi	Area fraction			
SSRD	Yüzeye gelen güneş radyasyonu	J/m ²			
TE	Toplam buharlaşma	m su eşdeğeri			


3.2.3 Ön işleme

Yangın tespiti için yapılan analizlerde spektral indislerin hesaplanmasından önce, tüm uydu görüntüleri veri tutarlılığını sağlamak ve gürültüyü azaltmak amacıyla ön işleme adımlarından geçirilmiştir. Bu kapsamda, Google Earth Engine (GEE) ortamında

ölçekleme, bulut ve su maskesi uygulamaları gerçekleştirilmiş ve her bir çalışma alanı için yangın öncesi ve yangın sonrası mozaikler oluşturulmuştur. Sentinel-2 verileri için Harmonized Surface Reflectance ürününe ait optik bantlar, sayısal değerlerin yüzey yansıtımına dönüştürülmesi amacıyla 0.0001 ölçekleme faktörü ile çarpılmıştır. Her bir ilgi alanı (AOI) için, bulut oranı %10'un altında olan görüntüler kullanılarak kısa bir zaman aralığında medyan kompozit yöntemi ile yangın öncesi ve yangın sonrası mozaikler üretilmiştir. Elde edilen mozaikler AOI sınırlarına göre kırılmış ve Scene Classification Layer (SCL) kullanılarak su yüzeyleri (SCL = 6) maskelenmiştir. Yangın indekslerinin hesaplanmasında kullanılan bazı bantlar, özellikle SWIR1 ve SWIR2, Sentinel-2 veri setinde özgün olarak 20 m mekânsal çözünürlükte sunulduğundan, bu bantlar 10 m çözünürlüğe yeniden örneklenmiş ve görünür ile yakın kızılötesi (NIR) bantlarla mekânsal tutarlılık sağlanmıştır. Landsat 8 ve Landsat 9 verileri için ise optik bantlara USGS tarafından sağlanan resmi radyometrik ölçekleme parametreleri uygulanmış, yüzey yansıtım değerleri 0.0000275 çarpanı ile ölçeklenmiş ve -0.2 ofseti eklenmiştir. Sentinel-2'ye kıyasla daha uzun tekrar geçiş süresi göz önünde bulundurularak, yangın öncesi ve sonrası mozaikler daha geniş bir zaman aralığında oluşturulmuş ve yalnızca bulut örtüsü %20'nin altında olan sahneler kullanılmıştır. Su yüzeyleri, yakın kızılötesi bant yansıtım değerine dayalı bir eşik yöntemi kullanılarak ($SR_B5 < 0.04$) maskelenmiştir. Landsat 8/9 verilerinde yangın indekslerinin hesaplanmasında kullanılan tüm optik bantlar 30 m mekânsal çözünürlükte sunulduğundan, ek bir yeniden örnekleme işlemine ihtiyaç duyulmamıştır.

Türkiye çalışma alanı için oluşturulan veri seti yangın olayları sırasında ortaya çıkan NO_2 konsantrasyonlarındaki ani artışları ve düşük arka plan koşullarını daha iyi temsil edebilmek amacıyla uygulanan bir ön işleme süreci sonucunda oluşturulmuştur. Bu kapsamda yersel NO_2 ölçümlerinin istatistiksel dağılımı dikkate alınmış ve değişkenliğin daha belirgin olduğu üst (%90 üzeri) ve alt (%10 altı) persentil aralıklarında yer alan gözlemler özellikle veri setine dahil edilmiştir. Bu gözlemler yangın kaynaklı kirletici artışlarını ve yangın dışı dönemlerdeki arka plan seviyelerini temsil etmesi nedeniyle korunmuştur. Bu aşamanın ardından veri setinde yer alan tüm eksik (null) gözlemler analiz kapsamı dışında bırakılmıştır. Ayrıca, fiziksel olarak anlamlı olmayan ve uydu tabanlı NO_2 sütun yoğunluğu veya yersel NO_2 konsantrasyonu negatif değer alan gözlemler veri setinden çıkarılmıştır. Bu işlem,


ölçüm hataları veya veri işleme kaynaklı anomalilerin analiz sonuçları üzerindeki etkisini azaltmak ve fiziksel tutarlılığı sağlamak amacıyla uygulanmıştır. Uygulanan ön işleme adımları sonucunda oluşturulan veriseti, toplam 3135 gözlemden oluşmaktadır. Bu veri seti için uydu tabanlı NO₂ sütun yoğunlukları (TROPOMI-S5P) ile yersel NO₂ konsantrasyonları arasındaki Pearson korelasyon katsayısı 0.637 olarak hesaplanmış olup, bu değer iki veri kaynağı arasında orta düzeyde bir doğrusal ilişki bulunduğunu göstermektedir. CO parametresi için toplam veri sayısı 1728 olup uydu tabanlı CO sütun yoğunlukları (TROPOMI-S5P) ile yersel CO konsantrasyonları arasındaki Pearson korelasyon katsayısı 0.411 olarak hesaplanmıştır (Şekil 3.2).



Şekil 3.2 : Türkiye çalışma alanındaki uydu ve yersel veriler arasındaki korelasyon analizi.

Kaliforniya çalışma alanı için oluşturulan veri seti, yersel ve uydu tabanlı NO₂ ve CO gözlemleri arasında fiziksel ve istatistiksel tutarlılığı sağlamak amacıyla uygulanan temel bir ön işleme süreci sonucunda elde edilmiştir. Bu kapsamda, Amerika Birleşik Devletleri Çevre Koruma Ajansı (United States Environmental Protection Agency, EPA) tarafından sağlanan yersel hava kalitesi verileri başlangıçta ABD geneli için indirilmiş olup, yaklaşık bir milyondan fazla saatlik gözlem içeren bu veri kümesi içerisinde Kaliforniya eyaletine ait istasyonlar, Google Colab ortamında gerçekleştirilen mekânsal ve öznitelik tabanlı filtreleme işlemleriyle ayrıştırılmıştır. Ön işleme aşamasında hem yersel ölçümler hem de uydu tabanlı gözlemler için eksik (NaN) değer içeren ve fiziksel olarak anlamlı olmayan negatif değerler veri setinden çıkarılmıştır. Bu temizlik adımı, olası ölçüm hataları ve veri işleme kaynaklı anomalilerin analiz sonuçları üzerindeki etkisini azaltmak amacıyla tüm veri setine aynı şekilde uygulanmıştır. Uygulanan ön işleme adımları sonucunda oluşturulan nihai veri seti NO₂ parametresi için toplam 5055 gözlemden oluşmaktadır. Bu veri seti için uydu tabanlı NO₂ sütun yoğunlukları (TROPOMI-S5P) ile yersel NO₂

konsantrasyonları arasındaki Pearson korelasyon katsayısı 0.709 olarak hesaplanmıştır. CO parametresi için toplam veri sayısı 2498 olup uydu tabanlı CO sütun yoğunlukları (TROPOMI-S5P) ile yersel CO konsantrasyonları arasındaki Pearson korelasyon katsayısı 0.252 olarak hesaplanmıştır (Şekil 3.3).



Şekil 3.3 : Kaliforniya çalışma alanındaki uydu ve yersel veriler arasındaki korelasyon analizi.


3.3 Makine öğrenmesi yöntemleri

Makine öğrenmesi yöntemleri, çok değişkenli ve doğrusal olmayan ilişkilerin bulunduğu veri setlerinde tahmin ve modelleme performansını artırmak amacıyla yaygın olarak kullanılmaktadır. Özellikle uzaktan algılama ve çevresel analizlerde, farklı kaynaklardan elde edilen yüksek boyutlu verilerin birlikte değerlendirilmesine olanak sağlaması nedeniyle bu yöntemler öne çıkmaktadır. Bununla birlikte, çalışma alanı, veri yapısı ve araştırma amacına bağlı olarak en iyi performansı sağlayan makine öğrenmesi yöntemi değişebileceğinden, literatürde genellikle birden fazla algoritmanın karşılaştırmalı olarak test edilmesi tercih edilmektedir.

3.3.1 Rastgele orman (Random Forest)

Random Forest, birden çok karar ağacının çıktılarını bir araya getirerek daha güvenilir tahminler üreten bir makine öğrenmesi yöntemidir (Li vd., 2022). Bu yöntem ilk olarak 2001 yılında Breiman tarafından ortaya konmuştur. Her ağaç, veri ve değişkenlerin rastgele bir alt kümesiyle eğitildiği için modeller arası korelasyon azalır ve genel hatayı düşürür. Breiman, modelin doğruluğunun ağaçların bireysel başarısı (strength) ile aralarındaki bağımlılığın (correlation) dengesiyle belirlendiğini göstermiştir (Breiman, 2001). Random Forest, uzaktan algılama çalışmalarında yüksek boyutlu ve

çok kaynaklı verilerle çalışabilme, değişken önemini belirleme ve aşırı öğrenmeye karşı dayanıklı yapısı nedeniyle en yaygın kullanılan sınıflandırıcılardan biri haline gelmiştir (Belgiu & Drăguț, 2016). Şekil 3.4'te gösterildiği üzere Rastgele Orman yöntemi, aynı girdi örneğinin birden fazla karar ağacı tarafından bağımsız olarak değerlendirilmesi ve bu ağaçlardan elde edilen çıktıların çoğunluk oylaması veya ortalaması alınarak nihai sonucun üretilmesine dayanmaktadır.



Şekil 3.4 : Rastgele Orman yöntemi.

3.3.2 Destek vektör makinesi (Support Vector Machine)

Support Vector Machine (SVM), Cortes ve Vapnik (1995) tarafından geliştirilen ve verileri yüksek boyutlu bir özellik uzayında temsil ederek genelleme yeteneği yüksek karar fonksiyonları oluşturan bir öğrenme yöntemidir. Bu yaklaşım, maksimum marjin ilkesine dayanmakta olup doğrusal ve doğrusal olmayan problemlerin etkin biçimde modellenmesine olanak sağlamaktadır (Cortes & Vapnik, 1995). Sürekli hedef değişkenler için bu temel yapı, Support Vector Regression (SVR) olarak uyarlanmış ve ϵ -duyarsız kayıp fonksiyonu ile model karmaşıklığının kontrol edilmesi sağlanmıştır (Vapnik vd., 1996; Yang vd., 2024).


3.3.3 Gradyan artırma makinesi (Gradient Boosting Machine)

Gradient Boosting Regressor, Gradient Boosting Machines (GBM) yaklaşımının sürekli hedef değişkenler için kullanılan regresyon formudur ve aynı temel algoritmik yapıya dayanmaktadır. Bu algoritmada, çoğunlukla karar ağaçlarından oluşan zayıf öğrenciler ardışık olarak eğitilmekte ve her adımda önceki modelin hatalarını azaltmaya yönelik yeni bir model oluşturulmaktadır (Friedman, 2001; Wen vd., 2021).

Seçilen kayıp fonksiyonunun negatif gradyanı temel alınarak geliştirilen bu yapı sayesinde, doğrusal olmayan ve karmaşık ilişkiler kademeli olarak daha iyi temsil edilebilmektedir (Natekin & Knoll, 2013). Bu özellikleri sayesinde Gradient Boosting Regressor, yüksek boyutlu ve çok kaynaklı verilerde güçlü tahmin performansı sunan esnek ve etkili bir regresyon yöntemi olarak yaygın biçimde tercih edilmektedir.

3.3.4 Aşırı gradyan artırma (Extreme Gradient Boosting)

XGBoost, 2016 yılında Chen ve Guestrin tarafından geliştirilen, gradyan ağaç artırımı temelli hızlı ve ölçeklenebilir bir makine öğrenmesi yöntemidir. Düzenleştirme ve seyrek veriyle başa çıkma özellikleri sayesinde yüksek doğruluk ve verimlilik sağlar (Chen & Guestrin, 2016). XGBoost algoritması, her yinelemede gradyan bilgisini kullanarak hataları minimize eder ve zayıf karar ağaçlarını birleştirerek güçlü bir tahmin modeli oluşturur (Wei vd., 2025). Büyük veri setlerinde paralel işlem yeteneği ve yüksek hesaplama verimliliği, XGBoost'u benzer gradyan tabanlı yöntemlere kıyasla daha avantajlı hale getirmektedir (Shetty vd., 2024). Şekil 3.5'te gösterildiği üzere XGBoost yöntemi, bir önceki ağaçların hatalarını azaltmayı hedefleyen ardışık karar ağaçlarının katkılarının ağırlıklı olarak toplanmasıyla sonuç tahminin elde edilmesine dayanmaktadır.




Şekil 3.5 : XGBoost yöntemi.

3.3.5 Kategorik Güçlendirme (Categorical Boosting)

CatBoost, gradyan artırma temelli bir algoritma olup, özellikle kategorik verilerin dönüştürülmeden modele dahil edilebilmesi için geliştirilmiştir. Yandex araştırmacıları tarafından 2017 yılında önerilen bu yöntem, karar ağaçları üzerinde çalışarak dengeli ve yüksek doğrulukta tahminler üretir (Prokhorenkova vd., 2018).

CatBoost'un temel katkılarından biri, kategorik değişkenlerde yanlış bilgi aktarımını (target leakage) azaltan Ordered Target Statistics yaklaşımıdır ve ayrıca Ordered Boosting ile eğitim sırasında oluşabilecek tahmin sapması düşürülerek modelin daha kararlı şekilde öğrenmesi sağlanır (Hancock & Khoshgoftaar, 2020). Bu nedenle CatBoost, heterojen veri setlerinde daha stabil çalışan ve genelleme performansı yüksek bir gradyan artırma yöntemidir. Sonuç olarak, kategorik değişkenler için sıralı hedef istatistiklerini kullanarak oluşturulan ardışık karar ağaçlarının çıktılarının ağırlıklı ortalamasının alınmasıyla nihai tahmini üretmektedir (Şekil 3.6).



Şekil 3.6 : CatBoost yöntemi.

3.3.6 Hafif gradyan artırma makinesi (Light Gradient Boosting Machine)

LightGBM, Gradyan Artırmalı Karar Ağaçları (Gradient Boosting Decision Tree-GBDT) tabanlı bir topluluk öğrenme algoritmasıdır. Büyük ölçekli veri kümeleri ve yüksek boyutlu özellik uzayları için Microsoft araştırmacıları tarafından 2017 yılında geliştirilmiştir (Ke vd., 2017). Algoritma, sürekli değişkenleri histogramlara dönüştürerek hesaplama maliyetini düşürmekte ve ağaçları seviye bazlı büyütme yerine kaybı en fazla azaltan yaprak üzerinden genişletmektedir (Tırınk, 2025). Ağaçlar ardışık olarak oluşturulmakta ve her adımda kayıp fonksiyonu minimize edilerek zayıf öğrencilerin birleşimiyle güçlü bir tahmin modeli elde edilmektedir (W. Zhu vd., 2025). Bu yapı sayesinde LightGBM, klasik GBDT yöntemlerine göre daha

hızlı eğitilirken, doğrusal olmayan ve karmaşık ilişkileri başarılı biçimde modelleyebilmektedir.

3.3.7 Uzun kısa süreli bellek (Long Short-Term Memory)

Tekrarlayan sinir ağlarında uzun zaman aralıklarına yayılan bilgilerin öğrenilmesi, hata sinyalinin zaman içinde zayıflaması nedeniyle oldukça zordur. Bu sorunu aşmak amacıyla Sepp Hochreiter ve Jürgen Schmidhuber, 1997 yılında Uzun Kısa Süreli Bellek (LSTM) mimarisini önermiştir (Hochreiter & Schmidhuber, 1997). Klasik yinelemeli sinir ağlarından (RNN) farklı olarak LSTM, gradyan kaybolması problemini azaltan özel bir hücre yapısına sahiptir (Han vd., 2025). LSTM mimarisinde bilgi akışı kapı mekanizmaları aracılığıyla kontrol edilmektedir. Giriş, unutma ve çıkış kapılarından oluşan bu yapı sayesinde hücre durumu zaman adımları boyunca seçici biçimde güncellenerek uzun zaman aralıklarına yayılan bilgilerin korunması sağlanmaktadır (Fania vd., 2025). Önceki RNN tabanlı yöntemlere kıyasla daha hızlı öğrenme sağlamakta ve daha önce çözülememiş uzun dönemli bağımlılık problemlerinde başarılı sonuçlar üretmektedir.


3.4 Shapley Katkı Değerleri (SHAP) ile Açıklanabilirlik

Açıklanabilir Yapay Zeka (Explainable Artificial Intelligence, XAI), makine öğrenmesi ve derin öğrenme modellerinin karar verme süreçlerinin anlaşılmasını amaçlayan yaklaşımları ifade etmektedir. XAI yöntemleri, modelin yapısına doğrudan gömülü olan içsel açıklanabilirlik ve model eğitimi sonrasında uygulanan sonradan açıklanabilirlik yaklaşımları olarak iki gruba ayrılmaktadır (J. Liu vd., 2024). Post-hoc açıklama yöntemleri teknik olarak modelden bağımsız (model-agnostic) ve modele özgü (model-specific) olarak iki gruba ayrılmaktadır. Modelden bağımsız yaklaşımlar farklı mimarilere uygulanabildiği için daha geniş bir kullanım alanı sunarken, modele özgü yaklaşımlar modelin iç mekanizmasını dikkate alarak çoğu zaman daha hedefe yönelik açıklamalar sağlayabilmektedir (Taskin vd., 2024). Sonradan açıklanabilirlik yöntemleri arasında yer alan Shapley Katkı Değerleri (SHAP) modelden bağımsız yapısı sayesinde farklı algoritmalara uygulanabilmekte ve hem küresel hem de yerel düzeyde değişken katkılarını nicel olarak sunabilmesi nedeniyle uzaktan algılama çalışmalarında en sık tercih edilen XAI yöntemlerinden biri olmuştur (Höhl vd., 2024).

SHAP, Lundberg ve Lee tarafından 2017’de model tahminlerini yorumlamak için birleştirici bir çerçeve olarak önerilmiştir (Lundberg & Lee, 2017). SHAP, her bir girdinin model çıktısına olan katkısını Shapley değerleri aracılığıyla nicel olarak ifade ederek, modelin beklenen çıktısından sapmanın hangi değişkenler tarafından ne ölçüde oluşturulduğunu ortaya koymaktadır (Aksoy vd., 2024). Shapley değerleri pozitif ya da negatif olabilmekte, pozitif değerler tahmini artırırken negatif değerler azaltmakta ve değerlerin büyüklüğü değişkenin tahmine etkisinin şiddetini göstermektedir (Günther vd., 2024). Teknik olarak SHAP, her bir değişkenin marjinal katkısını tüm olası özellik koalisyonları üzerinden ortalayarak (feature coalitions) hesaplar ve bu sayede tutarlı (consistent) ve yerel olarak doğru (locally accurate) açıklamalar üretir (Valerio vd., 2025). Bu çalışmada SHAP sonuçları, modelin hem küresel hem de yerel düzeyde nasıl davrandığını bütüncül biçimde yorumlayabilmek amacıyla dört temel grafik üzerinden incelenecektir: SHAP özet grafiği, özellik önem grafiği (feature importance), bağımlılık grafikleri (dependence plots) ve tekil örnek açıklamaları için kuvvet grafikleri (force/waterfall).

3.4.1 Özellik önem grafiği


Özellik önem grafikleri, modelin küresel ölçekte hangi değişkenlere daha duyarlı olduğunu göstermek için kullanılır. Bu amaçla her bir girdinin tahmine katkısı SHAP (Tree SHAP) değerleriyle hesaplanır ve değişkenler tüm örnekler boyunca ortalama mutlak SHAP değerine göre sıralanır (Meng vd., 2020). Şekil 3.7’de özellik önem grafiğine ait örnek gözükmemektedir. Bu grafikten en yüksek ortalama $|SHAP|$ değerinin uydudan gelen NO_2 değişkeninde olduğu görülmektedir. Bu bulgu, model çıktısının en güçlü biçimde uydu kaynaklı NO_2 bilgisi tarafından yönlendirildiğini göstermektedir. Bunu sırasıyla yükselti ve meteorolojik değişkenler izlemekte olup, bu değişkenler modelin tahminlerinde ikincil fakat anlamlı katkılar sunmaktadır.



Şekil 3.7 : SHAP özellik önem grafiği.

3.4.2 Özet grafiği

Özet grafiği değişkenlerin model çıktısına olan etkisinin yönünü ve dağılımını SHAP değerleri üzerinden göstermek için kullanılmaktadır. Değişkenler önem sırasına göre listelenir ve renk skalası etki gücünü gösterir, kırmızı tonlar daha güçlü etkiyi, mavi tonlar ise daha zayıf etkiyi temsil eder (Alam vd., 2025). Şekil 3.8'e bakıldığında no2_satellite_umol değişkeni en geniş yayılıma sahip olup model tahminleri üzerinde en baskın etkiyi oluşturmaktadır. Bu değişkende yüksek özellik değerlerinin çoğunlukla pozitif SHAP bölgesinde yoğunlaşması, uydu NO₂ değerleri arttıkça modelin tahmin ettiği NO₂ seviyelerinin de artma eğiliminde olduğunu göstermektedir. Elevation ve T2M değişkenlerinde SHAP değerlerinin hem pozitif hem negatif yönde dağıldığı görülmekte olup, etkinin doğrusal olmayan bir karakter sergileyebileceğine işaret etmektedir. Diğer meteorolojik ve yüzey değişkenlerinin SHAP dağılımları daha dar bir aralıkta kalmış ve bu değişkenlerin katkılarının görece sınırlı olduğu anlaşılmıştır.




Şekil 3.8 : SHAP özet grafiği.

3.4.3 Kuvvet grafiği

Kuvvet grafiği (force plot), yerel açıklanabilirlik kapsamında örnek düzeyindeki değişken katkılarını görselleştirerek tekil bir tahminin hangi girdiler tarafından ve hangi yönde etkilendiğinin daha açık biçimde yorumlanmasını sağlar (Liao vd., 2025). Kuvvet grafiği, tekil bir tahminin nasıl oluştuğunu göstermek için önce modelin başlangıç tahmini olan baz değer (base value) değerini referans alır. Baz değer, genellikle veri seti genelindeki ortalama çıktı düzeyini temsil eder ve her bir değişkenin katkısı bu başlangıç değerini artırarak ya da azaltarak nihai tahmine ulaşılmasını sağlar. Şekil 3.9'da grafikte kırmızı tonlar tahmini yükselten katkıları,

mavi tonlar ise tahmini düşüren katkıları ifade eder. Bu örnek kuvvet grafiği'nde uydu kaynaklı NO₂ değişkeni ve sıcaklık gibi girdilerin tahmini artırıcı yönde güçlü katkı verdiği görülmektedir. Buna karşılık yüzey güneş radyasyonu ve basınç değişkenleri tahmini azaltıcı yönde etkileyerek artışı kısmen dengelemektedir.



Şekil 3.9 : SHAP kuvvet grafiği.

3.5 Doğruluk Analizi

Doğruluk analizi, gerçekleştirilen modelleme sonuçlarının tutarlı ve bilimsel olarak kullanılabilir olduğunun ortaya konması açısından kritik bir adımdır. Bu nedenle özellikle makine öğrenmesi ve derin öğrenme tabanlı çalışmalarda, modelin eğitim sürecinde kullanılmayan (bağımsız) veriler doğruluk değerlendirmesi için ayrılır. Böylece modelin daha önce hiç görmediği örnekler üzerindeki performansı ölçülerek, gerçek anlamda öğrenme mi gerçekleştirdiği yoksa eğitimi ezberlediği mi sorusuna cevap aranmaya çalışılır. Veri seti eğitim ve test kümelerine ayrılır. Eğitim kümesi modelin öğrenme sürecinde kullanılırken, test kümesi yalnızca nihai performansın tarafsız bir şekilde raporlanması için saklı tutulur. Buna ek olarak, tek bir eğitim, test bölmesinin oluşturabileceği örnekleme yanlılığını azaltmak ve performansın daha kararlı bir şekilde tahmin edilmesini sağlamak için çapraz doğrulama yöntemleri yaygın olarak kullanılmaktadır. Bu yöntemde eğitim verisi eşit büyüklükte katmanlara ayrılır. Her yinelemede katmanların bir kısmı modelin kurulumu için kullanılırken kalan katman doğrulama amacıyla ayrılır ve süreç her katmanın en az bir kez doğrulamada yer alacağı şekilde tekrarlanır (Long vd., 2022). Böylece performans ölçütleri farklı bölmeler boyunca tekrarlanarak ortalama davranış ve olası sapmalar daha sağlam biçimde ortaya konmaktadır. Doğruluk analizlerinde modellerden çıkan tahmin değerleri ile gerçek yersel ölçümler karşılaştırılır (Ngo vd., 2023). Regresyon problemlerinde model performansı determinasyon katsayısı R^2 ve hata büyüklüğünü doğrudan temsil eden kök ortalama kare hata (RMSE) metrikleri üzerinden

değerlendirilmektedir. R^2 açıklanan varyans düzeyini ifade etmektedir. Denklem 3.5’de determinasyon katsayısının nasıl hesaplandığı görülmektedir.

$$R^2 = 1 - \frac{\sum_{i=1}^k (x_i - y_i)^2}{\sum_{i=1}^k (x_i - \bar{x})^2} \quad (3.5)$$

Burada x_i gözlenen (gerçek) değerleri ifade etmektedir, y_i ise model tarafından tahmin edilen değerleri temsil etmektedir. Gözlenen değerlerin ortalamasını ifade eden $\bar{x}$ iken k toplam gözlem sayısını göstermektedir.

RMSE ise tahminlerin gerçek değerlere olan tipik sapmasını ifade eder. Hedef değişkeniyle aynı ölçüm biriminde ifade edilir ve bu nedenle konsantrasyon birimlerinde (ör. ppbv veya $\mu\text{g}/\text{m}^3$) raporlanır (Siddique vd., 2024). Denklem 3.6’da RMSE için kullanılan formül görülmektedir. Burada x_i i ’inci gözlemin gerçek (ölçülen) değeridir, y_i ise i ’inci gözlem için model tarafından üretilen tahmin değeridir.

$$RMSE = \sqrt{\frac{1}{k} \sum_{i=1}^k (x_i - y_i)^2} \quad (3.6)$$

Bu iki ölçütün birlikte raporlanması, yalnızca uyum düzeyini değil aynı zamanda hatanın ölçeğini de görünür kılarak model başarımının daha bütüncül ve karşılaştırılabilir biçimde yorumlanmasına olanak tanır.



4. BULGULAR VE TARTIŞMA


4.1 Türkiye Çalışma Alanı

4.1.1 Orman yangınlarının spektral indisler kullanılarak tespiti

Ulusal ölçekte değerlendirildiğinde, 2025 yangın sezonu boyunca Türkiye genelinde tespit edilen toplam yanmış alan büyüklüğü, Sentinel-2A/B verileri kullanılarak 101503.99 hektar (ha), Landsat 8/9 verileri kullanılarak ise 100058.78 ha olarak hesaplanmıştır. İki sensör arasında elde edilen bu yakın değerler, farklı mekânsal ve zamansal çözünürlüklere sahip olmalarına rağmen, her iki veri setinin de yangından etkilenen alanların genel büyüklüğünü tutarlı bir şekilde temsil ettiğini göstermektedir.

Şekil 4.1’de sunulan mekânsal dağılım incelendiğinde, büyük ölçekli yangınların ağırlıklı olarak Ege ve Akdeniz kıyı kuşağında yoğunlaştığı görülmektedir. Bu durum, söz konusu bölgelerdeki özellikle yaz aylarında belirginleşen kuraklık koşulları ve insan kaynaklı baskıların yangın oluşumu ve yayılımı üzerindeki belirleyici etkisiyle ilişkilendirilebilir. Buna karşılık, İç Anadolu ve Doğu Anadolu bölgelerinde yanmış alanların daha sınırlı ve parçalı bir dağılım sergilemesi, bitki örtüsü sürekliliğinin ve yanıcı biyokütle miktarının görece düşük olmasıyla açıklanabilir.

Çizelge 4.2’de sunulan en büyük 15 orman yangınına ait yanmış alan büyüklükleri incelendiğinde, Sentinel-2 A/B ve Landsat-8/9 verileri arasında tüm çalışma alanları için yüksek düzeyde bir tutarlılık olduğu görülmektedir (Tumer & Sertel, 2025). En geniş yanmış alanlar Bilecik/Sakarya, Seferihisar/İzmir ve Çeşme/İzmir bölgelerinde tespit edilmiştir. Sentinel-2 A/B verilerinin çoğu çalışma alanında Landsat-8/9’a kıyasla hafifçe daha yüksek yanmış alan değerleri üretmesi, yüksek mekânsal çözünürlüğün özellikle parçalı ve heterojen yangın sınırlarının daha ayrıntılı biçimde yakalanmasına olanak tanınmasıyla açıklanabilir. Buna karşılık, Mersin ve Şarköy/Çanakkale gibi bazı alanlarda Landsat-8/9’un nispeten daha yüksek alan değerleri üretmesi, zamansal geçiş farkları ve yangın sonrası toparlanma sürecinin sensörler arasında farklı zamanlarda örneklenmesinden kaynaklanmış olabilir.




Şekil 4.1 : 2025 yılında Türkiye'de gerçekleşen en büyük orman yangınları.

Şekil 4.2 : 2025'te Türkiye'de gerçekleşen en büyük 15 orman yangını.

No	Çalışma alanı	Yanan alan (ha)		Zaman aralığı (2025)
		Sentinel-2 A/B	Landsat-8/9	
1	Bilecik/Sakarya	12921.7	12434.6	19-22 Temmuz
2	Seferihisar/İzmir	11468.2	11090.3	29 Haziran – 2 Temmuz
3	Çeşme/İzmir	10277.2	10257.9	2-4 Temmuz
4	Karabük	7804.2	7440.4	22-26 Temmuz
5	Gölpazarı/Sakarya	6912.5	6840.6	27 Haziran – 2 Temmuz
6	Mersin	6809.8	6921.5	13-14 Ağustos
7	Şarköy/Çanakkale	6754.0	6890.1	15-20 Temmuz
8	Gelibolu/Çanakkale	5355.8	5316.2	16-18 Ağustos
9	Harmancık/Bursa	4440.6	4370.1	26-30 Temmuz
10	Hatay	3882.9	3731.7	30 Haziran – 2 Temmuz
11	Buca/İzmir	1988.0	1974.5	29 Haziran – 5 Temmuz
12	Uşak	1891.6	1836.6	26-27 Temmuz
13	Kahramanmaraş	1789.6	1708.1	26-28 Temmuz
14	Görsu-Kestel/Bursa	1443.2	1445.5	26-27 Temmuz
15	Güzelyalı/Çanakkale	1392.1	1377.1	11-13 Ağustos

Genel olarak, sensörler arasında gözlenen alan farklarının sınırlı düzeyde kalması, büyük ölçekli yangınların hem Sentinel-2 A/B hem de Landsat-8/9 verileriyle güvenilir biçimde haritalanabildiğini ve çoklu uydu kullanımının yangın hasar değerlendirmelerinde metodolojik sağlamlık sağladığını ortaya koymaktadır.


Şekil 4.3’de gözüken görsellerde yangın günlerinde ve hemen sonrasında yüksek sıcaklık değerlerine sahip alanların mekânsal olarak yoğunlaştığı bölgeler izlenebilmekte, bu alanlar yangının etkilediği sahaları ve yayılım yönünü işaret etmektedir. ECOSTRESS verileri Türkiye genelinde düzenli ve sık zaman aralıklarıyla elde edilemediğinden, yangın sürecinin tamamı kesintisiz olarak gözlemlenememiştir. Bununla birlikte, yangının aktif olduğu günlerde elde edilen örnek görüntüler, yüksek sıcaklık anomalileri aracılığıyla yangın alanlarının genel sınırlarını ve büyüme eğilimini ortaya koymaktadır.



Şekil 4.3 : Sakarya ve Bursa yangınlarına ait ECOSTRESS verisi & Sentinel 2A/B SWIR/NIR/RED kombinasyonu.


Şekil 4.4 ve Şekil 4.5 birlikte değerlendirildiğinde, her iki yangın alanında da dNDVI ve dNDMI haritalarının bitki örtüsü ve nem koşullarında belirgin bir azalmaya işaret ettiği görülmektedir. Ancak Seferihisar yangınında dNDVI ve dNDMI değişimlerinin daha homojen ve geniş alanlara yayıldığı, Sakarya/Bilecik yangınında ise bu değişimlerin daha parçalı ve heterojen bir mekânsal dağılım sergilediği dikkat çekmektedir. Yanma şiddeti haritaları incelendiğinde, Seferihisar yangınında yüksek

ve orta-yüksek şiddet sınıflarının daha geniş ve bütüncül alanlar oluşturduğu, Sakarya/Bilecik yangınında ise yüksek şiddetli alanların çekirdek bölgelerde yoğunlaştığı ve çevresinde düşük ile orta şiddet sınıflarına geçiş gösterdiği görülmektedir.



Şekil 4.4 : İzmir/Seferihisar yangın alanı; (a) Sentinel-2 tabanlı dNDVI, (b) Landsat 8/9 tabanlı dNDVI fark haritası, (c) Sentinel-2 tabanlı dNDMI, (d) Landsat 8/9 tabanlı dNDMI fark haritası, (e) Sentinel-2 dNBR indeksine dayalı yanma şiddeti sınıfları ve (f) Landsat 8/9 dNBR indeksine dayalı yanma şiddeti sınıfları.

Sentinel-2A/B ve Landsat 8/9 tabanlı sonuçlar her iki çalışma alanında da benzer mekânsal örüntüler sunarken, Sentinel-2'nin özellikle Sakarya/Bilecik gibi parçalı yanmış alanlarda yangın sınırlarını daha ayrıntılı biçimde temsil ettiği gözlenmiştir.



Şekil 4.5 : Sakarya/ Bilecik yangın alanı; (a) Sentinel-2 tabanlı dNDVI, (b) Landsat 8/9 tabanlı dNDVI fark haritası, (c) Sentinel-2 tabanlı dNDMI, (d) Landsat 8/9 tabanlı dNDMI fark haritası, (e) Sentinel-2 dNBR indeksine dayalı yanma şiddeti sınıfları ve (f) Landsat 8/9 dNBR indeksine dayalı yanma şiddeti sınıfları.

4.1.2 Makine öğrenmesi modellerinin NO₂ ve CO tahmin performansları

Türkiye çalışma alanı için 90 istasyondan alınarak 15 Mayıs -30 Haziran 2025 tarihleri arasında oluşturulan NO₂ veri seti, model eğitimi ve değerlendirmesi amacıyla eğitim ve test alt kümelerine ayrılmıştır. Veri seti toplam 3135 gözlemden oluşmaktadır bunun %80'i eğitim, %20'si test amacıyla kullanılmıştır. Sonuç olarak eğitim veri seti 2508 gözlemden, test veri seti ise 627 gözlemden oluşacak şekilde bölünmüştür. CO veri seti için de aynı yaklaşım izlenmiştir. 15 Mayıs-30 Haziran 2025 tarihleri arasında 55 istasyondan alınarak oluşturulan CO veri seti toplamda 1728 gözlemden oluşmaktadır. Eğitim veri seti sayısı 1382, test veri seti sayısı ise 346 olacak şekilde ayrılmıştır.

Öncelikle makine öğrenmesi yöntemlerinde modelleri eğitmek için en uygun parametreleri bulmak adına ızgara arama yöntemi (grid search) kullanılmıştır. Burada klasik tam grid search yerine, hesaplama maliyetini azaltmak ve daha geniş parametre uzaylarını etkin biçimde tarayabilmek amacıyla rastgeleleştirilmiş arama (Randomized Search), ardışık eleme tabanlı arama (Successive Halving) ve olasılıksal/Bayesyen optimizasyon yaklaşımları kullanılmıştır. Bu yöntemler, tüm parametre kombinasyonlarını denemek yerine, performans metriği açısından daha yüksek katkı potansiyeline sahip parametre bölgelerine odaklanarak daha verimli bir optimizasyon sağlamaktadır.

Çizelge 4.1'de NO₂ modeli sonuçları, ağaç tabanlı boosting yaklaşımlarının öne çıktığını göstermektedir. En yüksek test başarımı CatBoost modeli ile elde edilmiştir ve test R² değeri 0.808, test RMSE değeri 6.644 µg/m³ olarak görülmektedir. GBR ve LightGBM modelleri yakın performans sergilemiş, Random Forest ve XGBoost daha düşük doğruluk değerlerinde kalmıştır. Bu tablo, NO₂ değişkeninin doğrusal olmayan ilişkilerinin boosting tabanlı yöntemlerle daha iyi temsil edilebildiğini göstermektedir.

Literatürde Sentinel-5P verileri ile meteorolojik ve yardımcı coğrafi değişkenlerin birlikte kullanıldığı çalışmalarda, R² değerlerinin genellikle 0.54-0.80 aralığında değiştiği görülmektedir. Örneğin Doğu Asya genelini kapsayan (Kang vd., 2021) çalışmada Random Forest ve XGBoost modelleri için R² 0.66–0.70 ve RMSE 4.75-5.07 ppb aralığında sonuçlar raporlanmıştır. Benzer şekilde Çin genelinde gerçekleştirilen çalışmalarda XGBoost ve türev modeller için R² yaklaşık 0.73-0.75 seviyelerine ulaşıldığı bildirilmektedir (Chi vd., 2022; Shao vd., 2023).

Bu çalışmada elde edilen sonuçlar incelendiğinde, CatBoost ($R^2 = 0.808$, RMSE = 6.644) ve Gradient Boosting Regressor ($R^2 = 0.804$, RMSE = 6.698) modellerinin en yüksek test başarımını sağladığı görülmektedir. Bu performans değerleri, özellikle Avrupa geneli için raporlanan XGBoost tabanlı çalışmaların üzerinde yer almakta ve karmaşık doğrusal olmayan ilişkilerin ağaç tabanlı topluluk (ensemble) modelleri ile daha etkili biçimde temsil edilebildiğini göstermektedir.

Random Forest modeli bu çalışmada $R^2 = 0.761$ ile literatürde sıkça raporlanan 0.65-0.80 aralığıyla tutarlı bir sonuç üretmiştir. Buna karşın SVR modelinin $R^2 = 0.563$ ve RMSE = 10.015 ile görece düşük performans sergilemesi, yüksek boyutlu ve doğrusal olmayan uydu ve meteoroloji ilişkilerinin çekirdek tabanlı yöntemlerle yeterince temsil edilemediğini göstermektedir. Benzer eğilimler, Milano/İtalya ve Vietnam odaklı çalışmalarda da SVR ve klasik regresyon modellerinin daha yüksek hata değerleri üretmesiyle raporlanmıştır (Cedeno Jimenez & Brovelli, 2023; Ngo vd., 2023).

Derin öğrenme tabanlı LSTM modelinin bu çalışmada Test $R^2 = 0.140$ gibi sınırlı bir performans sergilemesi, literatürde bildirilen bazı LSTM uygulamalarıyla örtüşmektedir. Özellikle günlük ölçekli ve istasyon sayısı sınırlı veri setlerinde, LSTM modellerinin yeterli zamansal çeşitliliği öğrenemediği ve klasik ensemble yöntemlerinin gerisinde kaldığı bilinmektedir.

Çizelge 4.1 : Türkiye çalışma alanı için geliştirilen NO₂ parametresi makine öğrenmesi modellerinin performans karşılaştırması.

Model	5-fold CV R^2	Eğitim R^2	Test R^2	Test RMSE ($\mu\text{g}/\text{m}^3$)
Random Forest	[0.732 0.683 0.702 0.734 0.65]	0.855	0.761	7.41
LightGBM	[0.792 0.771 0.733 0.771 0.696]	0.924	0.791	6.924
XGBoost	[0.74 0.681 0.689 0.691 0.757]	0.833	0.767	7.305
GBR	[0.763 0.74 0.695 0.75 0.668]	0.895	0.804	6.698
CatBoost	[0.759 0.754 0.74 0.717 0.673]	0.906	0.808	6.644
SVR	[0.552 0.561 0.568 0.548 0.536]	0.736	0.563	10.015
LSTM	-	0.564	0.140	13.803

Aynı anda iki farklı yerde çıkan Bursa yangınları nedeniyle artış gösteren NO₂ tahmin haritalarında 40 $\mu\text{g}/\text{m}^3$ limit değerin üstündeki kısımlar filtrelenerek hava kalitesinden olumsuz etkilenen alanda kaç tane yapı bulunduğu çıkarılmıştır. OSM binalar (Url-2) verisinden elde edilen analizlere göre bu alanda yaklaşık 2506 yapı bulunmaktadır. Aynı şekilde Sakarya yangını için de 130 yapının bulunduğu gözükmemektedir. Bursa yangınlarının daha yoğun şehirleşmiş alanlara yakın konumlanması, şehir genelinde

hava kalitesi üzerindeki olumsuz etkinin daha belirgin olmasına neden olmuştur. Bu durum, Bursa yangınlarının Sakarya yangınına kıyasla çok daha geniş bir nüfusu potansiyel olarak etkilediğini ortaya koymaktadır.

Çizelge 4.2 incelendiğinde Türkiye çalışma alanı için geliştirilen CO tahmin modelleri arasında ağaç tabanlı yöntemlerin Random Forest LightGBM XGBoost GBR ve CatBoost genel olarak daha yüksek performans sergilediği görülmektedir. Özellikle GBR modeli, 5-fold çapraz doğrulamada yaklaşık 0.76 ortalama R^2 , test verisinde 0.833 R^2 ve 168.851 $\mu\text{g}/\text{m}^3$ RMSE değeri ile en başarılı sonuçları sunarak öne çıkmaktadır. LightGBM modeli de yüksek test R^2 ve görece düşük RMSE değerleriyle güçlü bir performans sergilemiştir. Random Forest modeli dengeli bir performans sunmakla birlikte gradyan artırma tabanlı yöntemlerin gerisinde kalmıştır. CatBoost ve XGBoost modelleri yüksek eğitim başarısına rağmen test aşamasında sınırlı bir performans düşüşü göstermiştir bu durum kısmi aşırı uyum eğilimine işaret etmektedir. SVR ve LSTM modellerinin ise hem R^2 hem de RMSE metrikleri açısından diğer yöntemlere kıyasla belirgin biçimde zayıf kaldığı görülmektedir. Bu sonuçlar CO gibi atmosferik taşınım ve uzun ömür etkilerinin baskın olduğu bir kirletici için doğrusal olmayan ilişkileri güçlü biçimde yakalayabilen ağaç tabanlı makine öğrenmesi yaklaşımlarının daha uygun olduğunu göstermektedir

Çizelge 4.2 : Türkiye çalışma alanı için geliştirilen CO parametresi makine öğrenmesi modellerinin performans karşılaştırması.

Model	5-fold CV R^2	Eğitim R^2	Test R^2	Test RMSE ($\mu\text{g}/\text{m}^3$)
Random Forest	[0.704 0.802 0.767 0.665 0.667]	0.885	0.763	200.891
LightGBM	[0.778 0.814 0.796 0.717 0.781]	0.999	0.820	175.328
XGBoost	[0.76 0.838 0.632 0.792 0.754]	0.951	0.809	180.356
GBR	[0.727 0.799 0.808 0.712 0.74]	0.965	0.833	168.851
CatBoost	[0.804 0.833 0.777 0.711 0.731]	0.953	0.789	189.516
SVR	[0.451 0.481 0.472 0.439 0.475]	0.533	0.477	298.586
LSTM	-	0.544	0.157	13.664


CO için RMSE hata değerlerinin yüksek olması, değişkenin daha geniş bir değer aralığına sahip olması ve meteoroloji ile taşınım süreçlerine daha duyarlı olmasıyla ilişkilendirilebilir. Genel olarak, Türkiye çalışma alanında hem NO_2 hem de CO için boosting tabanlı modellerin daha kararlı ve başarılı sonuçlar ürettiği görülmüştür.

Şekil 4.6'da 21 Temmuz 2025 Sakarya yangın dönemi için üretilen yersel NO_2 tahmin haritaları, modeller arasındaki performans farklarını açık biçimde yansıtmaktadır. Random Forest diğer haritalara göre genel olarak daha düşük değerler tahmin etmiştir.


Fakat Bursa alanındaki yangın alanı kırmızı olarak gözlenmektedir. XGBoost ve LightGBM, mekânsal değişkenliği daha iyi temsil etse de yer yer aşırı düzgünleştirme etkisi göstermektedir. Buna karşılık Gradient Boosting ve özellikle CatBoost modelleri, yangından etkilenen bölgelerde daha belirgin NO₂ artışlarını ortaya koymuş ve en yüksek test performanslarıyla (CatBoost $R^2 = 0.808$, GBR $R^2 = 0.804$) tutarlı mekânsal örüntüler sunmuştur.

Şekil 4.7’de Bursa yangın dönemi (27 Temmuz 2025) için üretilen yersel NO₂ tahmin haritaları incelendiğinde, modeller arasında belirgin mekânsal farklılıklar olduğu görülmektedir. Random Forest haritası daha homojen ve bastırılmış bir dağılım sergilerken, XGBoost ve LightGBM modelleri NO₂ dağılımındaki mekânsal değişkenliği daha belirgin biçimde yansıtmaktadır. Gradient Boosting ve CatBoost haritalarında ise yangından etkilenen bölgelerde daha keskin ve tutarlı NO₂ artışları dikkat çekmektedir. Bütün modeller Bursa’da aynı anda çıkan iki yangını da tespit edebilmiştir.


Şekil 4.8’de Bursa yangın dönemi (27 Temmuz 2025) için üretilen yersel CO tahmin haritaları, modeller arasındaki performans farklarını açık biçimde yansıtmaktadır. Random Forest ve XGBoost yüksek CO değerlerini daha belirgin vurgularken, LightGBM ve CatBoost daha dengeli ve yumuşak mekânsal geçişler sunmaktadır. Gradient Boosting bazı bölgelerde CO seviyelerini görece yüksek tahmin etse de tüm modeller yangın kaynaklı CO artışının temel mekânsal örüntüsünü tutarlı biçimde yakalamıştır. CO tahmin haritalarında, yangın alanları çevresinde artışlar gözlenebilir olmakla birlikte, elde edilen mekânsal desenlerin detay seviyesi sınırlı kalmaktadır. Bu durumun temel nedenleri arasında Sentinel-5P TROPOMI CO verisinin görece düşük mekânsal çözünürlüğü, uydu tabanlı CO sütun yoğunluğu ile yersel CO ölçümleri arasındaki korelasyonun NO₂’ye kıyasla daha zayıf olması ve yersel CO istasyon verilerinin hem mekânsal hem de zamansal açıdan sınırlı sayıda bulunması yer almaktadır. Bu kısıtlar, yangın kaynaklı CO artışlarının genel eğiliminin haritalarda izlenebilmesine rağmen, daha ayrıntılı ve keskin mekânsal yapıların elde edilmesini engellemiştir.



Şekil 4.6 : Türkiye çalışma alanında yer alan Sakarya yangın dönemi (21 Temmuz 2025) sırasında farklı makine öğrenmesi modelleri kullanılarak üretilen yersel NO₂ tahmin haritaları. İlk harita, Sentinel-5P TROPOMI verisinin troposferik NO₂ sütun yoğunluğunu göstermektedir.



Şekil 4.7 : Türkiye çalışma alanında yer alan Bursa yangın dönemi (27 Temmuz 2025) sırasında farklı makine öğrenmesi modelleri kullanılarak üretilen yersel NO₂ tahmin haritaları. İlk harita, Sentinel-5P TROPOMI verisinin troposferik NO₂ sütun yoğunluğunu göstermektedir.



Şekil 4.8 : Türkiye çalışma alanında yer alan Bursa yangın dönemi sırasında farklı makine öğrenmesi modelleri kullanılarak üretilen yersel CO tahmin haritaları. İlk harita, Sentinel-5P TROPOMI verisinin CO sütun yoğunluğunu göstermektedir.

4.1.3 SHAP analizi ile tahminlerdeki etkili değişkenlerin belirlenmesi

Çizelge 4.3'te makine öğrenmesi modellerine giren değişkenler verilmiştir. BU değişkenlerin modellerdeki kararlara olan etkisi SHAP analizi ile değerlendirilmiştir.

Çizelge 4.3 : SHAP analizinde kullanılan değişkenler.

İsim	Veri
no2_satellite_umol	Yersel CO
co_satellite_umol	Sütun sayısal yoğunluğu CO
elevation	Yükselti
T2M	2m hava sıcaklığı
D2M	2m çiy noktası sıcaklığı
WS_calc	10m rüzgâr hızı
WD_calc	10m rüzgâr yönü
SP	Yüzey basıncı
LAI_HV	Yüksek bitki örtüsü yaprak alan indeksi
LAI_LV	Düşük bitki örtüsü yaprak alan indeksi
SSRD	Yüzeye gelen güneş radyasyonu
TE	Toplam buharlaşma

SHAP analizi sonuçları, tüm makine öğrenmesi modellerinde uydu tabanlı NO₂ değişkeninin (no2_satellite_umol) yersel NO₂ tahmininde en baskın açıklayıcı parametre olduğunu Şekil 4.9'da göstermektedir. Bu bulgu, Sentinel-5P TROPOMI verisinin yersel ölçümlerle güçlü bir ilişkiye sahip olduğunu ve model çıktılarının fiziksel olarak anlamlı bir temele dayandığını ortaya koymaktadır. Tüm modellerde ikinci en önemli değişken olarak yükselti (elevation) öne çıkmakta, bu durum topografyanın sınır tabakası dinamikleri ve kirletici birikimi üzerindeki etkisini doğrulamaktadır. Bitki örtüsünü temsil eden LAI_HV ve LAI_LV değişkenlerinin özellikle LightGBM, GBR ve CatBoost modellerinde daha yüksek önem değerlerine sahip olması, yüzey özelliklerinin ve arazi örtüsünün NO₂ dağılımı üzerindeki dolaylı etkilerini yansıtmaktadır. Meteorolojik değişkenler (T2M, rüzgâr hızı ve yönü, yüzey basıncı) ise tüm modellerde daha sınırlı ancak tutarlı bir katkı sunmuş. Modeller arası karşılaştırmada, ağaç tabanlı gradyan artırma yaklaşımlarının (özellikle XGBoost, LightGBM ve CatBoost) değişken önem sıralamalarında daha dengeli ve ayrıntılı bir dağılım sunduğu, Random Forest modelinde ise baskın değişkenlerin daha belirgin şekilde ayrıştığı gözlenmiştir. Bu durum, boosting tabanlı modellerin karmaşık ve doğrusal olmayan ilişkileri daha hassas biçimde yakalayabildiğini göstermektedir. Genel olarak SHAP sonuçları, kullanılan veri setinin fiziksel süreçlerle uyumlu

olduğunu ve modellerin yersel NO₂ tahmininde anlamlı, yorumlanabilir ve güvenilir çıktılar ürettiğini ortaya koymaktadır.

Şekil 4.10’da sunulan SHAP özellik önem grafikleri, Türkiye çalışma alanında yersel CO tahminlerinde topografik ve yüzey özelliklerinin belirleyici rol oynadığını açıkça ortaya koymaktadır. Tüm modellerde yükseklik (elevation) değişkeninin en baskın faktör olarak öne çıkması, CO birikiminin topoğrafya ile ilişkili atmosferik taşınım ve hapsolme süreçlerinden güçlü biçimde etkilendiğini göstermektedir. Düşük ve yüksek bitki örtüsü yoğunluğunu temsil eden LAI_LV ve LAI_HV değişkenlerinin yüksek öneme sahip olması, yangın dönemlerinde biyokütle yanmasının ve yüzey örtüsünün CO emisyonları üzerindeki etkisini vurgulamaktadır. Sentinel-5P kaynaklı CO sütun yoğunluğu değişkeninin tüm modellerde üst sıralarda yer almasına rağmen NO₂ gibi ilk sırada yer almaması uydu gözlemleri ile yersel CO konsantrasyonları arasındaki korelasyonun daha zayıf olmasından kaynaklanıyor olabilir.

Çizelge 4.4 ve 4.5’te sunulan deneysel kurulumlar, SHAP analiziyle elde edilen değişken önem sıralamalarının model performansına olan etkisini nicel olarak test etmek amacıyla tasarlanmıştır.


Çizelge 4.4 : Türkiye çalışma alanı için yükseklik (DEM) yardımcı verisi kullanılmadan geliştirilen NO₂ makine öğrenmesi modellerinin performans karşılaştırması.

Model	5-fold CV R ²	Eğitim R ²	Test R ²	Test RMSE (µg/m ³)
Random Forest	[0.65 0.574 0.595 0.646 0.602]	0.802	0.704	8.24
LightGBM	[0.680 0.625 0.633 0.675 0.611]	0.779	0.696	8.357
XGBoost	[0.638 0.568 0.573 0.629 0.635]	0.746	0.688	8.461
GBR	[0.649 0.585 0.572 0.649 0.603]	0.817	0.712	8.123
CatBoost	[0.662 0.605 0.591 0.563 0.609]	0.831	0.719	8.028


Çizelge 4.5 : Türkiye çalışma alanı için SHAP analizine göre en düşük katkıya sahip değişkenler (D2M, TE ve SSRD) dışlanarak oluşturulan NO₂ makine öğrenmesi modellerinin performans sonuçları.

Model	5-fold CV R ²	Eğitim R ²	Test R ²	Test RMSE (µg/m ³)
Random Forest	[0.73 0.699 0.717 0.736 0.648]	0.851	0.765	7.348
LightGBM	[0.786 0.772 0.759 0.769 0.689]	0.916	0.791	6.918
XGBoost	[0.763 0.692 0.702 0.697 0.772]	0.843	0.773	7.221
GBR	[[0.758 0.747 0.719 0.752 0.668]	0.915	0.812	6.564
CatBoost	[0.765 0.759 0.75 0.724 0.671]	0.899	0.814	6.538


Çizelge 4.4 ve 4.5 birlikte değerlendirildiğinde, SHAP analizinde öne çıkan bulguların model performansları üzerinde sayısal olarak da karşılık bulduğu görülmektedir.




(a)




(b)



(c)




(d)



(e)

Şekil 4.9 : Türkiye çalışma alanı NO₂ SHAP özellik önem grafikleri (a) RF, (b) XGBoost, (c) LightGBM,(d) GBR, (e) CatBoost.



Şekil 4.10 : Türkiye çalışma alanı CO SHAP özellik önem grafikleri (a) RF, (b) XGBoost, (c) LightGBM, (d) GBR,(e) CatBoost.


Çizelge 4.4 ve 4.5 birlikte değerlendirildiğinde, SHAP analizinde öne çıkan bulguların model performansları üzerinde sayısal olarak da karşılık bulduğu görülmektedir. DEM kullanılmadan geliştirilen modellerde test R^2 değerlerinin yaklaşık 0.69-0.72 aralığında kalması, topografyanın etkilerinin model tarafından öğrenememesine yol açmakta ve performans kaybına işaret etmektedir. SHAP analizine göre en düşük katkıya sahip olan D2M, TE ve SSRD değişkenleri model girdilerinden çıkarılarak oluşturulan ikinci deneysel kurulumda ise, tüm makine öğrenmesi modellerinde test performanslarının belirgin biçimde iyileştiği gözlenmiştir. Bu durumda test R^2 değerleri 0.77-0.81 aralığına yükselmiş, buna karşılık test RMSE değerleri tüm modellerde düşüş göstermiştir. Elde edilen bu sonuçlar, söz konusu değişkenlerin çalışılan zaman aralığı ve mekânsal ölçekte yersel NO_2 değişimini açıklamada sınırlı katkı sunduğunu ve modele gürültü ekleyerek genellenebilirliği olumsuz etkileyebildiğini göstermektedir. Özellikle gradyan artırma tabanlı modellerde (LightGBM, XGBoost, GBR ve CatBoost) performans artışının daha belirgin olması, bu modellerin gereksiz veya düşük bilgi içeren değişkenlere karşı daha duyarlı olduğunu ortaya koymaktadır. Genel olarak bu bulgular, SHAP analizinin yalnızca model açıklanabilirliği sağlamakla kalmayıp, aynı zamanda değişken seçimi açısından da etkili bir araç olduğunu ve daha sade bir özellik seti ile daha yüksek tahmin başarımı elde edilebileceğini göstermektedir.

Şekil 4.11’de sunulan SHAP dağılım grafiklerinde tüm modellerde uydu tabanlı NO_2 değişkeni (*no2_satellite_umol*) en baskın açıklayıcı parametre olarak öne çıkmakta, yüksek değerlerin çoğunlukla pozitif SHAP değerleriyle ilişkilendiği görülmektedir. Bu durum, uydu gözlemleri ile yersel NO_2 konsantrasyonları arasında güçlü ve tutarlı bir ilişki bulunduğunu göstermektedir. Yükselti (elevation) değişkeni ise tüm modellerde ikinci en etkili parametre olup, yüksek rakımlara karşılık gelen değerlerin genellikle negatif SHAP değerleri üretmesi, topografyanın kirletici birikimini sınırlayıcı bir rol oynadığını göstermektedir. Bitki örtüsünü temsil eden LAI_HV ve LAI_LV değişkenleri, özellikle gradyan artırma tabanlı modellerde orta düzeyde ancak tutarlı bir etki sergilerken, meteorolojik değişkenlerin (T2M, rüzgâr hızı ve yönü, yüzey basıncı) katkılarının daha sınırlı kaldığı görülmektedir. D2M, TE ve SSRD gibi değişkenlerin SHAP değerlerinin sıfıra yakın yoğunlaşması, bu parametrelerin çalışılan zaman aralığında yersel NO_2 değişimini açıklamada düşük bilgi içerdiğini ortaya koymaktadır.


Şekil 4.12’de sunulan SHAP özet grafikleri, CO tahminlerinde değişkenlerin modele katkısının yalnızca önem sırasıyla değil, aynı zamanda etki yönü ve yayılımı ile birlikte değerlendirilmesi gerektiğini göstermektedir. Tüm modellerde yükseklik değişkeninin geniş bir SHAP dağılımına sahip olması, topoğrafyanın CO birikimi ve taşınımı üzerinde güçlü ve değişken bir etkiye sahip olduğunu ortaya koymaktadır. LAI_LV ve LAI_HV değişkenlerinde yüksek değerlerin çoğunlukla pozitif SHAP katkılarıyla ilişkilendirilmesi, yangın dönemlerinde yoğun bitki örtüsünün CO konsantrasyonlarını artırıcı yönde etkilediğini göstermektedir. Uydu tabanlı CO sütun yoğunluğunun SHAP dağılımında yüksek değerlere karşılık gelen pozitif katkılar gözlenirse de, bu etkinin topografik ve yüzey değişkenlerine kıyasla daha dağınık olması, uydu-yersel CO ilişkisinin mekânsal ve zamansal olarak heterojen olduğunu düşündürmektedir.

Şekil 4.13’te sunulan SHAP kuvvet grafikleri, Türkiye çalışma alanında seçilen bir test örneği için farklı modellerin NO₂ tahminlerine hangi değişkenlerin ne yönde katkı sunduğunu açık biçimde ortaya koymaktadır. Tüm modellerde uydu tabanlı NO₂ sütun yoğunluğu tahmini artırıcı yönde en baskın değişken olarak öne çıkarken, yüzey basıncı, rüzgâr hızı ve güneşlenme ile ilişkili değişkenlerin de tahmin üzerinde anlamlı katkılar sağladığı görülmektedir. Buna karşılık yükseklik ve bazı meteorolojik parametrelerin tahmini düşürücü yönde etkide bulunduğu dikkat çekmektedir. Gerçek değer (9.54) ile tahminler karşılaştırıldığında, en düşük mutlak hatanın CatBoost modelinde, onu takiben Gradient Boosting modelinde elde edilmesi, bu modellerin genel performans metriklerinde öne çıkmasıyla tutarlıdır.

Şekil 4.14’te sunulan SHAP kuvvet grafiklerine bakıldığında tüm modellerde uydu tabanlı NO₂ sütun yoğunluğu ve rüzgâr hızı tahmini artırıcı yönde baskın değişkenler olarak öne çıkarken, yükseklik ve bazı meteorolojik parametrelerin tahmini düşürücü etkiler sunduğu görülmektedir. Gerçek değer (8.14) ile tahminler karşılaştırıldığında, en düşük mutlak hatanın XGBoost modelinde, onu Random Forest ve Gradient Boosting modellerinin izlediği görülmektedir. Buna karşılık CatBoost ve özellikle LightGBM modellerinde daha yüksek tahmin sapmaları gözlenmiş olup, bu durum değişken katkılarının bu örnek özelinde daha dengesiz birleşmesiyle ilişkilendirilebilir. Bununla birlikte, SHAP katkılarının yönsel tutarlılığı tüm modellerde korunmakta, bu da tahminlerin fiziksel olarak anlamlı ve açıklanabilir olduğunu göstermektedir.



Şekil 4.11 : Türkiye çalışma alanı NO₂ SHAP özet grafikleri (a) RF, (b) XGBoost, (c) LightGBM, (d) GBR, (e) CatBoost.



Şekil 4.12 : Türkiye çalışma alanı CO SHAP özet grafikleri (a) RF, (b) XGBoost, (c) LightGBM, (d) GBR, (e) CatBoost.


Şekil 4.15'te gösterilen kuvvet grafiklerinde uydu tabanlı NO₂ sütun yoğunluğu tahmini artırıcı yönde baskın değişken olarak öne çıkarken, rüzgâr yönü, yüzey basıncı ve yükseklik gibi değişkenlerin de tahmin üzerinde belirgin etkileri görülmektedir. Gerçek değer (56.92) ile tahminler karşılaştırıldığında, en düşük mutlak hatanın Gradient Boosting ve CatBoost modellerinde elde edilmesi genel performans metrikleriyle uyumlu olduğu göstermektedir.

Şekil 4.16'da sunulan SHAP kuvvet grafikleri, düşük NO₂ düzeyine sahip dördüncü test örneğinde modellerin tahmin davranışlarının belirgin biçimde ayrıştığını göstermektedir. Random Forest modeli, rüzgâr yönü (WD_calc) ve yaprak alan indeksi (LAI_HV) kaynaklı artırıcı katkıları dengeleyen uydu tabanlı NO₂ ve yükseklik etkileri sayesinde gerçek değere görece yakın bir tahmin (mutlak hata = 1.82) üretmiştir. XGBoost ve LightGBM modellerinde ise SSRD ve rüzgâr değişkenlerinin güçlü artırıcı katkıları, uydu NO₂ ve meteorolojik düşürücü etkileri aşarak belirgin aşırı tahmine yol açmış (mutlak hata > 5), bu durum değişken katkılarının bu örnek özelinde dengesiz biçimde birleştiğini göstermiştir. CatBoost ve Gradient Boosting modelleri, rüzgâr ve radyasyon kaynaklı artışları uydu NO₂ ve nem parametreleriyle daha dengeli biçimde bastırarak daha sınırlı tahmin sapmaları üretmiş (mutlak hata = 3.67 ve 3.24), ancak bu örnekte Random Forest modelinin daha isabetli sonuç verdiği görülmüştür.

Şekil 4.17'de sunulan SHAP kuvvet grafikleri, orta düzey NO₂ konsantrasyonuna sahip beşinci test örneğinde tüm modellerin belirgin biçimde eksik tahmin (underestimation) eğilimi gösterdiğini ortaya koymaktadır. Random Forest ve Gradient Boosting modellerinde, uydu tabanlı NO₂ sütun yoğunluğu ve sıcaklık kaynaklı artırıcı etkiler, rüzgâr hızı, yüzey basıncı ve evapotranspirasyonun güçlü düşürücü katkıları tarafından bastırılmış ve yüksek mutlak hatalara yol açmıştır. XGBoost, CatBoost ve LightGBM modellerinde de benzer şekilde SSRD, sıcaklık ve yükseklik etkilerinin artırıcı katkılarına rağmen, meteorolojik düşürücü bileşenlerin baskın gelmesi sonucu tahminler gerçek değerlerin yaklaşık 10-11 birim altında kalmıştır. Bu örnek özelinde, hiçbir model yüksek NO₂ seviyesini yeterince temsil edemezken, değişken katkılarının tüm modellerde benzer yönde birleşmesi, hatanın modelden çok girdi uzayındaki temsil sınırlılıklarıyla ilişkili olduğunu göstermektedir.



Şekil 4.13 : Türkiye çalışma alanı NO₂ 1. test örneği (18 Temmuz 2025) için SHAP kuvvet grafikleri.



Şekil 4.14 : Türkiye çalışma alanı NO₂ 2. test örneği (24 Haziran 2025) için SHAP kuvvet grafikleri.




Şekil 4.15 : Türkiye çalışma alanı NO₂ 3. test örneği (23 Mayıs 2025) için SHAP kuvvet grafikleri.


Kuvvet grafiklerinde yer alan test örnekleri incelendiğinde, Şekil 4.13'te sunulan açıklamanın Marmara Bölgesi'nde yer alan Sakarya Merkez istasyonuna (40.77°N, 30.41°E) ait bir ölçümü temsil ettiği görülmektedir. Şekil 4.14'te açıklanan örnek, Ege Bölgesi'nde yer alan İzmir ili Yeni Foça'daki ölçüm istasyonuna (38.74°N, 26.83°E) ait bir gözlemi yansıtırken, Şekil 4.15'te yer alan örnek İstanbul metropol alanında konumlanan Sultangazi istasyonuna (41.11°N, 28.87°E) ait bir ölçümü temsil etmektedir. Şekil 4.16'da sunulan kuvvet grafiği, Akdeniz Bölgesi'nde yer alan Antalya ili Alanya ilçesindeki ölçüm istasyonuna (36.56°N, 31.99°E) ait bir gözlemi göstermektedir. Son olarak, Şekil 4.17'de açıklanan örnek, İstanbul metropol alanında bulunan ancak Sultangazi'ye kıyasla farklı bir konumsal noktada yer alan Arnavutköy istasyonuna (41.22°N, 28.71°E) ait ölçümü temsil etmektedir.

Bu istasyonlara ait ölçülen NO₂ değerleri incelendiğinde, Sakarya Merkez, İzmir Yeni Foça ve Antalya Alanya istasyonlarında görece düşük konsantrasyonların gözlemlendiği görülmektedir. Bu durum, söz konusu istasyonların kentsel baskının daha sınırlı olduğu bölgelerde yer alması ile tutarlıdır. Buna karşılık İstanbul ili Sultangazi'de yer alan istasyonda ölçülen NO₂ değerinin diğer örneklerle kıyasla belirgin biçimde daha yüksek olması, bu bölgenin yoğun kentsel yapı, trafik ve insan faaliyetlerinin etkisi altında olduğunu göstermektedir. İstanbul Arnavutköy istasyonunda gözlenen orta düzeydeki NO₂ değeri ise, kentsel etkilere maruz kalmakla birlikte Sultangazi'ye kıyasla daha düşük yoğunluklu bir çevresel yapıya işaret etmektedir.

Türkiye çalışma alanına ait NO₂ SHAP analizi, modellerin fiziksel olarak tutarlı davrandığını göstermektedir. Tüm modellerde uydu tabanlı NO₂ değişkeni (no2_satellite_umol) en baskın açıklayıcı parametre olup, TROPOMI verileri ile yersel ölçümler arasındaki güçlü ilişkiyi ortaya koymaktadır. Yükselti (elevation) değişkeninin öne çıkması, topoğrafyanın kirletici birikimi üzerindeki etkisini doğrulamaktadır. LAI_HV ve LAI_LV değişkenleri, özellikle gradyan artırma tabanlı modellerde yüzey özelliklerinin NO₂ dağılımına katkı sunduğunu göstermektedir. Buna karşılık D2M, TE ve SSRD gibi değişkenlerin düşük SHAP katkıları, bu parametrelerin sınırlı bilgi içerdiğine işaret etmektedir. Genel olarak sonuçlar, Türkiye için geliştirilen NO₂ tahmin modellerinin yorumlanabilir ve güvenilir olduğunu ortaya koymaktadır.



Şekil 4.16 : Türkiye çalışma alanı NO₂ 4. test örneği (21 Temmuz 2025) için SHAP kuvvet grafikleri.




Şekil 4.17 : Türkiye çalışma alanı NO₂ 5. test örneği (23 Temmuz 2025) için SHAP kuvvet grafikleri.

Şekil 4.18’de sunulan SHAP kuvvet grafikleri, yüksek CO konsantrasyonuna sahip bir test örneğinde tüm modellerin genel olarak eksik tahmin eğilimi gösterdiğini ortaya koymaktadır. Random Forest ve Gradient Boosting modellerinde uydu tabanlı CO sütun yoğunluğunun güçlü artırıcı etkisine rağmen, rüzgâr hızı, yüzey basıncı ve nemle ilişkili düşürücü katkılar baskın gelmiş ve daha yüksek mutlak hatalara (31.56 ve 27.78) yol açmıştır. XGBoost ve LightGBM modelleri bu örnekte daha dengeli katkılar üretmiş ve görece daha düşük mutlak hatalar sergilemiştir. Tablo sonuçlarıyla uyumlu biçimde, GBR ve LightGBM modellerinin daha yüksek test R^2 ve daha düşük RMSE değerlerine sahip olması, SHAP grafiklerinde gözlenen daha dengeli katkı dağılımlarını desteklemektedir.

Şekil 4.19’da yer alan SHAP kuvvet grafikleri, bu test örneğinde tüm modellerin CO konsantrasyonunu aşırı tahmin etme eğiliminde olduğunu göstermektedir. Uydu tabanlı CO sütun yoğunluğu ve yüzey basıncının güçlü artırıcı etkileri, rüzgâr ve nemle ilişkili düşürücü katkıları baskılamış ve tahminlerin gerçek değerlerin belirgin biçimde üzerine çıkmasına neden olmuştur. Özellikle LightGBM modelinde bu dengesizlik daha belirgin hâle gelmiş ve en yüksek mutlak hata bu modelde gözlenmiştir. Random Forest, XGBoost ve CatBoost modelleri daha sınırlı sapmalar üretmiş olsa da, değişken katkılarının benzer yönde birleşmesi bu örneğin girdi özellikleri açısından modeller için zorlayıcı bir durum oluşturduğunu ortaya koymaktadır.


Şekil 4.20’de sunulan SHAP kuvvet grafikleri, bu yüksek CO değerine sahip test örneğinde modellerin değişken katkılarını farklı ağırlıklarla birleştirdiğini göstermektedir. Random Forest, XGBoost ve CatBoost modellerinde uydu tabanlı CO sütun yoğunluğu ve yüzey basıncı güçlü biçimde öne çıkarken, yükseklik ve sıcaklıkla ilişkili katkıların baskın hâle gelmesi tahminlerin gerçek değerden uzaklaşmasına neden olmuştur. Gradient Boosting modelinde bu etkiler daha dengeli bir yapı sergilerken, LightGBM modeli artırıcı ve azaltıcı katkılar arasında daha uyumlu bir denge kurarak gerçek değere en yakın sonucu üretmiştir. Bu durum, yüksek konsantrasyon koşullarında modellerin değişken etkileşimlerini farklı biçimlerde yorumladığını ortaya koymaktadır.




Şekil 4.18 : Türkiye çalışma alanı CO 1. test örneği (20 Haziran 2025) için SHAP kuvvet grafikleri.




Model: Random Forest | Gerçek: 217.50 | Tahmin: 282.70 | Mutlak hata: 65.20




Model: XGBoost | Gerçek: 217.50 | Tahmin: 268.82 | Mutlak hata: 51.33




Model: CatBoost | Gerçek: 217.50 | Tahmin: 271.25 | Mutlak hata: 53.76




Model: CatBoost | Gerçek: 217.50 | Tahmin: 271.25 | Mutlak hata: 53.76



Model: LightGBM | Gerçek: 217.50 | Tahmin: 303.85 | Mutlak hata: 86.35



Şekil 4.19 : Türkiye çalışma alanı CO 2. test örneği (20 Haziran 2025) için SHAP kuvvet grafikleri.




Şekil 4.20 : Türkiye çalışma alanı CO 3. test örneği (20 Mayıs 2025) için SHAP kuvvet grafikleri.


Şekil 4.21’de sunulan SHAP kuvvet grafikleri, bu test örneğinde modellerin CO tahminlerine etki eden değişkenleri farklı ağırlıklarla değerlendirdiğini göstermektedir. Random Forest ve Gradient Boosting modellerinde uydu tabanlı CO sütun yoğunluğu ile yüzey basıncı katkıları dengeli biçimde birleşmiş ve daha sınırlı tahmin sapmaları üretilmiştir. Buna karşılık XGBoost ve CatBoost modellerinde rüzgâr yönü ve bitki örtüsü ile ilişkili değişkenlerin daha baskın hâle gelmesi, tahminlerin gerçek değerden daha fazla ayrışmasına neden olmuştur. LightGBM modelinde ise artırıcı ve azaltıcı katkılar arasındaki dengenin bozulması, bu örnek özelinde en yüksek sapmanın ortaya çıkmasına yol açmıştır. Genel olarak bu sonuçlar, CO tahmininde model davranışının değişken etkileşimlerine oldukça duyarlı olduğunu ortaya koymaktadır.

Şekil 4.22’deki SHAP kuvvet grafikleri, bu test örneğinde CO tahminlerinin özellikle uydu tabanlı CO sütun yoğunluğu, sıcaklık ve yükseklik değişkenleri etrafında şekillendiğini göstermektedir. CatBoost modeli, artırıcı ve azaltıcı katkıları daha dengeli biçimde birleştirerek gerçek değere en yakın tahmini üretirken, Random Forest modeli de benzer şekilde sınırlı bir sapma sergilemiştir. XGBoost, Gradient Boosting ve LightGBM modellerinde ise sıcaklık ve nemle ilişkili değişkenlerin baskın hâle gelmesi, tahminlerin gerçek değerden daha fazla uzaklaşmasına neden olmuştur. Bu örnek, CO tahmininde bazı modellerin meteorolojik değişkenlere aşırı duyarlı tepki verebildiğini ve bu durumun model çıktıları üzerinde belirleyici rol oynadığını ortaya koymaktadır.

Şekil 4.18’de yer alan örnek Manisa ili Akhisar’daki ölçüm istasyonunu (38.93°N, 27.84°E), Şekil 4.19’da sunulan örnek Eskişehir ili Vişnepark bölgesindeki istasyonu (39.76°N, 30.50°E) temsil etmektedir. Şekil 4.20’de açıklanan kuvvet grafiği Denizli ili Sümer Mahallesi’nde bulunan ölçüm istasyonuna (37.79°N, 29.09°E) ait bir gözlemi yansıtırken, Şekil 4.21’deki örnek Aydın ili Efeler ilçesinde yer alan istasyona (37.83°N, 27.84°E) karşılık gelmektedir. Son olarak, Şekil 4.22’de sunulan örnek Manisa ili Turgutlu ilçesinde konumlanan ölçüm istasyonuna (38.50°N, 27.71°E) ait bir gözlemi temsil etmektedir. CO konsantrasyonları incelendiğinde, en düşük değer Eskişehir Vişnepark istasyonunda, en yüksek değer ise Denizli Sümer istasyonunda gözlemlendiği görülmektedir. Bu durum, istasyonların konumsal ve yerel çevresel koşullarının CO düzeyleri üzerindeki etkisini ortaya koymaktadır.



Şekil 4.21 : Türkiye çalışma alanı CO 4. test örneği (21 Mayıs 2025) için SHAP kuvvet grafikleri.




Şekil 4.22 : Türkiye çalışma alanı CO 5. test örneği (10 Haziran 2025) için SHAP kuvvet grafikleri.


4.2 Kaliforniya Çalışma Alanı

4.2.1 Orman yangınlarının spektral indisler kullanılarak tespiti

Şekil 4.23 ve Çizelge 4.6’da , Kaliforniya Los Angeles çalışma alanında 2025 yılında meydana gelen başlıca orman yangınlarının mekânsal dağılımını ve yanmış alan büyüklüklerini ortaya koymaktadır. Bu kapsamda, Sentinel-2 A/B ve Landsat 8/9 uydu görüntülerine dayalı olarak hesaplanan yanmış alan değerleri çalışma kapsamında üretilmiş, elde edilen sonuçlar CAL FIRE tarafından raporlanan resmi yangın alanı verileriyle karşılaştırılmıştır. Şekil 4.23’te Sentinel2A/B yanlış renkli görüntüsü üzerinde siyah sınırlar CAL FIRE verisini temsil etmektedir. Yanan alanlar dNBR indeksi kullanılarak çıkartılmış olup Şekil 4.24’te yangın şiddetleri de gözükmemektedir. Mekânsal dağılım incelendiğinde, Palisades ve Eaton yangınlarının çalışma alanı içinde açık ara en geniş yanmış alanlara sahip olduğu, Kenneth, Hurst ve Lidia gibi yangınların ise daha sınırlı ve parçalı bir yayılım sergilediği görülmektedir. Özellikle Palisades yangınının kıyı kesimlerinde geniş alanlara yayıldığı, Eaton yangınının ise daha iç kesimlerde yoğunlaştığı dikkat çekmektedir. Sentinel-2 ve Landsat 8/9 tabanlı yanmış alan haritaları, yangın sınırlarının konumsal olarak net biçimde ayırt edilebildiğini göstermektedir. Ayrıca iki uydu verisiyle hesaplanan alan değerlerinin CAL FIRE raporlarıyla büyük ölçüde uyumlu olması, uygulanan yanmış alan belirleme yaklaşımının güvenilirliğini ortaya koymaktadır.



Şekil 4.23 : Kaliforniya Los Angeles yangınları 2025.




Şekil 4.24 : LA yangınları dNBR yangın şiddeti haritaları (a) Sentinel 2A/B, (b) Landsat 8/9.

Çizelge 4.6 : Kaliforniya Los Angeles yanan orman alanları 2025.


Orman yangını	Yanan Alan (dönüm)		
	Landsat 8/9	Sentinel 2 A/B	CAL FIRE
Palisades	24280.341	23525.641	23448
Eaton	14489.358	13927.157	14021
Kenneth	945.075	872.120	1052
Hurst	854.825	796.449	799
Lidia	367.185	322.180	395
Sunset	47.904	41.144	43
Archer	29.658	25.757	19

Şekil 4.25'te sunulan LST zaman serileri incelendiğinde, Eaton ve Palisades yangın alanlarında 7 Ocak 2025 tarihinde başlayan yangınlar sonrasında ortalama yüzey sıcaklıklarında günden güne belirgin dalgalanmalar ve genel olarak artış eğilimi olduğu görülmektedir. Yangın başlangıcını takip eden günlerde LST değerlerinde gözlenen yükseliş, yangının aktif olduğu dönemlerde bitki örtüsünün aşamalı olarak tahrip edilmesi ve bunun sonucunda yüzeyde çıplak alanların artmasıyla ilişkilendirilebilir. Bu durum, yüzeyin daha fazla güneş enerjisi soğurmasına ve termal rejimin değişmesine neden olmaktadır. Zaman serileri ayrıca, yüzey sıcaklıklarındaki değişimlerin yangınların günler içerisindeki ilerleyişiyle uyumlu bir seyir izlediğini göstermektedir. Özellikle Palisades yangın alanında, daha geniş ve süreklilik gösteren yanmış alanlara bağlı olarak LST değişkenliğinin Eaton yangınına kıyasla daha yüksek olduğu gözlenmiştir.



Şekil 4.25 : (a) Eaton yangın alanı ve (b) Palisades yangın alanı için Sentinel 2 görüntüleri. (c) Eaton yangın alanı ve (d) Palisades yangın alanı için ECOSTRESS tabanlı ortalama LST (K) değerlerinin 1 Aralık 2024-28 Şubat 2025 tarihleri arasındaki zaman serisi.


Şekil 4.26’da 7 Ocak 2025 tarihinde başlayan Palisades yangını için ECOSTRESS verilerinden elde edilen yüzey sıcaklığı (LST) haritalarının zamansal değişimi sunulmaktadır. Yangın öncesi dönemi temsil eden 1 ve 5 Ocak tarihli haritalarda, yangın alanı içerisinde yüzey sıcaklıklarının görece homojen ve düşük seviyelerde seyrettiği görülmektedir. Yangının başlamasını takiben 8 Ocak itibarıyla, yangın sınırları içerisinde belirgin sıcaklık artışlarının ortaya çıktığı görülmektedir. İlerleyen günlerde (9, 11 ve 13 Ocak), yüksek LST değerlerinin hem alan olarak genişlediği hem de yangının günler içerisindeki yayılım yönüyle uyumlu bir dağılım sergilediği gözlenmektedir. Özellikle aktif yanmanın gerçekleştiği bölgelerde yüzey sıcaklıklarının belirgin biçimde arttığı, buna karşılık yangın etkisinin azaldığı alanlarda daha düşük LST değerlerinin hâkim olduğu görülmektedir.



Şekil 4.26 : 7 Ocak 2025 Kaliforniya/Palisades yangın alanı için ECOSTRESS LST haritaları. (a) 1 Ocak 2025, (b) 5 Ocak 2025, (c) 8 Ocak 2025, (d) 9 Ocak 2025, (e) 11 Ocak 2025 ve (f) 13 Ocak 2025 tarihlerine aittir.

Şekil 4.27’de 7 Ocak 2025 tarihinde başlayan Palisades yangınına ait ECOSTRESS tabanlı yüzey sıcaklığı (LST) haritalarının zamana bağlı değişimini göstermektedir. Yangının başlamasıyla birlikte, 8 Ocak tarihinden itibaren yangın sınırları içerisinde yüzey sıcaklıklarında dikkat çekici artışlar meydana gelmiştir. Takip eden günlerde (9, 11 ve 13 Ocak), yüksek LST değerlerinin yangın alanı içerisinde daha geniş bölgeleri kapsadığı ve sıcaklık dağılımının yangının zamansal ilerleyişine paralel bir yapı sergilediği gözlenmektedir. Palisades yangın alanında yüksek yüzey sıcaklıklarının daha geniş ve süreklilik gösteren bir mekânsal dağılıma sahip olduğu görülürken, Eaton yangınında sıcaklık artışlarının daha sınırlı ve yerel odaklar halinde yoğunlaştığı dikkat çekmektedir. Bu durum, Palisades yangınının daha büyük bir alanı etkilemesi ve yanmış alanların daha bütüncül bir yapı sergilemesiyle ilişkilendirilebilir. Elde edilen sonuçlar, ECOSTRESS verilerinin yangın sonrası termal değişimlerin izlenmesi

ve yangın dinamiklerinin değerlendirilmesi açısından güçlü ve tamamlayıcı bir uzaktan algılama veri kaynağı olduğunu ortaya koymaktadır.



Şekil 4.27 : 7 Ocak 2025 Kaliforniya/Eaton yangın alanı için ECOSTRESS LST haritaları. (a) 5 Ocak 2025, (b) 8 Ocak 2025, (c) 9 Ocak 2025, ve (d) 13 Ocak 2025.

4.2.2 Makine öğrenmesi modellerinin NO₂ ve CO tahmin performansları

Kaliforniya çalışma alanı için 1 Ocak-30 Temmuz 2025 tarihleri arasında 52 istasyondan alınarak oluşturulan NO₂ veri seti, model eğitimi ve değerlendirmesi amacıyla eğitim ve test alt kümelerine ayrılmıştır. Toplamda 5055 gözlemden oluşan veri setinin %80'i eğitim, %20'si test amacıyla kullanılmış olup, eğitim veri seti 4169, test veri seti ise 1043 olacak şekilde bölünmüştür. CO parametresi için de 1 Ocak – 30 Temmuz 2025 zaman aralığında 30 istasyondan alınarak oluşturulan ve 2498 gözlemden oluşan veri seti makine öğrenmesi için test ve eğitim için iki parçaya ayrılmıştır. Eğitim veri seti sayısı 1998, test veri seti sayısı ise 500 olarak belirlenmiştir.

Çizelge 4.7'de sunulan sonuçlar, Kaliforniya çalışma alanı için geliştirilen NO₂ tahmin modellerinin performanslarının belirgin biçimde farklılaştığını göstermektedir. Ağaç

tabanlı ve gradyan artırma yaklaşımlarının (LightGBM, XGBoost, GBM ve CatBoost) hem çapraz doğrulama hem de test verisi üzerinde daha yüksek başarı sergilediği, buna karşılık SVR ve LSTM modellerinin görece daha düşük performans sunduğu görülmektedir. Özellikle CatBoost ve LightGBM modelleri, yüksek test R^2 değerleri ve düşük RMSE sonuçları ile öne çıkmakta, bu durum karmaşık ve doğrusal olmayan ilişkilerin yakalanmasında boosting tabanlı yöntemlerin daha etkili olduğunu ortaya koymaktadır. Random Forest modeli dengeli bir performans sergilese de, boosting tabanlı modellere kıyasla daha sınırlı bir tahmin doğruluğu sunmaktadır. Tüm değerlendirme ölçütleri birlikte ele alındığında, en yüksek test R^2 (0.863) ve en düşük test RMSE (4.249) değerlerini sağlayan CatBoost modeli, Kaliforniya çalışma alanı için en iyi performansı gösteren model olarak belirlenmiştir.

Çizelge 4.7 : Kaliforniya çalışma alanı için geliştirilen NO₂ modellerinin performans karşılaştırması.

Model	5-fold CV R^2	Eğitim R^2	Test R^2	Test RMSE ($\mu\text{g}/\text{m}^3$)
Random Forest	[0.67 0.739 0.713 0.73 0.727]	0.875	0.750	5.752
LightGBM	[0.813 0.824 0.845 0.834 0.828]	0.93	0.85	4.411
XGBoost	[0.848 0.802 0.854 0.828 0.839]	0.929	0.850	4.447
GBM	[0.817 0.828 0.828 0.828 0.834]	0.911	0.844	4.536
CatBoost	[0.846 0.842 0.857 0.857 0.846]	0.934	0.863	4.249
SVR	[0.632 0.621 0.615 0.624 0.629]	0.699	0.628	7.006
LSTM	-	0.552	0.654	5.269

Burada NO₂ parametresinin yarattığı kirlilik sonucu 40 $\mu\text{g}/\text{m}^3$ sınır değerinin üzerine çıkan alanlar filtrelenmiş ve GitHub (Url-1) kaynağından elde edilen bina verileri ile analiz edilmiştir. Elde edilen bulgular, Los Angeles kentinde yaklaşık 2.985.521 yapının bulunduğu geniş bir alanda hava kalitesinin olumsuz etkilendiğini göstermektedir. Bu durum, söz konusu alanlarda yaşayan yüksek sayıdaki kentsel nüfusun yangın kaynaklı hava kirliliğine maruz kaldığını ve etkilenen popülasyonun ölçek olarak oldukça büyük olduğunu ortaya koymaktadır.

Çizelge 4.8’de sunulan performans metrikleri, Kaliforniya çalışma alanında geliştirilen CO tahmin modellerinin genel olarak ağaç tabanlı yöntemlerde daha başarılı sonuçlar ürettiğini göstermektedir. LightGBM, GBR ve CatBoost modelleri test aşamasında en yüksek açıklama gücüne ($R^2 \approx 0.75$ -0.79) ve en düşük RMSE değerlerine (≈ 55 -61 $\mu\text{g}/\text{m}^3$) ulaşarak öne çıkmıştır. Buna karşılık Random Forest modelinin test performansının daha sınırlı kaldığı, SVR ve LSTM modellerinin ise


hem düşük R^2 hem de yüksek hata değerleri nedeniyle CO'nun mekânsal dağılımını yeterince temsil edemediği görülmektedir.

Çizelge 4.8 : Kaliforniya çalışma alanı için geliştirilen CO parametresi modellerinin performans karşılaştırması.


Model	5-fold CV R^2	Eğitim R^2	Test R^2	Test RMSE ($\mu\text{g}/\text{m}^3$)
Random Forest	[0.539 0.52 0.315 0.495 0.519]	0.755	0.603	77.239
LightGBM	[0.736 0.612 0.715 0.723 0.754]	0.996	0.792	55.938
XGBoost	[0.724 0.662 0.556 0.649 0.679]	0.854	0.737	62.805
GBR	[0.695 0.61 0.704 0.666 0.744]	0.946	0.748	61.489
CatBoost	[0.709 0.593 0.696 0.705 0.739]	0.902	0.782	57.172
SVR	[0.402 0.364 0.368 0.350 0.363]	0.535	0.370	97.300
LSTM	-	0.638	0.351	96.303

Şekil 4.28'de Kaliforniya çalışma alanında Los Angeles yangın dönemi olan 10 Ocak 2025 için farklı makine öğrenmesi modelleriyle üretilen yersel NO_2 tahmin haritaları sunulmaktadır. Ağaç tabanlı modeller, NO_2 dağılımında birbirine benzer ve tutarlı mekânsal örüntüler üretmiş olup özellikle kıyı kesimleri ve yangından etkilenen alanlarda daha yüksek değerler gözlenmektedir. Bu modellerde mekânsal geçişler büyük ölçüde korunmuş ve dağılım fiziksel olarak daha dengeli bir yapı sergilemiştir. Buna karşılık LSTM modeline ait haritada yüksek NO_2 değerlerinin geniş alanlara yayıldığı ve mekânsal gürültünün arttığı görülmektedir. Bu durum LSTM modelinin bu tarih ve çalışma alanı için kararlı bir mekânsal temsil üretemediğini göstermektedir. SVR modelinin ise LSTM modeline göre görsel olarak daha tutarlı sonuçlar verdiği görülmüştür. Değişimleri daha dengeli seviyede gösterebilmiştir, fakat diğer modellere göre bazı bölgelerde aşırı veya az tahmin yönelimi görsel olarak ta belli olmaktadır. İlk haritada sunulan Sentinel-5P TROPOMI NO_2 sütun yoğunluğu, model çıktılarında gözlenen genel mekânsal desenler için referans oluşturmaktadır.

Şekil 4.29'da sunulan yersel CO tahmin haritaları, performans metrikleriyle uyumlu mekânsal desenler sergilemektedir. LightGBM, GBR ve CatBoost modelleri, Sentinel-5P TROPOMI kaynaklı CO sütun yoğunluğunda gözlenen genel eğilimleri korurken, yersel ölçekte daha dengeli ve sürekli CO dağılımları üretmiştir. XGBoost ve Random Forest modellerinde ise bazı bölgelerde daha parçalı ve yerel aşırılıklar dikkat çekmektedir. Modeller arasında ayrıntı düzeyi farklılık gösterse de, CO dağılımının genel mekânsal örüntüsü büyük ölçüde korunmuştur. Bununla birlikte Sentinel-5P CO verisinde bulunan eksik kısımlar ve yersel CO verilerinin sınırlı sayıda olması, haritalarda daha keskin ve ayrıntılı mekânsal yapıların elde edilmesini kısıtlamıştır.



Şekil 4.28 : Kaliforniya çalışma alanında yer alan Los Angeles yangın dönemi (10 Ocak 2025) sırasında farklı makine öğrenmesi modelleri kullanılarak üretilen yersel NO₂ tahmin haritaları. İlk harita, Sentinel-5P TROPOMI verisinin troposferik NO₂ sütun yoğunluğunu göstermektedir.




Şekil 4.29 : Kaliforniya çalışma alanında yer alan Los Angeles yangın dönemi (10 Ocak 2025) sırasında farklı makine öğrenmesi modelleri kullanılarak üretilen yersel CO tahmin haritaları. İlk harita, Sentinel-5P TROPOMI verisinin CO sütun yoğunluğunu göstermektedir.


4.2.3 SHAP analizi ile tahminlerdeki etkili deęişkenlerin belirlenmesi

Şekil 4.30’da sunulan SHAP ortalama önem deęerleri, Kaliforniya çalışma alanında da Türkiye çalışma alanına benzer şekilde, geliştirilen tüm NO₂ tahmin modellerinde uydu tabanlı NO₂ deęişkeninin (no2_satellite_umol) en baskın açıklayıcı parametre olduğunu göstermektedir. Bunun yanı sıra, her iki çalışma alanında da yükselti deęişkeninin görece yüksek SHAP deęerlerine sahip olması, topografyanın NO₂ dağılımı üzerindeki etkisinin farklı coęrafı koşullarda dahi tutarlı olduğunu ortaya koymaktadır. Uydu verisini takiben öne çıkan dięer deęişkenlerin sıralaması modellere ve bölgelere baęlı olarak farklılık gösterse de, bitki örtüsünü temsil eden LAI deęişkenleri her iki çalışma alanında da orta düzeyde katkı sunmaktadır. Meteorolojik deęişkenlerin katkıları ise genel olarak ikincil düzeyde kalmakta, bu durum NO₂ dağılımının kısa zaman ölçeğinde daha çok uydu gözlemleri ve yüzey/topografik özellikler tarafından kontrol edildiğini göstermektedir. Bu sonuçlar, geliştirilen modellerin farklı bölgelerde benzer fiziksel süreçleri yakalayabildiğini ve elde edilen bulguların genellenebilirliğini desteklemektedir. SVR modelinde SHAP sonuçları, NO₂ tahminlerinin büyük ölçüde uydu tabanlı NO₂ deęişkenine dayandığını ve dięer deęişkenlerin katkısının oldukça sınırlı kaldığını göstermektedir. Buna karşılık LSTM modelinde sıcaklık ve bitki örtüsü gibi meteorolojik deęişkenlerin görece daha baskın hâle geldięi, ancak bu dağılımın fiziksel tutarlılık açısından ağaç tabanlı modellere kıyasla daha zayıf olduğu görülmektedir.

Şekil 4.31’de sunulan SHAP özellik önem grafikleri, Kaliforniya çalışma alanında CO tahminlerinin ağırlıklı olarak meteorolojik ve topografik deęişkenler tarafından belirlendiğini göstermektedir. Random Forest modelinde yükseklik ve rüzgâr hızı öne çıkarken, CatBoost ve XGBoost modellerinde yüzey basıncı ile sıcaklık deęişkenlerinin baskın olduğu görülmektedir. LightGBM modelinde yükseklik açık ara en etkili deęişken hâline gelmiş, Gradient Boosting modelinde ise yüzey basıncı ve yükseklik birlikte belirleyici olmuştur. Tüm modellerde uydu tabanlı CO sütun yoğunluğunun katkısının sınırlı kalması, Kaliforniya çalışma alanında CO dağılımının kısa zaman ölçeğinde meteorolojik koşullara daha duyarlı olduğunu ortaya koymaktadır.



Şekil 4.30 : Kaliforniya çalışma alanı NO₂ SHAP özellik önem grafikleri (a) RF, (b) CatBoost, (c) XGBoost, (d) LightGBM, (e) GBM, (f) SVR, (g) LSTM.



Şekil 4.31 : Kaliforniya çalışma alanı CO SHAP özellik önem grafikleri (a) RF, (b) CatBoost, (c) XGBoost, (d) LightGBM, (e) GBM.

Çizelge 4.9’da, SHAP sonuçlarında yüksek katkıya sahip olduğu belirlenen yükselti (DEM) değişkeni model girdilerinden çıkarıldığında, tüm modellerin test R^2 değerlerinde düşüşler ve test RMSE değerlerinde artışlar meydana geldiği görülmektedir. Bu durum, yükselti bilgisinin Kaliforniya çalışma alanında NO_2 dağılımının açıklanmasında önemli bir role sahip olduğunu ve model performansına anlamlı katkı sunduğunu göstermektedir. Buna karşılık, çizelge 4.10’de SHAP analizine göre en düşük katkıya sahip olan rüzgâr yönü (Wd), toplam buharlaşma (TE) ve rüzgâr hızı (Ws) değişkenleri modelden çıkarıldığında, modellerin test performanslarının korunabildiği ve bazı modellerde iyileşmelerin dahi sağlandığı gözlenmiştir. Bu bulgular, düşük bilgi içeren değişkenlerin modelden elenmesinin gürültüyü azaltarak genellenabilirliği artırabildiğini ve SHAP analizinin değişken seçimi açısından etkili bir karar destek aracı olduğunu ortaya koymaktadır.

Çizelge 4.9 : Kaliforniya çalışma alanı için yükseklik (DEM) yardımcı verisi kullanılmadan geliştirilen modellerinin performans karşılaştırması.

Model	5-fold CV R^2	Eğitim R^2	Test R^2	Test RMSE ($\mu g/m^3$)
Random Forest	[0.693 0.744 0.73 0.744 0.739]	0.871	0.755	5.689
LightGBM	[0.827 0.812 0.842 0.82 0.815]	0.913	0.840	4.599
XGBoost	[0.825 0.798 0.834 0.799 0.808]	0.889	0.812	4.983
GBM	[0.817 0.798 0.821 0.813 0.831]	0.89	0.825	4.804
CatBoost	[0.836 0.82 0.838 0.843 0.839]	0.920	0.851	4.434

Çizelge 4.10 : Türkiye çalışma alanı için SHAP analizine göre en düşük katkıya sahip değişkenler (Wd, TE ve Ws) dışlanarak oluşturulan modellerinin performans sonuçları.

Model	Eğitim R^2	Test R^2	Test RMSE ($\mu g/m^3$)
Random Forest	0.871	0.755	5.689
LightGBM	0.913	0.840	4.599
XGBoost	0.889	0.812	4.983
GBM	0.89	0.825	4.804
CatBoost	0.920	0.851	4.434
LSTM	0.581	0.674	5.307

Şekil 4.32’de Kaliforniya çalışma alanı için farklı modellerle elde edilen NO_2 tahminlerine ait SHAP özet grafikleri sunulmaktadır. Yüksek uydu NO_2 değerlerinin model çıktısını artırıcı yönde etkilediği görülmektedir. Bu durum, Sentinel-5P verisinin yersel NO_2 tahmininde güçlü bir ön bilgi sağladığını göstermektedir.


Yükselti değişkeni çoğu modelde önemli bir yere sahiptir. Düşük yükseltelerde NO_2 birikiminin arttığı gözlenmektedir. Meteorolojik değişkenler orta düzeyde etki

göstermektedir. Sıcaklık ve çiy noktası sıcaklığı bazı modellerde artırıcı yönde katkı sunmaktadır. Rüzgâr hızının ise NO₂ üzerinde genellikle azaltıcı etki oluşturduğu görülmektedir. Bitki örtüsünü temsil eden LAI değişkenleri özellikle ağaç tabanlı modellerde anlamlı katkı sağlamaktadır.


Ağaç tabanlı modellerde değişken önem sıralamaları büyük ölçüde benzerdir. Bu durum, modellerin tutarlı ve fiziksel olarak yorumlanabilir sonuçlar ürettiğini göstermektedir. SVR modelinde değişken etkilerinin daha sınırlı olduğu görülmektedir. LSTM modelinde ise sıcaklık ve bitki örtüsü değişkenlerinin görece önemi artmaktadır.

Şekil 4.33'te sunulan SHAP özet grafikleri performans metrikleriyle birlikte değerlendirildiğinde, en iyi performans gösteren LightGBM ve CatBoost modellerinde CO tahminlerinin ağırlıklı olarak yükseltti, yüzey basıncı ve hava sıcaklığı değişkenleri tarafından şekillendiği görülmektedir. Bu üç değişkenin her iki modelde de benzer sıralama ve katkı yönleriyle öne çıkması, modellerin CO dağılımını belirleyen fiziksel süreçleri tutarlı biçimde öğrendiğini göstermektedir. SHAP dağılımları incelendiğinde, yükseklik ve yüzey basıncı için yüksek değerlerin çoğunlukla tahmini düşürücü, düşük değerlerin ise artırıcı yönde etki ettiği dikkat çekmektedir. Buna karşılık uydu tabanlı CO sütun yoğunluğu değişkeninin etki yönünün daha zayıf ve dağınık olması, CO tahminlerinde tek bir baskın yönlü ilişkinin kurulamadığını ve meteorolojik değişkenlerin belirleyici rol oynadığını ortaya koymaktadır.


Şekil 4.34'te sunulan SHAP kuvvet grafikleri, Kaliforniya çalışma alanında seçilen bu test örneğinde modellerin tahmin davranışlarının performans metrikleriyle tutarlı biçimde ayrıştığını göstermektedir. Test R² değeri en yüksek olan CatBoost (R² = 0.863) ve XGBoost (R² = 0.850) modellerinde, uydu tabanlı NO₂ sütun yoğunluğunun artırıcı etkisi meteorolojik değişkenlerle daha dengeli biçimde birleştirilmiş ve daha düşük mutlak hatalar elde edilmiştir. Buna karşılık Random Forest ve SVR modellerinde değişken katkılarının daha dengesiz dağılması, bu modellerin görece daha düşük test başarımlarıyla (R² = 0.750 ve 0.628) uyumlu bir tahmin sapmasına yol açmıştır. LSTM modelinde ise sınırlı değişken katkıları ve düşük açıklama gücü, metriklerde gözlenen zayıf performansla (R² = 0.654) tutarlı bir tablo ortaya koymaktadır.




Şekil 4.32 : Kaliforniya çalışma alanı NO₂ SHAP özet grafikleri (a) RF, (b) CatBoost, (c) XGBoost, (d) LightGBM, (e) GBM, (f) SVR, (g) LSTM.




(a)




(b)



(c)



(d)



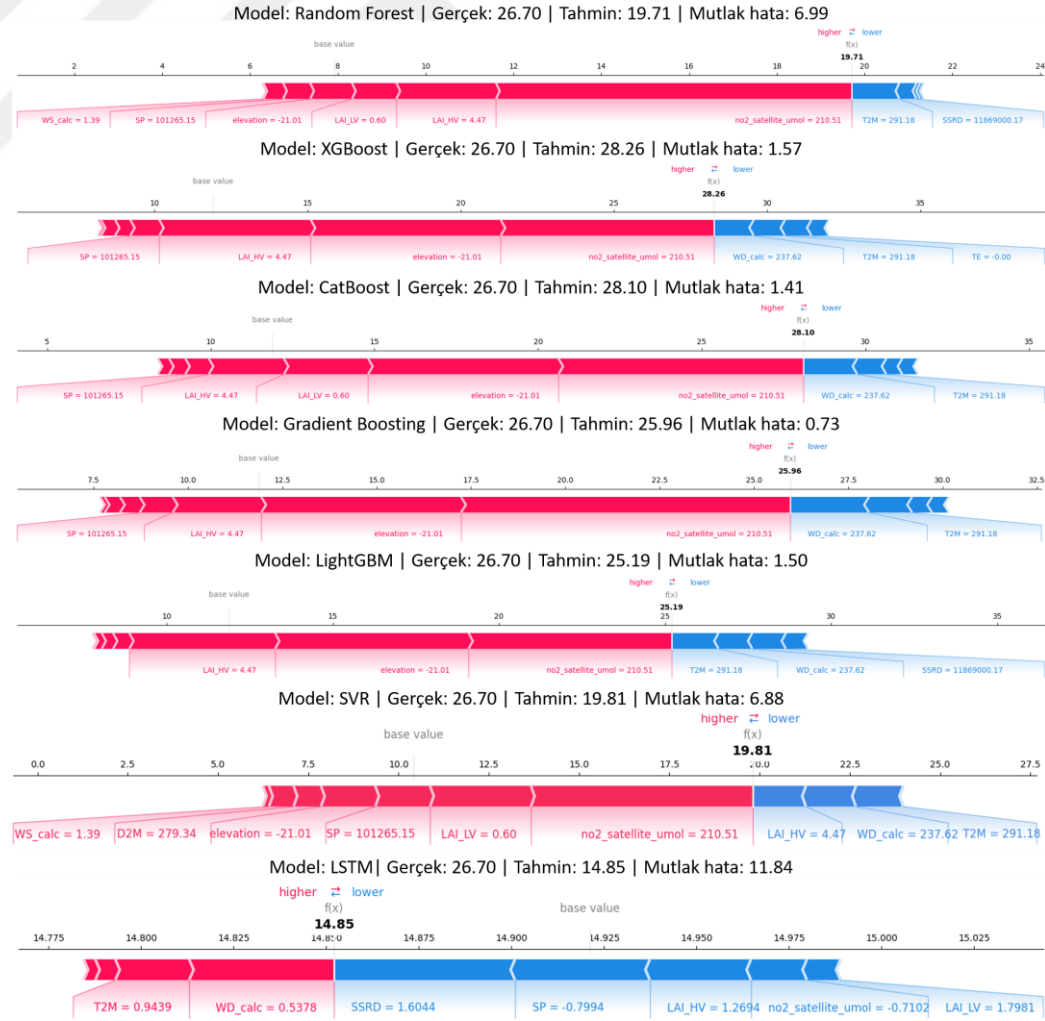
(e)

Şekil 4.33 : Kaliforniya çalışma alanı CO SHAP özet grafikleri (a) RF, (b) CatBoost, (c) XGBoost, (d) LightGBM, (e) GBM .

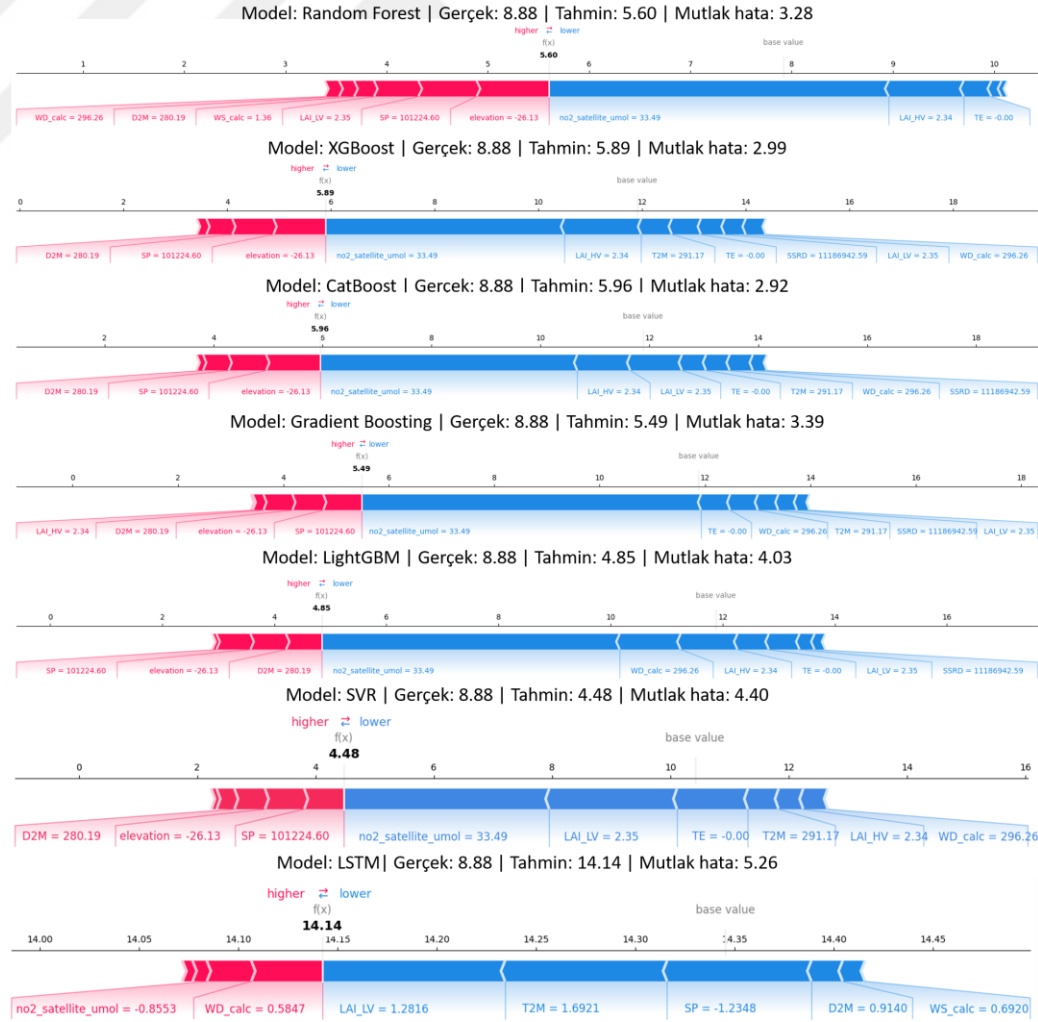
Şekil 4.35'te sunulan SHAP kuvvet grafikleri, bu test örneğinde ağaç tabanlı modellerin NO₂ tahminlerini benzer değişken dengeleriyle oluşturduğunu göstermektedir. Random Forest, XGBoost, CatBoost ve Gradient Boosting modellerinde uydu tabanlı NO₂ sütun yoğunluğunun artırıcı etkisi, yüzey basıncı ve rüzgârla ilişkili değişkenlerin düşürücü katkılarıyla dengelenmiş ve birbirine yakın tahminler elde edilmiştir. LightGBM ve SVR modellerinde ise bu denge daha zayıf kurulmuş, uydu NO₂ etkisinin sınırlı kalması tahminlerin gerçek değerden daha fazla ayrışmasına yol açmıştır. LSTM modelinde değişken katkılarının dar bir aralıkta toplanması ve uydu NO₂ bilgisinin etkisinin oldukça zayıf olması, bu örnekte modelin NO₂ dağılımını yeterince temsil edemediğini ortaya koymaktadır.

Şekil 4.36'da sunulan SHAP kuvvet grafikleri, bu test örneğinde modellerin NO₂ tahminlerini belirgin biçimde farklı değişken kombinasyonlarıyla oluşturduğunu göstermektedir. CatBoost, Gradient Boosting ve LightGBM modellerinde uydu tabanlı NO₂ sütun yoğunluğunun artırıcı etkisi, yüzey basıncı ve meteorolojik değişkenlerle dengelenmiş ve gerçek değere daha yakın tahminler üretilmiştir. XGBoost modeli benzer bir katkı yapısı sergilese de tahmin sapması görece daha yüksek kalmıştır. Buna karşılık Random Forest ve özellikle SVR modellerinde değişken katkılarının dengesiz biçimde birleşmesi, tahminlerin gerçek değerden belirgin biçimde uzaklaşmasına neden olmuştur. LSTM modelinde ise değişken katkılarının dar bir aralıkta toplanması ve uydu NO₂ bilgisinin sınırlı etkisi, bu örnekte modelin NO₂ dağılımını yeterince temsil edemediğini göstermektedir.

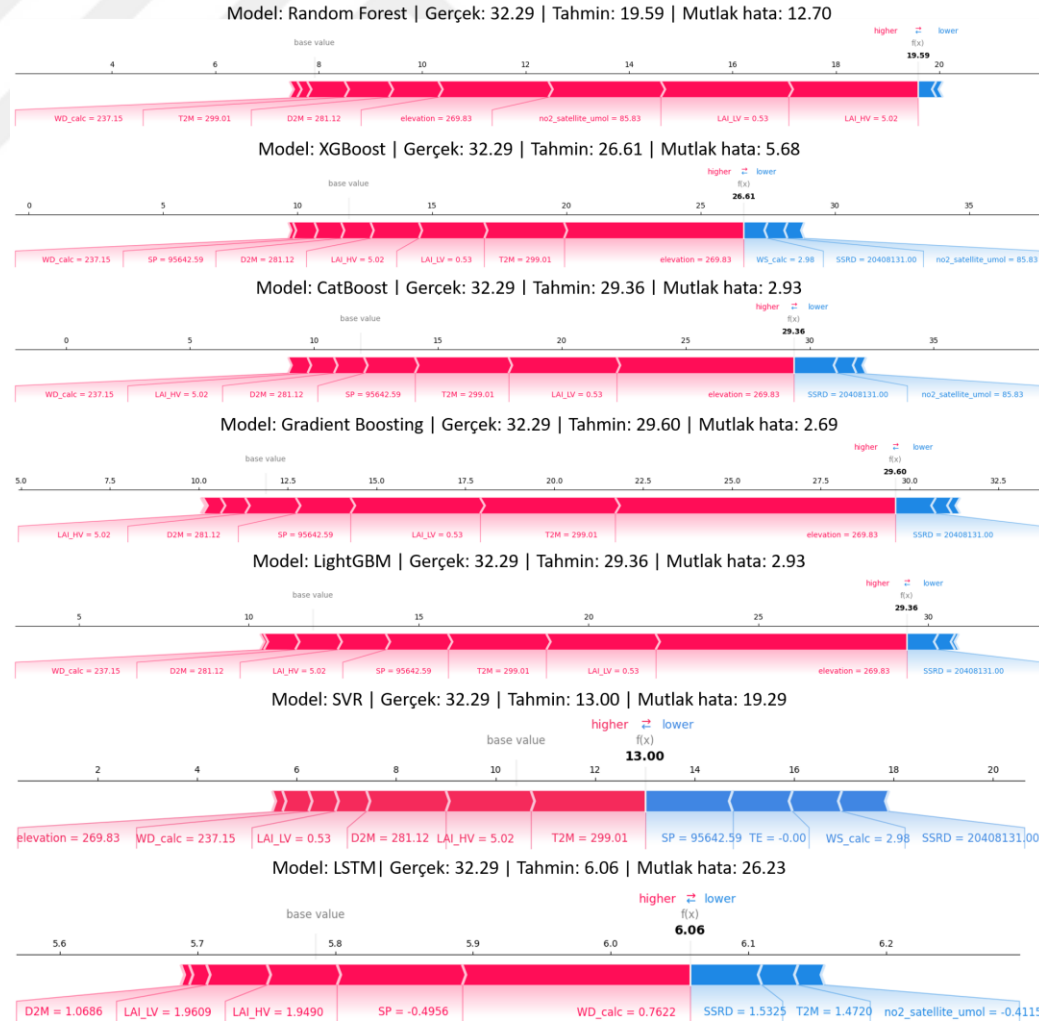
Şekil 4.37'de sunulan SHAP kuvvet grafikleri, bu test örneğinde ağaç tabanlı modellerin NO₂ tahminlerini yüksek doğrulukla ürettiğini ortaya koymaktadır. Random Forest modelinde uydu tabanlı NO₂ sütun yoğunluğu ile yükseklik değişkenlerinin dengeli katkıları sayesinde çok düşük bir mutlak hata değeri (0.05) elde edilmiştir. XGBoost ve CatBoost modellerinde de benzer katkı desenleri gözlenmiş, mutlak hata değerlerinin sırasıyla 0.42 ve 0.38 seviyesinde kalması bu modellerin güçlü test performanslarıyla tutarlı bir tablo oluşturmuştur. Gradient Boosting ve LightGBM modellerinde katkı yönleri korunmakla birlikte denge noktasının bir miktar kayması hata değerlerini artırmıştır. Buna karşılık LSTM modelinde uydu NO₂ bilgisinin etkisinin zayıflaması ve meteorolojik değişkenlerin baskın hâle gelmesi, daha yüksek bir tahmin sapmasına yol açmış olabilir.



Şekil 4.34 : Kaliforniya çalışma alanı NO₂ 1. test örneği (4 Mart 2025) için SHAP kuvvet grafikleri.



Şekil 4.35 : Kaliforniya çalışma alanı NO₂ 2. test örneği (9 Mart 2025) için SHAP kuvvet grafikleri.

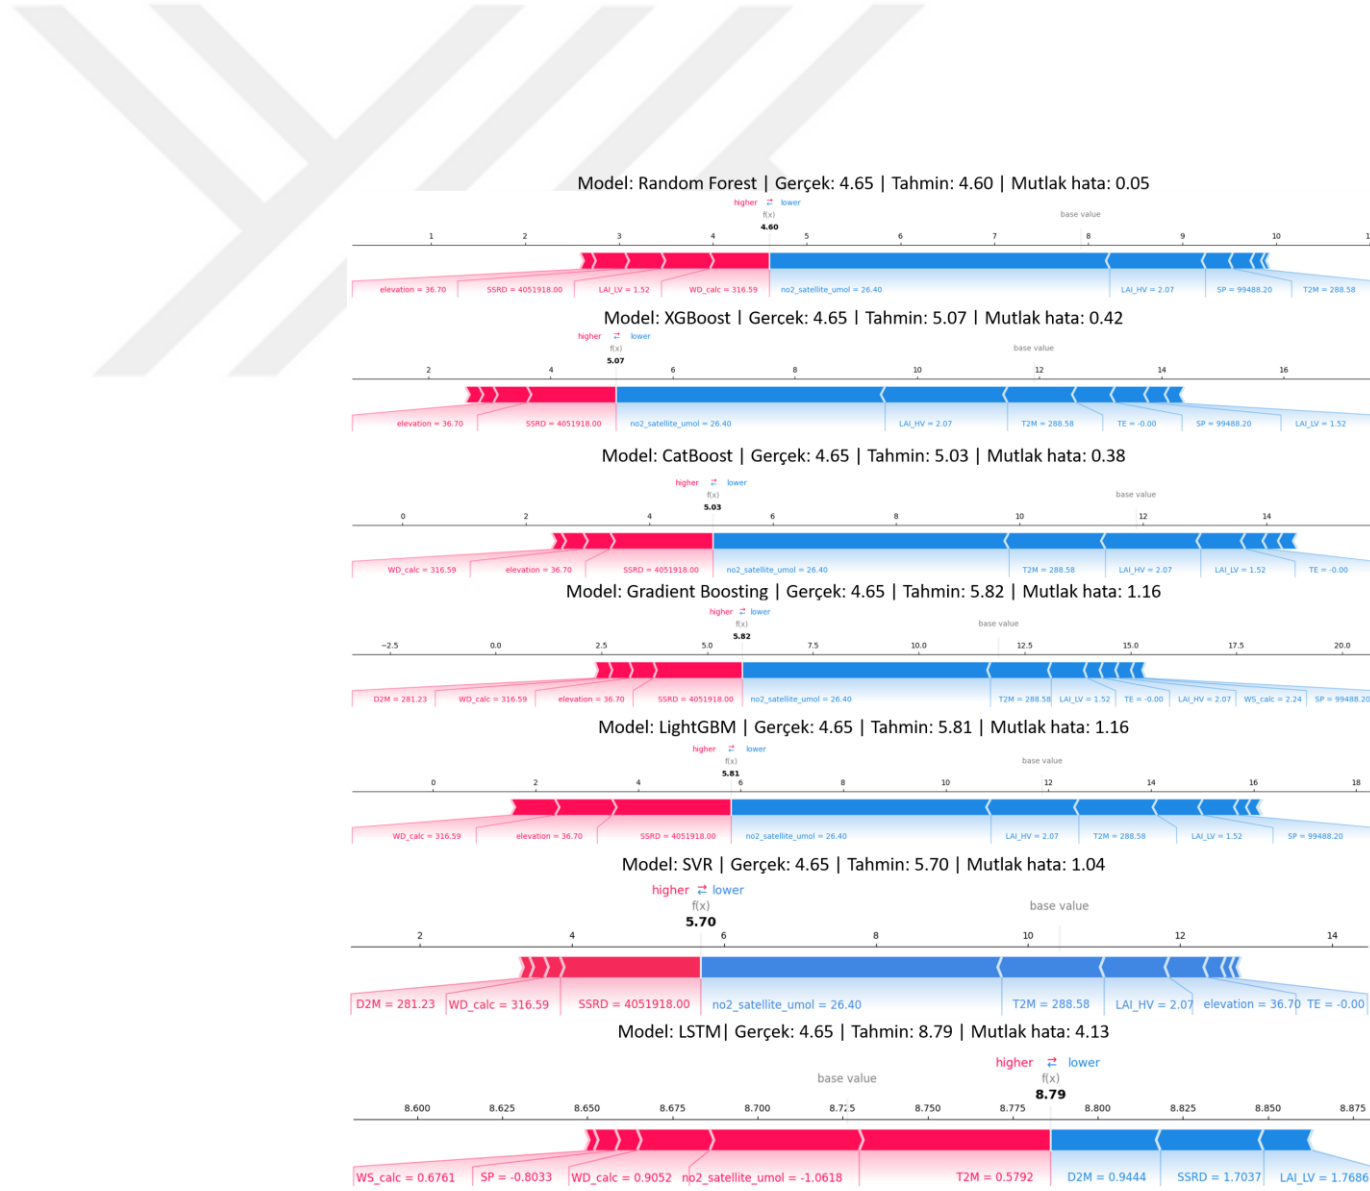


Şekil 4.36 : Kaliforniya çalışma alanı NO₂ 3. test örneği (23 Mayıs 2025) için SHAP kuvvet grafikleri.

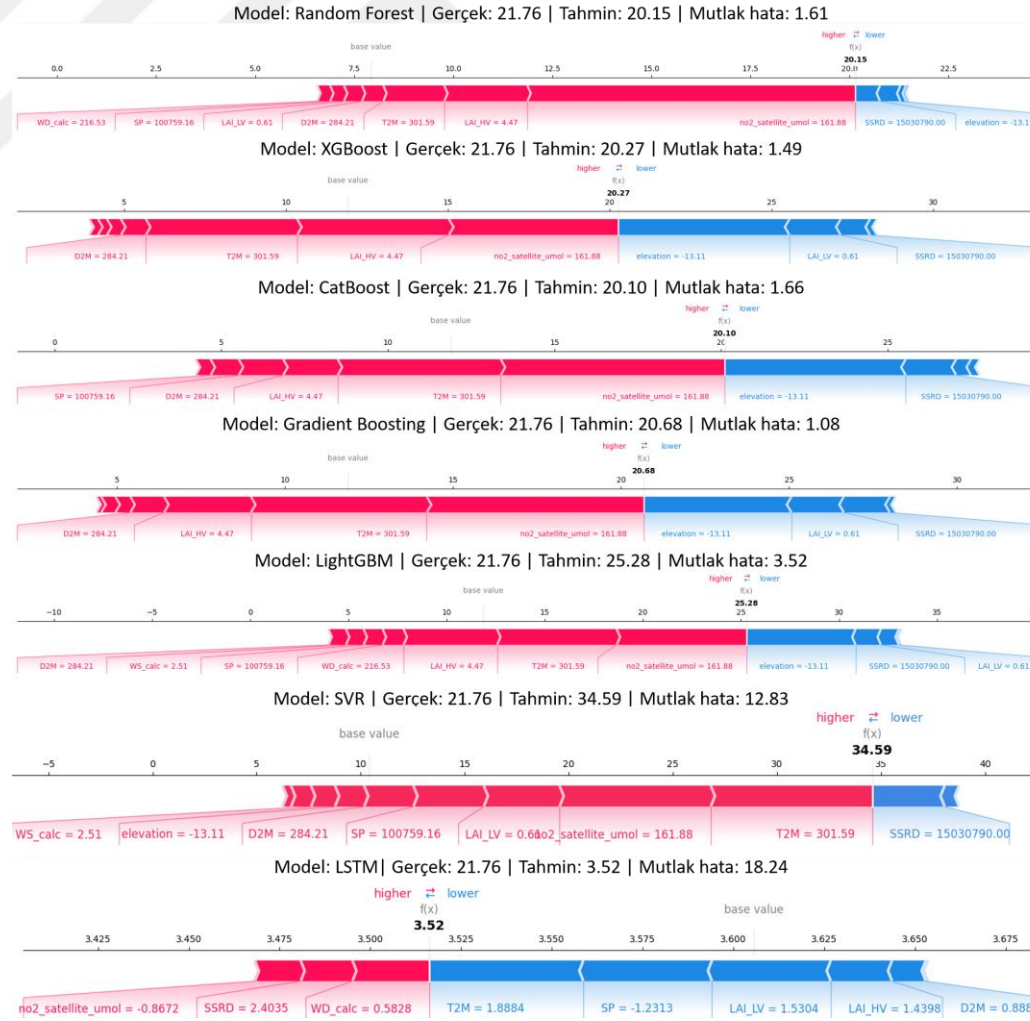
Şekil 4.38’de sunulan SHAP kuvvet grafikleri, bu test örneğinde ağaç tabanlı modellerin NO₂ tahminlerini benzer katkı dengeleriyle oluşturduğunu göstermektedir. Random Forest, XGBoost, CatBoost ve Gradient Boosting modellerinde uydu tabanlı NO₂ sütun yoğunluğu ile sıcaklık değişkenlerinin artırıcı etkileri, yüzey basıncı ve rüzgârla ilişkili azaltıcı katkılarla dengelenmiş ve mutlak hata değerleri 1-2 aralığında kalmıştır. Özellikle Gradient Boosting modelinde en düşük mutlak hata değeri (1.08) elde edilmesi, SHAP grafiğinde gözlenen dengeli katkı yapısıyla uyumludur. LightGBM modelinde katkı yönleri korunmakla birlikte denge noktasının kayması hatayı artırmıştır (mutlak hata = 3.52). Buna karşılık SVR ve LSTM modellerinde değişken katkılarının daha dengesiz biçimde birleşmesi ve uydu NO₂ bilgisinin sınırlı etkisi hatayı yükseltmiş olabilir.

Ayrıca kuvvet grafiklerinde yer alan test örnekleri incelendiğinde, Şekil 4.34’te sunulan açıklamanın Los Angeles kent merkezine yakın konumlanan 4008 numaralı istasyona (33.86°N, 118.20°W) ait bir ölçümü temsil ettiği görülmektedir. Şekil 4.35’te açıklanan örnek, daha kırsal karaktere sahip San Joaquin bölgesinde bulunan 1003 numaralı istasyona (37.96°N, 121.28°W) ait bir gözlemi yansıtırken, Şekil 4.36’da yer alan örnek ise Los Angeles metropol alanının doğusunda konumlanan ve iç kesimlerde yer alan San Bernardino bölgesindeki 26 numaralı istasyona (34.07°N, 117.53°W) ait ölçümü temsil etmektedir. Şekil 4.37’de sunulan kuvvet grafiği, Kuzey Kaliforniya’da yer alan ve daha düşük nüfus yoğunluğuna sahip Butte bölgesindeki 8 numaralı istasyona (39.76°N, 121.84°W) ait bir gözlemi göstermektedir. Son olarak, Şekil 4.38’de açıklanan örnek, Los Angeles kentinde bulunan ancak Şekil 4.34’teki istasyona kıyasla farklı bir konumsal noktada yer alan 1302 numaralı istasyona (33.90°N, 118.21°W) ait ölçümü temsil etmektedir. Los Angeles kentinde yer alan iki farklı istasyona (Şekil 4.34 ve Şekil 4.38) ait örneklerin benzer değerleri göstermesi, bu istasyonların birbirine görece yakın konumda bulunmaları ve yoğun kentsel alan içerisinde yer almaları ile tutarlıdır.

Türkiye ve Kaliforniya çalışma alanları birlikte değerlendirildiğinde, her iki bölgede de uydu tabanlı NO₂ değişkeninin yersel NO₂ tahminlerinde en baskın parametre olduğu ve yükselti (elevation) değişkeninin her iki çalışma alanında da tutarlı biçimde ikinci en önemli açıklayıcı değişken olarak öne çıktığı görülmektedir. Bu durum, farklı coğrafi ve iklimsel koşullara rağmen topoğrafyanın NO₂ dağılımı üzerindeki etkisinin genel ve genellenebilir bir fiziksel kontrol mekanizması olduğunu göstermektedir.



Şekil 4.37 : Kaliforniya çalışma alanı NO₂ 4. test örneği (23 Şubat 2025) için SHAP kuvvet grafikleri.




Şekil 4.38 : Kaliforniya çalışma alanı NO₂ 5. test örneği (24 Mart 2025) için SHAP kuvvet grafikleri.


Şekil 4.39'daki SHAP kuvvet grafikleri, bu test örneğinde CO tahminlerinin modeller için oldukça zorlayıcı bir durumu temsil ettiğini göstermektedir. Tüm modellerde tahmin değeri, temel değerden itibaren geniş bir aralıkta sapma göstermiş olup, bu durum değişken katkılarının güçlü fakat tutarsız biçimde birikmesiyle ilişkilidir. Özellikle uydu tabanlı CO sütun yoğunluğu ile yüzey basıncı ve sıcaklık değişkenlerinin katkıları, modeller arasında benzer yönlerde ilerlese de, bu katkıların birbirini yeterince dengeleyememesi yüksek mutlak hata değerlerine yol açmıştır. Gradient Boosting ve LightGBM modellerinde katkıların daha sınırlı bir aralıkta toplanması, görece daha düşük hata değerleriyle sonuçlanırken, Random Forest, XGBoost ve CatBoost modellerinde katkıların geniş ölçekte yayılması tahmin kararlılığını azaltmıştır. Bu örnek, CO tahminlerinde tekil güçlü değişkenlerin varlığının her zaman daha doğru sonuçlara karşılık gelmediğini ve değişkenler arası etkileşimlerin model performansı üzerinde belirleyici olduğunu açık biçimde ortaya koymaktadır.

Şekil 4.40'taki SHAP kuvvet grafikleri, bu test örneğinde CO tahminlerinin modelden modele belirgin biçimde farklılaştığını göstermektedir. XGBoost ve Gradient Boosting modellerinde değişken katkılarının daha dengeli birleşmesi, düşük mutlak hata değerleriyle sonuçlanmıştır. Buna karşılık CatBoost ve LightGBM modellerinde katkıların denge noktası gerçek değerden daha fazla uzaklaşmış, Random Forest modelinde ise katkıların geniş bir aralıkta yayılması tahmin belirsizliğini artırmıştır. Bu durum, CO tahminlerinde modelin değişken katkılarını dengeleme biçiminin hata büyüklüğü üzerinde belirleyici olduğunu göstermektedir.


Şekil 4.41'de sunulan SHAP kuvvet grafikleri, bu test örneğinde CO tahminlerinin performans metrikleriyle uyumlu biçimde ayrıştığını göstermektedir. Test aşamasında en yüksek açıklama gücüne sahip modeller olan Gradient Boosting ($R^2 = 0.748$) ve XGBoost ($R^2 = 0.737$), değişken katkılarını daha dengeli biçimde birleştirerek görece daha düşük mutlak hata değerleri üretmiştir. Buna karşılık Random Forest ve LightGBM modellerinde katkıların daha geniş bir aralığa yayılması, test R^2 değerlerinin düşmesiyle (sırasıyla 0.603 ve 0.792) uyumlu bir tahmin belirsizliği oluşturmuştur. SVR ve LSTM modellerinde ise hem düşük test R^2 değerleri (0.370 ve 0.351) hem de yüksek hata değerleri, CO tahminlerinde bu yaklaşımların sınırlı kaldığını açıkça ortaya koymaktadır.



Şekil 4.39 : Kaliforniya çalışma alanı CO 1. test örneği (26 Mayıs 2025) için SHAP kuvvet grafikleri.



Şekil 4.40 : Kaliforniya çalışma alanı CO 2. test örneği (7 Mayıs 2025) için SHAP kuvvet grafikleri.




Şekil 4.41 : Kaliforniya çalışma alanı CO 3. test örneği (20 Ocak 2025) için SHAP kuvvet grafikleri.


Şekil 4.42’de gösterilen test örneğinde CatBoost modelinin çok düşük mutlak hata değeri (4.15), SHAP kuvvet grafiğinde uydu tabanlı CO sütun yoğunluğu ile meteorolojik değişkenlerin dengeli biçimde birleşmesiyle uyumludur. XGBoost ve Random Forest modellerinde benzer katkı yönleri korunmakla birlikte katkıların denge noktası gerçek değerden daha fazla uzaklaşmış ve hata değerleri artmıştır (17.79 ve 27.43). LightGBM modelinde ise azaltıcı katkıların baskın hâle gelmesi tahmin belirsizliğini artırmış ve en yüksek hata bu modelde gözlenmiştir.

Ayrıca kuvvet grafiklerinde yer alan test örnekleri incelendiğinde, Şekil 4.39’da sunulan açıklamanın Güney Kaliforniya’da yer alan ve kentsel karaktere sahip Orange bölgesindeki 7 numaralı istasyona (33.83°N, 117.94°W) ait bir gözlemi temsil ettiği görülmektedir. Şekil 4.40’ta açıklanan örnek, Los Angeles metropol alanının doğusunda konumlanan ve iç kesimlerde yer alan Riverside bölgesindeki 5001 numaralı istasyona (33.85°N, 116.54°W) ait bir ölçümü yansıtmaktadır. Şekil 4.41’de yer alan örnek, Orta Kaliforniya’da bulunan ve daha kırsal karaktere sahip Stanislaus bölgesindeki 5 numaralı istasyona (37.64°N, 120.99°W) ait bir gözlemi temsil etmektedir. Şekil 4.42’de sunulan kuvvet grafiği, yine Riverside bölgesinde yer alan 5001 numaralı istasyona (33.85°N, 116.54°W) ait farklı bir konumsal örneği göstermektedir. Son olarak, Şekil 4.43’te açıklanan örnek, Los Angeles metropol alanının doğusunda konumlanan San Bernardino bölgesindeki 9004 numaralı istasyona (34.11°N, 117.27°W) ait bir ölçümü temsil etmektedir. Burada Riverside bölgesindeki aynı istasyona ait iki farklı tarihte alınan ölçümün aynı CO konsantrasyon değerini göstermesi, bu istasyonda farklı zamanlarda benzer çevresel koşulların oluşabildiğini ve modelin bu tür durumlarda tutarlı çıktılar üretebildiğini göstermesi açısından dikkat çekicidir.

Kaliforniya çalışma alanı için CO SHAP analizleri, CO tahminlerinin NO₂’ye kıyasla daha karmaşık ve zorlayıcı olduğunu göstermektedir. Tüm modellerde CO dağılımının ağırlıklı olarak yükselti, yüzey basıncı ve hava sıcaklığı gibi meteorolojik ve topografik değişkenler tarafından belirlendiği, uydu tabanlı CO sütun yoğunluğunun ise daha zayıf ve dağınık bir katkı sunduğu görülmektedir. Bu durum, CO’nun daha uzun atmosferik ömre ve taşınma duyarlı bir kirletici olması nedeniyle, kısa zaman ölçeğinde yerel konsantrasyonların meteorolojik koşullar tarafından daha güçlü biçimde kontrol edildiğini ve değişkenler arası etkileşimlerin model performansında belirleyici rol oynadığını ortaya koymaktadır.



Şekil 4.42 : Kaliforniya çalışma alanı CO 4. test örneği (17 Şubat 2025) için SHAP kuvvet grafikleri.



Şekil 4.43 : Kaliforniya çalışma alanı CO 5. test örneği (1 Şubat 2025) için SHAP kuvvet grafikleri.


4.3 Aktarımlı Öğrenme

Bu çalışmada aktarımlı öğrenme yaklaşımı, Kaliforniya çalışma alanında eğitilen makine öğrenmesi modellerinin, veri yoğunluğu ve yangın dinamikleri farklılık gösteren Bursa ve İzmir yangın bölgesine uygulanması amacıyla kullanılmıştır. Aktarımlı öğrenme, bir bölgede veya görevde öğrenilen ilişkilerin, benzer fiziksel süreçlere sahip ancak veri açısından daha sınırlı başka bir bölgeye aktarılmasını temel alır. Bu kapsamda Kaliforniya için Sentinel-5P uydu verileri, meteorolojik değişkenler ve yardımcı coğrafi parametreler kullanılarak eğitilen modeller, yeniden eğitim yapılmaksızın Bursa ve İzmir yangın dönemine uygulanmıştır. Bu yaklaşımın temel amacı, sınırlı yersel ölçüm verisine sahip bölgelerde dahi yangın kaynaklı hava kirleticisi dağılımlarının tahmin edilebilirliğini test etmek ve model genellenebilirliğini değerlendirmektir. Böylece, farklı coğrafi ve iklimsel koşullar altında geliştirilen modellerin ne ölçüde taşınabilir olduğu analiz edilerek aktarımlı öğrenmenin pratik uygulanabilirliği ortaya konulmuştur.

4.3.1 Kaliforniyadaki eğitilmiş modellerin Bursa yangınına uygulanması

Şekil 4.44'te, Kaliforniya çalışma alanında eğitilen CatBoost modelinin Sakarya yangın dönemi (21 Temmuz 2025) için ürettiği yersel NO₂ tahmin haritası sunulmaktadır. Harita incelendiğinde, yangın bölgesinde NO₂ artışının Türkiye verileriyle eğitilen modellere kıyasla daha düşük düzeyde tahmin edildiği görülmekle birlikte, artışın mekânsal örüntüsünün yangın alanı ile uyumlu biçimde ayırt edilebildiği dikkat çekmektedir. Bu tarih için toplam 52 yersel doğrulama noktasının tamamı raster kapsamı içinde yer almakta olup tüm noktalardan başarıyla tahmin değeri elde edilmiştir. Nokta raster karşılaştırması sonucunda modelin test performansı $R^2 = 0.269$ ve $RMSE = 10.47 \mu\text{g}/\text{m}^3$ olarak hesaplanmıştır. Görece düşük açıklama gücü, Kaliforniya ve Sakarya çalışma alanları arasındaki emisyon yapıları, meteorolojik koşullar ve uydu ve yersel veri ilişkilerindeki farklılıklarla ilişkilendirilebilir. Buna karşın modelin yangın kaynaklı NO₂ artışını mekânsal olarak ayırt edebilmesi, aktarımlı öğrenme yaklaşımının sınırlı doğrulukla da olsa yangın etkisinin genel desenini yakalayabildiğini göstermektedir.

Kaliforniya'da Üretilen CatBoost ile NO₂ Tahmini (21 Temmuz 2025)




Şekil 4.44 : Sakarya yangını için Kaliforniya’da üretilen CatBoost ile NO₂ tahmin haritası.

4.3.2 Kaliforniyadaki eğitilmiş modellerin İzmir yangınına uygulanması

Şekil 4.45’te, Kaliforniya çalışma alanında eğitilen CatBoost modelinin İzmir yangın dönemi (3 Temmuz 2025) için ürettiği yersel NO₂ tahmin haritası sunulmaktadır. Harita incelendiğinde, Seferihisar yangınının Türkiye’deki en büyük yangınlardan biri olmasına rağmen NO₂ artışının kıyı hattı boyunca sınırlı düzeyde temsil edilebildiği görülmektedir. Bunun temel nedeni, yangının deniz kıyısına çok yakın konumlanması ve ERA5-Land meteorolojik verilerinin yalnızca kara yüzeyini kapsaması nedeniyle kıyı–deniz etkileşiminin modele tam olarak yansıtılamamasıdır. Ayrıca rüzgârın yangın günü ağırlıklı olarak denize doğru esmesi, yangın kaynaklı emisyonların kara üzerinde birikmesini sınırlamış ve uydu ve yersel ilişkiyi zayıflatmıştır. Buna karşın aynı gün kıyıdan daha içeride meydana gelen başka bir yangının, tahmin haritasında kırmızı tonlarla daha belirgin biçimde ortaya çıkması, modelin kara içindeki yangın etkilerini daha net yakalayabildiğini göstermektedir. Bu tarih için toplam 48 yersel doğrulama noktasının tamamı raster kapsama alanında yer almakta olup tüm noktalardan başarıyla değer alınmıştır. Nokta raster karşılaştırması sonucunda elde edilen performans metrikleri $R^2 = 0.008$ ve $RMSE = 9.77 \mu\text{g}/\text{m}^3$ olarak hesaplanmış, bu sonuçlar aktarımlı öğrenme yaklaşımının kıyı ve rüzgâr etkisinin baskın olduğu

koşullarda sınırlı doğruluk ürettiğini ancak mekânsal örüntüyü kısmen ayırt edebildiğini ortaya koymuştur.

Kaliforniya'da Üretilen CatBoost ile NO₂ Tahmini (3 Temmuz 2025)



Şekil 4.45 : İzmir yangını için Kaliforniya’da üretilen CatBoost ile NO₂ tahmin haritası.

4.4 ERA-5 Land ve GRIDMET Karşılaştırma

Bu çalışmada NO₂ tahmin modellerinde kullanılan meteorolojik girdilerin etkisini incelemek amacıyla ERA5-Land ve GRIDMET veri setleri ayrı deneyler kapsamında karşılaştırılmıştır. Her iki veri seti geniş alanlar için istasyon bağımsız meteorolojik bilgi sunmaktadır ancak zamansal çözünürlük ve değişken tanımları bakımından farklı özellikler taşımaktadır.

ERA5-Land saatlik zaman çözünürlüğüne sahip küresel bir yeniden analiz ürünüdür. Bu çalışma kapsamında ERA5-Land verileri 19-22 UTC saatleri arasındaki saatlik gözlemler kullanılarak modele dâhil edilmiştir. GRIDMET veri seti ise günlük zaman çözünürlüğüne sahiptir ve gün geneline ait ortalama meteorolojik koşulları temsil etmektedir.

Bu çalışmada meteorolojik girdiler ERA5-Land ve GRIDMET veri setlerinden elde edilmiştir. ERA5-Land veri setinden 2 metre hava sıcaklığı (T2M), çığ noktası sıcaklığı (D2M), yüzey basıncı (SP), güneş radyasyonu (SSRD), toplam yağış (TP) ve

toplam buharlaşma (TE) değişkenleri doğrudan kullanılmıştır. Rüzgâr değişkenleri ERA5-Land'de u ve v bileşenleri şeklinde sunulduğundan, rüzgâr hızı ve yönü bu bileşenlerden türetilerek hesaplanmıştır. Buna karşılık GRIDMET veri setinde rüzgâr hızı ve yönü doğrudan günlük değerler olarak sağlandığından, bu değişkenler herhangi bir ek hesaplama yapılmadan modele dâhil edilmiştir.

GRIDMET veri setinden ayrıca maksimum ve minimum hava sıcaklıkları kullanılarak günlük ortalama sıcaklık hesaplanmış, nem koşulları buhar basıncı açığı (VPD) üzerinden temsil edilmiştir. Evapotranspirasyon GRIDMET'te referans evapotranspirasyon (ETO) değişkeni ile ifade edilmiştir. Bu yaklaşım, ERA5-Land ve GRIDMET veri setlerinin farklı fiziksel tanımlara ve zamansal çözünürlüklere sahip olmasına rağmen, her iki veri setinin de kendi iç tutarlılıkları korunarak modele entegre edilmesini sağlamıştır.

Vejetasyon bilgisini temsil etmek amacıyla her iki deney setine de Sentinel-2 yüzey yansıtım verilerinden türetilen NDVI değişkeni eklenmiştir. NDVI, ilgili tarihe en yakın bulutsuz Sentinel-2 görüntüsü kullanılarak kırmızı (B4) ve yakın kızılötesi (B8) bantlar üzerinden hesaplanmıştır. ERA5-Land tabanlı çalışmalarda vejetasyon etkisinin LAI değişkenleri ile güçlü biçimde temsil edildiği görülmüş olsa da, GRIDMET veri setinde LAI bilgisi bulunmamaktadır. Bu nedenle, modeller arası karşılaştırılabilirliği sağlamak ve vejetasyonun NO₂ dağılımı üzerindeki etkisini her iki veri setinde de tutarlı biçimde yansıtmak amacıyla NDVI ortak bir yardımcı değişken olarak kullanılmıştır.

Çizelge 4.11 ve Çizelge 4.12 birlikte değerlendirildiğinde, ERA5-Land ve GRIDMET tabanlı modellerin genel performanslarının birbirine oldukça yakın olduğu görülmektedir. Her iki veri setinde de CatBoost modeli en yüksek test başarımını göstermiştir. GRIDMET kullanıldığında CatBoost için Test R² değeri 0.854, Test RMSE değeri 4.549 iken, ERA5-Land kullanıldığında Test R² 0.872'ye yükselmiş ve Test RMSE 4.259'a düşmüştür. Bu durum, ERA5-Land'in özellikle CatBoost modeli için daha tutarlı ve güçlü bir tahmin performansı sunduğunu göstermektedir.

LightGBM ve XGBoost modelleri açısından bakıldığında, her iki veri setinde de benzer düzeyde sonuçlar elde edilmiştir. Test R² değerleri GRIDMET ve ERA5-Land arasında sınırlı farklar göstermekte, RMSE değerleri ise birbirine oldukça yakın seyretmektedir. Buna karşılık ERA5-Land kullanılan deneylerde 5-fold çapraz

doğrulama sonuçlarının daha dengeli olduğu dikkat çekmektedir. Bu bulgu, saatlik çözünürlüğe sahip ERA5-Land verilerinin zamansal değişkenliği modele daha iyi yansıttığını ve genellenebilirliği bir miktar artırdığını göstermektedir.

Çizelge 4.11 : GRIDMET ve NDVI kullanılarak eğitilen model performansları.

Model	5-fold CV R ²	Eğitim R ²	Test R ²	Test RMSE (µg/m ³)
LightGBM	[0.796 0.749 0.81 0.79 0.829]	0.907	0.843	4.709
XGBoost	[0.802 0.768 0.824 0.803 0.832]	0.939	0.846	4.664
CatBoost	[0.837 0.797 0.806 0.799 0.796]	0.920	0.854	4.549

Çizelge 4.12 : ERA-5 Land ve NDVI kullanılarak eğitilen model performansları.

Model	5-fold CV R ²	Eğitim R ²	Test R ²	Test RMSE (µg/m ³)
LightGBM	[0.8 0.747 0.823 0.818 0.837]	0.919	0.844	4.697
XGBoost	[0.787 0.749 0.824 0.811 0.813]	0.912	0.840	4.763
CatBoost	[0.858 0.817 0.825 0.82 0.804]	0.934	0.872	4.259


Şekil 4.46’da yer alan SHAP özellik önem grafikleri hem GRIDMET hem de ERA5-Land tabanlı modellerde uydu tabanlı NO₂ ve yükselti değişkenlerinin tüm algoritmalarda en yüksek katkıya sahip olduğunu göstermektedir. GRIDMET kullanılarak eğitilen modellerde VPD ve ETO gibi nem ve yüzey süreçlerini temsil eden değişkenlerin katkısı daha belirgin hâle gelirken, ERA5-Land tabanlı modellerde hava sıcaklığı ve güneş radyasyonu öne çıkmaktadır. Bu farklılık, veri setlerinin fiziksel tanımları ve zamansal çözünürlüklerindeki ayrımların model öğrenme yapısına doğrudan yansıdığını göstermektedir.

Şekil 4.47’de sunulan SHAP özet grafikleri, GRIDMET ve ERA5-Land tabanlı modellerde değişkenlerin etki yönlerinin büyük ölçüde benzer olduğunu göstermektedir. Uydu kaynaklı NO₂ ve yükselti değişkenlerinde, yüksek değerlerin model çıktısını genellikle yukarı yönlü etkilediği, düşük değerlerin ise tahmini aşağı çektiği gözlenmektedir. Hava sıcaklığı ve güneş radyasyonu değişkenlerinde ise etki yönü daha karmaşık bir yapı sergilemekte, ancak ERA5-Land kullanılan modellerde bu değişkenlerin tahmin üzerindeki yönlü etkisi daha tutarlı biçimde ayrılmaktadır. NDVI değişkeninin etkisi her iki veri setinde de sınırlı kalmakta ve daha çok ikincil bir kontrol değişkeni olarak rol oynadığı anlaşılmaktadır.


Şekil 4.48’de GRIDMET ve ERA5-Land veri setleri kullanılarak üretilen NO₂ tahmin haritaları karşılaştırıldığında, her iki yaklaşımın da genel mekânsal dağılım desenlerini tutarlı biçimde yansıttığı görülmektedir. GRIDMET’in daha yüksek mekânsal

özünürlüğü, özellikle kıyı ve kentsel alanlarda daha ayrıntılı ve yerel değışimleri vurgulayan tahminlerin elde edilmesini sağlamıştır. Buna karşılık, ERA5-Land verisi daha kaba mekânsal özünürlüğe sahip olduğundan, tahmin haritalarında mekânsal geçişler daha yumuşak ve genelleştirilmiş bir yapı sergilemektedir. Ancak ERA5-Land'in saatlik zaman özünürlüğü, gün içi meteorolojik değışkenliğin modele daha dengeli biçimde yansıtılmasına katkı sağlamaktadır.







(a)




(b)




(c)



(d)




(e)




(f)


Şekil 4.46 : SHAP özellik önem grafikleri GRIDMET için (a) RF, (b) CatBoost, (c) LightGBM, ERA-5 Land için (d) RF, (e) CatBoost, (f)LightGBM.




(a)




(b)




(c)



(d)




(e)



(f)

Şekil 4.47 : SHAP özet grafikleri GRIDMET için (a) RF, (b) CatBoost, (c) LightGBM, ERA-5 Land için (d) RF, (e) CatBoost, (f) LightGBM.



Şekil 4.48 : Kaliforniya çalışma alanında ERA-5 Land ile GRIDMET veri setlerinden alınan yardımcı değişkenler ile üretilen NO₂ tahmin haritaları.



5. SONUÇ VE ÖNERİLER

Orman yangınları, doğal ekosistemler üzerinde ciddi tahribatlara yol açmasının yanı sıra, atmosferik bileşimi değiştirerek hava kalitesi üzerinde de önemli etkiler oluşturmaktadır. Yangınlar sırasında ve sonrasında atmosfere salınan gazlar, özellikle azot dioksit (NO_2) ve karbon monoksit (CO) gibi kirleticilerin kısa süreli ancak belirgin artışlar göstermesine neden olmaktadır. Yangın olaylarının hem sıklığının hem de şiddetinin artması, bu etkilerin izlenmesini ve doğru biçimde değerlendirilmesini giderek daha önemli hâle getirmektedir. Bu kapsamda uzaktan algılama verileri ve makine öğrenmesi yöntemleri, geniş alanlarda hava kalitesinin izlenmesi için güçlü araçlar sunmaktadır.

Sentinel-2A/B ve Landsat 8/9 verileri kullanılarak yangın sonrası yanmış alanlar ve yanma şiddeti belirlenmiş, elde edilen sonuçlar farklı uydu sensörlerinin yangın etkilerini tutarlı biçimde temsil edebildiğini göstermiştir. Farklı spektral indislerin birlikte kullanılması, yangın sonrası ekosistem değişimlerinin mekânsal olarak daha ayrıntılı biçimde analiz edilmesine katkı sağlamıştır. Yanan alanların dağılımını açıklayan mevcut bilimsel yaklaşımlar ve literatürde raporlanan bulgular ile de örtüşmektedir. Elde edilen sonuçlar, yanan alanların uzaktan algılama temelli yöntemlerle doğru ve anlamlı biçimde tespit edilebildiğini göstermektedir.

Hava kalitesi modelleme sonuçları incelendiğinde, ağaç tabanlı ve gradyan artırma temelli makine öğrenmesi algoritmalarının diğer yöntemlere kıyasla daha başarılı olduğu görülmüştür. Türkiye çalışma alanında özellikle CatBoost ve LightGBM modelleri, yangın sonrası NO_2 değişimlerini daha tutarlı biçimde temsil etmiştir. Bu durum, doğrusal olmayan ilişkilerin ve değişkenler arasındaki etkileşimlerin bu modeller tarafından daha etkin şekilde öğrenilebildiğini göstermektedir.

CO değişkeni biyokütle yanması ile doğrudan ilişkili olmasına rağmen, bu çalışmada CO tahminlerinin NO_2 'ye kıyasla daha zayıf sonuçlar verdiği görülmüştür. Bunun temel nedenleri arasında CO 'nun uzun atmosferik ömre sahip olması ve bölgesel ile uzun menzilli taşınımına daha açık olması yer almaktadır. Buna ek olarak TROPOMI, NO_2 ve SO_2 'yi görünür–morötesi (UV–VIS) spektral bantlarda, CO 'yu ise kısa dalga

kızılötesi (SWIR) bantlarda Güneş ışığı soğurmasına dayalı olarak belirlemektedir. CO ölçümlerinde kullanılan SWIR bantlarının yüzey yansıtımına duyarlı olması, özellikle su yüzeyleri ve düşük yansıtıcılı alanlarda belirsizlikleri artırmakta ve CO'nun mekânsal olarak daha zayıf temsil edilmesine neden olmaktadır.

Ayrıca yangın kaynaklı kirleticilerin atmosferdeki dağılımı, yalnızca emisyon miktarına değil, dumanın hangi yükseklikte atmosfere enjekte edildiğine de bağlıdır. Dumanın sınır tabakası üzerine taşınması durumunda, uydu tarafından gözlenen kolon yoğunlukları ile yüzeye yakın konsantrasyonlar arasındaki ilişki zayıflayabilmektedir. Gelecek çalışmalarda duman yükselme yüksekliğini temsil eden parametrelerin modellere dâhil edilmesi, yangın kaynaklı kirleticilerin taşınımının daha gerçekçi biçimde modellenmesine katkı sağlayabilir.

Makine öğrenmesi modellerinin kapalı kutu yapısı, elde edilen sonuçların yorumlanmasını zorlaştırabilmektedir. Bu nedenle çalışma kapsamında açıklanabilir yapay zekâ yaklaşımlarından yararlanılmıştır. SHAP analizleri, model çıktılarının hangi değişkenler tarafından yönlendirildiğini ortaya koyarak, değişken katkılarının çalışma alanına ve çevresel koşullara bağlı olarak farklılaşabildiğini göstermiştir. Topografik bilginin modele dâhil edilmesiyle hava kalitesi dağılımlarının mekânsal olarak daha iyi temsil edilebildiği görülmüştür. SHAP sonuçlarına dayalı olarak katkısı sınırlı olan değişkenlerin modelden çıkarıldığı senaryolarda, model performanslarının korunduğu ve bazı durumlarda daha iyi sonuçlar elde edildiği görülmüştür. Bu bulgu, değişken seçiminin açıklanabilirlik temelli analizlerle desteklenmesinin önemini göstermektedir.

Bu çalışmanın en önemli kısıtlarından biri, Sentinel-5P verisinin günde yalnızca tek bir geçişle sağladığı anlık görüntü niteliğidir. Yangınların saatlik ve hatta dakikalık ölçekte hızlı biçimde değişebilmesi, bu tür dinamik süreçlerin tek bir uydu geçişi ile tam olarak yakalanmasını zorlaştırmaktadır. Ayrıca yoğun duman ve bulutluluk koşulları, uydu algoritmaları tarafından piksel maskeleyesine neden olabilmekte ve veri sürekliliğini sınırlayabilmektedir. Bununla birlikte Sentinel-5P ölçümleri troposferik veya toplam kolon yoğunluklarını temsil ettiğinden, yüzeye yakın solunabilir konsantrasyonların doğrudan belirlenmesi mümkün değildir.

Bu çalışmayı ileriye taşıyan önemli bir unsur uydu verilerinin sağladığı geniş mekânsal kapsama alanı olsa da yersel hava kalitesi ölçümlerinin sınırlı olması çalışmanın temel

kısıtlarından biridir. Uydu tabanlı kolon ölçümleri ile yüzeye yakın yersel konsantrasyonlar arasındaki fiziksel farklar, atmosferik taşınım ve karışım süreçleri nedeniyle doğrudan ilişkilendirmeyi zorlaştırabilmektedir. Makine öğrenmesi modellerinin başarımı doğrudan kullanılan veri setine bağlıdır. Bu nedenle daha yoğun ve dengeli yersel ölçümlerle desteklenen çalışmaların daha güvenilir sonuçlar üreteceği açıktır.

Gelecekte yapılacak çalışmalarda, uydu tabanlı gözlemlerin kimyasal taşınım modelleri ile birlikte kullanılması önerilmektedir. Bu tür hibrit yaklaşımlar, kolon ölçümlerinin yüzey konsantrasyonlarına indirgenmesini sağlayarak yangın kaynaklı kirleticilerin taşınım ve birikim süreçlerinin daha gerçekçi biçimde modellenmesine katkı sunabilir. Ayrıca daha yoğun ve dengeli yersel ölçüm ağı ile desteklenen çalışmalar, makine öğrenmesi modellerinin genellenebilirliğini ve doğruluğunu önemli ölçüde artıracaktır.



KAYNAKLAR

- Aksoy, S., Sertel, E., Roscher, R., Tanik, A., & Hamzehpour, N.** (2024). Assessment of soil salinity using explainable machine learning methods and Landsat 8 images. *International Journal of Applied Earth Observation and Geoinformation*, 130, 103879. <https://doi.org/10.1016/j.jag.2024.103879>
- Alam, S. M. K., Li, P., Rahman, M., Fida, M., & Elumalai, V.** (2025). Key factors affecting groundwater nitrate levels in the Yinchuan Region, Northwest China: Research using the eXtreme Gradient Boosting (XGBoost) model with the SHapley Additive exPlanations (SHAP) method. *Environmental Pollution*, 364, 125336. <https://doi.org/10.1016/j.envpol.2024.125336>
- Amici, S., Spiller, D., Ansalone, L., & Miller, L.** (2022). Wildfires Temperature Estimation by Complementary Use of Hyperspectral PRISMA and Thermal (ECOSTRESS & L8). *Journal of Geophysical Research: Biogeosciences*, 127(12), e2022JG007055. <https://doi.org/10.1029/2022JG007055>
- Anadolu Ajansı.** (t.y.). 10 dead as forest fire traps responders in central Türkiye: Minister. Geliş tarihi 21 Aralık 2025, gönderen <https://www.aa.com.tr/en/turkiye/10-dead-as-forest-fire-traps-responders-in-central-turkiye-minister/3640260>
- Arıkan, C., Tümer, İ., Aksoy, S., & Sertel, E.** (2022). Determination of burned areas using Sentinel-2A imagery and machine learning classification algorithms. *4th Intercontinental Geoinformation Days*, 4, 43-46.
- Armstrong, Z. N.** (2025, Temmuz 11). *NASA Scientific Visualization Studio | Overview Maps of 2025 Los Angeles Fires*. NASA Scientific Visualization Studio. <https://svs.gsfc.nasa.gov/5568/>
- Avila, T. C., Lafferty, D. C., Stover, M., Guerrero, S., Samantula, C., Wing, I. S., & Srivier, R. L.** (2025). Downscaled CMIP5 projections of physical fire risk understate historical trends. *Environmental Research Letters*, 20(8), 084025. <https://doi.org/10.1088/1748-9326/ade892>
- Barros, B., Oliveira, M., & Morais, S.** (2025). Air Pollution and Health Impacts of Wildfire Seasons: Insights from Northern Portugal. *Water, Air, & Soil Pollution*, 236(7), 406. <https://doi.org/10.1007/s11270-025-08047-2>
- 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>
- Bilgiç, E., & Elbir, T.** (2025). Sentinel-5P Uydu Verileri ve Makine Öğrenmesi Yöntemiyle İzmir Atmosferinde Saatlik NO2 Konsantrasyonlarının Tahmini. *Karaelmas Fen ve Mühendislik Dergisi*, 15(1), Article 1. <https://doi.org/10.7212/karaelmasfen.1591188>
- Binet, M. V., Micheletti, M. I., & Piacentini, R. D.** (2024). Propagation of NO2 originated in intense fires in the Paraná River Delta analyzed from satellite observations. *Advances in Space Research*, 74(2), 682-694. <https://doi.org/10.1016/j.asr.2024.04.030>
- Breiman, L.** (2001). Random Forests. *Machine Learning*, 45(1), 5-32. <https://doi.org/10.1023/A:1010933404324>

- Casey, J. A., Gu, Y. M., Schwarz, L., Frankland, T. B., Wilner, L. B., McBrien, H., Flores, N. M., Dey, A. K., Lee, G. S., Chen, C., Benmarhnia, T., & Tartof, S. Y. (2025). The 2025 Los Angeles Wildfires and Outpatient Acute Healthcare Utilization. *medRxiv*, 2025.03.13.25323617. <https://doi.org/10.1101/2025.03.13.25323617>
- Castro-Melgar, I., Tsagkou, A., Zacharopoulou, M., Basiou, E., Athinelis, I., Katris, E.-A., Kalavrezou, I.-E., & Parcharidis, I. (2025). Wildfires During Early Summer in Greece (2024): Burn Severity and Land Use Dynamics Through Sentinel-2 Data. *Forests*, 16(2), 268. <https://doi.org/10.3390/f16020268>
- Cedeno Jimenez, J. R., & Brovelli, M. A. (2023). NO2 Concentration Estimation at Urban Ground Level by Integrating Sentinel 5P Data and ERA5 Using Machine Learning: The Milan (Italy) Case Study. *Remote Sensing*, 15(22), 5400. <https://doi.org/10.3390/rs15225400>
- Chen, T., & Guestrin, C. (2016). XGBoost: A Scalable Tree Boosting System. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 785-794. <https://doi.org/10.1145/2939672.2939785>
- Chi, Y., Fan, M., Zhao, C., Yang, Y., Fan, H., Yang, X., Yang, J., & Tao, J. (2022). Machine learning-based estimation of ground-level NO2 concentrations over China. *Science of The Total Environment*, 807, 150721. <https://doi.org/10.1016/j.scitotenv.2021.150721>
- Copernicus Data Space. (t.y.). *Sentinel-2 | Copernicus Data Space Ecosystem*. Geliş tarihi 21 Aralık 2025, gönderen <https://dataspace.copernicus.eu/data-collections/copernicus-sentinel-data/sentinel-2>
- Cortes, C., & Vapnik, V. (1995). Support-vector networks. *Machine Learning*, 20(3), 273-297. <https://doi.org/10.1007/BF00994018>
- Costa-Saura, J. M., Bacciu, V., Sirca, C., Cappelluti, O., Spano, D., & Elia, M. (2025). The growing link between heatwaves and megafires: Evidence from southern Mediterranean countries of Europe. *Natural Hazards*, 121(15), 17731-17742. <https://doi.org/10.1007/s11069-025-07488-6>
- Deng, F., Chen, Y., Li, L., Wang, C., Cao, L., & Peng, C. (2022). Estimation of near-surface NO2 based on TROPOMI and provincial control stations' data using machine learning. *2022 5th World Conference on Mechanical Engineering and Intelligent Manufacturing (WCMEIM)*, 639-644. <https://doi.org/10.1109/WCMEIM56910.2022.10021549>
- Di Carlo, P., Aruffo, E., Biancofiore, F., Busilacchio, M., Pitari, G., Dari-Salisburgo, C., Tuccella, P., & Kajji, Y. (2015). Wildfires impact on surface nitrogen oxides and ozone in Central Italy. *Atmospheric Pollution Research*, 6(1), 29-35. <https://doi.org/10.5094/APR.2015.004>
- Earth Resources Observation and Science (EROS) Center. (2020, Mart 4). *USGS EROS Archive—Landsat Archives—Landsat 8-9 Operational Land Imager and Thermal Infrared Sensor Collection 2 Level-1 Data*. <https://www.usgs.gov/centers/eros/science/usgs-eros-archive-landsat-archives-landsat-8-9-operational-land-imager-and>
- Echo Flash. (t.y.). *Daily Flash*. Geliş tarihi 21 Aralık 2025, gönderen <https://erccportal.jrc.ec.europa.eu/ECHO-Products/Echo-Flash#/echo-flash-items/29287>

- Elliot, W. J.** (2002). Soil Erosion in Forest Ecosystems and Carbon Dynamics. İçinde *The Potential of U.S. Forest Soils to Sequester Carbon and Mitigate the Greenhouse Effect*. CRC Press.
- Emang, G. P., Touge, Y., & Kazama, S.** (2020). Evaluating Trees Crowns Damage for the 2017 Largest Wildfire in Japan Using Sentinel-2A NDMI. *IGARSS 2020 - 2020 IEEE International Geoscience and Remote Sensing Symposium*, 6794-6797. <https://doi.org/10.1109/IGARSS39084.2020.9323345>
- Fania, A., Amoroso, N., Lacalamita, A., Maggipinto, T., Monaco, A., & Bellotti, R.** (2025). Deep Learning for NO₂ Forecasting in Italy: An LSTM-Based Approach. *Procedia Computer Science*, 270, 5463-5472. <https://doi.org/10.1016/j.procs.2025.10.014>
- Fania, A., Monaco, A., Pantaleo, E., Maggipinto, T., Bellantuono, L., Cilli, R., Lacalamita, A., Rocca, M. L., Tangaro, S., Amoroso, N., Bellotti, R., Fania, A., Monaco, A., Pantaleo, E., Maggipinto, T., Bellantuono, L., Cilli, R., Lacalamita, A., Rocca, M. L., ... Bellotti, R.** (2024). Estimation of Daily Ground Level Air Pollution in Italian Municipalities with Machine Learning Models Using Sentinel-5P and ERA5 Data. *Remote Sensing*, 16(7). <https://doi.org/10.3390/rs16071206>
- FAO.** (2024). *Global forest products facts and figures 2023*. FAO ; <https://openknowledge.fao.org/handle/20.500.14283/cd3650en>
- Fiore, A. M., Mickley, L. J., Zhu, Q., & Baublitz, C. B.** (2024). Climate and Tropospheric Oxidizing Capacity. *Annual Review of Earth and Planetary Sciences*, 52(Volume 52, 2024), 321-349. <https://doi.org/10.1146/annurev-earth-032320-090307>
- Friedman, J. H.** (2001). Greedy Function Approximation: A Gradient Boosting Machine. *The Annals of Statistics*, 29(5), 1189-1232.
- Future Earth, The Earth League, & WCRP.** (2021). *10 New Insights in Climate Science 2021*. Zenodo. <https://doi.org/10.5281/zenodo.7025334>
- Griffin, D., Hempel, C., McLinden, C., Kharol, S. K., Lee, C., Fogal, A., Sioris, C., Shephard, M., & You, Y.** (2025). Development and validation of satellite-derived surface NO₂ estimates using machine learning versus traditional approaches in North America. *Atmospheric Measurement Techniques*, 18(23), 7497-7511. <https://doi.org/10.5194/amt-18-7497-2025>
- Guo, R., Yan, J., Zheng, H., & Wu, B.** (2024). Assessment of the Analytic Burned Area Index for Forest Fire Severity Detection Using Sentinel and Landsat Data. *Fire*, 7(1), 19. <https://doi.org/10.3390/fire7010019>
- Günther, A., Najjar, H., & Dengel, A.** (2024). Explainable Multimodal Learning in Remote Sensing: Challenges and Future Directions. *IEEE Geoscience and Remote Sensing Letters*, 21, 1-5. <https://doi.org/10.1109/LGRS.2024.3404596>
- Han, Z., Fan, M., Song, S., Liang, X., Song, M., He, G., Tao, J., & Chen, L.** (2025). An Improved Hybrid GC-LSTM Framework for Hourly Nowcasting of Ground-Level NO₂ Concentrations Over Beijing-Tianjin- Hebei Region. *IEEE Transactions on Geoscience and Remote Sensing*, 63, 1-14. <https://doi.org/10.1109/TGRS.2024.3514158>
- Hancock, J. T., & Khoshgoftaar, T. M.** (2020). CatBoost for big data: An interdisciplinary review. *Journal of Big Data*, 7(1), 94. <https://doi.org/10.1186/s40537-020-00369-8>
- He, M. Z., Yitshak-Sade, M., Just, A. C., Gutiérrez-Avila, I., Dorman, M., de Hoogh, K., Mijling, B., Wright, R. O., & Kloog, I.** (2023). Predicting fine-scale daily NO₂ over Mexico city using an ensemble modeling approach.

- Atmospheric Pollution Research*, 14(6), 101763.
<https://doi.org/10.1016/j.apr.2023.101763>
- Henk Eskes, Jos van Geffen, Folkert Boersma, Kai-Uwe Eichmann, Arnoud Apituley, Mattia Pedernana, Maarten Sneep, J. Pepijn Veefkind, & Diego Loyola.** (2022). Sentinel-5 precursor/TROPOMI Level 2 Product User Manual Nitrogen dioxide. *Ministry of Infrastructure and Water Management*, 4.1.0. <https://sentinels.copernicus.eu/documents/247904/2474726/Sentinel-5P-Level-2-Product-User-Manual-Nitrogen-Dioxide.pdf>
- Hersbach, H., Bell, B., Berrisford, P., Hirahara, S., Horányi, A., Muñoz-Sabater, J., Nicolas, J., Peubey, C., Radu, R., Schepers, D., Simmons, A., Soci, C., Abdalla, S., Abellan, X., Balsamo, G., Bechtold, P., Biavati, G., Bidlot, J., Bonavita, M., ... Thépaut, J.-N.** (2020). The ERA5 global reanalysis. *Quarterly Journal of the Royal Meteorological Society*, 146(730), 1999-2049. <https://doi.org/10.1002/qj.3803>
- Hislop, S., Jones, S., Soto-Berelov, M., Skidmore, A., Haywood, A., & Nguyen, T. H.** (2018). Using Landsat Spectral Indices in Time-Series to Assess Wildfire Disturbance and Recovery. *Remote Sensing*, 10(3), 460. <https://doi.org/10.3390/rs10030460>
- 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>
- Höhl, A., Obadic, I., Fernández-Torres, M.-Á., Najjar, H., Oliveira, D. A. B., Akata, Z., Dengel, A., & Zhu, X. X.** (2024). Opening the Black Box: A systematic review on explainable artificial intelligence in remote sensing. *IEEE Geoscience and Remote Sensing Magazine*, 12(4), 261-304. <https://doi.org/10.1109/MGRS.2024.3467001>
- Huang, S., Tang, L., Hupy, J. P., Wang, Y., & Shao, G.** (2021). A commentary review on the use of normalized difference vegetation index (NDVI) in the era of popular remote sensing. *Journal of Forestry Research*, 32(1), 1-6. <https://doi.org/10.1007/s11676-020-01155-1>
- Ialongo, I., Virta, H., Eskes, H., Hovila, J., & Douros, J.** (2020). Comparison of TROPOMI/Sentinel-5 Precursor NO₂ observations with ground-based measurements in Helsinki. *Atmospheric Measurement Techniques*, 13(1), 205-218. <https://doi.org/10.5194/amt-13-205-2020>
- International Institute for Sustainable Development (IISD).** (2025). *Summary of the twentieth session of the United Nations Forum on Forests (UNFF20), 5–9 May 2025* [Earth Negotiations Bulletin, Vol. 13 No. 235]. International Institute for Sustainable Development. <https://enb.iisd.org/un-forum-forests-unff20-summary>
- Jing, P., Deng, W., Crabtree, T., Chen, D., Harbison, J., Whalen, M., & Wang, J.** (2026). Assessing the impact of 2023 wildfire smoke on ozone and public health in Chicago communities. *Atmospheric Environment*, 368, 121773. <https://doi.org/10.1016/j.atmosenv.2026.121773>
- Jones, M. W., Veraverbeke, S., Andela, N., Doerr, S. H., Kolden, C., Mataveli, G., Pettinari, M. L., Le Quéré, C., Rosan, T. M., van der Werf, G. R., van Wees, D., & Abatzoglou, J. T.** (2024). Global rise in forest fire emissions linked to climate change in the extratropics. *Science*, 386(6719), ead15889. <https://doi.org/10.1126/science.adl5889>
- Kang, Y., Choi, H., Im, J., Park, S., Shin, M., Song, C.-K., & Kim, S.** (2021). Estimation of surface-level NO₂ and O₃ concentrations using TROPOMI data

- and machine learning over East Asia. *Environmental Pollution*, 288, 117711. <https://doi.org/10.1016/j.envpol.2021.117711>
- Ke, G., Meng, Q., Finley, T., Wang, T., Chen, W., Ma, W., Ye, Q., & Liu, T.-Y.** (2017). LightGBM: A Highly Efficient Gradient Boosting Decision Tree. *Advances in Neural Information Processing Systems*, 30. <https://proceedings.neurips.cc/paper/2017/hash/6449f44a102fde848669bdd9eb6b76fa-Abstract.html>
- Keeley, J. E.** (2009). Fire intensity, fire severity and burn severity: A brief review and suggested usage. *International Journal of Wildland Fire*, 18(1), 116. <https://doi.org/10.1071/WF07049>
- Keeping, T., Bergin, C., Pinto, I., Ekberzade, B., Voulgarakis, A., Grillakis, M., Papavasileiou, G., Xanthopoulos, G., Lagouvardos, K., Giannaros, Yucel, I., Atalay, H., Barnes, C., Vahlberg, M., Kadihasanoglu, A., Singh, R., Çağla Tunç, D., Otto, F., Philip, S., ... Raju, E.** (2025). Weather conditions leading to deadly wildfires in Türkiye, Cyprus and Greece made 10 times more likely due to climate change. *Centre for Environmental Policy*. <https://eur02.safelinks.protection.outlook.com/?url=https%3A%2F%2Fspiral.imperial.ac.uk%2Fentities%2Fpublication%2F6f847383-0125-42df-a3fd-6ed47d7b24c4&data=05%7C02%7CCorinne.Voces%40mu.ie%7C82a777a318494bc302d108dde5f53dc0%7C1454f5ccbb354685bbd98621fd805>
- Krieger, G., Moreira, A., Fiedler, H., Hajnsek, I., Werner, M., Younis, M., & Zink, M.** (2007). TanDEM-X: A Satellite Formation for High-Resolution SAR Interferometry. *IEEE Transactions on Geoscience and Remote Sensing*, 45(11), 3317-3341. <https://doi.org/10.1109/TGRS.2007.900693>
- Li, M., Wu, Y., Bao, Y., Liu, B., & Petropoulos, G. P.** (2022). Near-Surface NO₂ Concentration Estimation by Random Forest Modeling and Sentinel-5P and Ancillary Data. *Remote Sensing*, 14(15), 3612. <https://doi.org/10.3390/rs14153612>
- Liao, B., Zhou, T., Liu, Y., Li, M., Zhang, T., Liao, B., Zhou, T., Liu, Y., Li, M., & Zhang, T.** (2025). Tackling the Wildfire Prediction Challenge: An Explainable Artificial Intelligence (XAI) Model Combining Extreme Gradient Boosting (XGBoost) with SHapley Additive exPlanations (SHAP) for Enhanced Interpretability and Accuracy. *Forests*, 16(4). <https://doi.org/10.3390/f16040689>
- Liu, C., Wu, S., Dai, Z., Wang, Y., Du, Z., Liu, X., & Qiu, C.** (2023). High-Resolution Daily Spatiotemporal Distribution and Evaluation of Ground-Level Nitrogen Dioxide Concentration in the Beijing–Tianjin–Hebei Region Based on TROPOMI Data. *Remote Sensing*, 15(15), Article 15. <https://doi.org/10.3390/rs15153878>
- Liu, J., Wang, Y., Lu, Y., Zhao, P., Wang, S., Sun, Y., Luo, Y., Liu, J., Wang, Y., Lu, Y., Zhao, P., Wang, S., Sun, Y., & Luo, Y.** (2024). Application of Remote Sensing and Explainable Artificial Intelligence (XAI) for Wildfire Occurrence Mapping in the Mountainous Region of Southwest China. *Remote Sensing*, 16(19). <https://doi.org/10.3390/rs16193602>
- Long, S., Wei, X., Zhang, F., Zhang, R., Xu, J., Wu, K., Li, Q., & Li, W.** (2022). Estimating daily ground-level NO₂ concentrations over China based on TROPOMI observations and machine learning approach. *Atmospheric Environment*, 289, 119310. <https://doi.org/10.1016/j.atmosenv.2022.119310>
- Lundberg, S. M., & Lee, S.-I.** (2017). A Unified Approach to Interpreting Model Predictions. *Advances in Neural Information Processing Systems*, 30.

- <https://proceedings.neurips.cc/paper/2017/hash/8a20a8621978632d76c43dfd28b67767-Abstract.html>
- Manisalidis, I., Stavropoulou, E., Stavropoulos, A., & Bezirtzoglou, E.** (2020). Environmental and Health Impacts of Air Pollution: A Review. *Frontiers in Public Health*, 8. <https://doi.org/10.3389/fpubh.2020.00014>
- Masek, J. G., Wulder, M. A., Markham, B., McCorkel, J., Crawford, C. J., Storey, J., & Jenstrom, D. T.** (2020). Landsat 9: Empowering open science and applications through continuity. *Remote Sensing of Environment*, 248, 111968. <https://doi.org/10.1016/j.rse.2020.111968>
- Mazzeo, G., Falconieri, A., Filizzola, C., Genzano, N., Pergola, N., & Marchese, F.** (2025). Wildfire Detection and Mapping by Satellite With an Enhanced Configuration of the Normalized Hotspot Indices: Results From Sentinel-2 and Landsat 8/9 Data Integration. *IEEE Transactions on Geoscience and Remote Sensing*, 63, 1-21. <https://doi.org/10.1109/TGRS.2025.3528641>
- Meng, Y., Yang, N., Qian, Z., Zhang, G., Meng, Y., Yang, N., Qian, Z., & Zhang, G.** (2020). What Makes an Online Review More Helpful: An Interpretation Framework Using XGBoost and SHAP Values. *Journal of Theoretical and Applied Electronic Commerce Research*, 16(3), 466-490. <https://doi.org/10.3390/jtaer16030029>
- Muñoz-Sabater, J., Dutra, E., Agustí-Panareda, A., Albergel, C., Arduini, G., Balsamo, G., Boussetta, S., Choulga, M., Harrigan, S., Hersbach, H., Martens, B., Miralles, D. G., Piles, M., Rodríguez-Fernández, N. J., Zsoter, E., Buontempo, C., & Thépaut, J.-N.** (2021). ERA5-Land: A state-of-the-art global reanalysis dataset for land applications. *Earth System Science Data*, 13(9), 4349-4383. <https://doi.org/10.5194/essd-13-4349-2021>
- Natekin, A., & Knoll, A.** (2013). Gradient boosting machines, a tutorial. *Frontiers in Neurorobotics*, 7. <https://doi.org/10.3389/fnbot.2013.00021>
- Ngo, T. X., Phan, H. D. T., & Nguyen, T. T. N.** (2023). Development of ground-level NO₂ models in Vietnam using machine learning and satellite observations with ancillary data. *Frontiers in Environmental Science*, 11. <https://doi.org/10.3389/fenvs.2023.1187592>
- Nzabarinda, V., Bao, A., Tie, L., Uwamahoro, S., Kayiranga, A., Ochege, F. U., Muhirwa, F., & Bao, J.** (2025). Expanding forest carbon sinks to mitigate climate change in Africa. *Renewable and Sustainable Energy Reviews*, 207, 114849. <https://doi.org/10.1016/j.rser.2024.114849>
- Phiri, D., Simwanda, M., Salekin, S., Nyirenda, V. R., Murayama, Y., Ranagalage, M., Phiri, D., Simwanda, M., Salekin, S., Nyirenda, V. R., Murayama, Y., & Ranagalage, M.** (2020). Sentinel-2 Data for Land Cover/Use Mapping: A Review. *Remote Sensing*, 12(14). <https://doi.org/10.3390/rs12142291>
- Prokhorenkova, L., Gusev, G., Vorobev, A., Dorogush, A. V., & Gulin, A.** (2018). CatBoost: Unbiased boosting with categorical features. *Advances in Neural Information Processing Systems*, 31. <https://proceedings.neurips.cc/paper/2018/hash/14491b756b3a51daac41c24863285549-Abstract.html>
- Qin, K., Gao, H., Liu, X., He, Q., Tiwari, P., & Cohen, J. B.** (2024). The global daily High Spatial–Temporal Coverage Merged tropospheric NO₂ dataset (HSTCM-NO₂) from 2007 to 2022 based on OMI and GOME-2. *Earth System Science Data*, 16(11), 5287-5310. <https://doi.org/10.5194/essd-16-5287-2024>

- Reshi, A. R., Pichuka, S., & Tripathi, A.** (2024). Applications of Sentinel-5P TROPOMI Satellite Sensor: A Review. *IEEE Sensors Journal*, 24(13), 20312-20321. <https://doi.org/10.1109/JSEN.2024.3355714>
- Roy, D. P., Wulder, M. A., Loveland, T. R., C.e., W., Allen, R. G., Anderson, M. C., Helder, D., Irons, J. R., Johnson, D. M., Kennedy, R., Scambos, T. A., Schaaf, C. B., Schott, J. R., Sheng, Y., Vermote, E. F., Belward, A. S., Bindschadler, R., Cohen, W. B., Gao, F., ... Zhu, Z.** (2014). Landsat-8: Science and product vision for terrestrial global change research. *Remote Sensing of Environment*, 145, 154-172. <https://doi.org/10.1016/j.rse.2014.02.001>
- Schantz, M. C., Hardegree, S. P., Abatzoglou, J. T., Fullhart, A., Adhikhari, K., Harmel, R. D., Thorp, K. R., Leyton, J. O., & Smith, D. R.** (2026). Precipitation forecasting utility for proactive agroecosystem management: A case study from the Texas Gulf LTAR site. *Journal of Environmental Quality*, 55(1), e70132. <https://doi.org/10.1002/jeq2.70132>
- Schneider, S. R., Lee, K., Santos, G., & Abbatt, J. P. D.** (2021). Air Quality Data Approach for Defining Wildfire Influence: Impacts on PM_{2.5}, NO₂, CO, and O₃ in Western Canadian Cities. *Environmental Science & Technology*, 55(20), 13709-13717. <https://doi.org/10.1021/acs.est.1c04042>
- Schollaert, C., Connolly, R., Cushing, L., Jerrett, M., Liu, T., & Marlier, M.** (2025). Air Quality Impacts of the January 2025 Los Angeles Wildfires: Insights from Public Data Sources. *Environmental Science & Technology Letters*, 12(8), 911-917. <https://doi.org/10.1021/acs.estlett.5c00486>
- Sefercik, U. G., & Jacobsen, K.** (2025). Quality Comparison of Free-of-Charge Global DSMs: ALOS AW3D30, TanDEM-X 12 m, TanDEM-X EDEM, TanDEM-X 90 m, and Sentinel-1. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, XLVIII-M-6-2025*, 265-272. ISPRS, EARSeL & DGPF Joint Istanbul Workshop "Topographic Mapping from Space" dedicated to Dr. Karsten Jacobsen's 80th Birthday - 29-31 January 2025, Istanbul, Türkiye. <https://doi.org/10.5194/isprs-archives-XLVIII-M-6-2025-265-2025>
- Shao, Y., Zhao, W., Liu, R., Yang, J., Liu, M., Fang, W., Hu, L., Adams, M., Bi, J., & Ma, Z.** (2023). Estimation of daily NO₂ with explainable machine learning model in China, 2007-2020. *Atmospheric Environment*, 314, 120111. <https://doi.org/10.1016/j.atmosenv.2023.120111>
- Shen, J., Cohen, R. C., Wolfe, G. M., & Jin, X.** (2025). Impacts of wildfire smoke aerosols on near-surface ozone photochemistry. *Atmospheric Chemistry and Physics*, 25(15), 8701-8718. <https://doi.org/10.5194/acp-25-8701-2025>
- Shetty, S., Schneider, P., Stebel, K., David Hamer, P., Kylling, A., & Koren Berntsen, T.** (2024). Estimating surface NO₂ concentrations over Europe using Sentinel-5P TROPOMI observations and Machine Learning. *Remote Sensing of Environment*, 312, 114321. <https://doi.org/10.1016/j.rse.2024.114321>
- Shrestha, K. L., Gyawali, A., Gyawali, S., Joshi, P., & Sharma, S.** (2025). Modeling the impact of wildfire on air quality in Nepal using WRF-Chem and Sentinel-5P. *Environmental Pollution*, 382, 126545. <https://doi.org/10.1016/j.envpol.2025.126545>
- Siddique, M. A., Naseer, E., Usama, M., & Basit, A.** (2024). Estimation of Surface-Level NO₂ Using Satellite Remote Sensing and Machine Learning: A review.

- IEEE Geoscience and Remote Sensing Magazine*, 12(3), 8-34.
<https://doi.org/10.1109/MGRS.2024.3398434>
- Spoto, F., Sy, O., Laberinti, P., Martimort, P., Fernandez, V., Colin, O., Hoersch, B., & Meygret, A.** (2012). Overview Of Sentinel-2. *2012 IEEE International Geoscience and Remote Sensing Symposium*, 1707-1710.
<https://doi.org/10.1109/IGARSS.2012.6351195>
- Taskin, G., Aptoula, E., & Ertürk, A.** (2024). Explainable AI for Earth observation: Current methods, open challenges, and opportunities. İçinde *Advances in Machine Learning and Image Analysis for GeoAI* (ss. 115-152). Elsevier.
<https://doi.org/10.1016/B978-0-44-319077-3.00012-2>
- Tatli, H., & Serkendiz, H.** (2025). Heatwave dynamics in Türkiye: A long-term spatiotemporal analysis of frequency, duration, and intensity (1970–2022). *Environmental Monitoring and Assessment*, 197(7), 752.
<https://doi.org/10.1007/s10661-025-14246-5>
- Tırnık, S.** (2025). Machine learning-based forecasting of air quality index under long-term environmental patterns: A comparative approach with XGBoost, LightGBM, and SVM. *PLOS ONE*, 20(10), e0334252.
<https://doi.org/10.1371/journal.pone.0334252>
- Tumer, İ. N., & Sertel, E.** (2025, Kasım). *Comparative Analysis of Burned Area Detection Using Sentinel-2 and Landsat 8/9 in the 2025 Türkiye Wildfires*. 2025 4th International Conference on Geographic Information and Remote Sensing Technology, Rome, Italy.
- Valerio, A., Chen, Y.-C., Liu, C.-Y., Chen, Y.-Y., Lin, C.-Y., Valerio, A., Chen, Y.-C., Liu, C.-Y., Chen, Y.-Y., & Lin, C.-Y.** (2025). A Hybrid Regression–Kriging–Machine Learning Framework for Imputing Missing TROPOMI NO2 Data over Taiwan. *Remote Sensing*, 17(12).
<https://doi.org/10.3390/rs17122084>
- Vapnik, V., Golowich, S., & Smola, A.** (1996). Support Vector Method for Function Approximation, Regression Estimation and Signal Processing. *Advances in Neural Information Processing Systems*, 9.
<https://proceedings.neurips.cc/paper/1996/hash/4f284803bd0966cc24fa8683a34afc6e-Abstract.html>
- Veefkind, J. P., Aben, I., McMullan, K., Förster, H., de Vries, J., Otter, G., Claas, J., Eskes, H. J., de Haan, J. F., Kleipool, Q., van Weele, M., Hasekamp, O., Hoogeveen, R., Landgraf, J., Snel, R., Tol, P., Ingmann, P., Voors, R., Kruizinga, B., ... Levelt, P. F.** (2012). TROPOMI on the ESA Sentinel-5 Precursor: A GMES mission for global observations of the atmospheric composition for climate, air quality and ozone layer applications. *Remote Sensing of Environment*, 120, 70-83. <https://doi.org/10.1016/j.rse.2011.09.027>
- Vega García, M., & Aznarte, J. L.** (2020). Shapley additive explanations for NO2 forecasting. *Ecological Informatics*, 56, 101039.
<https://doi.org/10.1016/j.ecoinf.2019.101039>
- Wall, T., Steinberg, M., & Shew, D.** (2025). Community-led rebuilding after the LA wildfires. *Nature Sustainability*, 8(4), 326-326.
<https://doi.org/10.1038/s41893-025-01531-x>
- Wang, Y., Faloona, I. C., & Houlton, B. Z.** (2023). Satellite NO2 trends reveal pervasive impacts of wildfire and soil emissions across California landscapes. *Environmental Research Letters*, 18(9), 094032. <https://doi.org/10.1088/1748-9326/acec5f>

- Wang, Y., Yuan, Q., Li, T., Zhu, L., & Zhang, L.** (2021). Estimating daily full-coverage near surface O₃, CO, and NO₂ concentrations at a high spatial resolution over China based on S5P-TROPOMI and GEOS-FP. *ISPRS Journal of Photogrammetry and Remote Sensing*, 175, 311-325. <https://doi.org/10.1016/j.isprsjprs.2021.03.018>
- Wei, Q., Song, W., Dai, B., Wu, H., Zuo, X., Wang, J., Chen, J., Li, J., Li, S., & Chen, Z.** (2025). Spatiotemporal estimation of surface NO₂ concentrations in the Pearl River Delta region based on TROPOMI data and machine learning. *Atmospheric Pollution Research*, 16(3), 102353. <https://doi.org/10.1016/j.apr.2024.102353>
- Wen, H.-T., Lu, J.-H., Jhang, D.-S., Wen, H.-T., Lu, J.-H., & Jhang, D.-S.** (2021). Features Importance Analysis of Diesel Vehicles' NO_x and CO₂ Emission Predictions in Real Road Driving Based on Gradient Boosting Regression Model. *International Journal of Environmental Research and Public Health*, 18(24). <https://doi.org/10.3390/ijerph182413044>
- WHO.** (2021). *WHO global air quality guidelines: Particulate matter (PM_{2.5} and PM₁₀), ozone, nitrogen dioxide, sulfur dioxide and carbon monoxide*. World Health Organization. <https://www.who.int/publications/i/item/9789240034228>
- Yang, C.-H., Chen, P.-H., Yang, C.-S., & Chuang, L.-Y.** (2024). Analysis and Forecasting of Air Pollution on Nitrogen Dioxide and Sulfur Dioxide Using Deep Learning. *IEEE Access*, 12, 165236-165252. <https://doi.org/10.1109/ACCESS.2024.3494263>
- Yilgan, F., Miháliková, M., Kara, R. S., & Ustuner, M.** (2025). Analysis of the forest fire in the 'Bohemian Switzerland' National Park using Landsat-8 and Sentinel-5P in Google Earth Engine. *Natural Hazards*, 121(5), 6133-6154. <https://doi.org/10.1007/s11069-024-07052-8>
- Yue, J., Tian, J., Tian, Q., Xu, K., & Xu, N.** (2019). Development of soil moisture indices from differences in water absorption between shortwave-infrared bands. *ISPRS Journal of Photogrammetry and Remote Sensing*, 154, 216-230. <https://doi.org/10.1016/j.isprsjprs.2019.06.012>
- Zahabnazouri, S., Belmont, P., David, S., Wigand, P. E., Elia, M., & Capolongo, D.** (2025). Detecting Burn Severity and Vegetation Recovery After Fire Using dNBR and dNDVI Indices: Insight from the Bosco Difesa Grande, Gravina in Southern Italy. *Sensors*, 25(10), 3097. <https://doi.org/10.3390/s25103097>
- Zhu, W., Du, N., Wang, L., Zuo, Y., Deng, X., Geng, Y., & Qian, L.** (2025). Joint estimation and driving mechanism analysis of NO₂ and PM_{2.5} in Northwest China based on a hybrid modeling approach. *Atmospheric Pollution Research*, 102787. <https://doi.org/10.1016/j.apr.2025.102787>
- Zhu, Y., Murugesan, S. B., Masara, I. K., Myint, S. W., & Fisher, J. B.** (2025). Examining wildfire dynamics using ECOSTRESS data with machine learning approaches: The case of South-Eastern Australia's black summer. *Remote Sensing in Ecology and Conservation*, 11(3), 266-281. <https://doi.org/10.1002/rse2.422>
- Url-1** <<https://github.com/microsoft/USBldingFootprints>>, erişim tarihi 20.01.2026
- Url-2** <<https://download.geofabrik.de/europe/turkey.html>> , erişim tarihi 20.01.2026



ÖZGEÇMİŞ

Ad-Soyad

:İlay Nur Tümer

ÖĞRENİM DURUMU:

- **Lisans** : 2022, İstanbul Teknik Üniversitesi, İnşaat Fakültesi, Geomatik Mühendisliği

MESLEKİ DENEYİMLER:

- 2024 – Devam Ediyor: Araştırma Görevlisi
İTÜ İnşaat Fakültesi Harita Mühendisliği Bölümü

AKADEMİK YAYINLAR:

- Sertel, E., Kabadayi, M. E., Sengul, G. S., & **Tumer, I. N.** (2024). HexaLCSeg: A historical benchmark dataset from Hexagon satellite images for land cover segmentation [Software and Data Sets]. *IEEE Geoscience and Remote Sensing Magazine*, 12(3), 197-206.
- **Tumer, I. N.** & Sertel E. (2025, November). Comparative analysis of burned area detection using Sentinel-2 and Landsat 8/9 in the 2025 Türkiye wildfires In 4th International Conference on Geographic Information and Remote Sensing Technology (GIRST 2025), Rome, Italy. IEEE.
- Sengul, G. S., **Tumer, I. N.**, Sertel, E., & Ustaoglu, B. (2025, October 8–10). Detection of hazelnut orchards with Sentinel-2 imagery and machine learning classification algorithms. In *Symposium on GeoSpatial Technologies: Visions and Horizons 2025 (GeoVisions 2025)*, Çanakkale, Türkiye.
- **Tumer, I. N.**, Sengul, G. S., Sertel, E., & Ustaoglu, B. (2024, July). Object-Based Detection of Hazelnut Orchards Using Very High Resolution Aerial Photographs. In *2024 12th International Conference on Agro-Geoinformatics (Agro-Geoinformatics)* (pp. 1-5). IEEE.
- Kabadayi, M. E., Sertel, E., **Tumer, I. N.**, & Sengul, G. S. (2024, July). Analyzing Historical Land Cover Change at the Interplay of Urbanization, Rural Depopulation, and Agricultural Land Abandonment in Bulgaria and Turkey Since the 1950s. In *IGARSS 2024-2024 IEEE International Geoscience and Remote Sensing Symposium* (pp. 4722-4726). IEEE.
- Arıkan, C., **Tümer, İ. N.**, Aksoy, S., & Sertel, E. (2022). Determination of burned areas using Sentinel-2A imagery and machine learning classification algorithms. *Intercontinental Geoinformation Days*, 4, 43-46.