

**DOĞAL AFETLERDE ÇEVİRİMİÇİ DAVRANIŞ
VERİLERİNE DAYALI İHTİYAÇ TAHMİNİ VE
KAYNAK TAHSİS OPTİMİZASYONU: 2023
KAHRAMANMARAŞ DEPREMLERİ UYGULAMASI**

**DEMAND PREDICTION AND RESOURCE
ALLOCATION OPTIMIZATION BASED ON ONLINE
BEHAVIORAL DATA IN NATURAL DISASTERS: AN
APPLICATION TO THE 2023 KAHRAMANMARAŞ
EARTHQUAKES**

MEHMET DEMİR

DR. ÖĞR. ÜYESİ ERDİ DAŞDEMİR

Tez Danışmanı

Hacettepe Üniversitesi

Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliğinin

Endüstri Mühendisliği Anabilim Dalı için Öngördüğü

YÜKSEK LİSANS TEZİ olarak hazırlanmıştır.

2025

ÖZET

DOĞAL AFETLERDE ÇEVİRİMİÇİ DAVRANIŞ VERİLERİNE DAYALI İHTİYAÇ TAHMİNİ VE KAYNAK TAHSİS OPTİMİZASYONU: 2023 KAHRAMANMARAŞ DEPREMLERİ UYGULAMASI

Mehmet DEMİR

Yüksek Lisans, Endüstri Mühendisliği Bölümü

Tez Danışmanı: Dr. Öğr. Üyesi Erdi DAŞDEMİR

Haziran 2025, 94 sayfa

Doğal afetler, ani meydana gelişleri ve yıkıcı etkileriyle toplumların fiziksel, ekonomik ve sosyal yapısını derinden sarsan olaylardır. Deprem, sel ve orman yangını gibi afetler sonrasında, kısa süre içinde arama-kurtarma, sağlık hizmetleri, gıda ve barınma gibi temel ihtiyaçlara yönelik yoğun bir talep oluşur. Bu taleplerin zamanında ve etkili bir şekilde karşılanması, afet yönetimi sürecinin en kritik unsurlarından biridir.

Afet sonrası, arama-kurtarma, ekipman, kolluk kuvvetleri, sağlık hizmeti ve gibi temel yardımları ihtiyaç duyulan bölgelere ulaştırmak gerekir. Ancak afetten etkilenen bölgelerdeki ihtiyaç düzeylerini belirlemek bilgiye erişimin kısıtlı olması, iletişim altyapısının zarar görmesi ve talep dinamiklerinin hızlı değişmesi nedeniyle çok zordur. Özellikle afet tek bir merkezle sınırlı kalmayıp geniş bir coğrafi alanda etkili olmuşsa, kaynakların hangi bölgelere ne ölçüde tahsis edileceği sorunu daha karmaşık hâle gelir. Kaynakların harekete geçirilmesi için gerçek taleplerin belirlenmesini beklemek mümkün değildir. Bu nedenle, potansiyel ihtiyaç bölgelerinin ve bu bölgelerdeki tahmini talep

düzeylelerinin erken ve isabetli bir şekilde öngörülmesi, kaynakların etkin ve zamanında tahsisi açısından kritik bir öneme sahiptir.

Bu çalışmada, eş zamanlı müdahale gerektiren doğal afetlerdeki talep belirsizliği ve bu belirsizlik nedeniyle karmaşıklaşan kaynak tahsis problemlerini ele alıyoruz. Çözüm için çevrimiçi davranış verilerine dayalı iki aşamalı bir “tahmin et – optimize et” (predict-then-optimize) yaklaşımı geliştiriyoruz. Yaklaşımımızı, 6 Şubat 2023’te Türkiye’nin güneydoğusunda meydana gelen Kahramanmaraş merkezli depremlerine ait gerçek veriler üzerine uygulamaktayız. İlk aşama, “tahmin et” aşaması, makine öğrenmesi modelleri kullanarak talep belirsizliği problemini adresliyoruz. Bu kapsamda ilk olarak afet sonrası erken dönemde sosyal medya paylaşımları (X, eski adıyla Twitter, gönderileri) ve arama motoru eğilimlerini (Google arama trendi verileri) kullanan bir talep endeksi geliştiriyoruz. X gönderilerindeki yardım çağrısı içeren verileri belirlemek amacıyla, 5000 adet X gönderisini “yardım çağrısı içeriyor” (1) veya “içermiyor” (0) şeklinde manuel olarak etiketliyoruz. Veri kümesini eğitim, test ve doğrulama olarak ayırıyoruz; bu yapı üzerinden BERT (Bidirectional Encoder Representations From Transformers) tabanlı bir metin sınıflandırma modeli geliştiriyoruz. Öncelikle, metin verileri üzerindeki noktalama işaretleri, özel karakterler, kullanıcı etiketlerini temizliyoruz, metinleri küçük harfe dönüştürerek standardize ediyoruz. Bu ön işlem adımlarının ardından, hem geleneksel makine öğrenmesi algoritmaları (Destek Vektör Makineleri, Lojistik Regresyon, Rastgele Orman) hem de bağlamsal anlam öğrenme yeteneğine sahip BERT tabanlı derin öğrenme modeli kullanarak performans karşılaştırması yapıyoruz. Sonrasında X gönderileri ve Google arama trendi verilerini birleştirerek bölgesel ölçekte bir talep popülerliği endeksi oluşturuyoruz. Ardından, geliştirdiğimiz endeks ve afet bölgelerine ait çeşitli demografik ve yapısal değişkenleri kullanarak afetten etkilenen bölgelerdeki göreceli talep düzeylerini belirleyen Ridge regresyon modelleri geliştiriyoruz. Regresyon modellerini geliştirirken talep popülerliği endeksi ile afetten etkilenen illerin çeşitli demografik ve fiziksel değişkenlerine logaritmik, karekök, ters, kare ve küp dönüşümleri ile ikili/üçlü etkileşimler uygulanarak toplamda 113 özellik oluşturuyoruz. Ardından, bu geniş özellik seti içerisindeki çoklu doğrusal ilişkiyi azaltmak amacıyla 0,95 korelasyon eşiği ile hedef odaklı bir değişken eleme süreci yürüterek ve özellik sayısını 33’e düşürüyoruz. Modelleme aşamasında, çoklu hedef değişkenli Ridge regresyon yöntemi kullanarak 7, 8, 9 ve 10 Şubat tarihleri için talep tahminlerini gerçekleştiriyoruz. İkinci aşamada, “optimize et” aşamasında da

ise bu tahminlere dayanarak, çoklu kaynakları etkili ve dengeli bir şekilde afet bölgelerine tahsis eden bir ađ akış optimizasyon modeli geliřtiriyoruz. Böylece, sınırlı sayıdaki arama-kurtarma, sađlık ve lojistik gibi ekiplerin zamansal ve bölgesel dađıtımın planlarını belirliyoruz.

Son yıllarda makine öğrenmesi ve yapay zekâ tabanlı tahmin modelleri, afet gibi belirsizlik içeren ortamlarda karar destek süreçlerinde kullanılmaktadır. Öte yandan, kaynak yönetimi veya tahsisi problemleri, yöneylem araştırması literatüründe kapsamlı uygulama alanına sahip temel problem sınıflarındandır. Bu tez çalışması, tahmine dayalı optimizasyon (predict-then-optimize) paradigmasını benimseyerek deprem özelinde tahmin ve optimizasyon süreçlerinin bütünleşik biçimde çalıştığı bir çözüm yaklaşımı geliřtirmekte, bu yöntemi Kahramanmaraş depremine ait gerçek verileri kullanarak uygulamakta ve böylelikle literatür ve pratiđe yönelik katkı sunmaktadır.

Anahtar Kelimeler: Dođal afet, Kahramanmaraş depremi, insani yardım, kaynak tahsis optimizasyonu, talep tahmini, çevrimiçi davranış verileri, metin sınıflandırma, Ridge regresyon

ABSTRACT

DEMAND PREDICTION AND RESOURCE ALLOCATION OPTIMIZATION BASED ON ONLINE BEHAVIORAL DATA IN NATURAL DISASTERS: AN APPLICATION TO THE 2023 KAHRAMANMARAŞ EARTHQUAKES

Mehmet DEMİR

Master Science, Department of Industrial Engineering

Supervisor Assist. Prof. Dr. Erdi DAŞDEMİR

June 2025, 94 pages

Natural disasters are events that deeply shake the physical, economic and social structure of societies with their sudden occurrence and devastating effects. After disasters such as earthquakes, floods and forest fires, there is an intense demand for basic needs such as search and rescue, health services, food and shelter in a short time. Meeting these demands in a timely and effective manner is one of the most critical elements of the disaster management process.

After a disaster, it is necessary to deliver basic aid such as search and rescue, equipment, law enforcement, health services to the regions in need. However, determining the levels of need in the regions affected by the disaster is very difficult due to limited access to information, damaged communication infrastructure and rapid change in demand dynamics. Especially if the disaster is not limited to a single center but has affected a wide geographical area, the problem of allocating resources to which regions and to what extent becomes more complex. It is not possible to wait for the determination of real demands to mobilize resources. Therefore, early and accurate prediction of potential need regions

and estimated demand levels in these regions is of critical importance for the effective and timely allocation of resources.

In this study, we address the demand uncertainty in natural disasters that require simultaneous intervention and the resource allocation problems that become complicated due to this uncertainty. For the solution, we develop a two-stage “predict-then-optimize” approach based on online behavioral data. We apply our approach to real data belonging to the earthquake centered in Kahramanmaraş that occurred on February 6, 2023 in the southeast of Turkey. In the first stage, the “predict” stage, we address the demand uncertainty problem using machine learning models. In this context, we first develop a demand index that uses social media shares (X, formerly known as Twitter, posts) and search engine trends (Google search trend data) in the early post-disaster period. In order to identify the data containing calls for help in X posts, we manually label 5000 X posts as “contains calls for help” (1) or “does not contain” (0). We divide the dataset into training, test and validation; We develop a text classification model based on BERT based on this structure. First, we clean the text data from punctuation marks, special characters, and user labels, and standardize the texts by converting them to lowercase. After these pre-processing steps, we compare the performance using both traditional machine learning algorithms (Support Vector Machines, Logistic Regression, Random Forest) and a BERT-based deep learning model capable of learning contextual meaning. Then, we combine X posts and Google search trend data to create a regional demand popularity index. Then, we develop Ridge regression models that determine the relative demand levels in disaster-affected regions using the index we developed and various demographic and structural variables belonging to disaster regions. While developing the regression models, we apply logarithmic, square root, inverse, square and cube transformations and binary/triple interactions to the demand popularity index and various demographic and physical variables of the provinces affected by the disaster, creating a total of 113 features. Then, in order to reduce the multicollinearity within this large feature set, we conduct a target-oriented variable elimination process with a correlation threshold of 0,95 and reduce the number of features to 33. In the modeling phase, we perform demand forecasts for February 07, 08, 09 and 10 using the Ridge regression method with multiple target variables. In the second phase, in the “optimize” phase, we develop a network flow optimization model that allocates multiple resources to disaster areas in an effective and balanced manner based on these forecasts. Thus, we determine the temporal and regional

distribution plans of a limited number of teams such as search and rescue, health and logistics. In recent years, machine learning and artificial intelligence-based forecasting models have been used in decision support processes in uncertain environments such as disasters. On the other hand, resource management or allocation problems are among the basic problem classes with extensive application in the operations research literature. This thesis develops a solution approach in which prediction and optimization processes work in an integrated manner by adopting the predict-then-optimize paradigm, and applies this method using real data from the Kahramanmaraş earthquake, thus contributing to literature and practice.

Keywords: Natural disaster, Kahramanmaraş earthquake, humanitarian aid, resource allocation optimization, demand forecasting, online behavior data, text classification, Ridge regression

TEŞEKKÜR

Öncelikle, bugünlere gelmemde en büyük emeğe ve fedakârlığa sahip olan kıymetli annem ve babama, eğitimim için birlikte geçireceğimiz zamandan feragat eden desteğini esirgemeyen, sevgisi, sabrı ve cesaretlendirmesi için sevgili eşime şükranlarımı sunarım.

Tez çalışmamın her aşamasında, gece gündüz demeden, engin bilgi birikimi, akademik rehberliği ve özverili katkılarıyla bana yol gösteren değerli danışmanım Dr. Öğr. Üyesi Erdi DAŞDEMİR'e en derin saygı ve şükranlarımı sunmayı bir borç bilirim. Kendisi, yalnızca akademik bilgisiyle değil, aynı zamanda, sabrı, yapıcı eleştirileri ve ilham verici motivasyonu bu süreci benim için daha anlamlı ve verimli hale getirmiştir.

Yüksek lisans serüvenim boyunca hem akademik hem de kişisel gelişimime ışık tutan, bu meşakkatli ve bir o kadar da kıymetli yolculuğa adım atmamda beni cesaretlendiren, en kararsız anlarımda yol gösteren, bilgi birikimi, deneyimi, nezaketi ve duruşuyla hayatıma yön veren kıymetli büyüğüm Dr. Sercan DÖNMEZ'e en içten ve en derin teşekkürlerimi sunarım. Bu süreçte bana duyduğu güven, verdiği destek ve gösterdiği anlayış için minnettarım.

Motivasyonumun düştüğü anlarda desteğiyle yeniden çalışma şevk ve azmimi yükselten, iyi ve kötü günümde yanımda olan can dostum Aykut TEMİRKAYA'ya ve iş yoğunluğuna rağmen benden destek, güler yüz ve sabırlarını esirgemeyen mesai arkadaşlarım ve değerli yöneticilerime teşekkürü borç bilirim.

İÇİNDEKİLER

| | |
|---|------|
| ÖZET | i |
| ABSTRACT..... | iv |
| TEŞEKKÜR..... | vii |
| İÇİNDEKİLER | viii |
| ŞEKİLLER DİZİNİ | x |
| ÇİZELGELER DİZİNİ | xi |
| SİMGELER VE KISALTMALAR | xii |
| 1. GİRİŞ | 1 |
| 1.1. Tezin Literatüre Katkısı | 5 |
| 1.2. Tezin Organizasyonu | 5 |
| 2. LİTERATÜR TARAMASI | 7 |
| 2.1. Çevrimiçi Davranış Verilerinin Kullanımı | 7 |
| 2.2. Afet Yönetimi ve Kaynak Tahsisi | 12 |
| 2.3. Kahramanmaraş Depremi Üzerinde İlgili Literatür | 15 |
| 3. ÇALIŞMANIN KAPSAMI: PROBLEM, YÖNTEM, VERİ..... | 16 |
| 3.1. Problem Tanımı | 16 |
| 3.2. Uygulama Senaryosu: 6 Şubat 2023 Kahramanmaraş Depremi..... | 17 |
| 3.3. Yöntemsel Yaklaşım: Tahmin Et-Optimize Et..... | 19 |
| 3.4. Veri Yapısı, Ön İşleme ve Diğer Özellikler | 20 |
| 3.4.1. Google Trends Arama Verileri | 21 |
| 3.4.2. X (eski adıyla Twitter) Gönderileri | 28 |
| 3.4.3. Yapısal ve Demografik Veriler..... | 31 |
| 3.5. Performans Metrikleri..... | 31 |
| 3.6. Çalışmanın Varsayımları ve Sınırlamaları..... | 32 |
| 4. SOSYAL WEB İNDEKSİ VE ÖZNİTELİK MÜHENDİSLİĞİ | 35 |
| 4.1. Çevrimiçi Davranış Göstergesi: Sosyal Web İndeksi (SWI)..... | 35 |

| | |
|---|----|
| 4.1.1. Yardım Talebi İçeren X Gönderilerinin Elde Edilmesi | 39 |
| 4.1.2. Google Trend Popülerlik Değerlerinin Elde Edilmesi..... | 43 |
| 4.1.3. SWI Sonuçları..... | 44 |
| 4.2. Öznitelik Mühendisliği ile Yeni Demografik ve Yapısal Öznitelikler | 46 |
| 5. TAHMİN MODELİ GELİŞTİRME | 53 |
| 5.1. Tahmin Modeli Kurulumu | 53 |
| 5.1.1. Ridge Regresyon Kavramsal Temel | 54 |
| 5.1.2. Standardizasyon | 56 |
| 5.1.3. Ridge Regresyon Regülasyon Katsayısı Seçimi..... | 57 |
| 5.2. Çoklu Çıktı ile Tahmin Modeli ve Sonuçlar..... | 58 |
| 5.2.1. Modelin Doğrulanması | 62 |
| 5.2.2. Yönetimsel İçgörüler..... | 65 |
| 5.3. Tekli Çıktı ile Her Hedefe Özel Tahmin Modeli ve Sonuçlar | 65 |
| 5.3.1. İkinci Gün (7 Şubat) SWI Tahmini..... | 66 |
| 5.3.2. Üçüncü Gün (8 Şubat) SWI Tahmini | 67 |
| 5.3.3. Dördüncü Gün (9 Şubat) SWI Tahmini | 68 |
| 5.3.4. Beşinci Gün (10 Şubat) SWI Tahmini | 69 |
| 5.3.5. Yönetimsel İçgörüler | 69 |
| 5.3.6. Modelin Doğrulanması | 71 |
| 6. MATEMATİKSEL OPTİMİZASYON İLE KAYNAK TAHSİSİ..... | 74 |
| 6.1. Modelin Tanımı | 74 |
| 6.2. Matematiksel Notasyonu | 75 |
| 6.3. Optimizasyon Modeli | 76 |
| 6.4. Deneysel Kurulum | 80 |
| 6.5. Optimizasyon Sonuçları..... | 81 |
| 6.6. Matematiksel Model Sonuçları İle SWI'nın Değerlendirilmesi | 83 |
| 7. SONUÇ..... | 89 |
| 8. KAYNAKLAR | 91 |
| ÖZGEÇMİŞ..... | 94 |

ŞEKİLLER DİZİNİ

| | |
|---|----|
| Şekil 3.1. Afetten Etkilenen İller (KTÜ, 2023) | 18 |
| Şekil 3.2. Yöntemsel Yaklaşım Akış Diyagramı | 20 |
| Şekil 3.3. Yardım Kelimesinin Zaman İçerisindeki Popülaritesi | 22 |
| Şekil 3.4. Acil Kelimesinin Zaman İçerisindeki Popülaritesi | 23 |
| Şekil 3.5. AFAD Kelimesinin Zaman İçerisindeki Popülaritesi | 24 |
| Şekil 3.6. Deprem Kelimesinin Zaman İçerisindeki Popülaritesi | 25 |
| Şekil 3.7. Enkaz Kelimesinin Zaman İçerisindeki Popülaritesi | 26 |
| Şekil 3.8. Kızılay Kelimesinin Zaman İçerisindeki Popülaritesi | 27 |
| Şekil 3.9. 6-10 Şubat 2023 Tarihleri Arasındaki Toplam Gönderi Sayısı | 29 |
| Şekil 3.10. 6-10 Şubat 2023 Tarihleri Arasındaki Toplam Yardım Çağrısı Sayısı | 30 |
| Şekil 4.1. Şehirlerin SWI Değerlerinin Zaman İçerisindeki Değişimi | 45 |
| Şekil 4.2. 33 Öznitelik ile Hedef Değişkenler Arasındaki Korelasyon Matrisi | 52 |
| Şekil 5.1. α Parametresine Göre MSE ve R^2 Değişimi | 57 |
| Şekil 5.2. R^2 ve Düzeltilmiş R^2 Zaman İçerisinde Değişimi | 61 |
| Şekil 5.3. MSE, MAE, MAPE'nin Zaman İçerisinde Değişimi | 61 |
| Şekil 5.4. Gerçek ve Tahmin Edilen Değerler | 62 |
| Şekil 5.5. Artık Grafikleri | 63 |
| Şekil 5.6. Etki Analizi Grafikleri | 64 |
| Şekil 5.7. Artık Grafikleri | 71 |
| Şekil 5.8. Etki Grafikleri | 72 |
| Şekil 5.9. Gerçek ve Tahmin Edilen Değerler | 73 |
| Şekil 6.1. Amaç Fonksiyonun Senaryoları Göre Değişimi | 82 |
| Şekil 6.2. Senaryolara Göre Çözüm Süresinin Değişimi | 83 |
| Şekil 6.3. $ I =30$ İçin Tahsis Edilen Ekip Sayıları ve SWI Değerleri | 84 |

ÇİZELGELER DİZİNİ

| | |
|--|----|
| Çizelge 3.1. Yapısal ve Demografik Veriler..... | 31 |
| Çizelge 3.2. SWI Algoritması İçin Değişken ve Notasyonlar..... | 36 |
| Çizelge 4.1. Sınıflandırma Modellerinin Performansları..... | 42 |
| Çizelge 4. 2. Tahmin Edilen Acil Yardım Gönderi Sayısı..... | 43 |
| Çizelge 4.3. Google Trend Popülerlik Skorları..... | 43 |
| Çizelge 4.4. SWI Değerleri..... | 44 |
| Çizelge 4.5. Öznitelik Mühendisliği ile Elde Edilen Değişkenler | 46 |
| Çizelge 4.6. İkili ve Üçlü Etkileşimler ile Elde Edilen Değişkenler | 47 |
| Çizelge 4.7. Grup Özellikleri ve İçerikleri..... | 48 |
| Çizelge 4.8. 33 Öznitelik | 50 |
| Çizelge 5.1. İterasyon Sonrasında Eklenen Öznitelikler | 59 |
| Çizelge 5.2. En Belirleyici Öznitelikler | 59 |
| Çizelge 5.3. SWI Tahmin Performansı | 61 |
| Çizelge 5.4. İkinci Gün Performans Metrikleri..... | 66 |
| Çizelge 5.5. Üçüncü Gün Performans Metrikleri..... | 67 |
| Çizelge 5.6. Dördüncü Gün Performans Metrikleri | 68 |
| Çizelge 6.1. Kaynak Tahsis Optimizasyon Modeli Matematiksel Notasyon | 76 |
| Çizelge 6.2. 7 Şubat'a İlişkin Tahsis Edilen Ekip Sayıları ve SWI Karşılaştırması | 85 |
| Çizelge 6.3. 8 Şubat'a İlişkin Tahsis Edilen Ekip Sayıları ve SWI Karşılaştırması | 86 |
| Çizelge 6.4. 9 Şubat'a İlişkin Tahsis Edilen Ekip Sayıları ve SWI Karşılaştırması | 86 |
| Çizelge 6.5. 10 Şubat'a İlişkin Tahsis Edilen Ekip Sayıları ve SWI Karşılaştırması | 87 |

SİMGELELER VE KISALTMALAR

Kısaltmalar

| | |
|-------|---|
| API | Application Programming Interface |
| BERT | Bidirectional Encoder Representations from Transformers |
| OLS | Ordinary Least Squares |
| SVM | Support Vector Machine |
| SWI | Sosyal Web İndeksi |
| LOOCV | Leave-One-Out Cross-Validation |
| MSE | Mean Squared Error |
| MAE | Mean Absolute Error |
| MAPE | Mean Absolute Percentage Error |

1. GİRİŞ

Doğal afetler, insan kontrolü dışında meydana gelen ve yeryüzündeki doğal süreçlerin bir sonucu olarak ortaya çıkan; can kayıplarına, yaralanmalara ve tüm insanlık için ciddi çevresel, sosyal ve ekonomik yıkımlara yol açan olaylardır. Doğal afet yönetimi; afet öncesi hazırlık, afet anında acil müdahale ve afet sonrası iyileştirme süreçlerini kapsayan, can kayıplarını en aza indirmeyi, mal kaybını azaltmayı ve toplumsal toparlanmayı hızlandırmayı hedefleyen çok yönlü bir süreçtir (Alexander, 2018).

Afet sonrası müdahale süreçlerinin en kritik unsurlarından biri, hangi bölgelere ne tür ve ne miktarda yardım ulaştırılacağına dair kararların hızlı ve doğru bir şekilde verilmesidir. Bu problem, literatürde afetlerde kaynak tahsis problemi olarak adlandırılmakta olup, temel olarak sınırlı sayıdaki arama-kurtarma ekipleri, ekipman, tıbbi malzeme gibi kritik kaynakların ihtiyaç duyulan bölgelere etkin bir şekilde dağıtım ve ulaştırılmasını kapsamaktadır (örnek çalışmalar için bkz., (Wex vd., 2014 vd., Su vd., 2016)). Afet sonrası kaynak dağıtım problemine optimum çözümler üretebilmek için öncelikle etkilenen bölgelerdeki talebin doğru bir şekilde belirlenmesi gerekir. Ancak yardım talebi bilgisi, afetin hemen ardından büyük ölçüde belirsizdir. Afetlerin ani ve yıkıcı etkileri nedeniyle, iletişim altyapıları zarar görür ve ihtiyaç verilerinin sahadan sistematik olarak toplanması zaman alabilir. Ayrıca, afetler genellikle birden fazla bölgeyi eş zamanlı olarak etkiler ve bu da talebin belirlenmesini ve kaynak tahsisini daha da karmaşık hale getirir (çoklu ve eş zamanlı olaylar içeren afetler için bkz. (Lee vd., 2024)). Afet sonrasında, kaynak tahsisi kararlarının hızlı bir şekilde verilmesi gerekir ve talebin netleşmesini beklemek söz konusu değildir. Afet yönetimi literatürü, genellikle talebin bilindiğini veya sonsuz olduğunu varsayarak kaynak yönetim optimizasyonuna odaklanmaktadır. Ancak afet sonrasında talebin hızlı ve isabetli bir şekilde tahmin edilmesi hem zaman yönetimi hem de kaynakların doğru bir şekilde tahsis edilmesi açısından önemlidir.

Afet sonrası talep tahmini için afetten etkilenen bölgelerde afet sonrası ilk saatlerde ortaya çıkan çevrimiçi davranışlar, kaynak yönetimi için potansiyel bir veri kaynağı olarak değerlendirilebilir. Çevrimiçi davranış verileri, bireylerin internet ortamında gerçekleştirdiği etkileşimler ve dijital faaliyetler sonucunda oluşan verilerdir. Bu veriler, kullanıcıların bilgi arama, içerik paylaşma, sosyal medya etkileşimi gibi çevrimiçi aktivitelerinden elde edilir ve bireylerin ihtiyaçları, tercihleri veya acil durumlara

verdikleri tepkiler hakkında önemli ipuçları sunar. Bu veriler, afet sonrası erken dönemde ihtiyaçların ve yardım taleplerinin belirlenmesi için kritik bir bilgi kaynağı oluşturmaktadır. Örneğin, afet bölgelerindeki bireylerin sosyal medya platformları üzerinden yaptıkları paylaşımlar, afetin etkisini tahmin etmek için kullanılabilir. Bu paylaşımlar, afet bölgesindeki insanların ihtiyaçlarını, yaşadıkları durumları ve karşılaştıkları zorlukları gerçek zamanlı olarak yansıtabilmektedir. Örneğin, Kryvasheyeu vd. (2016) çalışmalarında, Sandy Kasırgası öncesi, sırası ve sonrasındaki Twitter etkinliğini analiz ederek sosyal medya paylaşımlarının hem afetin mekânsal ve zamansal etkilerini ortaya koyabildiğini hem de kişi başına düşen sosyal medya etkinliği ile ekonomik hasar arasında güçlü bir korelasyon olduğunu göstermektedir. Benzer şekilde Khare vd. (2020) Irma Kasırgası sırasında Florida’da atılan gönderilerden yola çıkarak sosyal medya verilerini benzin kıtlığı tahmininde kullanmakta ve kıtlık düzeylerini yüksek doğrulukla tahmin etmektedirler. Alexander (2014) ise sosyal medyanın acil durum ve afet yönetiminde kullanımını sosyal ve etik boyutlarıyla ele almakta, bu mecraların yalnızca bilgi izleme ve yayma açısından değil, aynı zamanda iş birliği geliştirme, toplumsal dayanışma oluşturma ve bağış kampanyalarını teşvik etme gibi işlevleriyle de kriz yönetimi süreçlerini dönüştürdüğünü vurgulamaktadır. Bu tür çalışmalar, sosyal medya verilerinin sadece durum farkındalığını artırmakla kalmayıp, aynı zamanda afet sonrası operasyonel karar destek süreçlerine entegre edilebileceğini göstermektedir.

Bu tez çalışmasında, eş zamanlı müdahale gerektiren doğal afetlerde, afetin bölgesel etkilerini ve ortaya çıkan yardım taleplerini tahmin etmeyi ve böylece afet yönetim süreçlerinde etkin kaynak tahsisi yapılmasını desteklemeyi amaçlamaktayız. Bu kapsamda problemi, çevrimiçi davranış verilerine dayalı iki aşamalı bir “tahmin et – optimize et” (predict-then-optimize) yaklaşımıyla ele almakta ve geliştirdiğimiz bu yaklaşımı 2023 Kahramanmaraş depremleri üzerine uygulamaktayız. 2023 Kahramanmaraş depremleri, 6 Şubat 2023 tarihinde meydana gelen ve Kahramanmaraş, Hatay, Gaziantep, Adıyaman, Malatya, Şanlıurfa, Diyarbakır, Adana, Osmaniye, Kilis ve Elazığ olmak üzere 11 ilde yıkıcı etkiler yaratan büyük bir affettir. Bu afet, 8 binden fazla insanın hayatını kaybetmesine ve 100 binden fazla insanın yaralanmasına neden olan Türkiye’nin yakın tarihindeki en büyük felaketlerden biri olmuştur.

Çalışmanın ilk aşamasında, “tahmin et” aşaması, 6–10 Şubat 2023 tarihleri arasında afetten etkilenen bölgelerden yapılan X (eski adıyla Twitter) gönderileri, Google arama

trendi verileri bu bölgelere ait demografik, coğrafi ve yapısal bazı verileri kullanarak zamansal ve mekânsal olarak görelî talep tahmini yapıyoruz. Sonrasında yardım çağrısı içeren X gönderisi tahminlerini ve Google arama trendi verilerini birleştirerek bölgesel ölçekte bir talep popülerliği endeksi oluşturuyoruz. Ardından, afet bölgelerine ait çeşitli demografik ve yapısal değişkenler ile ilk güne ait (6 Şubat) popülerlik endeksini kullanarak 7–10 Şubat tarihleri arasındaki günlere ait talep düzeylerini tahmin eden regresyon tabanlı tahmin modelleri geliştiriyoruz. Çalışmanın ikinci aşamasında ise, “optimize et” adımı oluşturulan bir ağ akışı tabanlı kaynak tahsis optimizasyonu modeli geliştiriyoruz. Bu modelde, ilk aşamada tahmin edilen bölgesel görelî talepler doğrultusunda, farklı kaynak noktalarında konumlanmış farklı tipte kaynakların, afetten etkilenen 11 bölgeye, dört günlük bir zaman dilimi boyunca zamansal ve mekânsal olarak en uygun şekilde tahsisini optimize ediyoruz. Bu iki aşama kapsamında izlediğimiz detaylı adımlar şu şekildedir:

Birinci aşama, tahmin-et aşamasıdır. İlk olarak 6-10 Şubat 2023 tarihleri arasındaki Google Trend verilerini toplamaktayız. Bu veriler, depremle ilgili ve acil yardım içeren anahtar kelimeler (örneğin, “enkaz,” “acil yardım,” “hastane” gibi) ile yapılan Google arama yoğunluklarını göstermektedir. Farklı kelimelerin popülaritelerini ölçekleyerek birleştirmekte ve il ve gün bazlı bir arama popülaritesi endeksi oluşturmaktayız. İkinci olarak, aynı dönemde, depremden etkilenen 11 ilde, afetle ilişkili X (eski adıyla Twitter) paylaşımlarını toplamaktayız. X verilerinde yardım çağrısı içeriklerini tespit edebilmek için öncelikle bir denetimli (supervised) tahmin modeli geliştirmekteyiz. Bu modelin eğitimi için manuel olarak etiketlediğimiz X verilerini kullanmakta ve tahmin modeli olarak BERT (Bidirectional Encoder Representations from Transformers) tabanlı bir metin sınıflandırma modeli kullanılmaktadır. Geliştirdiğimiz model ile il ve gün bazlı yardım çağrısı içeren paylaşımları sınıflandırıyoruz. Model, test verisi üzerinde %86 doğruluk ve %85 F1-score ile başarılı bir performans sergilemiş, bağlamsal anlamı yakalayabilme yeteneği sayesinde yardım çağrılarını tespit etmede yüksek doğruluk sağlamaktadır. Üçüncü olarak, elde edilen Google Trend verileri ve X yardım çağrıları ölçekleyerek ve eşit ağırlıklı olarak birleştirerek her il ve gün için depremin etkisini temsil edecek bir Sosyal Web İndeksi (SWI) geliştiriyoruz. Bu endeksin depremin etkisini temsil ettiğini varsayıyoruz. Son adımda, oluşturduğumuz SWI ve ilgili afet bölgelerine ilişkin nüfus yoğunluğu, bölgelerin afetin merkez üssüne olan uzaklıkları, bölgedeki binaların ortalama yaşı, binaların ortalama kat sayısı gibi önemli demografik, coğrafi ve yapısal

değişkenleri kullanarak Ridge regresyon ile talep tahmin modelleri geliştiriyoruz. Talep tahmin modelleri geliştirirken SWI ile afetten etkilenen illerin çeşitli demografik ve fiziksel değişkenlerine logaritmik, karekök, ters, kare ve küp dönüşümleri ile ikili/üçlü etkileşimler uygulanarak toplamda 113 özellik oluşturuyoruz. Ardından, bu geniş özellik seti içerisindeki çoklu doğrusal ilişkiyi azaltmak amacıyla 0,95 korelasyon eşiği ile hedef odaklı bir değişken eleme süreci yürüterek ve özellik sayısını 33'e düşürüyoruz. Modelleme aşamasında, çoklu ve tekli hedef değişkenli Ridge regresyon modelleri kurarak 7, 8, 9 ve 10 Şubat tarihleri için talep tahminlerini gerçekleştiriyoruz. Böylelikle ilk güne (6 Şubat) ait SWI değeri ve diğer değişkenleri kullanarak, sonraki günlerin (7, 8, 9, 10 Şubat) SWI değerlerini tahmin ediyoruz. Çoklu çıktıda tek bir model ile, tekli çıktıda ise her hedef değişken için ayrı bir model ile tahmin yapıyoruz. SWI tahminleri, her gün içerisinde, afetten etkilenen bölgelerin birbirine kıyasla görece yardım talebini temsil etmektedir. Çoklu çıktı Ridge regresyon modelimizde, ortalama R^2 değeri 0.72 olurken, hedef günler özelinde bakıldığında 7 ve 8 Şubat için 0,65, 9 Şubat için 0,73 ve 10 Şubat için ise 0,86'dır. Çoklu çıktı modelinde, 4 farklı hedef için MAPE değerleri yaklaşık olarak %10-%40 arasında değişmektedir. Tekli çıktı modelimizde ise, hedefe özgün değişken seçimiyle bu skorlar sırasıyla 0,66, 0,81, 0,85 ve 0,89'a yükseltmekteyiz. MAPE değerlerimiz ise yaklaşık olarak dört hedef için %9-%18 aralığına düşmektedir. İkinci aşama ise "optimize-et" aşamasıdır. Bu aşamada afet sonrası çoklu kaynak tahsisi problemi bir ağ akışı tabanlı optimizasyon modeliyle ele alınmaktadır. Model, arama-kurtarma ekipleri, ekipman, kolluk kuvvetleri ve tıbbi yardım ekipleri gibi farklı türdeki kaynakların, afetten etkilenen bölgelere etkin ve dengeli bir şekilde tahsisini amaçlamaktadır. Kaynaklar, çeşitli illerde başlangıçta konumlandırılmış olup, tahmin aşamasında elde edilen il ve gün bazlı görece talep düzeyleri doğrultusunda bölgelere tahsis edilmektedir. Model, dört günlük bir dönem boyunca her gün hangi kaynağın hangi bölgeye gönderileceğini belirlerken, zaman içinde sisteme yeni kaynakların dâhil olabileceğini ve mevcut kaynakların günler içinde iller arasında yer değiştirebileceğini dikkate almaktadır. Ayrıca, kaynaklar arasındaki operasyonel bağımlılıklar da modele entegre edilmiştir; örneğin, bir arama-kurtarma ekibinin bir bölgeye yönlendirilmesi durumunda, aynı bölgeye eşzamanlı olarak gerekli ekipmanın da tahsis edilmesi gerekmektedir. Geliştirilen optimizasyon modeli Gurobi çözümleyicisi kullanılarak çözülmüş ve gerçekleştirilen senaryo analizleriyle kaynakların farklı illerde konumlandırılmasının sistemin genel performansı üzerindeki etkileri değerlendirilmiştir.

1.1. Tezin Literatüre Katkısı

Bu tezde, eşzamanlı müdahale gerektiren afet senaryolarında yardım talebini öngörmek ve kaynak tahsisini planlamak üzere iki aşamalı, entegre bir “tahmin et – optimize et” (predict-then-optimize) yaklaşımı geliştiriyoruz. Bu yaklaşımı, 2023 Kahramanmaraş depremlerine ait verilerle uygulayarak hem makine öğrenmesi hem de yöneylem araştırması literatürüne veri temelli ve uygulamaları bir katkı sunmaktayız.

İlk aşamada geliştirdiğimiz Sosyal Web İndeksi ile çevrimiçi davranış verilerini, demografik ve çevresel değişkenlerle birleştirerek il ve gün bazında görelî yardım talebi tahminleri üretiyoruz. Gerçek ve tahmin veri setlerini açık olarak paylaşıyoruz.¹ Literatürde bu nitelikte bir veri seti bulunmadığı gibi, benzer veriler resmî kurumlar tarafından da paylaşılmamaktadır. Bu yönüyle çalışmamız, özellikle veri eksikliğinin yaygın olduğu gelecekteki optimizasyon tabanlı afet yönetimi araştırmalarına katkı sağlayacağını değerlendiriyoruz.

İkinci aşamada, bu tahminleri kullanan bir ağ akışı tabanlı optimizasyon modeli geliştiriyoruz. Model, farklı türdeki kaynakların tahmin edilen taleplere göre, zamansal ve mekânsal olarak en uygun şekilde tahsisini planlamakta; kaynak hareketliliğini, sisteme yeni kaynak girişini ve kaynaklar arası bağımlılıkları da dikkate almaktadır. Literatürde pek çok modelin talep verisi olmaksızın, genellikle sonsuz talep varsayımıyla çalıştığı düşünüldüğünde, sunduğumuz yaklaşım bu alanda veri temelli, uygulanabilir bir alternatif oluşturmaktadır.

Bu yönüyle tez, afet yönetimi ve karar destek sistemlerine hem yöntem hem de veri katkısı sağlamaktadır.

1.2. Tezin Organizasyonu

Bu tez çalışmasının ilerleyen bölümleri şu şekilde yapılandırılmıştır: İkinci bölüm, literatür taramasına ayrılmıştır ve afet yönetimi, talep tahmini ve kaynak tahsisi konularında yapılan önceki çalışmalar incelenmektedir. Bu bölümde, mevcut literatürdeki eksiklikler ve araştırma boşlukları detaylı bir şekilde ele alınmaktadır. Üçüncü bölümde, çalışmanın kapsamı izlenen yöntemsel çerçeve ve kullanılan veri kaynakları açıklanmaktadır. Dördüncü bölüm, sosyal medya ve arama verilerinden anlamlı göstergeler türetmeye yönelik gerçekleştirilen öznitelik mühendisliği süreçlerine

¹<https://github.com/edasdemirlab/earthquake-optimization-2024>

ayrılmıştır. Burada geliştirilen Sosyal Web İndeksi (SWI), afet talebinin tahmini için temel bir değişken olarak yapılandırılmaktadır. Beşinci bölümde, SWI ile bölgenin yapısal ve demografik öznitelikleri dikkate alan tahmin modelleri geliştirilmektedir. Altıncı bölümde ise, elde edilen tahmin sonuçlarına dayalı olarak kaynakların afet bölgelerine etkin biçimde tahsisini sağlayan matematiksel optimizasyon modeli sunulmakta, bu modelin karar destek sistemleri bağlamındaki katkısı vaka çalışmasıyla gösterilmektedir. Son olarak, yedinci bölümde genel bulgular özetlenmekte, literatür ile karşılaştırmalı değerlendirmeler yapılmakta ve gelecek çalışmalara yönelik önerilerde bulunmaktadır.

2. LİTERATÜR TARAMASI

Doğal afetler, insan kontrolü dışında gelişen ve ciddi çevresel, sosyal ve ekonomik etkiler yaratarak can ve mal kaybına neden olan doğal olaylardır. Doğal afet yönetimi ise, afet öncesi hazırlık, afet anında müdahale ve sonrasında iyileştirme aşamalarını içeren; kayıpları azaltmayı ve toplumsal toparlanmayı hızlandırmayı amaçlayan çok boyutlu bir süreçtir (Alexander, 2018). Afet sonrasında, afetten etkilenen bölgelerde çeşitli yardım ihtiyaçları baş gösterir. Bu ihtiyaçların başında arama kurtarma, tıbbi yardım, kolluk kuvvetleri gibi can kurtarmaya ve güvenliğe yönelik temel insani ihtiyaçlar ortaya çıkar. Bu ihtiyaçlar afetin büyüklüğüne bağlı olarak günler sürebilmekte ve eş zamanlı olarak farklı bölgelerde ortaya çıkabilmektedir. Afet sonrasında meydana gelecek kayıpları azaltabilmek için kaynak tahsisinin doğru yapılması gerekir. İyi bir kaynak tahsisi için de kaynak ve taleplerin bilinmesi gerekir. Çalışmamız hem afet yönetiminde yöneylem araştırması literatürünü hem de sosyal medya verileri ile tahmin konusunu ilgilendirdiği için ilgili çalışmalar iki başlık altında sunulmaktadır. Son olarak da Kahramanmaraş depremiyle ilgili az sayıda çalışma üçüncü bir başlık altında incelenmektedir.

2.1. Çevrimiçi Davranış Verilerinin Kullanımı

Doğal afet öncesi yapılan çalışmalarla genellikle kaynakların konum ve miktarları planlanır ancak talebi bilmek mümkün değildir. Talep, afetin büyüklüğüne bağlı olarak ancak afetin ilk saatlerinde oluşmaya başlar ve ancak günler sonrasında gerçekten bilinebilir. Kaynak dağıtımının başlatılması için ise günlerce bekleme lüksü yoktur. Talebin, afet sonrası ilk saatlerde gelecek yardım çağrılarını kullanarak tahmin edilmesi kaynak tahsisinin hızlı ve iyi yapılmasına olanak sağlar. Afet esnasında ve sonrasında ilk saatlerdeki yardım çağrılarını afet yönetim birimlerine sesli veya yazılı olarak yapılabilir. Son yıllarda afetler esnasında ve sonrasında sosyal medyanın kullanımında da bir artış yaşanmaktadır. Sosyal medya ile yapılan yardım çağrılarını daha kısa süre içerisinde daha çok insana ulaşabilmektedir.

Kryvasheyeu vd. (2016), Sandy Kasırgası sürecinde sosyal medya etkinliğinin afetin zamansal ve mekânsal etkilerini yansıttığını ve kişi başına düşen paylaşım sayısı ile ekonomik kayıplar arasında güçlü bir ilişki bulunduğunu göstermektedir. Khare ve Batta (2020) ise Irma Kasırgası sırasında atılan gönderileri kullanarak benzin kıtlığını yüksek doğrulukla tahmin etmektedir. Benzer şekilde, Khare vd. (2023) Irma Kasırgası örneğinde, afet sırasında sosyal medya verilerini kullanarak temel ihtiyaç malzemesi

kıtlığını tahmin eden ve arama sürecini optimize eden bir yöntem sunmaktadır. Sosyal medya verilerinin eklenmesi ile arama süresinin %41 oranında azaldığını belirtmektedirler. Alexander (2014) ise, sosyal medyanın kriz yönetiminde bilgi akışının ötesinde toplumsal dayanışma ve iş birliğini destekleyici bir araç olarak da rol oynadığını vurgulamaktadır. Bu çalışmalar, sosyal medya verilerinin yalnızca durum farkındalığı sağlamakla kalmayıp, afet sonrası karar destek süreçlerine entegre edilebileceğini ortaya koymaktadır.

Sosyal medya verileri kullanılırken veri çıkarımı ve filtreleme, olay tespiti ve etki analizi ve müdahale stratejileri belirleme ve yardım temini olmak üzere 3 aşamalı bir yol izlenmektedir (Nazer vd., 2017). Müdahale planlamasının etkin bir şekilde yürütülebilmesi ve kriz anlarında doğru kararların alınabilmesi için durumsal farkındalığın oluşturulması büyük önem taşımaktadır. Bu amaçla, sosyal medya platformlarında paylaşılan gönderiler, dikkat ve tavsiye, bilgi kaynağı, bağış, yaralanma ve hasar gibi çeşitli kategorilere ayıran sınıflandırıcılar kullanılarak analiz edilmektedir (Imran vd., 2013). Bu sınıflandırıcılar sayesinde elde edilen veriler, karar vericilerin daha hızlı ve etkili müdahale stratejileri geliştirmesine katkı sağlamaktadır.

Afet sonrası sosyal medya paylaşımlarındaki dil değişimlerinin analizi, belirli anahtar kelimelerin mekânsal dağılımını harita üzerinde görselleştirerek kriz yönetimine katkı sağlamaktadır. Geleneksel kelime frekansı analizlerinden farklı olarak, "sürpriz metrikleri" kullanılarak, afet öncesinde düşük frekansta görülen ancak kriz anında ani artış gösteren kelimeler tespit edilmektedir. Bu süreç, geçmiş dil kullanım verilerinin istatistiksel modellenmesi ve afet sürecindeki kelime eğilimleriyle karşılaştırılması yoluyla gerçekleştirilir (Sampson vd., 2015). Örneğin, Hurricane Sandy sırasında "flood" ve "water" kelimelerinin artışı, selin etkilediği bölgelerin belirlenmesini sağlarken, "power" ve "blackout" kelimelerinin yoğunlaşması, elektrik kesintilerinin tespit edilmesine yardımcı olmuştur. Ayrıca, "explosion" kelimesinin yükselişi, Con Edison enerji santralindeki patlamanın gerçek zamanlı olarak haritalanmasına olanak tanımaktadır.

Sosyal medyada kullanıcılar tarafından paylaşılan içeriklerin gerçek zamanlı afet tespiti ve analizinde kullanılabileceğini ortaya koyan çalışmada, özellikle Twitter kullanıcılarının paylaşımları "sosyal sensörler" olarak tanımlanmaktadır. Çalışmada, Japonya'da meydana gelen deprem olaylarının Twitter verileri kullanılarak otomatik olarak tespiti amaçlanmıştır; paylaşımların afetle ilgili olup olmadığının belirlenmesi için

destek vektör makineleri kullanılarak sınıflandırma yapılmaktadır. Ayrıca, kullanıcıların paylaşımlarındaki konum verilerinden hareketle depremin merkezini tahmin etmek üzere Parçacık Filtresi kullanılmaktadır. Önerilen yöntemle, Japonya Meteoroloji Ajansı tarafından resmi olarak bildirilen depremlerin %96'sınının X (eski adıya Twitter) verileri üzerinden doğru bir şekilde tespit edildiği ortaya koymaktadır. Bu çalışma, sosyal medya verilerinin gerçek zamanlı afet yönetiminde etkin bir araç olabileceğini ve kullanıcıların gönüllü sensörler olarak katkı sağlayabileceğini göstermektedir (Sakaki vd. , 2010). Afet ve acil durumlar sırasında sosyal medya kullanıcılarının daha etkili bilgi paylaşımı yapabilmesi için "Tweak the Tweet" adlı bir yaklaşım geliştirmektedirler. Bu yaklaşım, X gibi mikroblog platformlarında paylaşılan bilgilerin acil durum ekipleri tarafından daha kolay işlenebilmesi amacıyla, kullanıcıların tweetlerini belirli bir sözdizimi ve hashtag sistemiyle paylaşmalarını teşvik etmektedir. Önerilen bu yapılandırılmış etiketleme sistemi sayesinde, kriz anında paylaşılan bilgiler daha organize ve anlamlı hale getirilerek hem acil müdahale ekipleri hem de diğer vatandaşlar için daha erişilebilir bir bilgi kaynağı oluşturulmaktadır. Araştırmada, yangın, yaralanma, yol kapanmaları gibi durumları belirtmek için özel hashtagler (#yangın, #yaralanma, #yolkapalı) kullanılarak bilgi akışı standartlaştırılmaktadır. Bu sayede paylaşılan veriler otomatik olarak toplanıp analiz edilerek kriz yönetiminde etkin bir şekilde kullanılabilir (Starbird ve Stamberger, 2010). Sosyal medya verileri üzerinden Covid-19 pandemisine yönelik kullanıcıların duygu ve görüşlerini analiz etmek için lexicon tabanlı (TextBlob, VADER ve SentiWordNet) ve makine öğrenimi tabanlı (Random Forest, Multinomial Naive Bayes, Support Vector Classifier) yöntemleri karşılaştırmaktadır. İngiltere'nin üçüncü lockdown dönemindeki tweet verileri kullanılarak gerçekleştirilen bu çalışma, VADER'in sosyal medyada kullanılan dile daha uygun olduğunu tespit etmektedirler (Qi ve Shabrina, 2023). Jakarta'daki sel felaketlerine yönelik yapılan başka bir çalışmada toplumun duygu ve algısını sosyal medya paylaşımlarından analiz etmek amaçlanmış ve X (eski adıyla Twitter) paylaşımları SVM (Support Vector Machine) yöntemiyle pozitif ve negatif olarak sınıflandırılmıştır. Analiz edilen paylaşımların büyük çoğunluğunun (%85'ten fazlası) negatif olduğu belirlenmiş, bu da toplumun Jakarta'daki sel yönetimine yönelik genel olarak olumsuz bir algıya sahip olduğunu ortaya koymaktadır (Saddam vd., 2023). Doğal afet yönetimini iyileştirmek amacıyla sosyal medya paylaşımlarını analiz ederek toplumun duygu durumunu ve afetlere yönelik genel algısını anlamaya odaklanan başka bir çalışmada, 6 Şubat 2023 tarihinde Kahramanmaraş'ta gerçekleşen depremler

esnasında paylaşılan yaklaşık 1000 adet tweet üzerinden farklı sınıflandırma yöntemleri karşılaştırmalı olarak değerlendirilmektedir. Çalışma kapsamında, Destek Vektör Makineleri, Rastgele Orman, XGBoost ve Naive Bayes gibi geleneksel makine öğrenimi modellerinin yanı sıra, bağlamı daha iyi yakalayabilen derin öğrenme tabanlı BERT-LSTM (Bidirectional Encoder Representations From Transformers-Long Short Term Memory) modeli de test edilmektedir. Elde edilen sonuçlar, özellikle BERT-LSTM birleşik modelinin, geleneksel yöntemlere kıyasla daha yüksek (%85,43) bir doğruluk oranına sahip olduğunu ortaya koymaktadır. Bu durum, derin öğrenme yaklaşımlarının sınırlı boyuttaki veri kümelerinde dahi etkili olabileceğini ve afet durumlarındaki sosyal medya analizleri için güçlü bir alternatif sunduğunu göstermektedir (Alharm ve Naim, 2024).

Duygu analizine yönelik diğer bir çalışmada ise otel yorumlarındaki örtük duygulara odaklanılmaktadır. Açıkça belirtilemeyen gizli duyguları ve tutumları ortaya çıkaran analize örtük duygu analiz denir. İlgili çalışmada otel yorumları olumlu ve olumsuz olmak üzere 2 sınıfa ayrılmakta ve Naive Bayes, Karar ağaçları, SVM ve lojistik regresyon ve LSTM yöntemi kullanılmaktadır. LSTM 0,9376 doğruluk oranı ile en büyük skoru vermektedir (Arrar vd., 2024).

Afet durumları sırasında X üzerinden paylaşılan gönderileri çoklu etiketli bilgi türlerine göre sınıflandırmayı amaçlayan başka bir çalışmada gönderiler tavsiye, arama kurtarma, bağış, alakasız gibi toplamda 25 farklı bilgi sınıfına ayrılmaktadır. Çalışmada, ön işleme adımlarının ardından standart bir BERT modeli üzerine 10 ek katman eklenerek oluşturulan fine-tuned BERT modeli kullanılmaktadır. Bu yaklaşım ile %81 doğruluk oranı elde etmektedir (Zahera vd., 2019).

Kod-karışık sosyal medya paylaşımlarında alaycılığı tespit etmek amacıyla gerçekleştirilen bir çalışmada, geleneksel makine öğrenmesi ve derin öğrenme yöntemleri karşılaştırılmakta ve en iyi performansın BERT-LSTM modeli ile elde edildiği gösterilmektedir. Makine öğrenmesi tabanlı yöntemlerden Rastgele Orman, Lojistik Regresyon, K-En Yakın Komşu ve Naive Bayes gibi modeller alaycı ifadeleri tespit etmede düşük doğruluk oranlarına sahipken, derin öğrenme tabanlı yöntemler belirgin şekilde daha iyi performans göstermektedir. Özellikle BERT tabanlı modeller, alaycı ve alaycı olmayan ifadeleri ayırt etmede en başarılı sonuçları elde etmekte ve BERT-LSTM modeli 0,92 F1-score ile tüm yöntemleri geride bırakmaktadır (Pandey ve Singh, 2023).

Sosyal medya gönderilerinin konum bilgisiyle etiketlenmiş olması, kullanıcıların fiziksel konumlarının ve etkileşimde buldukları mekânların daha doğru belirlenmesine olanak sağlar. Ancak gönderinin paylaşıldığı fiziksel konum ile içerikte bahsedilen olayın gerçekleştiği mekân farklı olabilmektedir. Dolayısıyla, sosyal medya analizlerinde yalnızca etiketlenen konumun kullanılması, içerik bağlamında yanıltıcı sonuçlara yol açabilir. Bu nedenle, paylaşım içeriği ile etiketlenen konum arasındaki ilişkinin detaylı analizi önem taşımaktadır. Cheng vd. (2010) sosyal medya gönderilerinin yaklaşık olarak %0,42'sinin, Morstatter vd. (2013) ise sosyal medya gönderilerinin yaklaşık olarak %3,17'sinin konum açısından etkin bir şekilde paylaşıldığını tespit etmektedirler. Sosyal medya gönderilerinin metin içerikleri de doğrudan coğrafi konum bilgileri içerebilir. Kullanıcılar, paylaştıkları gönderilerde gerçekleşen olayın veya eylemin hangi mekânsal konumda meydana geldiğini metin aracılığıyla belirtebilirler. Bu durum, gönderilerin analiz aşamasında içerikte bahsedilen konumların tespit edilmesine ve dolayısıyla konum olarak etiketlenmesine imkân tanımaktadır ancak, bu süreçte yazım hataları, standart dışı kısaltmalar, dil farklılıkları ve yerel söylemler gibi faktörler, metin içindeki konum bilgilerinin doğru ve etkili bir şekilde kullanılmasını zorlaştırmaktadır. Bu tür zorlukların üstesinden gelmek ve sosyal medya gönderilerinde geçen yer isimlerini, bölgeleri veya mekânları doğru bir şekilde tanımlayabilmek amacıyla çeşitli analiz yöntemleri ve doğal dil işleme teknikleri üzerine birçok çalışma gerçekleştirilmektedir. Bu çalışmaların temel amacı, içerik ve etiketlenen konum arasındaki tutarsızlıkları azaltmak, konum bilgisini daha doğru ve anlamlı bir şekilde analiz edebilmek ve sosyal medya verilerinden daha güvenilir sonuçlar elde etmektir. Middleton vd. (2013) “Adlandırılmış Varlık Tanıma” yöntemi ile sosyal medya gönderilerinde yer alan konum bilgilerini tespit etmeye çalışmışlardır. Kumar ve Singh (2019) ise konvolüsyonel sinir ağı tabanlı bir model kullanarak sosyal medya gönderilerinin içerisinde yer alan konum bilgilerini tespit etmeye çalışmaktadır.

Khare vd. (2020) çalışmalarında Irma Kasırgası sonrasında sosyal medya platformu X'teki (eski adıyla Twitter) paylaşımları analiz ederek benzin kıtlığı riskini öngörmeye çalışmışlardır. Poisson regresyonu ile ARIMA (AutoRegressive Integrated Moving Average) modelini birleştirerek, sosyal medya verilerinden benzin kıtlığına ilişkin tweet sayılarını tahmin eden hibrit bir model geliştirmişlerdir. Modelde nüfus, istasyon sayısı, kasırganın geliş hızı gibi değişkenler dikkate alarak kıtlık riski yüksek bölgeleri

belirlemişlerdir. Bu yaklaşım, sosyal medya verilerinin afet sonrası kaynak planlamasında etkin biçimde kullanılabileceğini göstermektedir.

Khare vd. (2023) doğal afetler sonrasında ihtiyaç duyulan temel malların aranmasını ve temin edilmesini optimize etmek amacıyla sosyal medya verilerini entegre eden yenilikçi bir metodoloji geliştirmektedirler. Özellikle kasırga sonrası ortaya çıkan benzin kıtlığı sorununa odaklanan bu çalışmada, X (eski adıyla Twitter) üzerinden paylaşılan ilgili tweetler analiz edilerek Bayes ağı temelli bir model oluşturulmuştur. Bu Bayes ağı, sosyal medya verilerini kullanarak benzin istasyonlarında kıtlık yaşanma olasılıklarını tahmin etmiş ve bu doğrultuda arama ve dağıtım yollarının daha verimli planlanmasını sağlamıştır. Böylece, ihtiyaç duyulan kaynakların hızlı ve etkili bir şekilde temin edilmesi mümkün olmuştur. Geliştirilen bu yöntem, afet sonrası müdahale süreçlerinde zaman ve kaynak tasarrufu sağlayarak kriz yönetimini iyileştiren önemli bir katkı sunmuştur.

2.2. Afet Yönetimi ve Kaynak Tahsisi

Literatürdeki afet yönetimi çalışmalarına genel bir bakış sunan Galindo ve Batta (2013) ile başlayan ve daha sonra güncellenen derleme çalışmalarda, afet operasyonları yönetimi alanındaki Yöneylem Araştırması/Yönetim Bilimleri tabanlı modellerin kapsamı, metodolojisi ve uygulama alanları analiz edilmiştir. Bu çalışmalarda, özellikle kaynak tahsisi, koordinasyon eksiklikleri ve iyileştirme aşamasındaki modelleme yetersizlikleri gibi konuların halen önemli araştırma boşlukları içerdiği vurgulanmaktadır. Fiedrich vd. (2000) çalışmalarında, depremin ardından ilk üç gün içinde can kaybını en aza indirmeyi amaçlayan bir kaynak tahsis modeli sunmuştur. Dinamik yapıya sahip bu model, sezgisel yöntemler ile çözümlenmekte ve karar vericilere yazılım destekli karar desteği sağlamaktadır. Su vd. (2016) eşzamanlı olarak ortaya çıkan çoklu olaylara birden fazla acil durum kaynağının paralel şekilde tahsis edilmesini ele alan, çoklu kısıt içeren bir tamsayılı doğrusal programlama modeli önermektedir. Bu yönüyle çalışma, tez kapsamında ele alınan 11 afet iline yönelik kaynak tahsisi problemine yapısal olarak benzetmekte olup, her iki modelde de sınırlı kapasiteye sahip kaynakların çoklu hedefler arasında etkin ve dengeli biçimde dağıtılması ortak amaç olarak öne çıkmaktadır. Wex vd. (2014) çalışmalarında, kurtarma birimlerinin eşzamanlı gerçekleşen olaylara etkin bir biçimde atanmasını sağlayan bir optimizasyon modeli önererek, olayların önem derecelerine göre ağırlıklandırılmış toplam tamamlanma süresini minimize etmeyi amaçlamaktadırlar. Model, farklı sezgisel algoritmalar ile hesaplamalı olarak değerlendirilmiş ve elde edilen bulgular, hem çözüm süresi açısından yüksek hesaplama verimliliği sağladığını hem de

mevcut yöntemlere kıyasla toplam zararı anlamlı ölçüde azaltma potansiyeli taşıdığını göstermektedir. Sarma vd. (2020) çalışmalarında bizim çalışmamıza benzer şekilde afet sonrası kısıtlı kaynak dağıtımını optimize etmek için sosyal medya tabanlı bir önceliklendirme mekanizması ve üç aşamalı matematiksel model önermektedir. Afet sonrası lojistik planlamada hasar görmüş yol ağlarının yapısal karmaşıklığını azaltmak amacıyla, bu ağları ağaç topolojisine indirgemiş ve teslimatların bölünebilir olması koşulunu dikkate alarak iki aşamalı (ana depo → ikincil depo → ihtiyaç noktaları), çok dönemli bir karışık tamsayılı programlama modeli önermektedirler. Lin vd. (2011) afet sonrası kritik öneme sahip malzemelerin (ilaç, su, gıda vb.) önceliklendirilmiş dağıtımını optimize eden sezgisel temelli bir lojistik model önermektedirler. Dukkanci vd. (2023) deprem sonrası insani yardım lojistiğinde talep ve yol ağı belirsizliklerini göz önünde bulundurarak, iki kademeli bir drone dağıtım sistemi önermekte ve bu sistemi senaryo tabanlı stokastik programlama ile modellemektedir. Model, İstanbul örneğinde test edilerek, belirli süre içinde karşılanmayan talebi minimize etmeyi hedeflemekte ve küçük/büyük dronelerin etkili kombinasyonlarını analiz etmektedir. Buna karşın, çalışmamızda bölgesel yardım talebi senaryo varsayımları üzerinden değil, sosyal medya ve Google Trend verilerinin birleştirilmesiyle oluşturulan SWI değeri kullanılarak tahmin etmekte ve kaynak tahsisini bu veriye dayalı olarak optimize etmekteyiz; dolayısıyla talep modellemesi açısından yöntemsel olarak ilgili çalışma ile ayrılmaktayız. Kılıcı vd. (2015) ise afet sonrası kritik öneme sahip unsurlardan biri olan geçici barınma alanlarının konumlandırılması problemine odaklanmaktadır. Geliştirdikleri karışık tamsayılı doğrusal programlama modeli ile barınma alanlarının kalite, kapasite dengesi ve erişilebilirlik kriterlerini dikkate alarak daha dengeli ve etkili bir yer seçimi yaklaşımı ortaya koymuşlardır. Tofghi vd. (2016) çalışmalarında yüksek deprem riski taşıyan Tahran kenti için insani yardım lojistik ağı tasarımı önermekte ve karma belirsizlik (stokastik ve bulanık) altında geliştirdikleri iki aşamalı model ile afet öncesi depo yerleşimi ve stoklama kararlarını, afet sonrası ise çok amaçlı dağıtım planlamasını optimize etmektedirler.

Han vd. (2011) afet bölgelerine hızlı ve etkili bir şekilde yardım gönderimi yapacak lojistik merkezinin en uygun şekilde konumlandırılmasını sağlamak amacıyla yenilikçi bir metodoloji önermektedir. Li vd. (2011) ise Amerika Birleşik Devletleri'nin kıyı bölgelerinde doğal afetlerden kaynaklanan acil barınma ihtiyaçlarını karşılamak amacıyla bir barınma ağı planlama ve yönetim modeli geliştirmektedir. Mete ve Zabinsky (2010)

afet yönetiminde ihtiyaç duyulan tıbbi malzemelerin hızlı ve verimli şekilde dağıtılması amacıyla iki aşamalı stokastik optimizasyon modeli geliştirilmiştir. Birinci aşamada, afet öncesinde hangi depoların kullanılacağı ve depolarda tutulacak malzeme miktarları belirlenerek maliyet ve hız açısından stratejik kararlar alınmıştır. İkinci aşamada ise afet gerçekleştiği anda oluşan koşullar (ulaşım süreleri, yol durumları vb.) göz önünde bulundurularak depolardan hastanelere yapılacak sevkiyat miktarları optimize edilmiştir.

Rath ve Gutjahr (2014) afet sonrası yardım lojistiğinde depo yerleştirme ve araç rotalama problemine yönelik olarak uzun vadeli sabit maliyetler, kısa vadeli operasyonel maliyetler ve maksimum karşılanan talep miktarı olmak üzere üç amaçlı optimizasyon modeli önermişlerdir. Afet sonrasında can kaybını en aza indirmek için ilk arama kurtarma döneminde mevcut kaynakların operasyonel alanlara en iyi şekilde tahsisi yapılmalıdır. Fiedrich vd. (2000) deprem sonrası arama-kurtarma kaynaklarının operasyonel alanlara etkin tahsisi için, toplam can kaybını minimize etmeye yönelik dinamik bir optimizasyon modeli geliştirmiştir. Model, kurtarma süreleri ve ekip performansını dikkate alırken, sezgisel algoritmalarla çözülmüş ve karar destek sistemleri için uygulanabilirliği gösterilmiştir. Kondaveti ve Ganz (2009) ise müdahale kaynaklarının etkili dağıtımı için bir karar destek sistemi önermiştir. Bu sistem, afetzedelerin coğrafi kümelerine ayırarak talepleri önceliklendirmekte ve kaynakları optimizasyon algoritmaları ile tahsis ederek etkin sevkiyat sağlamaktadır.

Pradhananga vd. (2016) afet öncesi kaynak planlaması ve kritik malzeme dağıtımı için üç aşamalı bir ağ yapısına sahip bütünleşik bir model geliştirmiştir. Model, doğrusal olmayan eksiklik maliyetleri ile sosyal maliyeti minimize etmekte ve afet sonrası kaynak eksikliği riskini azaltmaktadır. Majumder vd. (2019) eş zamanlı kriz bölgeleri arasında adil kaynak paylaşımını sağlamak amacıyla oyun teorisi temelli bir model önermiştir. Stratejik ve iş birliksiz yapıya sahip bu model, kaynakların nash dengesi ile optimal dağılımını hedeflemekte ve Kerala sel felaketi örneğiyle doğrulanmaktadır.

Mevcut literatürde afet yönetimi ve kaynak tahsisi çalışmalarında, genellikle talebin tam olarak bilinmediği ve kaynakların sınırsız olduğu varsayılmaktadır. Ancak, bu varsayımlar gerçek dünya koşullarıyla örtüşmemekte olup, afet sonrası talep çeşitli veri kaynakları kullanılarak tahmin edilebilirken, kaynaklar ise kısıtlıdır ve etkin şekilde dağıtılması gerekmektedir. Bu tez çalışma ile söz konusu boşluğu gidermek amacıyla, talebi ölçmek için SWI kavramını geliştirmekte ve kullanılmaktadır. SWI, afet sonrası dönemde Google Trends ve X (eski adıyla Twitter) verilerinin bir araya getirilmesiyle

oluřturulan ve bölgesel talebin dinamik bir göstergesi olarak deęerlendirilen bir indekstir. Literatürde yaygın olan soyut ve varsayımsal talep modellerinin aksine, bu çalışmada gerçek zamanlı ve veri odaklı bir yaklaşım benimsenerek, afetin bölgesel etkilerinin daha doğru bir şekilde modellenmesi amaçlanmaktadır. Böylelikle, afet sonrası acil müdahale süreçlerinde sınırlı kaynakların tahsisini daha etkin ve optimize bir şekilde gerçekleřtirmek için teorik modellemelerden ziyade gözlemsel verilere dayalı bir çerçeve sunmaktayız.

2.3. Kahramanmarař Depremi Özelinde İlgili Literatür

6 Şubat 2023 tarihinde meydana gelen Kahramanmarař merkezli depremler, sadece fiziksel yıkımın boyutu açısından deęil, aynı zamanda dijital platformlar aracılıęıyla toplumun afet sürecine verdięi tepkiler açısından da önemli bir araştırma alanı ortaya koymuřtur. Son dönemde literatürde bu depremlere odaklanan çeřitli çalışmalar yayımlanmış olmakla birlikte, bu çalışmaların büyük bölümü hasar tespiti, afet yönetimi önceliklendirme sistemleri ya da sosyal medya içeriklerinin sınıflandırılması gibi başlıklara odaklanmıştır. Örneęin, Özman vd. (2024), uydu görüntüleri üzerinden deprem sonrası hasarların sınıflandırılmasını hedefleyen bir görüntü işleme modeli önermektedir. Şahin vd. (2023) çalışmasında ise, bulanık analitik hiyerarşı süreci yöntemi ile Kahramanmarař merkezli depremlerde afet sonrası müdahale önceliklerini belirlemiřtir. Dolu ve Şen (2024) tarafından yapılan çalışmada ise, coęrafi referanslı sosyal medya verileri kullanılarak duygu analizi gerçekleştirilmekte, ancak bu analiz daha çok metinlerdeki duygusal tonun tespitine odaklanmaktadır. Öte yandan Özcan ve Iřık (2023), sosyal medya verilerinin kriz yönetimindeki rolünü ele almış; sosyal medyanın kurumlar açısından kriz sırasında halka ilişkiler kurma ve kamuoyunu bilgilendirme gibi işlevlerine odaklanmıştır. Bu tez çalışması ise mevcut literatürden farklı olarak, sosyal medya kaynaklı verileri nicel biçimde işleyerek yardım çağrısı içeriklerini sınıflandırmakta, bu verilerden türetilen SWI ile afet sonrası il ve gün düzeyinde yardım talebini modellemekte ve son olarak bu tahminleri bir optimizasyon modeli aracılıęıyla çoklu kaynak tahsisine entegre etmektedir. Bu yönüyle çalışma, hem sosyal medya verilerinin operatif karar destek süreçlerine entegrasyonu hem de deprem özelinde kaynak yönetimi konularında literatüre özgün bir katkı sunmaktadır.

3. ÇALIŞMANIN KAPSAMI: PROBLEM, YÖNTEM, VERİ

Bu bölümde, çalışmanın ele aldığı problemi, izlediğimiz yöntemsel yaklaşımı ve kullandığımız veri yapısını sunuyoruz. İlk olarak, afet sonrası kaynak tahsisini zorlaştıran belirsizlik, zaman baskısı ve sınırlı kaynak gibi faktörleri tanımlayarak problemimizin çerçevesini ortaya koymaktayız. Bu çalışmada, problemimizi 6 Şubat 2023 tarihinde meydana gelen ve Türkiye'nin güneydoğusunda çok sayıda ili etkileyen Kahramanmaraş merkezli depremler üzerinden ele alıyoruz. Geliştirdiğimiz tahmin ve optimizasyon yaklaşımını bu afet verileri üzerinde uyguladığımız için, problem bağlamını da bu gerçek senaryo çerçevesinde kurguluyoruz. Bu nedenle, bölümün ilgili kısmında söz konusu depremin kapsamı ve etkilerine ilişkin temel bilgileri paylaşmaktayız. Sonrasında, bu probleme çözüm üretmek amacıyla geliştirdiğimiz iki aşamalı “tahmin et – optimize et” yaklaşımını açıklamakta hem tahmin sürecinde hem de karar verme aşamasında kullandığımız yöntemleri adım adım aktarmaktayız. Bölümün devamında ise sosyal medya, arama trendi ve demografik verilere dayanan veri yapımızı tanıtmakta; bu veriler üzerinde gerçekleştirdiğimiz öznitelik oluşturma ve veri ön işleme adımlarını detaylandırmaktayız.

3.1. Problem Tanımı

Afet sonrası müdahale süreçlerinde, sınırlı sayıdaki arama-kurtarma, sağlık ve lojistik kaynağın ne zaman, nereye ve ne miktarda yönlendirileceğine dair kararları hızlı ve doğru biçimde verebilmek hayati önem taşımaktadır. Ancak afetin ilk saatlerinde bu kararları destekleyecek bilgi genellikle sınırlı, belirsiz ve dağınık durumdadır. İletişim altyapılarının zarar görmesi, ihtiyaç bilgilerinin sahadan zamanında toplanamaması ve birden fazla bölgenin eş zamanlı etkilenmesi gibi nedenlerle talebi doğru şekilde belirlemek oldukça zordur. Bu durum, kaynakların etkin tahsisini güçleştirir ve müdahale sürecini yavaşlatır.

Bu çalışmada, afet sonrası talep belirsizliğini azaltmak amacıyla çevrimiçi davranış verilerinden yararlanıyoruz. Çevrimiçi davranış verileri kapsamında, özellikle afetin ilk saatlerinde sosyal medya platformu X üzerindeki yardım çağrılarını içeren gönderiler ile Google arama trendlerinde gözlenen yardım içerikli sorgulara odaklanıyoruz. Bu tür veriler, bireylerin acil ihtiyaçlarını, konumlarını ve yardım beklentilerini erken aşamada yansıtması bakımından kritik öneme sahiptir. Yardım taleplerini bölgesel ve zamansal

düzyeyde tahmin edebilmek için bu iki kaynağı entegre ederek bir talep endeksi oluşturuyoruz.

Tahmin sürecinin ardından, elde ettiğimiz görelî talep öngörülerini doğrultusunda bir kaynak tahsisi optimizasyonu gerçekleştiriyoruz. Bu amaçla, ağ akışı temelli bir model geliştirerek farklı türdeki kaynakların—arama kurtarma, sağlık ve lojistik ekiplerinin—farklı merkezlerden, afetten etkilenen bölgelere, afet sonrası acil yardım zaman dilimi içinde en uygun şekilde tahsis edilmesini planlıyoruz.

Bu bağlamda, bu çalışmada ele alınan temel problem; afet sonrası erken dönemde yardım talebinin çevrimiçi davranış verileriyle tahmin edilmesi ve bu tahminlere dayanarak kaynakların etkin ve dengeli şekilde bölgelere tahsis edilmesidir.

3.2. Uygulama Senaryosu: 6 Şubat 2023 Kahramanmaraş Depremi

6 Şubat 2023 tarihinde Türkiye'nin güneydoğusunda, merkez üssü Kahramanmaraş ili Pazarcık ve Elbistan ilçeleri olan iki büyük deprem meydana gelmiştir. İlk deprem sabah saat 04:17'de 7.7 büyüklüğünde, ikinci deprem ise aynı gün saat 13:24'te 7.6 büyüklüğünde gerçekleşmiştir. Bu depremler, Türkiye'nin yakın tarihindeki en yıkıcı afetlerden biri olarak kayıtlara geçmiş, çok sayıda can kaybı ve ciddi altyapı hasarına neden olmuştur (AFAD, 2023). Kahramanmaraş, Hatay, Adıyaman, Malatya, Gaziantep, Şanlıurfa, Diyarbakır, Osmaniye, Elazığ, Kilis ve Adana olmak üzere Şekil 3.1.'de gösterilen 11 il doğrudan bu depremlerden etkilenmiştir. Bu iller, hem depremin merkez üslerine olan yakınlıkları hem de yüzey kırığı boyunca yer almaları nedeniyle ciddi düzeyde yapısal hasar, can kaybı ve altyapı yıkımı yaşamıştır. Bu 11 ilde 2022 Türkiye İstatistik Kurumu verilerine göre yaklaşık 14 milyon kişi yaşamaktadır. Nüfus yoğunluğunun yüksek olduğu Gaziantep, Hatay ve Adana gibi illerde yapı stoğunun önemli bir kısmı 2000 yılı öncesi yapıldığından, hasar riski daha yüksek olmuştur. Ayrıca kırsal alanda yığma yapıların fazlalığı, can kayıplarının artmasına neden olmuştur. Kent merkezlerinde ise çok katlı betonarme yapıların çökmeleri dikkat çekmiştir. Özellikle Kahramanmaraş, Hatay ve Adıyaman'da yapı güvenliği açısından ciddi sorunlar rapor edilmiştir (KTÜ, 2023).



Şekil 3.1. Afetten Etkilenen İller (KTÜ, 2023).

Afet sonrası binlerce can kaybı, on binlerce yaralanma ve yüz binlerce yapının yıkımı veya ağır hasarı ile sonuçlanmıştır. Depremin ardından barınma, ulaşım ve iletişim gibi kritik altyapı sistemleri ciddi hasar almış; kara ve demir yollarının bozulması nedeniyle afet bölgesine yardım ulaştırılmasında bölgesel gecikmeler yaşanmıştır. Afetin 108.812 km²'lik geniş bir alanda etkili olması ve eş zamanlı olarak birçok yerleşim yerinde müdahale gerektirmesi, afet yönetimi açısından büyük zorluk yaratmış; kaynakların dağıtımı, müdahale önceliklerinin belirlenmesi ve koordinasyon faaliyetlerinde ciddi karmaşa ve gecikmelere neden olmuştur.

Çalışmamızda, 6 Şubat 2023 tarihinde meydana gelen Kahramanmaraş merkezli depremler örnek olay olarak seçilmiştir. Bu tercih, afet sonrası çevrimiçi davranış verilerine —özellikle sosyal medya ve arama motoru verilerine— erişim kolaylığı sayesinde yapılmıştır. Depremin hemen ardından sosyal medya kullanıcıları, yardım taleplerini iletmek ve bilgi paylaşımında bulunmak amacıyla yoğun şekilde X (eski adıyla Twitter) platformunu kullanmış; bu içeriklerin önemli bir kısmı kullanıcılar, gönüllüler ve araştırma toplulukları tarafından açık kaynaklı veri kümeleri hâlinde paylaşılmıştır. Bu durum, afet bölgesinden gelen içeriklerin analizine dayalı veri temelli bir yaklaşım geliştirilmemizi mümkün kılmıştır. Ayrıca, söz konusu depremler çok sayıda ili eşzamanlı etkileyerek farklı türde ve yoğunlukta ihtiyaçların doğmasına yol açmış, bu yönüyle çalışmamızda geliştirilen çok bölgeli ve çok zamanlı kaynak tahsis modelinin gerçekçi bir senaryo üzerinde uygulanabilirliğini güçlendirmiştir. Özellikle eşzamanlı müdahale gerektiren bu tür afet yapıları, il ve gün bazlı görelî talep tahminine dayanan yaklaşımımızla büyük ölçüde örtüşmekte, modelin etkinliğini test etme açısından uygun bir zemin hazırlamaktadır.

Bu senaryo kapsamında, X gönderileri ve Google arama trendlerinden elde edilen verilerle oluşturduğumuz görelî talep tahminlerini, kaynak tahsisi kararlarının belirlenmesinde temel veri kaynağı olarak kullanmaktayız.

3.3. Yöntemsel Yaklaşım: Tahmin Et-Optimize Et

Problemin çözümü için iki aşamalı bir yöntem geliştiriyoruz. Bu aşamalar ve alt adımları bu bölümde açıklıyoruz.

Birinci aşama: Tahmin-et

1. Adım: Birinci adımda, 6-10 Şubat 2023 tarihleri için depremden etkilenen 11 ilden gönderilen afetle ilişkili X (eski adıyla Twitter) paylaşımlarını toplamaktayız. X verilerinde yardım çağrısı içeriklerini tespit edebilmek için öncelikle bir denetimli (supervised) tahmin modeli geliştirmekteyiz. Bu modelin eğitimi için manuel olarak etiketlediğimiz X verilerini kullanmakta ve tahmin modeli olarak BERT tabanlı bir metin sınıflandırma modeli kullanmaktayız. Geliştirdiğimiz model ile il ve gün bazlı yardım çağrısı içeren paylaşımları sınıflandırıyoruz. Model, test verisi üzerinde %86 doğruluk ve %85 F1-score ile başarılı bir performans sergilemiş, bağlamsal anlamı yakalayabilme yeteneği sayesinde yardım çağrılarını tespit etmede yüksek doğruluk sağlamıştır.

2. Adım: İkinci adımda, 6-10 Şubat 2023 tarihleri arasındaki Google Trend verilerini toplamaktayız. Bu veriler, depremle ilgili ve acil yardım içeren anahtar kelimeler (örneğin, “enkaz,” “acil yardım,” “hastane” gibi) ile yapılan Google arama yoğunluklarını göstermektedir. Farklı kelimelerin popülaritelerini ölçekleyerek birleştirmekte ve il ve gün bazlı bir arama popülaritesi endeksi oluşturmaktayız. Böylece, toplumsal ilgi ve yardım arayışı eğilimlerini nicel olarak temsil etmekteyiz.

3. Adım: Üçüncü adımda, Elde edilen Google Trend verileri ve X yardım çağrılarını ölçekleyerek ve eşit ağırlıklı olarak birleştirerek her il ve gün için depremin etkisini temsil edecek bir SWI geliştiriyoruz. Bu endeksin depremin etkisini temsil ettiğini varsayıyoruz.

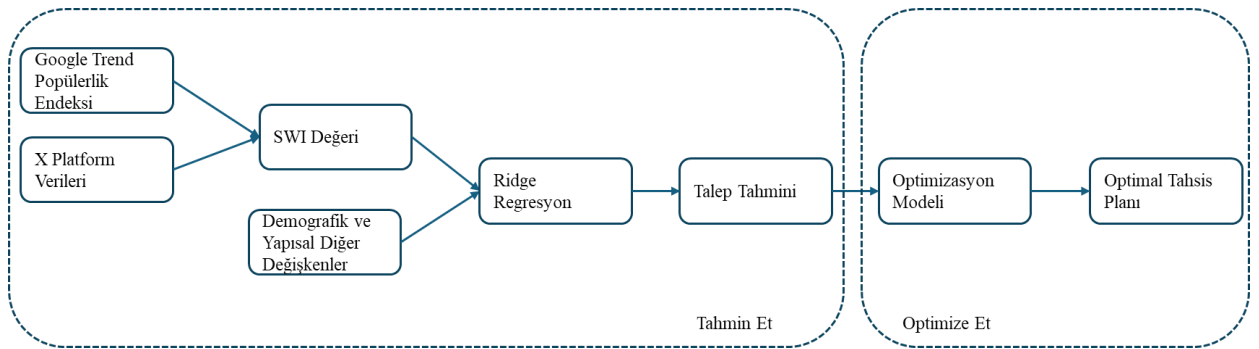
4. Adım: Dördüncü adımda, oluşturduğumuz SWI ve ilgili afet bölgelerine ilişkin nüfus yoğunluğu, bölgelerin afetin merkez üssüne olan uzaklıkları, bölgedeki binaların ortalama yaşı, binaların ortalama kat sayısı gibi önemli demografik, coğrafi ve yapısal değişkenleri kullanarak talep tahmin modelleri geliştiriyoruz. Bu modellerle, ilk güne (6 Şubat) ait SWI değeri ve diğer değişkenleri kullanarak, sonraki günlerin (7, 8, 9, 10 Şubat)

SWI değerlerini tahmin ediyoruz. SWI tahminleri, her gün içerisinde, afetten etkilenen bölgelerin birbirine kıyasla görece yardım talebini temsil etmektedir.

İkinci Aşama: Optimize-et

Tez çalışmasının ikinci aşamasında, afet sonrası çoklu kaynak tahsisi problemi bir ağ akışı tabanlı optimizasyon modeliyle ele alınmaktadır. Model, arama-kurtarma ekipleri, ekipman, kolluk kuvvetleri ve tıbbi yardım ekipleri gibi farklı türdeki kaynakların, afetten etkilenen bölgelere etkin ve dengeli bir şekilde tahsisini amaçlamaktadır. Kaynaklar, çeşitli illerde başlangıçta konumlandırılmış olup, tahmin aşamasında elde edilen il ve gün bazlı görece talep düzeyleri doğrultusunda bölgelere tahsis edilmektedir. Model, dört günlük bir dönem boyunca her gün hangi kaynağın hangi bölgeye gönderileceğini belirlerken, zaman içinde sisteme yeni kaynakların dâhil olabileceğini ve mevcut kaynakların günler içinde iller arasında yer değiştirebileceğini dikkate almaktadır. Ayrıca, kaynaklar arasındaki operasyonel bağımlılıklar da modele entegre edilmiştir; örneğin, bir arama-kurtarma ekibinin bir bölgeye yönlendirilmesi durumunda, aynı bölgeye eşzamanlı olarak gerekli ekipmanın da tahsis edilmesi gerekmektedir. Geliştirilen optimizasyon modeli Gurobi çözümleyicisi kullanılarak çözülmüş ve gerçekleştirilen senaryo analizleriyle kaynakların farklı illerde konumlandırılmasının sistemin genel performansı üzerindeki etkileri değerlendirilmiştir.

Sunmakta olduğumuz iki aşamalı yöntemsel yaklaşımımızı Şekil 3.2.'de bir akış diyagramıyla da göstermekteyiz.



Şekil 3.2. Yöntemsel Yaklaşım Akış Diyagramı

3.4. Veri Yapısı, Ön İşleme ve Diğer Öznitelikler

Bu bölümde, afet sonrası talep tahmini ve kaynak tahsisi süreçlerinde kullanılan veri yapısını detaylandırıyoruz. Çalışmada üç ana veri kaynağından yararlanıyoruz: sosyal medya platformu X (eski adıyla Twitter) üzerinden toplanan yardım çağrısı içerikli

gönderiler, Google Trends verileri aracılığıyla elde edilen yardım temalı arama eğilimleri ve afet bölgelerine ait yapısal ile demografik göstergeler. Bu veri kaynakları, hem afetin erken saatlerinde oluşan çevrimiçi davranışları yansıtarak talebin tahmin edilmesine olanak tanımakta, hem de bölgesel farklılıkları modelleyebilmek adına açıklayıcı değişkenler sunmaktadır.

3.4.1. Google Trends Arama Verileri


Google Trends, kullanıcıların belirli anahtar kelimelerle yaptıkları aramaların zaman ve bölge bazında görece yoğunluğunu gösteren bir analiz aracıdır. Bu veriler, toplumsal ilgi, endişe veya ihtiyaçların zaman içindeki değişimini gözlemlemeye olanak tanıdığı için afet gibi kriz durumlarında değerli bir erken gösterge kaynağı olarak kullanılabilir.

Google Trends verileri, ilgili anahtar kelimenin belirli bir bölgedeki görece popülerlik değerini 0 ile 100 arasında bir ölçekte sunmaktadır. Bir başka deyişle, Google Trend popülerlik değeri, belirli bir anahtar kelimenin bir bölgede toplam aramalar içindeki göreceli popülerliğini yansıtan bir metriktir. Bu değer, en yoğun arama yapılan şehir için 100 puan olarak normalize edilir ve diğer şehirler bu en yoğun şehirle kıyasla orantılı bir puan alır. Örneğin, bir şehirde "yardım" kelimesinin toplam aramalardaki oranı %5 ise ve bu oran diğer şehirlerde daha düşükse, bu şehir 100 puan alır. Diğer şehirlerin puanları, bu şehre göreceli olarak hesaplanır. Örneğin, bir şehirde "yardım" arama oranı %2,5 ise, bu oran 100 puanlık şehrin yarısı kadar popüler olduğunu ifade eder ve şehir 50 puan alır. Aynı şekilde, bir şehirde oran %4 ise, bu şehir 100 üzerinden 80 puan alır. Bu değerler, toplam arama hacmini değil, belirli bir terimin popülerliğini gösterir. Örneğin, 6 Şubat 2023 tarihinde Adana için "deprem" kelimesinin popülerlik değeri 71 ve "yardım" kelimesinin popülerlik değeri 41 olarak kaydedilmiştir. Bu, Adana'da "deprem" aramalarının, en yoğun arama yapan şehre göre %71 oranında popüler olduğunu, "yardım" aramalarının ise %41 oranında popüler olduğunu ifade eder. Ancak bu, Adana'daki toplam aramaların %71'inin "deprem" veya %41'in "yardım" kelimeleriyle ilgili olduğu anlamına gelmez. Her terim bağımsız olarak normalize edildiği için, bir şehirde farklı terimlerin popülerlik değerlerinin toplamı %100'den fazla olabilir.

6 Şubat 2023 tarihinde meydana gelen Kahramanmaraş merkezli depremler, Türkiye'deki 11 ili ciddi şekilde etkileyerek toplumun bilgi arama davranışında önemli değişimlere yol açmıştır. Bu süreçte, bireylerin bilgiye erişim ihtiyacı artmış ve yardım içerikli anahtar kelimelerle yapılan aramalarda belirgin bir yükseliş gözlemlenmiştir. Bu çalışma


kapsamında, söz konusu arama eğilimlerini analiz edebilmek amacıyla Google Trends platformunun sağladığı popülerlik verilerini kullanılarak, özellikle depremden doğrudan etkilenen illerdeki arama davranışları incelemekteyiz. Google Trends verileri, <https://trends.google.com/trends> adresi üzerinden erişilebilir olup, bu çalışmada söz konusu verilere manuel olarak erişmek yerine Python programlama dili ve pytrends kütüphanesi kullanılarak otomatik bir şekilde erişim sağladık.

Bu kapsamda, depremden etkilenen 11 ilde yapılan Google aramaları arasında “deprem”, “yardım”, “acil”, “enkaz”, “AFAD” ve “Kızılay” anahtar kelimelerini içeren sorguları, 6 Şubat 2023 ile 10 Şubat 2023 tarihleri arasındaki beş günlük dönem için Google Trends üzerinden elde etmekteyiz.




Şekil 3.3. Yardım Kelimesinin Zaman İçerisindeki Popüleritesi

Şekil 3.3.’te, 6-10 Şubat 2023 tarihleri arasında “yardım” kelimesine yönelik Google Trend popülerlik verileri 11 depremzede il özelinde gösterilmiştir. Genel olarak, tüm illerde zaman içinde yardım aramalarında belirgin bir artış gözlemlenmektedir. Bu eğilim, depremin hemen ardından artan toplumsal yardım ihtiyacını ve bu ihtiyaçların dijital ortamda nasıl yansıdığını ortaya koymaktadır. Özellikle Kahramanmaraş, Hatay ve Adıyaman gibi depremin merkezine yakın illerde popülerlik değerleri daha yüksek seviyelere ulaşmıştır. Öte yandan Elazığ ve Diyarbakır gibi görece daha az etkilenen illerde arama hacmi daha istikrarlı ve düşük seyretmiştir. Osmaniye’deki sıfır değerler ise teknik bir boşluk ya da çok düşük veri hacminden kaynaklı olabilir. Genel olarak grafik, halkın afet sonrası yardım arayışının hem zamanla hem de bölgesel etki düzeyiyle şekillendiğini göstermektedir.



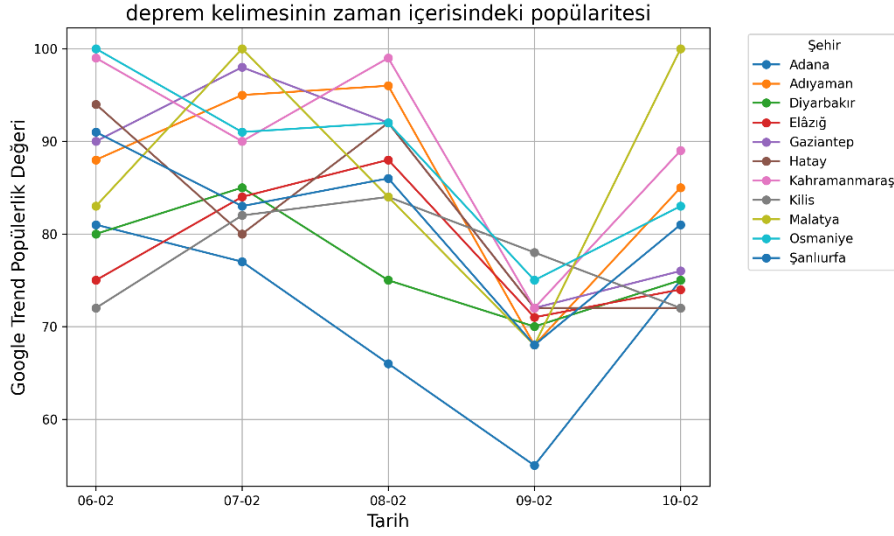
Şekil 3.4. Acil Kelimesinin Zaman İçerisindeki Popülaritesi

Şekil 3.4.’te 6-10 Şubat 2023 tarihleri arasında “acil” kelimesine yönelik Google Trend popülarite verileri 11 depremzede il özelinde gösterilmiştir. Grafik, iller arasında hem zaman hem de yoğunluk açısından önemli dalgalanmalar olduğunu göstermektedir. Kahramanmaraş, Hatay ve Gaziantep gibi depremin merkezine yakın illerde bazı günlerde “acil” kelimesine yönelik arama ilgisinin ani ve yüksek zirveler yaptığı görülmektedir; özellikle Kahramanmaraş’ın 8 Şubat’ta ulaştığı 100 değeri dikkat çekicidir. Bununla birlikte, bazı illerde sifıra yakın veya sıfır değerler gözlemlenmektedir; bu durum ilgili tarihlerde yeterli arama hacmine ulaşamadığı için için Google Trends tarafından veri atanmamış olmasından kaynaklandığını değerlendiriyoruz. Genel olarak, “yardım” kelimesine göre daha düzensiz ve keskin sıçramalara sahip bu grafik, “acil” kelimesinin daha spesifik, kriz anına odaklı ve ani bilgi ihtiyacını yansıttığını göstermektedir. Bu da toplumun afetin etkilerini hissettiği anda hızla bilgi arayışına geçtiğini ve bu aramanın özellikle bazı illerde çok yoğunlaştığını ortaya koymaktadır.




Şekil 3.5. AFAD Kelimesinin Zaman İçerisindeki Popülaritesi

Şekil 3.5.'te, 6-10 Şubat 2023 tarihleri arasında “AFAD” kelimesinin kelimesine yönelik Google Trend popülarite verileri 11 depremde il özelinde gösterilmiştir. Veriler, depremin hemen ardından başlayan bilgi arayışının kurumsal düzeyde nasıl yöneldiğini ortaya koymaktadır. Grafik genel olarak, tüm illerde ilk günlerde görece yüksek düzeyde bir arama ilgisi olduğunu, ancak 7-8 Şubat tarihlerinde belirgin bir düşüş yaşandığını göstermektedir. Bu düşüşün ardından 9-10 Şubat'ta hemen her ilde hızlı bir artış gözlemlenmektedir. Özellikle Osmaniye'nin 9 Şubat'ta ulaştığı 100 değeri, o gün için ülkedeki en yüksek “AFAD” arama yoğunluğunun bu şehirde olduğunu göstermektedir. Diğer illerde de benzer şekilde yükselen eğilimler, halkın afet sonrası dönemde resmi yardım ve yönlendirme kurumlarına olan ilgisinin giderek arttığını yansıtmaktadır. Bu durum, kriz anında güvenilir ve merkezi bilgi kaynağına yönelimin güçlü bir göstergesidir.



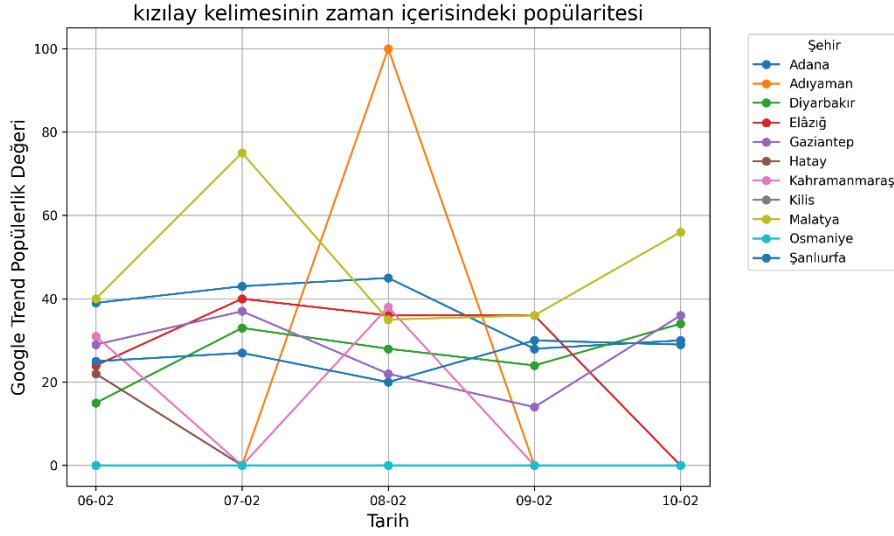
Şekil 3.6. Deprem Kelimesinin Zaman İçerisindeki Popülaritesi

Şekil 3.6.'da 6-10 Şubat 2023 tarihleri arasında “deprem” kelimesine yönelik Google Trend popülarite verileri 11 depremzede il özelinde gösterilmiştir. Grafik genel olarak, depremin yaşandığı 6 Şubat'ta ve onu takip eden birkaç gün boyunca “deprem” kelimesine yönelik arama ilgisinin çok yüksek olduğunu ve bu yüksek ilginin 7-8 Şubat tarihlerinde sürdüğünü ortaya koymaktadır. Bu dönem, halkın afetin boyutunu ve etkilediği bölgeleri anlamaya çalıştığı yoğun bilgi arayışı evresini temsil etmektedir. 9 Şubat'ta ise birçok ilde belirgin bir düşüş yaşanmış, ancak 10 Şubat itibarıyla bu düşüş yerini tekrar yükselişe bırakmıştır. Özellikle Malatya, Kahramanmaraş ve Şanlıurfa gibi illerde popülarite değerlerinin tekrar yüksek seviyelere çıktığı görülmektedir. Bu eğilim, ilk şokun ardından bilgi ihtiyacının yenilenen dalgalarla sürdüğünü ve kamuoyunun ilgisinin birkaç gün boyunca canlı kaldığını göstermektedir. Genel olarak grafik, afetin hemen ardından toplumun büyük bir kısmının “deprem” hakkında bilgiye ulaşma yönünde güçlü bir dijital refleks geliştirdiğini ortaya koymaktadır.



Şekil 3.7. Enkaz Kelimesinin Zaman İçerisindeki Popülaritesi

Şekil 3.7.'de 6-10 Şubat 2023 tarihleri arasında “enkaz” kelimesine yönelik Google Trend popülarite verileri 11 depremde il özelinde gösterilmiştir. Veriler, depremin ardından enkaz altında kalanlara ulaşma çabası ve bu bağlamda bilgi arayışının zaman içindeki seyrini ortaya koymaktadır. Genel olarak, 8 Şubat tarihinde pek çok ilde “enkaz” kelimesine yönelik arama yoğunluğunun zirveye ulaştığı görülmektedir; özellikle Kahramanmaraş ve Hatay illerinde bu tarihte çok yüksek değerler kaydedilmiştir. Bu durum, arama-kurtarma faaliyetlerinin kamuoyunun odağına en çok bu dönemde yerleştiğini göstermektedir. Bununla birlikte, bazı illerde sıfır değerler dikkat çekmektedir. Bu sıfır değerler, ilgili tarihlerde yeterli arama hacminin oluşmaması nedeniyle Google Trends tarafından veri atanmamış olmasından kaynaklanmaktadır. “Enkaz” kelimesine yönelik ilgi, diğer kelimelere kıyasla daha keskin dalgalanmalar göstermekte; bu da terimin, daha spesifik, olay yerindeki fiziksel yıkımla doğrudan ilişkili olduğunu ve bölgesel olarak farklı yoğunluklarda hissedildiğini göstermektedir. Genel olarak grafik, afetin fiziksel etkilerine yönelik dijital ilginin, belirli günlerde yoğunlaştığını ve özellikle yüksek yıkım yaşanan illerde daha belirgin olduğunu ortaya koymaktadır.



Şekil 3.8. Kızılay Kelimesinin Zaman İçerisindeki Popülaritesi

Şekil 3.8’te 6-10 Şubat 2023 tarihleri arasında “Kızılay” kelimesine yönelik Google Trend popülarite verileri 11 depremzede il özelinde gösterilmiştir. Genel eğilim, “Kızılay” kelimesine yönelik aramaların diğer afetle ilişkili kelimelere kıyasla daha düşük düzeyde ve dağınık olduğunu ortaya koymaktadır. Adıyaman ilinde 8 Şubat’ta gözlemlenen ani sıçrama ile 100 değerine ulaşılması dikkat çekici olup, bu bölgede belirli bir gün içinde Kızılay’a yönelik yoğun bir bilgi arayışı olduğunu göstermektedir. Bununla birlikte, Şanlıurfa ve Kilis gibi bazı illerde sıfır değerler görülmektedir; bu durum, o günlerde yeterli arama hacminin oluşmaması nedeniyle Google Trends tarafından veri atanmamış olmasından kaynaklanmaktadır. Grafik genel olarak, halkın Kızılay gibi resmi yardım kuruluşlarına olan dijital ilgisinin dalgalı ve bölgesel farklılıklar içerdiğini göstermektedir. Bu durum, Kızılay’ın yerel düzeydeki faaliyetlerinin veya medyada görünürlüğünün kamu arama davranışlarını etkileyebileceğini düşündürmektedir. Yardım kelimesine göre çok daha düşük seviyede kalan “Kızılay” aramaları, vatandaşların doğrudan yardım ihtiyacına yönelik aramalara yöneldiğini ve kurumsal aktörlere daha seçici ve belirli zaman dilimlerinde ilgi gösterdiğini ortaya koymaktadır.

Sonuç olarak, Google Trend arama verilerinden elde ettiğimiz popülarite değerleri bize mutlak arama hacmi bilgisini vermese bile, bu normalize edilmiş değerler, her bir anahtar kelime arama şehir bazlı popülaritelerini temsil etmektedir. Arama ilgisi ve yardım talebi arasında bir korelasyon olduğunu varsayarak, bu değerleri kamuoyunun dikkatinin ve dolayısıyla her bölgedeki potansiyel ihtiyaçların dolaylı bir göstergesi olarak varsayıyoruz. Örneğin, deprem sonrası bir senaryoda, "yardım" kelimesine yüksek oranda göreceli ilgi gösteren bir şehrin kurtarma operasyonları veya insani yardım için acil ilgiye

ihtiyacı olabilir. Elde edilen bulgular, "deprem" ve "yardım" gibi terimlerin afet bölgelerinde ne kadar öne çıktığını ve toplumsal bilgi arama davranışlarının hangi yönlere kaydığını anlamamıza olanak tanır. Bu analiz, afet bölgelerindeki arama eğilimlerini anlamak için değerli bir aracı oluştururken, ilerleyen aşamalarda bu veriler acil yardım tweet çağrılarını ile birleştirilerek geliştireceğimiz Sosyal Web İndeksi'nin hesaplanmasında kullanılacaktır.

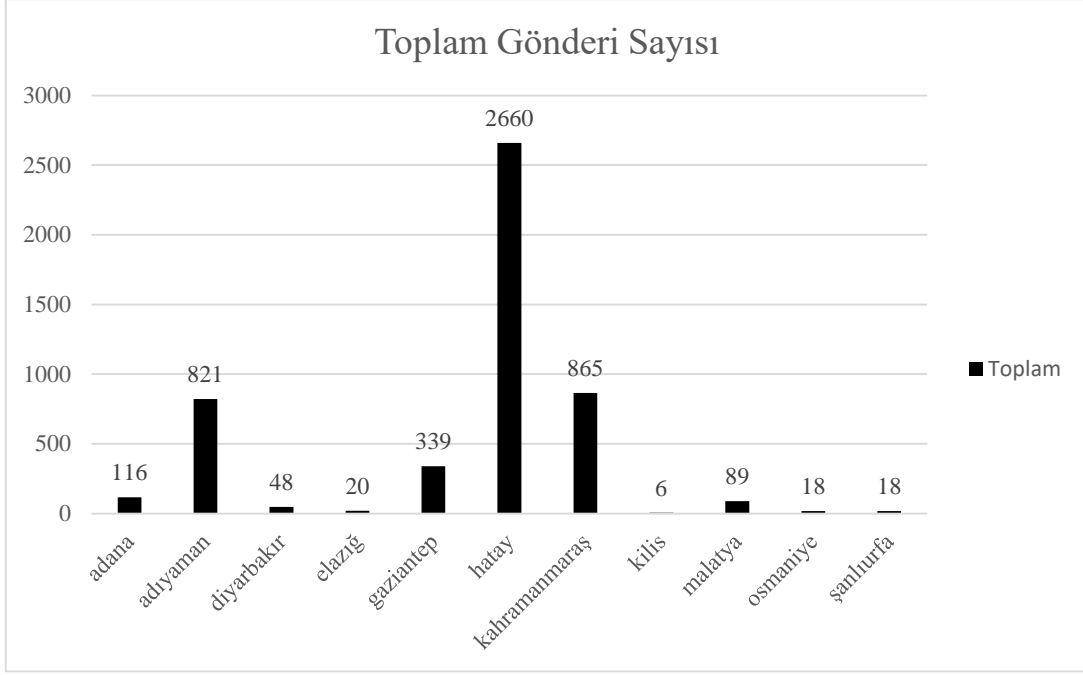
3.4.2. X (eski adıyla Twitter) Gönderileri

X (eski adıyla Twitter), kullanıcıların kısa metin tabanlı içerikler paylaşmasına olanak tanıyan, kamuya açık ve gerçek zamanlı bir sosyal medya platformudur. Bu platformda yapılan paylaşımlar, önceki adıyla "tweet" olarak bilinir ve günümüzde "X gönderisi" olarak adlandırılmaktadır. Her bir gönderi metin, görsel, video veya bağlantı içerebilir ve 280 karakterle sınırlıdır. X gönderileri bireyler, kurumlar, haber ajansları veya resmi makamlar tarafından paylaşılabilir ve içerikleri genellikle herkese açık olacak şekilde yayınlanır. Bu özellikleri sayesinde X, afet gibi ani gelişen olaylar sırasında bilgi paylaşımı ve yardım çağrılarının yayılması açısından önemli bir rol üstlenmektedir.

X platformundan veri elde etmek için genellikle geliştiricilere yönelik sunulan API (Application Programming Interface) hizmeti kullanılır. Geliştiriciler, X Developer Platform üzerinden başvuru yaparak erişim hakkı elde eder. Twitter döneminde bu API hizmeti temel düzeyde ücretsizdi; ancak platform X adını aldıktan sonra bu hizmet büyük ölçüde ücretli hâle gelmiş ve veri erişim sınırları daha katı bir şekilde belirlenmiştir.

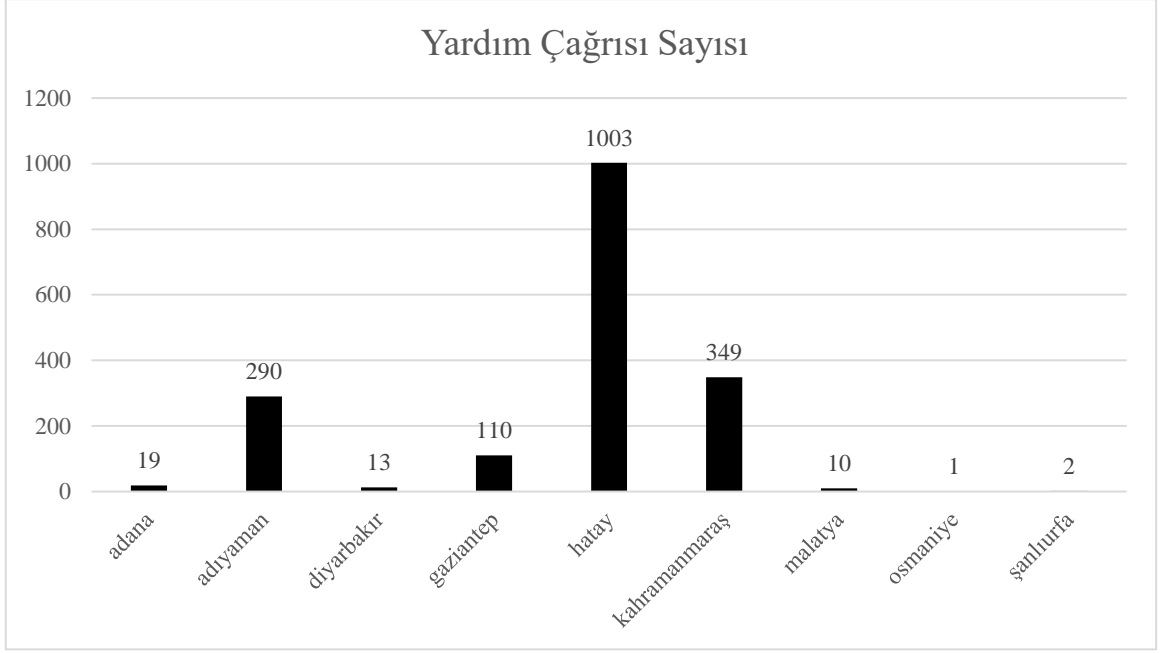
Bu çalışmada kullandığımız X verilerini, Mart 2024'te, o dönemde herkes tarafından erişilebilir durumda olan ve GitHub üzerinde araştırma amaçlı paylaşılmış bir veri kümesinden temin etmekteyiz. Veri seti, bir geliştirici tarafından X (Twitter) API'si aracılığıyla toplanmış olup, 6 Şubat 2023 tarihli depremin ardından depremden etkilenen 11 ilden 6–10 Şubat tarihleri arasında atılan kamuya açık gönderileri içermektedir.

Toplamda 5000 gönderiden oluşan veri seti, gönderilerin metin içeriklerini, gönderilerin atıldığı konum bilgilerini ve zaman damgalarını içermektedir.



Şekil 3.9. 6-10 Şubat 2023 Tarihleri Arasındaki Toplam Gönderi Sayısı

Şekil 3.9.'da afet bölgesindeki illerden 6–10 Şubat 2023 tarihleri arasında toplanan toplam gönderi sayıları yer almaktadır. Bu veriler, doğrudan yardım çağrılarını değil, o şehirlerden gelen tüm paylaşımları kapsamaktadır. En fazla tweetin 2660 ile Hatay'dan, ardından 865 ile Kahramanmaraş ve 821 ile Adıyaman'dan gelmiş olması, bu illerdeki sosyal medya kullanımının yoğunluğunu göstermektedir. Öte yandan Gaziantep (339) ve Adana (116) gibi iller orta düzeyde temsil edilirken, Diyarbakır, Elazığ, Malatya, Osmaniye, Şanlıurfa ve Kilis gibi şehirlerdeki gönderi sayılarının oldukça düşük olduğu görülmektedir. Bu farklar, bölgesel sosyal medya kullanım alışkanlıkları, nüfus yoğunluğu veya internet erişimi düzeyi ve afetin merkez üssüne olan coğrafi uzaklığı gibi çeşitli faktörlerden kaynaklanabileceğini değerlendiriyoruz.



Şekil 3.10. 6-10 Şubat 2023 Tarihleri Arasındaki Toplam Yardım Çağrısı Sayısı

Şekil 3.10.'da afet bölgesindeki illerden atılan ve acil yardım çağrısı içeren gönderi sayıları yer almaktadır. Verilere göre, en fazla yardım çağrısı Hatay'dan (1003 gönderi) yapılmış olup, bu ili sırasıyla Kahramanmaraş (349) ve Adıyaman (290) takip etmektedir. Bu durum, söz konusu illerde hem afetin fiziksel etkisinin hem de yardım talebinin dijital platformlara yansımalarının daha yoğun olduğunu göstermektedir. Gaziantep (110) görece daha az sayıda yardım çağrısıyla temsil edilirken, Adana (19), Diyarbakır (13), Malatya (10), Osmaniye (1) ve Şanlıurfa (2) gibi illerde ise acil yardım gönderi sayıları oldukça sınırlı kalmıştır. Bu farklılıklar hem illerdeki yıkım düzeyini hem sosyal medya kullanım davranışlarını hem de yardım çağrılarının dijital kanallar üzerinden iletilme eğilimlerini yansıtabilir.

Şekil 3.9. ve Şekil 3.10. birlikte değerlendirildiğinde, afet sonrası sosyal medya etkileşimi ile yardım çağrılarının iletilme sıklığı arasında pozitif yönlü bir ilişki olduğunu ortaya koymaktadır. Yani, bir bölgede sosyal medya kullanım yoğunluğu ne kadar fazlaysa, o bölgeden dijital platformlar aracılığıyla yapılan acil yardım çağrılarının sayısı da o oranda artmaktadır. Hatay, Kahramanmaraş ve Adıyaman örneklerinde bu durum açıkça gözlemlenmekte; bu iller hem toplam gönderi sayısı hem de yardım çağrısı içeriği bakımından diğer illere kıyasla belirgin şekilde öne çıkmaktadır. Bu durum, sosyal medyanın kriz anlarında sadece bir iletişim aracı değil, aynı zamanda yardım talebinin doğrudan aktarıldığı bir kanal haline geldiğini göstermektedir. Bu nedenle, afet sonrası

sosyal medya verilerinin hem nicel hem nitel düzeyde analiz edilmesi, müdahale önceliklerinin belirlenmesinde stratejik bir kaynak niteliği taşıdığını değerlendiriyoruz.

3.4.3 Yapısal ve Demografik Veriler

Afetlerin etkisi, yalnızca depremin büyüklüğüne değil, aynı zamanda etkilenen bölgelerin yapısal ve demografik özelliklerine de bağlıdır. Bu nedenle, talep tahmini sürecinde bölgesel farklılıkları dikkate alabilmek adına, ilgili illere ait yapısal ve demografik verileri modele dahil ediyoruz. Bina yaşı, ortalama kat sayısı, hane sayısı, nüfus büyüklüğü ve kişi başına düşen gelir gibi değişkenler hem fiziksel hasarın hem de yardım ihtiyacının düzeyini etkileyebilecek önemli göstergeler sunmaktadır. Çizelge 3.1.'de kullanılan değişkenlerin tanımlarını, veri kaynaklarını ve bu verilerin modelde nasıl temsil edildiğini açıklıyoruz.

Çizelge 3.1. Yapısal ve Demografik Veriler

| Değişken | Değer Aralığı | Açıklama | Veri Kaynağı |
|--|---------------------|--|---|
| Nüfus | (147.919-2.274.106) | Bölgede yaşayan insan sayısını göstermektedir. | TÜİK Adrese Dayalı Nüfus Kayıt Sistemi Sonuçları, 2022 |
| Merkez Üssüne Uzaklık | (34-262) | Bölgenin afet merkezine olan kuş uçuşu uzaklığını km olarak göstermektedir. | Google, Mesafe Ölç, 2024, https://www.google.com/maps |
| Eski Binalarda Oturan Hane Halkı Oranı | (24,08-47,85) | 2000 yılı ve öncesinde inşa edilen binalarda yaşayan hanehalkı oranını göstermektedir. | TÜİK, Bina ve Konut Nitelikleri Araştırması, 2021 |
| Ortalama Kat Sayısı | (3,3-5,9) | Bölgedeki binaların ortalama kat sayılarını ifade etmektedir. | TÜİK, Bina ve Konut Nitelikleri Araştırması, 2021 |
| Kişi Başı Yıllık Ortalama Gelir | (64.415-144.592) | Bölgede yaşayan insanların yıllık ortalama kişi başı gelirlerini ifade etmektedir. | TÜİK İl Bazında Gayrisafi Yurt İçi Hasıla, 2021 |
| Yüzey Alanı | (1412-19242) | Her ilin toplam kara yüzey alanını (km ²) belirtir. | Harita Genel Müdürlüğü, İl ve İlçe Yüz Ölçümleri |

3.5. Performans Metrikleri

Çalışmamızda hem tekli hem de çoklu hedef değişkenler için kapsamlı bir Ridge regresyon modelleme süreci yürüttük. Oluşturulan her bir modelin performansını sistematik biçimde değerlendirmek amacıyla R^2 , Düzeltilmiş R^2 , MSE (Mean Squared

Error), MAE (Mean Absolute Error) ve MAPE (Mean Absolute Percentage Error) kullandık. Chicco vd. (2021) çalışmalarında ifade ettiği üzere;

- R^2 , belirlilik kat sayısı, özniteliklerin hedef değişkendeki toplam değişkenliğin (varyansın) ne kadarını açıkladığını gösteren bir istatistiksel ölçüttür. 0 ile 1 arasında bir değer alır; değeri 1'e yaklaştıkça modelin açıklayıcılık gücü artar.
- Düzeltilmiş R^2 , klasik R^2 'nin öznitelik sayısına göre düzeltilmiş versiyonudur. Çok sayıda öznitelik içeren modellerde, yalnızca anlamlı katkı sağlayan özniteliklerin etkisini ortaya koymak amacıyla kullanılır. Bu metrik, modele gereksiz özniteliklerin eklenmesiyle şişen R^2 değerini telafi eder
- MSE, tahmin edilen ve gerçek değerler arasındaki ortalama kare farklarını ölçer. Ters dönüşüm olmadan, MSE hataları standartlaştırılmış alanda yansır ve anlamlı birimlerde yorumlamayı zorlaştırır.
- MAE, hedef değişkenle aynı birimlerde ortalama tahmin hatasını doğrudan gösterdiği için orijinal ölçekte hesaplandığında daha sezgisel olan ortalama mutlak hatayı temsil eder.
- MAPE, gerçek değerlere göre ortalama yüzde hatasını hesaplar. Bu metrik, gerçek hedef değerlere bölünmeyi içerdiği ve standartlaştırılmış değerler görelî hatayı bozabileceği için orijinal ölçüğü gerektirir.

3.6. Çalışmanın Varsayımları ve Sınırlamaları

Bu çalışmada, afet sonrası bölgesel ve zamansal talep seviyelerinin belirlenmesi amacıyla SWI endeksini geliştirmekte ve bu endeksi kaynak tahsis optimizasyonunda kullanılmaktayız. SWI, afetin ilk günlerinde sosyal medya gönderileri (X platformu) ve Google arama trendlerinden elde edilen dijital sinyaller aracılığıyla oluşturulmakta ve il-gün bazında görelî yardım ihtiyacını yansıtmaktadır.

Çalışmamız, bu dijital sinyallerin doğrudan ölçülemeyen talep düzeylerinin bir göstergesi olarak kullanılabileceği varsayımına dayanmaktadır. Belirli bir gün ve bölgeye ait yüksek SWI değeri, o bölgedeki yardım ihtiyacının sürdüğüne işaret etmektedir. Optimizasyon modelimiz, gözlemlenen SWI değerlerine dayanarak ideal kaynak tahsisini belirlemeyi amaçlamaktadır.

Ancak burada önemli bir sınırlılık söz konusudur: SWI verilerini kullanarak daha etkili bir kaynak tahsisi önerisinde bulunmaktayız; fakat SWI'nın kendisi, geçmişteki

(suboptimal) tahsis kararlarının bir sonucu olabilmektedir. Başka bir deyişle, SWI değerleri doğrudan gözlemlenen yardım çağrılarında ve arama davranışlarından türetilmekte, ancak bu sinyaller geçmiş kaynak gönderimlerinden etkilenmiş olabilmektedir. Örneğin, bir bölgeye yoğun şekilde yardım ulaştırılmışsa, bu durum halkın yardım çağrısında bulunma ihtiyacını azaltarak SWI değerlerini dolaylı biçimde düşürebilmektedir. Dolayısıyla SWI, yalnızca gerçek ihtiyaçları değil, aynı zamanda geçmiş tahsis kararlarının toplumsal yansımalarını da içermektedir.

Bu durum, modelimiz açısından önemli bir metodolojik çelişki doğurmaktadır: Önerdiğimiz tahsis planı geçmişte uygulanmış olsaydı, SWI değerleri muhtemelen farklı bir seyir izlerdi. Bu da modelin müdahalede bulunduğu bir sistemde, sinyalin (SWI'nın) zamansal evriminin değişeceğini göstermektedir. Örneğin, Hatay ili için 6 Şubat'ta yüksek olan SWI değeri, 7 Şubat'ta daha da artış göstermektedir. Bu durum, 6 Şubat'ta yeterli yardım ulaştırılmamış olmasının halkın dijital platformlardaki yardım çağrılarını artırmasına yol açtığını düşündürmektedir. Ancak modelimiz, 6 Şubat'ta Hatay'a yüksek SWI nedeniyle yeterli kaynak gönderimi yapacağını varsaydığından, yardım ihtiyacı ertesi gün azalacak ve 7 Şubat SWI değeri daha düşük seyredecektir. Dolayısıyla önerdiğimiz tahsis planı uygulandığında, takip eden günlerdeki SWI değerleri daha düşük olabilmektedir.

Biz bu çalışmada, mevcut veri yapısı nedeniyle SWI sinyallerini geçmiş tahsisten bağımsızmış gibi ele almaktayız. SWI'nın geçmiş kaynak tahsislerinden etkilenip etkilenmediği elbette önemli bir metodolojik sorudur; ancak bu ilişkinin yönü, büyüklüğü ve tutarlılığı açık biçimde belirlememizi sağlayacak gerçekte kullanılmış tahsis planına dair bir veri bulunmamaktadır. Bu nedenle, SWI verisini doğrudan bir "tahsis sonucu" olarak değil, halkın o andaki yardım ihtiyacına ilişkin algısını yansıtan bir davranışsal gösterge olarak kabul etmekteyiz. Uygulama açısından bu yaklaşım, mevcut veri kısıtları altında rasyonel ve işlevsel bir çözüm sunmaktadır.

Gelecekteki çalışmalar, SWI değerlerini optimize edilen kaynak tahsisiyle birlikte güncelleyebilen iteratif öğrenme yaklaşımlarını içerebilir. Bu sayede talep tahmini ve tahsis kararı eşzamanlı olarak geliştirilebilir. Dijital sinyallerin etkisi zaman içinde yeniden ağırlıklandırılabilir ve model, karar alma sürecine daha entegre bir şekilde katkı sağlayabilir. Bu tür iteratif modelleme yaklaşımlarını hayata geçirebilmek için, kaynak tahsis kararlarının zamansal ve mekânsal detaylarını içeren kapsamlı veri setlerine ihtiyaç duyulmaktadır. Ancak mevcut çalışma kapsamında, hangi tarihte hangi bölgeye ne tür ve

ne miktarda yardım gönderildiğine dair resmi ve bütüncül bir kaynak tahsisi verisi bulunmamaktadır. Bu eksiklik, SWI'nın tahsis sonrası nasıl evirildiğini doğrudan gözlemlemeyi ve dolayısıyla davranışsal sinyallerin tahsis kararları üzerindeki etkisini nedensel düzeyde analiz etmeyi kısıtlamaktadır.

Bu nedenle çalışmamızda, SWI verisini geçmişten bağımsız bir sinyal olarak ele alıyor; ancak bu varsayımın sınırlı geçerliliğe sahip olduğunu da açıkça kabul ediyoruz. Gelecekte sahadan toplanacak kaynak hareketliliği verileriyle zenginleştirilen veri setleri sayesinde bu ilişki daha kapsamlı şekilde analiz edilebilir. Böylece modelin, SWI tepkilerine göre kaynak tahsisi yapması ve tahsisin SWI üzerindeki etkisini gözlemlemesi mümkün hâle gelebilir. Bu da davranışsal verilerle operasyonel kararlar arasında geri besleme döngüsü kuran dinamik karar destek sistemlerinin geliştirilmesine olanak tanıyabilir.

4. SOSYAL WEB İNDEKSİ VE ÖZNETELİK MÜHENDİSLİĞİ

Bu bölümde, çevrimiçi davranış verilerini kullanarak afet bölgelerindeki yardım talebini temsil etmek amacıyla geliştirdiğimiz gösterge olan SWI'nın hesaplama sürecini ve çalışmada kullandığımız diğer öznitelikleri nasıl oluşturduğumuzu açıklıyoruz. SWI, tahmin ve optimizasyon modellerimizin temel bileşeni olup, afet sonrası erken dönemde bölgesel talep düzeylerini yansıtan birleşik bir gösterge niteliği taşımaktadır.

SWI'nin oluşturulması iki temel adımdan oluşur: İlk olarak, X (Twitter) platformundaki gönderileri analiz ederek yardım çağrısı içerip içermediğine göre sınıflandırıyoruz. Bu sınıflandırma, denetimli bir metin madenciliği yaklaşımıyla gerçekleştirilmekte ve yalnızca yardım çağrısı içeren içerikler SWI hesaplamasında dikkate alınmaktadır. İkinci olarak, bu veriler ile Google Trends'ten elde edilen yardım temalı arama popülerlik değerlerini birleştirerek, normalize edilmiş ağırlıklı ortalamalar yardımıyla il ve gün düzeyinde SWI skorlarını hesaplıyoruz.

SWI'nin dışında, model performansını artırmak amacıyla bazı yapısal ve demografik değişkenleri de çeşitli öznitelik mühendisliği teknikleriyle dönüştürüyoruz. Bu kapsamda, verileri kategorilere ayırıyor, oranlar oluşturuyor ve gruplama işlemleri uygulayarak tahmin modeline dahil edilecek açıklayıcı değişkenler geliştiriyoruz.

4.1. Çevrimiçi Davranış Göstergesi: Sosyal Web İndeksi (SWI)

SWI, afet sonrası erken dönemde il bazında yardım talebi yoğunluğunu tahmin etmeyi amaçlayan bileşik bir göstergedir. Bu endeks, mutlak talep değerlerini yansıtmak yerine, farklı bölgelerin birbirine göreceli yardım ihtiyacını ve zaman içindeki değişimini temsil eder. Tezin sonraki iki bölümünde detaylandıracağımız tahmin ve optimizasyon modelleri, bu endeks üzerine kuruludur. Modelde, ilk gün elde edilen SWI değerleri ve diğer öznitelikler kullanılarak, sonraki günlerin SWI değerleri tahmin edilmekte; bu tahminler doğrultusunda, beşinci bölümde kaynak tahsisi optimizasyonu gerçekleştirilmektedir. Tahmin modeli bölümünde, SWI'nın ilk gün değerlerini ve çeşitli demografik ile yapısal öznitelikleri kullanarak sonraki günlerin SWI değerlerini tahmin etmekteyiz. Böylece, afetin ilk saatlerinde elde edilen çevrimiçi davranış verilerinden yola çıkarak, zamanla değişen yardım talebi yoğunlukları tahmin edilmektedir. Optimizasyon modeli bölümünde ise, tahmin edilen bu SWI değerlerini bölgesel talep göstergeleri olarak kullanıyoruz. Geliştirdiğimiz ağ akışı temelli optimizasyon modeli, farklı türdeki kaynakların (arama-kurtarma, sağlık, lojistik) farklı merkezlerden, dört

günlük kritik zaman diliminde, bu tahmini talep seviyelerine göre en uygun şekilde afet bölgelerine yönlendirilmesini sağlamaktadır. Böylece, sınırlı kaynakların zamanında ve etkili biçimde tahsisi mümkün hâle gelmektedir.

SWI hesaplama sürecinde, öncelikle X (eski adıyla Twitter) gönderilerini acil yardım çağrısı içerip içermediğine göre sınıflandırıyoruz. Ardından, bu sınıflandırılmış gönderi verilerini ve Google Trends üzerinden elde edilen yardım temalı arama popülerlik değerlerini bir araya getiriyoruz. Her iki kaynaktan gelen bilgiyi normalize ederek, ağırlıklı ortalama yöntemiyle il ve gün düzeyinde SWI değerlerini oluşturuyoruz.

Aşağıda, afet sonrası yardım talebini temsil eden SWI'nin hesaplanmasına yönelik geliştirdiğimiz algoritmayı sunuyoruz. SWI algoritması; X gönderilerinin sınıflandırılması, Google Trends verilerinin işlenmesi ve her iki kaynağın normalize edilerek ağırlıklı biçimde birleştirilmesi olmak üzere üç ana adımdan oluşmaktadır. Algoritmada kullanılan değişken ve notasyonların tanımları Çizelge 3.2.'de verilmiştir.

Çizelge 3.2. SWI Algoritması İçin Değişken ve Notasyonlar

| Parametre | Açıklama |
|--------------|--|
| T | Zaman periyodu (örneğin, 6-10 Şubat 2023) |
| I | Afetten etkilenen iller kümesi |
| K | Google arama anahtar kelimeler seti |
| $\chi_{i,t}$ | İl i 'de, gün t 'de yardım çağrısı içerdiği tahmin edilen X gönderi sayısı |
| $g_{i,t}^k$ | İl i 'de, gün t 'de, anahtar kelime k için Google Trends skoru |
| w_χ | SWI hesaplamasında sınıflandırılmış X gönderilerinin normalize katkı ağırlığı |
| w_g | SWI hesaplamasında normalize edilmiş Google Trends skorlarının ağırlığı |

SWI Hesaplama Algoritması

Adım 1: X Gönderilerinin Sınıflandırılması

1.1. Gönderilere metin temizleme işlemi uygulanır (noktalama, küçük harf, özel karakter temizliği).

1.2. Rastgele seçilen bir alt küme manuel olarak etiketlenir:

- Yardım çağrısı içeriyorsa: 1
- İçermiyorsa: 0

1.3. Bu etiketli veriyle denetimli bir sınıflandırma modeli (ör. BERT) eğitilir.

1.4. Model, kalan gönderilere uygulanır ve tüm gönderiler otomatik olarak sınıflandırılır.

1.5. Her il $i \in I$ ve gün $t \in T$ için yardım çağrısı olarak tahmin edilen gönderi sayısı $\chi_{i,t}$ hesaplanır.

Adım 2: Google Trends Verilerinin İşlenmesi

2.1. Her il $i \in I$, gün $t \in T$ ve anahtar kelime $k \in K$ için Google Trends skorları elde edilir:

2.2. Her il $i \in I$ ve gün $t \in T$ için anahtar kelimelere ait skorların toplamı alınarak toplam Google Trend popülerlik skoru ($g_{i,t}$) Denklem 1 ile hesaplanır:

$$g_{i,t} = \sum_{k \in K} g_{i,t}^k \quad (1)$$

Adım 3: Normalizasyon ve SWI Hesaplama

3.1. $\chi_{i,t}$ ve $g_{i,t}$ değerleri tüm il ve günler boyunca min-max ölçeklendirme ile normalize edilir. Her il $i \in I$ ve gün $t \in T$ için, normalize edilmiş X gönderi sayıları ve $\bar{\chi}_{i,t}$ ve Google Trend popülerlik skoru $\bar{g}_{i,t}$, sırasıyla Denklem 2 ve 3 ile hesaplanır:

$$\bar{\chi}_{i,t} = \frac{\chi_{i,t} - \min_{i \in I, t \in T}(\chi_{i,t})}{\max_{i \in I, t \in T}(\chi_{i,t}) - \min_{i \in I, t \in T}(\chi_{i,t})} \quad (2)$$

$$\bar{g}_{i,t} = \frac{g_{i,t} - \min_{i \in I, t \in T}(g_{i,t})}{\max_{i \in I, t \in T}(g_{i,t}) - \min_{i \in I, t \in T}(g_{i,t})} \quad (3)$$

3.2. Her il $i \in I$ ve gün $t \in T$ için, normalize edilmiş değerler, sabit ağırlık katsayılarıyla birleştirilerek SWI değeri Denklem 4'te gösterildiği şekilde hesaplanır:

$$SWI_{i,t} = w_\chi \cdot \bar{\chi}_{i,t} + w_g \cdot \bar{g}_{i,t}, \text{ burada } w_\chi + w_g = 1 \quad (4)$$

Sunmakta olduğumuz SWI algoritmamız üç temel adım sonunda afet sonrası erken dönemde illerin görece yardım talep düzeylerini yansıtmak amacıyla geliştirdiğimiz bileşik bir gösterge olan SWI değerlerini hesaplamaktadır.

Birinci adımda, X platformundan elde edilen gönderileri, yardım çağrısı içerip içermediklerine göre sınıflandırıyoruz. Bu amaçla, gönderi metinleri üzerinde ön işleme ve etiketleme işlemleri gerçekleştiriyor; ardından bu verilerle eğittiğimiz denetimli bir sınıflandırma modeli kullanarak tüm veri kümesinde yardım içerikli gönderileri tespit

ediyoruz. Her il ve gün için yardım çağrısı içeren gönderi sayısı sayılarak $\chi_{i,t}$ değeri elde ediliyor.

İkinci adımda, Google Trends üzerinden 6 anahtar kelimeye (ör. “deprem”, “yardım”, “acil”, “enkaz”, “AFAD”, “kızılay”) ilişkin olarak, her il ve gün bazında arama popülerliği skorları toplanarak toplam Google Trend popülerlik skoru $g_{i,t}$ hesaplanıyor (Denklem 1).

Üçüncü adımda $\chi_{i,t}$ ve $g_{i,t}$ değerleri tüm iller ve günler için min-max normalizasyonuna tabi tutuluyor (Denklem 2 ve 3). Normalize edilmiş bu iki bileşen, sabit ağırlıklarla birleştirilerek SWI değeri elde ediliyor (Denklem 4). Bu bileşik gösterge, illerin gün bazındaki görelî yardım talebini ifade ediyor.

SWI değeri, acil yardım tweet sayısı ile Google Trend popülerlik değerinin ağırlıklı ortalaması alınarak hesaplanmaktadır. Ağırlıklı toplam yöntemi, genellikle toplanan değişkenlerin bağımsız olduğu durumlarda uygun bir yaklaşım sunmaktadır. Ancak, değişkenlerin bağımlı olduğu durumlarda geometrik toplama gibi alternatif yöntemlerin daha anlamlı olabileceği değerlendirilmektedir. Genel olarak, Google Trend popülerlik değeri bilgi arama davranışıyla yönlendirilen arama etkinliklerini temsil ederken, acil yardım tweet sayıları sosyal etkileşimleri ve söylemleri yansıtmaktadır. Bu çalışmada, Google Trend Popülerlik değeri ile acil yardım tweet sayısı arasındaki korelasyon katsayısı 0,22 olarak hesaplanmış olup, bu durum iki değişken arasında zayıf bir pozitif korelasyona işaret etmektedir. Bu nedenle, SWI değerinin hesaplanmasında bu iki değişkenin birleştirilmesi esnasında ağırlıklı toplam yöntemini kullanmaktayız. Elde ettiğimiz nihai SWI, afet dönemlerinde toplumsal ilgi ve davranışların daha bütüncül bir şekilde analiz edilmesini sağlamaktadır.

Aşağıdaki alt başlıklarda, **Adım 1** kapsamında X gönderilerini yardım çağrısı içerip içermediklerine göre sınıflandırmak için uyguladığımız yöntemleri ve bu doğrultuda oluşan $\chi_{i,t}$ değerlerini sunuyoruz. Ardından, **Adım 2** kapsamında Google Trends verilerini kullanarak her il ve gün için popülerlik skorlarını hesaplama sürecini ve elde ettiğimiz bütünlük $g_{i,t}$ değerlerini raporluyoruz.

4.1.1. Yardım Talebi İçeren X Gönderilerinin Elde Edilmesi

Elimizdeki X veri seti, 6 Şubat 2023 Kahramanmaraş merkezli depremin ardından, afet bölgesindeki 11 ilden 6-10 Şubat 2023 tarihlerinde atılan X gönderilerini içermektedir. Ancak bu gönderilerin tamamı doğrudan yardım çağrısı içermemektedir. Örneğin:

“kahramanmaraş türkoğlu ilçesi şekeroba mahallesi birkaç yardım tırı gitmiş fakat çevredekilere yeter...”

“yayalım lütfen arkadaşlar adıyaman besnideyim elimizde 4 tıra yakın malzeme erzak var. ulaştırmak istediğiniz kimsel...”

gibi gönderiler bilgi verici veya duygusal içerikli olabilirken, doğrudan bir yardım talebini ifade etmemektedir. Buna karşın:

“kahramanmaraş 12 şubat şazibey mahallesi azerbaycan bulvarı sevde apt no:122 akrabalarım enkaz altında lütfen yardım edin kac...”

“azerbaycan blv. 100b 46040 onikişubat kahramanmaraş serap apartmanı piazza avm civarı enkaz altında yakınımız var yardım...”

gibi gönderiler ise açık biçimde yardım çağrısı içermektedir ve bu tür içerikler, afet sonrası kaynak tahsisi açısından doğrudan anlam taşır.

Bu nedenle, gönderileri anlamlı biçimde ayrıştırabilmek adına denetimli bir metin sınıflandırma yaklaşımı benimsiyoruz. İlk olarak, tüm gönderilere temel metin ön işleme (temizleme) işlemleri uyguluyoruz. Ardından, rastgele seçtiğimiz bir alt kümedeki gönderileri manuel olarak etiketliyoruz: yardım çağrısı içerenler “1”, içermeyenler “0” etiketiyle işaretleniyor. Bu etiketli veri, bir sınıflandırma modeli eğitmek için kullanılıyor ve kalan tüm gönderiler bu model yardımıyla otomatik olarak sınıflandırılıyor. Böylece, sadece gerçekten yardım talebi barındıran içerikleri sonraki analizlerde kullanarak daha doğru ve güvenilir bir talep tahmin süreci yürütüyoruz.

Tüm gönderileri manuel olarak inceleyip yardım çağrısı içerip içermediğini belirlemek, teorik olarak mümkün görünse de çeşitli nedenlerle bu yaklaşımı tercih etmemekteyiz. Öncelikle, manuel sınıflandırma süreci zaman alıcı ve hataya açık bir işlemdir; özellikle içerik bağlamının yorumlanması subjektiflik barındırabilir ve tutarlılığı zorlayabilir. Burada yalnızca anahtar kelimelere dayalı bir filtreleme yaklaşımının yeterli olmadığını vurgulamak gerekir. İçerik bağlamı ve dilin nüansları, sadece kelime bazlı filtrelerle yakalanamayabilir. Bu nedenle, dilin bağlamını öğrenebilen ve anlamsal ayrımları

dikkate alan bir sınıflandırma modeli, SWI hesaplaması için daha güvenilir ve sistematik bir temel sunmaktadır. Ayrıca, bu tür bir yaklaşımın ölçeklenebilirliği sınırlıdır; farklı zaman dilimlerinde veya veri setlerinde aynı işlemin tekrarlanması pratik değildir. Bu nedenle, etiketli örneklem üzerinde eğittiğimiz denetimli bir sınıflandırma modelini kullanarak tüm veri seti üzerinde sistematik, tutarlı ve tekrarlanabilir bir sınıflandırma yapılmasını tercih etmekteyiz. Bu sayede hem işlem verimliliği sağlamakta hem de ileride benzer veri kümelerine uygulanabilir bir yöntem sunmaktayız.

Veri setimizi, acil yardım çağrısı içeren gönderiler ve acil yardım çağrısı içermeyen gönderiler olmak üzere iki sınıfa ayırıyoruz. Afet bölgesinden atılan gönderilerin acil yardım çağrısı içerip içermediğini belirlemeye yönelik sınıflandırma sürecinde kapsamlı bir ön işlem gerçekleştiriyoruz. Bu süreçte noktalama işaretleri, özel karakterler ve kullanıcı etiketleri vb. gibi anlam taşımayan unsurları temizledik; tüm metinler küçük harfe dönüştürülerek büyük/küçük harf duyarlılığına bağlı anlamsal farklılıkların önüne geçtik. Bu ön işlem adımlarının ardından hem geleneksel makine öğrenmesi algoritmalarını hem de BERT tabanlı bir dil modeli kullanarak performans karşılaştırması yapıyoruz. Geleneksel yöntemler olarak SVM yüksek genelleme yetenekleri sayesinde birçok metin sınıflandırma probleminde yaygın biçimde kullanılmakta olup, afet sonrası sosyal medya verilerinin analizinde de bu yöntemden faydalanılmaktadır ancak SVM modellerinin önemli sınırlılıkları bulunmaktadır; özellikle parametre seçiminin karmaşıklığı, algoritmik yapıların yüksek hesaplama maliyeti ve dengesiz veri kümelerinde doğruluk oranlarının belirgin biçimde düşmesi dikkat çekmektedir (Cervantes vd. , 2020). Model parametrelerinin istatistiksel olarak yorumlanabilirliği ve kullanım kolaylığı ile tercih edilen bir diğer yöntem olan Lojistik Regresyon (Dreiseitl & Ohno-Machado, 2002) ve çok sayıda giriş değişkeniyle çalışabilmesi, önemli değişkenleri önerebilmesi ve büyük veri kümelerinde verimli çalışması ise Rasgele Orman (Shah vd. , 2020) algoritmasını öne çıkaran başlıca özelliklerdendir. Bu geleneksel yöntemlerin ötesine geçerek bağlamsal anlam ilişkilerini daha derinlemesine yakalayabilen BERT modeli ise 2018 yılında Google AI tarafından geliştirilmiş bir dil modelidir yöntemdir (Devlin, 2018). Bu dil modeli kelimelerin bağlamını yalnızca tek yönlü (örneğin, soldan sağa ya da sağdan sola) ele alan geleneksel yöntemlerin aksine, kelimenin hem öncesindeki hem de sonrasındaki bağlamı dikkate alarak iki yönlü bir anlam çıkarımı yapmaktadır. Bu çift yönlü bağlamsal anlama yeteneği, metin içerisindeki sözcüklerin taşıdığı anlamları daha derin bir şekilde analiz etmeyi sağlamaktadır.

Dolayısıyla, BERT'in bu üstün bağlamsal anlama yeteneği, özellikle karmaşık dil yapıları içeren metinlerde sınıflandırma performansını artırmakta ve geleneksel yöntemlere kıyasla daha etkili sonuçlar elde edilmesine olanak tanımaktadır. Bu sebeplerle, sınıflandırma işlemi için BERT dil modelini kullanılmaktadır. Bu çalışma kapsamında gerçekleştirilen sınıflandırma sürecini, Python programlama dili kullanılarak Google Colab platformu üzerinde gerçekleştirmekteyiz. Google Colab, Python diline entegre edilmiş kullanıcı dostu bir arayüz sunmakta ve özellikle derin öğrenme uygulamaları için gerekli olan GPU (Graphics Processing Unit) desteğini sağlamaktadır. Bu yönüyle, yüksek hesaplama gücü gerektiren BERT modeli için gerekli donanımı kullanılmaktadır.

Çalışmada kullandığımız veri seti, afet sonrası sosyal medya paylaşımlarından oluşan 5000 adet X gönderisinden oluşmakta ve her bir gönderi manuel olarak "yardım çağrısı içeriyor" veya "içermiyor" şeklinde etiketlenmiştir. Veri, model başarımını değerlendirmeye olanak sağlayacak şekilde üçe ayrılmıştır: öncelikle verinin %70'i eğitim ve %30'u test olarak ayrılmış; ardından eğitim verisinin %20'si doğrulama amacıyla ayrılarak modelin hiperparametre optimizasyonu gerçekleştirdik. Eğitim süreci, BERT dil modelinin bağlamsal anlam öğrenimi için gereken yüksek hesaplama gücü nedeniyle yaklaşık 2,5 saat sürmüştür; süreç sonunda doğruluk ve F1-score gibi performans metrikleri, modelin sınıflandırma görevini yüksek başarıyla gerçekleştirdiğini göstermiştir.

Yapılan deneyler sonucunda elde edilen performans sonuçları Çizelge 4.1'de sunulmuştur. Sınıflandırma modelimizin başarımını değerlendirmek için iki temel performans ölçütü kullanıyoruz: doğruluk oranı (accuracy) ve F1 skoru. Doğruluk oranı, modelin tüm tahminleri içinde doğru yaptığı tahminlerin oranını gösterir. Ancak bu oran, özellikle dengesiz veri setlerinde (örneğin yardım çağrısı içeren gönderilerin sayısı azsa) yanıltıcı olabilir. Bu nedenle, modelin yardım çağrısı içeren gönderileri ne kadar doğru tespit ettiğini daha doğru değerlendirebilmek için F1 skoru da kullanıyoruz. F1 skoru, hassasiyet (modelin "yardım çağrısı" dediği gönderilerden gerçekten bu özelliği taşıyanların oranı) ve duyarlılık (gerçek yardım çağrısı içeriklerden modelin doğru tespit ettiklerinin oranı) metriklerinin dengeli bir birleşimidir. Bu sayede, modelin hem isabetli hem de kapsamlı tahmin yapma yeteneğini yansıtarak dengeli bir performans değerlendirmesi sağlar.

Çizelge 4.1.'de görüldüğü üzere, geleneksel yöntemlerin doğruluk oranları %82 ile %85 arasında değişmekte olup, F1-score değerleri en fazla %78 seviyesindedir. Bu durum, söz

konusu modellerin genel başarıyı kabul edilebilir düzeyde sağladığını, ancak acil yardım çağrısı gibi sınıf 1'e ait duyarlı içerikleri tespit etmede sınırlı kalabildiğini göstermektedir. Özellikle SVM modelinde gözlemlenen %74'lük F1-score değeri, bu tür karmaşık ve bağlama duyarlı metinlerde geleneksel yöntemlerin yeterince etkin olamayabileceğini ortaya koymaktadır. Öte yandan, BERT tabanlı önceden eğitilmiş bir dil modeli kullanılarak gerçekleştirilen sınıflandırmada, test verisi üzerinde %86 doğruluk oranı, ile %85 F1-score elde edilmiştir. BERT dil modeli büyük hacimli metin verileri üzerinde önceden eğitildiği için dilin yapısını, kelimeler arası ilişkileri ve bağlamsal anlamları öğrenmiş durumdadır. Örneğin, “yardım edin” ifadesinin genellikle acil durumlarla ilişkili olduğunu zaten kavrayabilmektedir ancak bu genel dil bilgisi, özel görevler için yeterli olmayabileceğinden, model üzerinde ince ayar (fine-tuning) işlemi uyguladık. Bu sayede modelimiz bağlamsal bilgiyi öğrenme ve cümle içindeki anlam ilişkilerini yakalama konusunda yüksek bir performans sergiledi. Özellikle dilsel olarak karmaşık ve kısa mesajlar içeren sosyal medya verilerinde, BERT'in kelimeleri sadece tekil anlamlarıyla değil, içinde buldukları bağlama göre işleyebilmesi, sınıflandırma performansını anlamlı biçimde artırmaktadır. BERT modelinin, özellikle acil yardım çağrısı gibi gerçek müdahale gerektiren içeriklerin doğru biçimde ayrıştırılmasında sağladığı yüksek performans, onu geleneksel yöntemlere kıyasla daha güvenilir ve tercih edilebilir hale getirmektedir.

Çizelge 4.1. Sınıflandırma Modellerinin Performansları

| Geleneksel Sınıflandırma Yöntemleri İle Sınıflandırma | | |
|--|-----------------|-----------------|
| Model | Doğruluk | F1-Score |
| Destek Vektör Makineleri | 0,82 | 0,74 |
| Rasgele Orman | 0,84 | 0,78 |
| Lojistik Regresyon | 0,85 | 0,78 |
| BERT Dil Modeli İle Sınıflandırma | | |
| Model | Doğruluk | F1-Score |
| BERT | 0,86 | 0,85 |

Sonuç olarak, afet bölgesinden atılan gönderileri sınıflandırmak için BERT tabanlı bir model kullanarak, her bir tweetin yardım çağrısı içerip içermediğini belirlemekteyiz.

Bu sınıflandırma sonucunda elde ettiğimiz, her il $i \in I$ ve gün $t \in T$ için yardım çağrısı olarak tahmin edilen gönderi sayılarını ($\chi_{i,t}$) Çizelge 4.2.'de sunuyoruz.

Çizelge 4. 2. Tahmin Edilen Acil Yardım Gönderi Sayısı

| İl | 6 Şubat | 7 Şubat | 8 Şubat | 9 Şubat | 10 Şubat |
|---------------|---------|---------|---------|---------|----------|
| Adana | 11 | 12 | 7 | 9 | 1 |
| Adıyaman | 61 | 57 | 30 | 24 | 18 |
| Diyarbakır | 0 | 2 | 4 | 0 | 3 |
| Elazığ | 0 | 0 | 0 | 0 | 0 |
| Gaziantep | 24 | 28 | 32 | 22 | 16 |
| Hatay | 228 | 187 | 158 | 116 | 81 |
| Kahramanmaraş | 61 | 71 | 60 | 42 | 25 |
| Kilis | 0 | 0 | 0 | 0 | 0 |
| Malatya | 9 | 18 | 8 | 10 | 7 |
| Osmaniye | 0 | 2 | 0 | 2 | 2 |
| Şanlıurfa | 0 | 0 | 1 | 0 | 2 |

4.1.2. Google Trend Popülerlik Değerlerinin Elde Edilmesi

Önceki bölümlerde anlatıldığı üzere afet sonrası acil yardım talebini modelleyebilmek amacıyla, Google Trends verileri kullanılarak afet bölgesinin çevrim içi arama davranışı analiz edilmiştir.

Afetle doğrudan ilişkili olan “deprem”, “acil”, “enkaz”, “AFAD” ve “Kızılay” anahtar kelimeleri seçilmiştir. Belirlenen kelimelerin, 11 afet bölgesinde 6-10 Şubat 2023 tarihleri arasındaki günlük arama popülerlik değerleri elde edilmiştir. Google Trends tarafından sağlanan bu veriler, her bölge ve tarih için bir görelî arama ilgisini temsil etmektedir. Ardından, bu değerler algoritmamızın Adım 2.2 ve 3.1. aşamalarında, sırasıyla toplama ve normalize edilme süreçlerine tabi tutulmakta ve böylelikle skorların tüm bölgeler arasında karşılaştırılabilir hale getirilmesi amaçlanmaktadır. Her il $i \in I$ ve gün $t \in T$ elde ettiğimiz bütünleşik Google Trend popülerlik skorlarını ($g_{i,t}$) Çizelge 4.3.’te sunuyoruz:

Çizelge 4.3. Google Trend Popülerlik Skorları

| İl | 6 Şubat | 7 Şubat | 8 Şubat | 9 Şubat | 10 Şubat |
|------------|---------|---------|---------|---------|----------|
| Adana | 301 | 294 | 302 | 273 | 322 |
| Adıyaman | 288 | 192 | 282 | 167 | 327 |
| Diyarbakır | 269 | 273 | 298 | 307 | 327 |
| Elazığ | 252 | 271 | 284 | 245 | 271 |
| Gaziantep | 293 | 299 | 300 | 340 | 373 |
| Hatay | 307 | 265 | 327 | 249 | 397 |

| İl | 6 Şubat | 7 Şubat | 8 Şubat | 9 Şubat | 10 Şubat |
|---------------|----------------|----------------|----------------|----------------|-----------------|
| Kahramanmaraş | 359 | 269 | 429 | 250 | 331 |
| Kilis | 130 | 147 | 178 | 178 | 234 |
| Malatya | 301 | 374 | 265 | 279 | 342 |
| Osmaniye | 287 | 191 | 193 | 264 | 250 |
| Şanlıurfa | 251 | 265 | 293 | 262 | 268 |

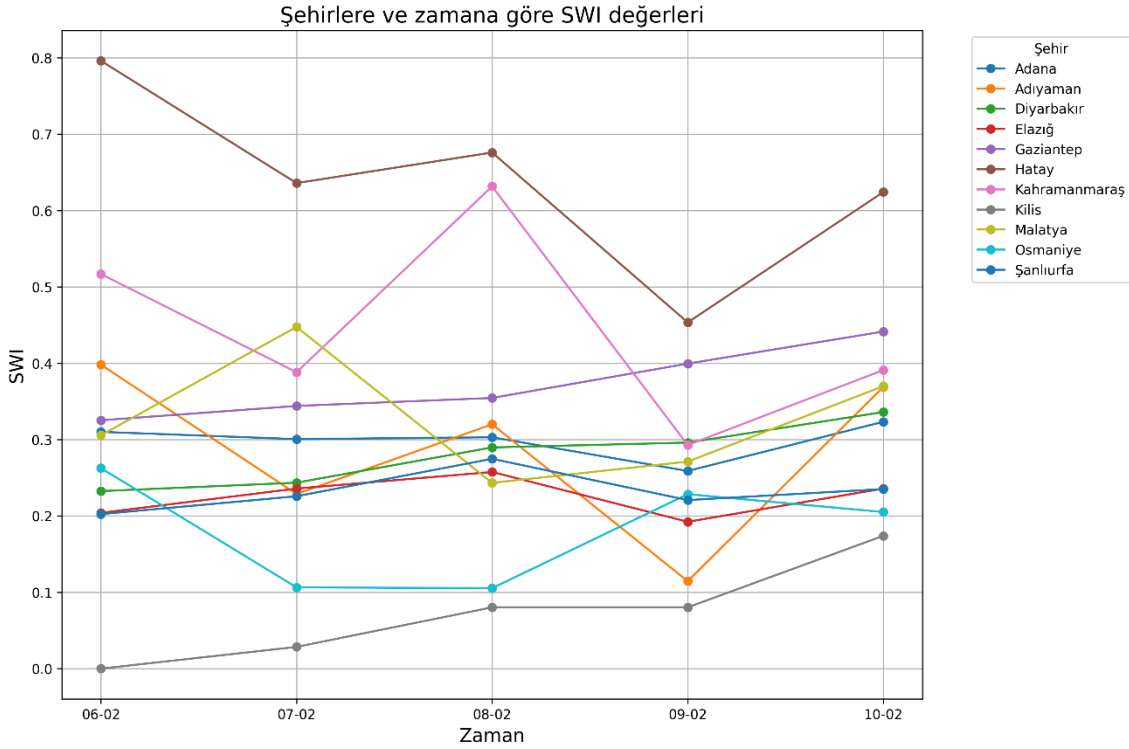
4.1.3. SWI Sonuçları

Her il $i \in I$ ve gün $t \in T$ için elde ettiğimiz ve sonraki ana bölümlerde anlatacağımız tahmin ve optimizasyon algoritmalarımızda kullandığımız $SWI_{i,t}$ değerlerini Çizelge 4.4.'te sunmaktayız.

Çizelge 4.4. SWI Değerleri

| İl | 6 Şubat | 7 Şubat | 8 Şubat | 9 Şubat | 10 Şubat |
|---------------|----------------|----------------|----------------|----------------|-----------------|
| Adana | 0,31 | 0,30 | 0,30 | 0,26 | 0,32 |
| Adıyaman | 0,4 | 0,23 | 0,32 | 0,11 | 0,37 |
| Diyarbakır | 0,23 | 0,24 | 0,29 | 0,3 | 0,34 |
| Elazığ | 0,2 | 0,24 | 0,26 | 0,19 | 0,24 |
| Gaziantep | 0,33 | 0,34 | 0,35 | 0,4 | 0,44 |
| Hatay | 0,80 | 0,64 | 0,68 | 0,45 | 0,62 |
| Kahramanmaraş | 0,52 | 0,39 | 0,63 | 0,29 | 0,39 |
| Kilis | 0 | 0,03 | 0,08 | 0,08 | 0,17 |
| Malatya | 0,31 | 0,45 | 0,24 | 0,27 | 0,37 |
| Osmaniye | 0,26 | 0,11 | 0,11 | 0,23 | 0,21 |
| Şanlıurfa | 0,2 | 0,23 | 0,27 | 0,22 | 0,24 |

Zaman içerisinde şehirlerin sahip olduğu SWI değerleri Şekil 4.1.'de gösterilmiştir.



Şekil 4.1. Şehirlerin SWI Değerlerinin Zaman İçerisindeki Değişimi

Grafikte, 6-10 Şubat 2023 tarihleri arasında illere göre SWI değerlerinin zaman içerisindeki değişimi gösterilmektedir. SWI, Google Trends ve sosyal medya verilerinin birleştirilmesiyle oluşturulmuş olup, afet sonrası dijital yardım talebini temsil etmektedir. Grafik genelinde, Hatay her gün en yüksek SWI değerlerine sahip şehir olarak öne çıkarken, bu ili Kahramanmaraş takip etmektedir; bu durum, her iki ilin de hem toplumsal ilginin hem de yardım çağrılarının yoğunlaştığı bölgeler olduğunu göstermektedir. Adıyaman'da başlangıçta yüksek olan değerlerin ortalarda düşüp yeniden artması, zaman içinde değişen yardım ihtiyacı ya da dijital etkileşim yoğunluğunu yansıtabilir. Osmaniye'de ise ilk günlerde düşük seviyede olan SWI değerleri gün geçtikçe artarak dijital yardım talebinin sonradan ivme kazandığını göstermektedir. Gaziantep, Diyarbakır ve Şanlıurfa gibi bazı illerde ise SWI değerlerinin daha stabil seyretmesi, yardım talebinin bu bölgelerde görece sabit kaldığına işaret etmektedir. Genel olarak grafik, afetin ardından dijital platformlarda ifade edilen yardım talebinin hem zamana hem de coğrafi konuma bağlı olarak farklılık gösterdiğini ve SWI endeksinin bu eğilimleri başarıyla yansıttığını ortaya koymaktadır.

4.2. Öznitelik Mühendisliği ile Yeni Demografik ve Yapısal Öznitelikler

Bu bölümde, tahmin modelimizi desteklemek amacıyla gerçekleştirdiğimiz diğer öznitelik mühendisliği adımlarını açıklıyoruz. Modelleme sürecinde, yalnızca mevcut ham verilerle yetinmek yerine, bu verilerin dönüştürülmesiyle elde edilen yeni değişkenleri de modele dahil ediyoruz. Özellikle yapısal ve demografik değişkenlerden —örneğin nüfus, bina yaşı, yüzey alanı, kişi başına gelir gibi— elde edilen yeni özniteliklerin, afet sonrası yardım talebini doğrudan açıklamak yerine, bu süreci daha iyi anlamamıza yardımcı olabileceğine inanıyoruz. Örneğin, nüfus ve yüzey alanı ayrı ayrı sınırlı bilgi sunarken, yüzey alanı başına düşen nüfus gibi bir oran, bir bölgedeki yapılaşma yoğunluğu hakkında daha anlamlı bir gösterge sunabilir. Bu bölümde, bu tür öznitelikleri üretmek için uyguladığımız kategorileştirme, oran hesaplama ve gruplama gibi dönüşümleri açıklıyoruz. Öznitelik mühendisliği ile elde ettiğimiz yeni yapısal ve demografik öznitelikler aşağıdaki Çizelge 4.5’te sunulmaktadır.

Çizelge 4.5. Öznitelik Mühendisliği ile Elde Edilen Değişkenler

| Değişken | Formül | Değer | Açıklama |
|----------------------------|--|------------------------|---|
| Nüfus Yoğunluğu | $\frac{\text{Nüfus}}{\text{Yüzey Alanı}}$ | (63,03-316,63) | Bir bölgedeki nüfus yoğunluğunu belirleyen temel gösterge olup, kentleşme ve mekânsal dağılım analizlerinde kullanılır. |
| Bina Yoğunluğu | $\frac{\text{Nüfus Ortalama Kat Sayısı}}{\text{Kat}}$ | (39.978,09-586.516,05) | Kişi başına düşen ortalama bina kat sayısını gösterir, konut yoğunluğu ve yapı stoku analizleri için önemlidir. |
| Deprem Risk İndeksi | $\frac{\text{Eski Binalarda Oturan Hane Halkı Oranı}}{\text{Ortalama Kat Sayısı}}$ | (5,61- 12,80) | Eski yapı stoğundaki hane halkı oranının kat sayısına göre hesaplanmasıyla elde edilen, deprem riski değerlendirmesinde kullanılan bir göstergedir. |
| Ekonomik Esneklik | $\frac{\text{Kişi Başı Yıllık Ortalama Gelir}}{\text{Nüfus}}$ | (0,029-0,801) | Kişi başına düşen gelirin ekonomik refah düzeyini ölçen göstergesidir, gelir dağılımı analizlerinde kullanılır. |
| Gelir Yoğunluğu Kat Sayısı | $\frac{\text{Nüfus / Kişi Başı Yıllık Ortalama Gelir}}{\text{Kat}}$ | (1,24- 33,68) | Ekonomik refahın ters göstergesi olup, yüksek değerler düşük refaha işaret eder. |
| -Yapısal Risk Oranı | $\frac{\text{Merkez Üssüne Uzaklık}}{\text{Ortalama Kat Sayısı}}$ | (7,72- 49,76) | Yapıların kat sayısına göre deprem merkez üssüne uzaklığını gösteren bir metriktir, afet yönetiminde kullanılır. |
| Gelir Yoğunluk Katsayısı | $\frac{\text{Kişi Başı Yıllık Ortalama Gelir}}{\text{Yüzey Alanı}}$ | (3,34- 83,93) | Bölgesel gelir yoğunluğunu ölçer, ekonomik gelişmişlik ve mekânsal dağılım analizlerinde kullanılır. |

| Değişken | Formül | Değer | Açıklama |
|---------------------|--|-----------------|--|
| Eski Bina Yoğunluğu | Eski Binalarda Oturan Hane Halkı Oranı / Yüzey Alanı | (0,0012-0,0232) | Eski yapı stoğunun bölgesel yoğunluğunu gösterir, kentsel dönüşüm planlamasında değerlendirilir. |

Yukarıdaki Çizelge 4.5.'te sunulan değişkenleri de ekledikten sonra elde ettiğimiz 14 adet özneteliğe matematiksel dönüşümler uygulayarak yeni öznetelikler oluşturmaktayız. Bu dönüşümler içerisinde, logaritmik, karekök, ters dönüşüm (inverse transform), kare (squared term) ve küp (cubed term) dönüşümler yer almaktadır. Sonrasında sırasıyla ikili ve üçlü etkileşim özellikleri yaratarak veri setimize eklemekteyiz. Bunlar Çizelge 4.6.'ta sunulmaktadır.

Çizelge 4.6. İkili ve Üçlü Etkileşimler ile Elde Edilen Değişkenler

| Etkileşim | Açıklama |
|--|--|
| Nüfus x Merkez Üssüne Uzaklık | Daha büyük şehirler daha merkezi veya dağınık olabilir. |
| Eski Binalarda Oturan Hane Halkı Oranı x Ortalama Kat Sayısı | Eski binaların yoğun olduğu bölgelerde kat sayısı genellikle daha düşük olabilir |
| Kişi Başı Ortalama Yıllık Gelir x Yüzey Alanı | Geniş alanlara yayılan bölgelerde kişi başı gelir daha farklı olabilir. |
| Nüfus x Ortalama Kat Sayısı | Nüfus arttıkça, daha yüksek katlı binaların oranı artabilir. |
| Merkez Üssüne Uzaklık x Kişi Başı Ortalama Yıllık Gelir | Merkezden uzak bölgelerde gelir seviyesi değişkenlik gösterebilir. |
| Nüfus x Yüzey Alanı | Büyük şehirler geniş alanlara yayılabilir ya da kompakt olabilir. |
| Eski Binalarda Oturan Hane Halkı Oranı x Kişi Başı Ortalama Yıllık Gelir | Eski yapı stokunun fazla olduğu bölgelerde gelir seviyeleri farklılık gösterebilir. |
| Nüfus x Eski Binalarda Oturan Hane Halkı Oranı | Nüfus yoğunluğu yüksek olan yerlerde eski binaların oranı daha fazla olabilir. |
| Ortalama Kat Sayısı x Kişi Başı Ortalama Yıllık Gelir | Daha yüksek binaların olduğu yerlerde kişi başına düşen gelir artabilir veya azalabilir. |

| Etkileşim | Açıklama |
|--|--|
| Eski Binalarda Oturan Hane Halkı Oranı, x Ortalama Kat Sayısı x Kişi Başı Yıllık Ortalama Gelir | Zengin semtlerde eski ama yüksek binaların varlığı, kentsel dönüşüm ve yapı kalitesi açısından değerlendirilebilir. |
| Nüfus x Yüzey Alanı x Merkez Üssüne Uzaklık | Geniş yüzölçümüne sahip şehirlerde nüfusun dağılımı, merkezi yoğunlaşma veya yayılmış yapılaşma olup olmadığını gösterir. |
| Eski Binalarda Oturan Hane Halkı Oranı x Merkez Üssüne Uzaklık x Kişi Başı Yıllık Ortalama Gelir | Merkezden uzak, eski yapı stokuna sahip ve gelir seviyesi yüksek olan bölgelerde kentsel dönüşüm ihtiyacı olabilir. |
| Nüfus x Ortalama Kat Sayısı x Kişi Başı Yıllık Ortalama Gelir | Kalabalık bölgelerde yüksek katlı binaların ve kişi başına düşen gelir seviyesinin nasıl değiştiği analiz edilebilir. |
| Merkez Üssüne Uzaklık x Ortalama Kat Sayısı x Kişi Başı Yıllık Ortalama Gelir | Merkezden uzak yerlerde yüksek gelirli bireylerin yaşadığı bölgelerde bina yüksekliklerinin nasıl değiştiği incelenebilir. |

Son olarak da 3 yeni grup özellik yaratıp bu yeni özellikler için K-means algoritması kullanarak mevcut özelliklerle 3 seviyeli bir kümeleme yapmaktayız. Grup özellikleri ve içerikleri Çizelge 4.7.'de sunulmaktadır.

Çizelge 4.7. Grup Özellikleri ve İçerikleri

| Özellik Kümesi | Kullanılan Özellikler | Küme Sayısı |
|-----------------------|--|--------------------|
| Bina Kümesi | Ortalama Kat Sayısı, Eski Binalarda Oturan Hane Halkı | 3 |
| Ekonomi Kümesi | Kişi Başı Yıllık Ortalama Gelir, Nüfus | 3 |
| Risk Kümesi, | Merkez Üssüne Uzaklık, Eski Binalarda Oturan Hane Halkı Oranı, Ortalama Kat Sayısı | 3 |

Başlangıçta yalnızca Nüfus, Merkez Üssüne Uzaklık, Eski Binalarda Oturan Hane Halkı Oranı, Ortalama Kat Sayısı, Kişi Başı Yıllık Ortalama Gelir ve Yüzey Alanı olmak üzere 6 temel özneliğimiz bulunmaktaydı. Bu öznelilikler yetersiz kaldığından, veri setinin temsil gücünü artırmak amacıyla çok yönlü bir öznelilik mühendisliği süreci

gerçekleştirdik. İlk aşamada, temel değişkenler arasında alan bilgisine dayalı olarak oluşturduğumuz oranlarla Çizelge 4.5.'te yer alan yeni öznitelikler türettik. Örneğin, nüfus ve yüzey alanı özniteliklerini kullanılarak nüfus yoğunluğunu hesapladık; bu özniteliğin, yerleşim yoğunluğunu doğrudan temsil ettiğini değerlendiriyoruz. Çizelge 4.5.'te yer alan oranlar ile doğrudan gözlemlenemeyen ancak afet etkisiyle yakından ilişkili olan risk, dayanıklılık ve yapılaşma düzeylerini modelleme sürecimize kazandırdık. İkinci aşamada, her bir sayısal öznitelige çeşitli matematiksel dönüşümler uygulayarak doğrusal olmayan ilişkileri yakalamayı hedefledik. Bu kapsamda, her özniteliğin logaritmik, karekök, ters dönüşüm (inverse transform), kare (squared term) ve küp (cubed term) dönüşümlerini aldık. Üçüncü olarak, temel öznitelikler arasında ikili ve üçlü etkileşim terimleri oluşturarak, Çizelge 4.6.'da yer alan öznitelikler arası bağlamsal ilişkileri modelledik. Örneğin, Nüfus ile Merkez Üssüne Uzaklık özniteliklerini çarparak, merkezden uzak ama yoğun nüfuslu bölgeleri tanımladık. Son olarak da 3 yeni grup özellik yaratıp bu yeni özellikler için K-means algoritması kullanarak mevcut öznitelikler ile Çizelge 4.7.'de yer alan 3 seviyeli bir kümeleme yapmaktayız.

Kapsamlı öznitelik mühendisliği süreci sonucunda, öznitelik sayımızı 113'e çıkardık. Ancak bu kadar fazla sayıda özniteliğin modele dâhil edilmesi, çoklu doğrusal ilişki (multicollinearity) riskini artırmakta ve modelimizin kararlılığını olumsuz yönde etkileyebilmekteydi. Bu nedenle, ilk aşamada yüksek düzeyde birbirine benzeyen değişkenleri tespit edebilmek amacıyla 0,95 eşik değerine sahip bir korelasyon analizi gerçekleştirdik. Tespit edilen yüksek korelasyonlu değişken çiftleri, hedef değişkenlerle olan ortalama korelasyon değerleri açısından karşılaştırdık; korelasyonları birbirine yakın olan çiftlerde, modelin yorumlanabilirliğini koruyabilmek adına orijinal değişkenlere öncelik verdik, açık şekilde daha yüksek tahmin gücüne sahip olanları ise türetilmiş olup olmadıklarına bakmaksızın koruduk.


Bu hedef odaklı seçim stratejisi sayesinde, açıklayıcı öznitelik sayımızı 113'ten 33'e düşürdük ve modelimizin gereksiz karmaşıklığını azaltılmış olduk. Bu 33 öznitelik Çizelge 4.8.'de öznitelikler ile hedef değişken arasındaki korelasyon matrisi Şekil 4.2. yer almaktadır. Özellik sayısını azaltılmamıza rağmen, kalan değişkenler arasında hâlâ yüksek korelasyonlar gözlemledik ve bu durum çoklu doğrusal ilişkinin daha ayrıntılı biçimde incelenmesini gerekli kıldı. Bu amaçla Varyans Enflasyon Faktörü (VIF) analizi uygulamak istedik, ancak 27 sayısal değişken olmasına rağmen matrisin sadece 11 ranka sahip olduğu tespit ettik. Bu durum, değişkenler arasında gizli doğrusal bağımlılıkların

bulduğunu ve matrisin tam ranklı olmadığını göstermekteydi; bu da VIF hesaplamalarının güvenilirliğini azaltmakta ve bazı katsayıların sonsuz değerlere ulaşmasına yol açmaktadır. Regresyon analizinde bu tür bir çoklu doğrusal ilişki klasik OLS (Ordinary Least Squares) modelleri açısından ciddi bir sorun oluştursa da çalışmamızda Ridge regresyon yaklaşımını tercih ettik. Ridge regresyon, L2 düzenleme yapısı sayesinde yüksek korelasyonlu değişkenlerin katsayılarını birbirine yaklaştırarak bu tür sorunları doğal olarak baskılar ve istikrarlı sonuçlar üretir.

Çizelge 4.8. 33 Öznitelik

| ID | Öznitelik Adı |
|----------|--|
| x_1 | 1.Gün SWI |
| x_2 | Merkez Üssüne Uzaklık |
| x_3 | Eski Binalarda Oturan Hane Halkı Oranı |
| x_4 | Ortalama Kat Sayısı |
| x_5 | Kişi Başı Yıllık Ortalama Gelir |
| x_6 | 1.Gün SWI ² |
| x_7 | Nüfusun Ters Dönüşümü |
| x_8 | Nüfus Yoğunluğunun ³ |
| x_9 | Bina Yoğunluğunun Logaritmik Dönüşümü |
| x_{10} | Deprem Risk İndeksi ³ |
| x_{11} | Nüfusun Kişi Başına Gelire Oranının Logaritmik Dönüşümü |
| x_{12} | Nüfusun Kişi Başına Gelire Oranının Küpü |
| x_{13} | Merkez Üssüne Uzaklığın Ortalama Kat Sayısına Oranın Ters Dönüşümü |
| x_{14} | Nüfus ile Merkez Üssüne Olan Uzaklığın Çarpımı |
| x_{15} | Eski Binalarda Oturan Hane Halkı Oranı ve Ortalama Kat Sayısının Çarpımı |
| x_{16} | Kişi Başı Yıllık Ortalama Gelir ve Yüzey Alanın Çarpımı |
| x_{17} | Nüfus ve Ortalama Kat Sayısının Çarpımı |

| ID | Öznitelik Adı |
|-----------|--|
| x_{18} | Merkez Üssüne Uzaklık ve Kişi Başı Yıllık Ortalama Gelirin Çarpımı |
| x_{19} | Nüfus ve Yüzey Alanın Çarpımı |
| x_{20} | Eski Binalarda Oturan Hane Halkı Oranı ve Kişi Başı Yıllık Ortalama Gelirin Çarpımı |
| x_{21} | Nüfus ve Eski Binalarda Oturan Hane Halkı Oranının Çarpımı |
| x_{22} | Ortalama Kat Sayısı ve Kişi Başı Yıllık Ortalama Gelirin Çarpımı |
| x_{23} | Eski Binalarda Oturan Hane Halkı Oranı, Ortalama Kat Sayısı ve Kişi Başı Yıllık Ortalama Gelirin Çarpımı |
| x_{24} | Nüfus, Yüzey Alanı ve Merkez Üssüne Uzaklığın Çarpımı |
| x_{25} | Eski Binalarda Oturan Hane Halkı Oranı, Merkez Üssüne Uzaklık ve Kişi Başı Yıllık Ortalama Gelirin Çarpımı |
| x_{26} | Nüfus, Ortalama Kat Sayısı ve Kişi Başı Yıllık Ortalama Gelirin Çarpımı |
| x_{27} | Merkez Üssüne Uzaklık, Ortalama Kat Sayısı ve Kişi Başı Yıllık Ortalama Gelirin Çarpımı |
| x_{28} | Bina Kümesi_1 |
| x_{29} | Bina Kümesi_2 |
| x_{30} | Ekonomi Kümesi_1 |
| x_{31} | Ekonomi Kümesi_2 |
| x_{32} | Risk Kümesi_1 |
| x_{33} | Risk Kümesi_2 |



Şekil 4.2. 33 Öznitelik ile Hedef Değişkenler Arasındaki Korelasyon Matrisi

5. TAHMİN MODELİ GELİŞTİRME

Bu bölümde, afet sonrası erken dönemde bölgesel yardım talebini temsil eden SWI değerlerini tahmin etmeye yönelik modeli geliştiriyoruz.

Modelde, öznitelik olarak her il için 6 Şubat 2023 tarihine ait SWI değeri ile, o ile özgü yapısal ve demografik öznitelikleri kullanıyoruz. Böylelikle veri setimiz 11 il ve 33 öznitelikten (11 x 33) oluşuyor. Bunların biri, 6 Şubat'a ait SWI değeri. Bir önceki bölümde sunduğumuz üzere, sekiz tanesi doğrudan elde edilen temel yapısal ve demografik veriler. Kalan öznitelikler ise bu temel verilerden çeşitli oranlama, kategorileştirme ve dönüşüm işlemleriyle elde ettiğimiz türetilmiş değişkenlerden oluşuyor.

Bu özniteliklere dayanarak, 7–10 Şubat 2023 tarihleri arasında her gün ve her il için (toplam 44 gözlem) SWI değerlerini hedef değişken olarak tahmin ediyoruz. Önceki bölümde açıkladığımız üzere, SWI oluşturma algoritmasında, X (eski adıyla Twitter) gönderileri ve Google Trends verileri [0,1] aralığında normalize edilmekte ve sabit ağırlıklarla birleştirilmektedir. Bu nedenle, SWI değerleri yapısal olarak her zaman 0 ile 1 arasında kalmaktadır. Bu değerler, mutlak yardım ihtiyacını değil, iller arasındaki göreceli yardım talebi düzeyini ifade eder. Örneğin, 7 Şubat günü için Hatay iline ait SWI değeri 0,8, Gaziantep için 0,4 olarak tahmin edildiyse, bu durum Hatay'ın, Gaziantep'e kıyasla yaklaşık iki kat daha fazla yardıma ihtiyaç duyduğunu göstermektedir. Afetin hemen ardından erişilebilecek sınırlı verilerle, bölgesel talebin nasıl şekilleneceğini öngörmeyi ve kaynak planlamasını daha erken aşamada yönlendirmeyi amaçlıyoruz. Tahmin modellerimizin detayları ve sonuçları izleyen alt bölümlerde sunulmaktadır.

5.1. Tahmin Modeli Kurulumu

Tahmin sürecinde, veri setimizin sınırlı boyutu nedeniyle klasik doğrusal regresyon modellerinin doğrudan kullanımı uygun değildir. Sadece 11 şehir ve her biri için 33 öznitelikten oluşan veri setimiz, aşırı öğrenmeye (overfitting) oldukça yatkındır. Bu tür küçük veri setlerinde, doğrusal modeller genellikle yüksek varyansa sahip olup, eğitim verisini çok iyi öğrenmelerine rağmen, yeni gözlemlerde düşük genelleme performansı gösterirler. Bu nedenle, L2 normuna dayalı düzenleme (regularization) içeren Ridge regresyon yöntemi tercih edilmiştir. Ridge regresyon, modelin katsayılarını küçültmeye yönelik bir ceza terimi ekleyerek, aşırı öğrenmenin önüne geçer ve modelin genelleme yeteneğini artırır. Bu yaklaşım, özellikle gözlem sayısının az, öznitelik sayısının görece

fazla olduđu durumlarda etkili bir dengeleme sađlar. Bylelikle model hem veriye uyum sađlar hem de ařırı karmařık hale gelmeden đrenmeyi bařarır.

Ek olarak, zniteliklerimizin lekleri arasında ciddi farklar mevcuttur. rneđin, birinci gne ait normalize edilmiř SWI deđeri 0–1 aralıđında iken, nfus gibi bazı deđiřkenler milyonlarla ifade edilmektedir. Standart dođrusal regresyon bu tr lek farklarına karřı duyarlıdır ve byk lekli zniteliklerin modele hkim olmasına neden olabilir. Ridge regresyon ise tm katsayıları eř zamanlı olarak cezalandırdıđı iin bu dengesizliđi azaltır ve daha dengeli bir model đrenmesini sađlar.

Modelleme srecinde iki farklı tahmin stratejisi uyguluyoruz: İlki, 1. gne ait zniteliklerle sonraki drt gnn (7–10 řubat) SWI deđerlerini aynı anda tahmin eden oklu ıktı (multi-output) regresyon yaklařımıdır. Buradaki motivasyonumuz, SWI'nın zamansal ilerleyiři birlikte ele alınarak ıktı deđiřkenleri arasındaki iliřkilerden faydalanmaktır. İkincisi, tekil ıktı (single-output) regresyon yaklařımı ile her bir gn iin ayrı bir tahmin modeli kuruyoruz. Bu yntemi uygulama motivasyonumuz ise her gnn SWI dinamiđini ayrı ayrı modelleyerek gnler arası farklılıkların daha net yakalayabilmektir.

Modelin eđitim ve test srelerinde, kk veri setimizin dođasına uygun olarak Bir Gzlemi Dıřarıda Bırakarak apraz Dođrulama (Leave-One-Out Cross-Validation, LOOCV) stratejisini kullanıyoruz. Bu yaklařımda, her iterasyonda bir řehir veri setinden dıřarıda bırakarak kalan 10 řehir ile model eđitiyor ve ardından dıřarıda bırakılan řehir iin tahmin yapıyoruz. Bu iřlem, her bir řehir bir kez test verisi olacak řekilde tm řehirler iin tekrarlanıyor. Bylelikle modelin genellenebilirliđi her řehir zelinde test edilmiř oluyor. te yandan, tahmin modeli iinde kullanılacak zniteliklerin belirlenmesinde İleriye Dođru Deđiřken Seimi (ya da Adım Adım Deđiřken Ekleme Stratejisi) uyguluyoruz. Bu yntem, boř bir modelle bařlayarak her adımda tahmin performansını en ok artıran zniteliđi modele ekler. Bu sayede hem modelin aıklayıcılıđı glendirilir hem de gereksiz deđiřkenlerin modele dahil edilmesi nlenerek ařırı đrenme riski azaltılır.

5.1.1. Ridge Regresyon Kavramsal Temel

Ridge regresyon, dođrusal regresyonun varyansını azaltarak genelleme kabiliyetini artırmayı amalayan bir dzenlileřtirme (regularization) yntemidir. zellikle oklu dođrusal bađlantı (multicollinearity) problemi bulunan veya rnekleme byklđ dřk

olan veri kümelerinde, tahmin gücünü artırmak için tercih edilir. McDonald (2009) çalışmasında Ridge tahmin edicilerinin artan önyargı pahasına varyansı düşürdüğünü ve bu sayede toplam ortalama kare hatasını azalttığını vurgulamıştır. Bu durum, özellikle öznitelikler arasında yüksek düzeyde korelasyon bulunduğunda daha da önem kazanmaktadır; çünkü klasik regresyon yöntemleri bu gibi durumlarda kararsız ve güvenilir tahminler üretirken, Ridge regresyon varyansı kontrol altına alarak modelin genellenebilirliğini artırmaktadır.

Klasik doğrusal regresyon modelinde, bir hedef değişken y 'nin tahmini \hat{y} ile p adet öznitelik $X = [x_1, x_2, \dots, x_p]$ arasındaki ilişki aşağıdaki Denklem 5'teki gibi modellenir:

$$\hat{y} = \beta_0 + \beta_1 \cdot x_1 + \beta_2 \cdot x_2 + \dots + \beta_p \cdot x_p \quad (5)$$

Modelin katsayıları, genellikle En Küçük Kareler (Ordinary Least Squares, OLS) yöntemiyle belirlenir. OLS, tahmin hatalarının karesinin toplamını (Residual Sum of Squares, RSS) minimize etmeye çalışır (Denklem 6):

$$RSS = \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (6)$$

Ancak, bu yöntem küçük veri kümelerinde veya yüksek boyutlu veri setlerinde aşırı öğrenme (overfitting) riskini artırır. Ridge regresyon, bu riski azaltmak için OLS hedef fonksiyonuna bir ceza terimi (penalty term) ekler (Denklem 7):

$$RSS_{ridge} = \sum_{i=1}^n (y_i - \hat{y}_i)^2 + \alpha \sum_{j=1}^p \beta_j^2 \quad (7)$$

Denklem 7'de $\alpha \geq 0$, regülasyon katsayısıdır. Bu değer arttıkça, katsayılar daha fazla küçültülür. Diğer ifade, $\sum_{j=1}^p \beta_j^2$, ise Denklem 5'teki tüm regresyon katsayılarının karelerinin toplamı olup L2 normunu temsil eder.

Bu ceza terimi, büyük katsayıları cezalandırarak modelin aşırı uyum göstermesini engeller ve tahmin edilen katsayıların daha dengeli olmasını sağlar. Özellikle farklı ölçeklerdeki özniteliklerin yer aldığı veri setlerinde, Ridge regresyon tüm özniteliklerin etkisini düzenleyerek daha dengeli bir model oluşturur.

Ridge regresyon tercih etmemizdeki temel motivasyonlarımız şunlardır: Veri setimiz yalnızca 11 il ve 33 öznitelikten oluşmakta, yani örneklem sayısı oldukça sınırlıdır. Bu durum, klasik doğrusal regresyon yöntemlerinde yüksek varyans ve aşırı öğrenme riskini artırmaktadır. Ridge regresyon, L2 ceza terimi ile model katsayılarını düzenleyerek bu riski azaltır ve genelleme yeteneğini artırır. Ayrıca veri setimizde farklı ölçeklere sahip öznitelikler bulunduğundan, Ridge regresyon çalışmamız için uygun bir yöntemdir.

Bu çalışmada Ridge regresyon uygulamaları için Python'un popüler `scikit-learn` kütüphanesini kullanmaktayız.

5.1.2. Standardizasyon

Denklem 7'deki ceza terimi, tüm katsayıların karesini içerdiğinden, farklı ölçeklerdeki öznitelikler ceza teriminde dengesizliğe yol açar. Örneğin: Nüfus (milyonlar mertebesinde) ve SWI (0-1 aralığında). Bu durumda, büyük ölçekli değişkenler daha yüksek ceza alır ve model onları otomatik olarak küçümser. Bu da önyargılı sonuçlara yol açar.

Çalışmamızda, Ridge regresyonu uygulamadan önce tüm öznitelikleri standardize ettik. Standardizasyon için Python'un popüler `scikit-learn` kütüphanesinde yer alan `StandardScaler()` fonksiyonunu kullanmaktayız. Bu işlemde, her özneliğin ortalamasını 0, standart sapmasını ise 1 olacak şekilde dönüştürmekteyiz. Yani bir özneliğe ait x gözlemini, özneliğin ortalamasını (μ) ve standart sapmasını (σ) kullanarak aşağıdaki Denklem 8 ile standart formdaki z değerine dönüştürüyoruz:

$$z = \frac{x - \mu}{\sigma} \quad (8)$$

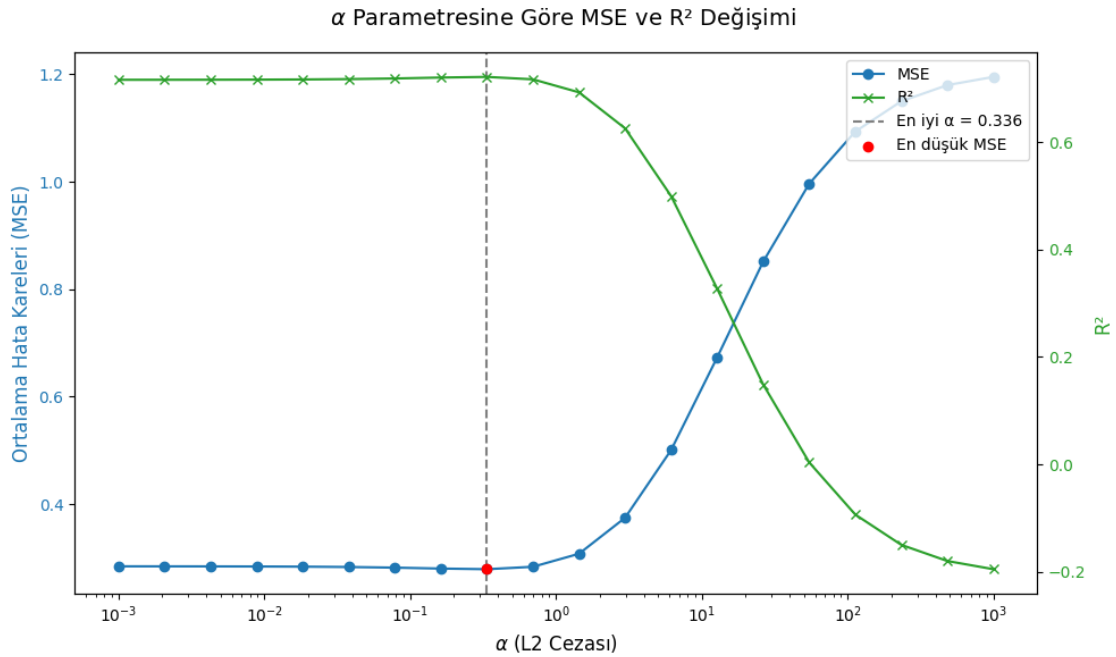
Böylece, farklı büyüklükteki değişkenlerin (örneğin nüfus milyonlarla ifade edilirken, bazı oranlar 0-1 aralığında olabilir) model üzerindeki etkisi dengelenmektedir. Yani özniteliklerin farklı ölçeklerde olmasının modelin performansını bozmasını önler. Bu şekilde standartlaştırma, Ridge, Lasso, SVM, K-means gibi ölçek duyarlı ve regularization uygulayan (ceza terimi ekleyen) modellerde yaygındır ve doğru ve dengeli öğrenmeyi sağlar.

Dikkat çekmek isteriz ki modellerimizi standardize edilmiş veriler üzerinde eğitiyoruz. Ancak performans metriklerini, model tahminleri orijinal ölçeğe geri dönüştürüp hesaplıyor ve raporluyoruz.

5.1.3. Ridge Regresyon Regülasyon Katsayısı Seçimi

Modelin regülasyon katsayısı olan α parametresini, farklı değerler için **LOOCV** stratejisi ile test ederek belirliyoruz. Bu amaçla, α değeri için 10^{-3} ile 10^3 arasında logaritmik olarak dağıtılmış 20 farklı aday değer değerlendirmekte, her biri için model performansı (özellikle ortalama hata kareleri – MSE ve determinasyon katsayısı – R^2) ölçülmektedir. En düşük genel MSE değerini sağlayan α değeri “en uygun” kabul edilerek nihai Ridge modeli oluşturulmaktadır.

Alfa değerini belirlerken modeli çoklu çıktı yaklaşımıyla eğitip test ediyoruz. Bu süreçte elde ettiğimiz en iyi α değerini, hem çoklu hem de tekli çıktı modellerinde kullanıyoruz. Aynı α değerini iki yaklaşımda da kullanmamızın nedeni, her iki modelin de aynı öznelikler ve hedef değişken yapısıyla çalışmasıdır. Bu sayede, çoklu çıktı modeli için optimize ettiğimiz alfa değeri, tekli modeller için de uygun bir regularizasyon gücü sağlamaktadır. Ayrıca, veri setimiz oldukça küçük olduğu için her iki model türü için ayrı ayrı alfa ayarı yapmak, aşırı uyuma (overfitting) yol açabilir ve sonuçların tutarlılığını zayıflatabilir. Bu yüzden, modelin genellenebilirliğini korumak ve karşılaştırılabilirliği artırmak amacıyla aynı α değerini her iki yaklaşımda da tercih ediyoruz. Bu kapsamda bulduğumuz sonuçları Şekil 5.1.’de sunmaktayız. Şekil 5.1’de de görüldüğü üzere, $\alpha = 0,336$ değerini seçerek bu tezdeki Ridge regresyon modellerimizi kuruyoruz.



Şekil 5.1. α Parametresine Göre MSE ve R^2 Değişimi

5.2. Çoklu Çıktı ile Tahmin Modeli ve Sonuçlar

Bu bölümde, afet sonrası yardım talebini temsil eden SWI değerlerini tahmin etmeye yönelik çoklu çıktı regresyon modelimizi sunuyoruz. Modelimiz, ilk güne ait SWI değeri ve bölgelere ait yapısal-demografik öznitelikleri kullanarak 7–10 Şubat tarihleri arasında oluşacak SWI değerlerini, yani dört ayrı günü aynı anda tahmin etmeyi amaçlamaktadır. Bu yaklaşım, yardım planlaması açısından zaman boyutlu öngörüler elde etmeye olanak tanımakta ve modelin zamansal öngörü gücünü daha bütüncül bir biçimde değerlendirmemizi sağlamaktadır.

Modelimiz her şehir i için, 6 Şubat gününe ait öznitelikleri ($SWI_{i,1}$ ve diğer yapısal-demografik göstergeler) kullanarak, $t = 2,3,4,5$ için ilgili $SWI_{i,t}$ değerlerini tahmin etmektedir. Burada $SWI_{i,t}$ ifadesi, i . şehre ait t . gündeki yardım talebi göstergesini temsil eder. Örneğin, model Hatay için $SWI_{Hatay,t}$, $t = 2,3,4,5$ değerlerini üretir. Bu yapı sayesinde model, her şehrin zaman içindeki talep eğilimini yakalayarak 4 farklı gün için aynı anda tahmin sunar.

Model performansını değerlendirmek için tercih ettiğimiz temel ölçüt Ortalama R^2 değeridir. Her bir hedef (her güne ait SWI tahminleri) için ayrı ayrı R^2 skoru hesaplanmakta ve bunların ortalaması alınarak genel model başarısı ölçülmektedir. Ortalama R^2 kullanımı, özellikle tüm hedeflerin eşit öneme sahip olduğu durumlarda uygundur; böylece modelin yalnızca bazı hedeflerde iyi performans gösterip diğerlerinde başarısız olmasının önüne geçilmiş olur. Ayrıca, büyük varyansa sahip hedeflere karşı modelin önyargılı olmasını önleyerek, modelin genel istikrarına daha bütüncül bir bakış sunar.

Modelde özniteliklerin seçiminde 33 öznitelikten oluşan tam aday havuzuyla başlamaktaız. Her iterasyonda, tahmin başarısını en çok artıran öznitelik modele dahil edilmektedir. Çizelge 5.1.'de ileriye doğru değişken seçimi sürecinde her iterasyonda eklenen öznitelikler ve bunların modelin ortalama R^2 skoruna etkisi yer almaktadır. Bu süreçte toplam üç öznitelik modele dahil edilmiş ve dördüncü iterasyonda durma kriteri sağlanmaktadır. Durma kriteri, ileriye doğru değişken seçimi (forward selection) sürecinde modele yeni bir öznitelik eklendiğinde modelin performansının artık anlamlı şekilde artmadığı noktada süreci durdurmak için kullanılan ölçüttür. Bizim uygulamamızda dördüncü iterasyonda: yeni öznitelik eklendiğinde R^2 artışı ya çok az ya da negatif olduğu için süreç durmaktadır.

Çizelge 5.1. İterasyon Sonrasında Eklenen Öznitelikler

| İterasyon | Eklenen Öznitelik | Ortalama R^2 |
|-----------|---------------------------------|----------------|
| 1 | 1. Gün SWI | 0,61 |
| 2 | Nüfus Yoğunluğunun ³ | 0,66 |
| 3 | Ortalama Kat Sayısı | 0,72 |
| 4 | - | 0,72 |

Bu sonuçlara göre, yalnızca üç öznitelik ile elde edilen %72,1'lik Ortalama R^2 değeri, modelin güçlü bir genelleme yeteneğine sahip olduğunu göstermektedir. Özellikle ilk gün SWI değeri, yoğun yapılaşmayı temsil eden Nüfus Yoğunluğunun³ ve Ortalama Kat Sayısı, yardım talebinin tahmini açısından en belirleyici öznitelikler olarak öne çıkmaktadır.

Çizelge 5.2. En Belirleyici Öznitelikler

| ID | Öznitelik Adı |
|-------|---------------------------------|
| x_1 | 1.Gün SWI |
| x_4 | Ortalama Kat Sayısı |
| x_8 | Nüfus Yoğunluğunun ³ |

İleriye doğru değişken seçimiyle belirlenen Çizelge 5.2.'de yer alan üç öznitelik x_1 (1.Gün_SWI), x_4 (Ortalama Kat Sayısı), x_8 (Nüfus Yoğunluğunun³) kullanılarak oluşturulan çoklu çıktı Ridge regresyon modelinin her bir hedef değişken için denklemini aşağıda sunuyoruz:

$$y_2 (2. Gün SWI) = -0,0424 + (0,8474 \times x_1) + (0,1043 \times x_8) + (0,3220 \times x_4) \quad (9)$$

$$y_3 (3. Gün SWI) = -0,0449 + (0,9290 \times x_1) + (-0,0195 \times x_8) + (0,1856 \times x_4) \quad (10)$$

$$y_4 (4. Gün SWI) = -0,0559 + (0,4973 \times x_1) + (0,5204 \times x_8) + (0,4182 \times x_4) \quad (11)$$

$$y_5(5. \text{Gün SWI}) = 0,0061 + (0,7392 \times x_1) + (0,3013 \times x_8) + (0,2130 \times x_4) \quad (12)$$

Regresyon modellerimizde görüleceği üzere, çoklu çıktılı Ridge regresyonu modelimizde her hedef değişkenin kendi katsayı kümesi vardır çünkü model bunları aynı özellikleri ve düzenlemeyi paylaşmalar bile ayrı regresyon problemleri olarak ele alır. Katsayılar, özelliklerin hedefler genelindeki değişken etkisini vurgular. Örneğin, x_1 , özellikle y_2 (0,84) ve y_3 (0,92) için sürekli olarak güçlü olumlu etkilere sahiptir ve bu da kısa vadeli tahminlerdeki temel rolünü gösterir. x_8 , y_4 (0,52) ve y_5 (0,30) üzerinde olumlu bir etkiye sahipken, x_4 , y_4 (0,41) için zirveye ulaşan istikrarlı bir olumlu etki gösterir. Bu modeller, farklı faktörlerin zaman içinde sonuçları nasıl şekillendirdiğini yansıtmaktadır.

Dört farklı gün için SWI tahmin performansını Çizelge 5.3.'te sunuyoruz. Buna ek olarak, Şekil 5.2.'te her bir gün için R^2 ve düzeltilmiş R^2 değerlerinin değişimini; Şekil 5.3.'te de ise MSE, MAE ve MAPE performans metriklerinin günlere göre değişimini görselleştiriyoruz.

R^2 değerleri tahmin performansının güçlü olduğunu göstermektedir. R^2 değeri, günler ilerledikçe artmakta; 2. günde yaklaşık 0,65, 5. günde ise 0,85 seviyelerine ulaşmaktadır. Bu, modelin sonraki günlerde SWI değişimini daha iyi tahmin ettiğini gösterir. Özellikle 4. ve 5. gün için tahmin başarısı yüksektir (0,72 ve 0,85). Düzeltilmiş R^2 değerleri de 4. ve 5. gün için iyi düzeyde kabul edilebilir. Bu metrik, modelin açıklayıcılığını öznelik sayısı dikkate alınarak değerlendirir. Bu da seçilen üç özneliğin tahmin gücüne katkı sağladığını göstermektedir.

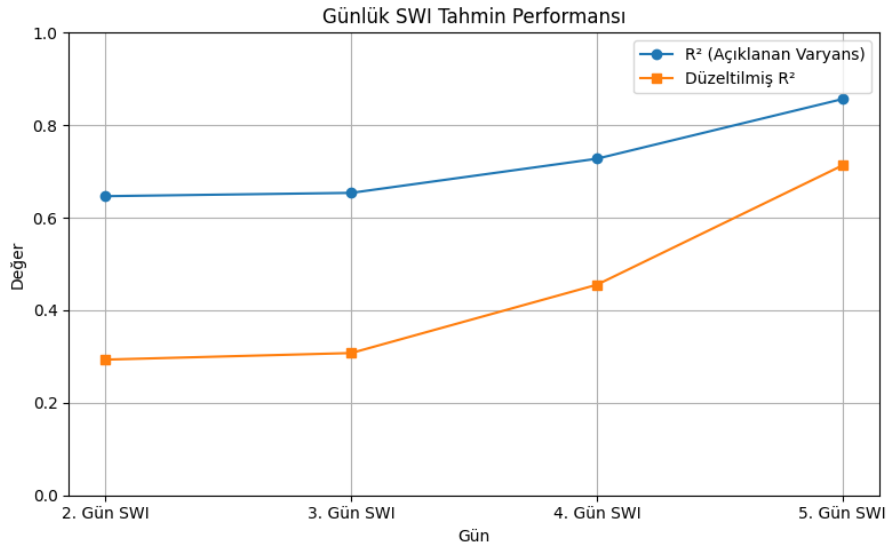
MSE ve MAE, 4. ve 5. günlerde belirgin şekilde düşmektedir. Bu düşüş, modelin sonraki günlerdeki öngörü gücünün güçlendiğini ve hataların hem mutlak hem orantısız olarak azaldığını ortaya koyar. MAPE 3. günde %40 civarında zirve yapmasına rağmen, 4. ve 5. günlerde sırasıyla %27 ve %13'e kadar gerilemektedir.

MAPE'in düşüşü özellikle 5. günde modelin oldukça isabetli tahminler yaptığını gösterir. MAPE'in 3. günde yükselmesinin nedeni, o gün için SWI değerlerinin düşük olması ve bu durumda oransız hataların şişmesidir ki bu metrik bu tür durumlara duyarlıdır. Genel olarak, modelin ilerleyen günler için daha başarılı tahminler yaptığı gözlemlenmektedir. Ayrıca, bu sonuçlar, aynı öznelik setiyle dört farklı gün için de başarılı tahminler elde edilebilmesinin, seçilen değişkenlerin tahmin gücünün yüksek ve gürbüz (robust)

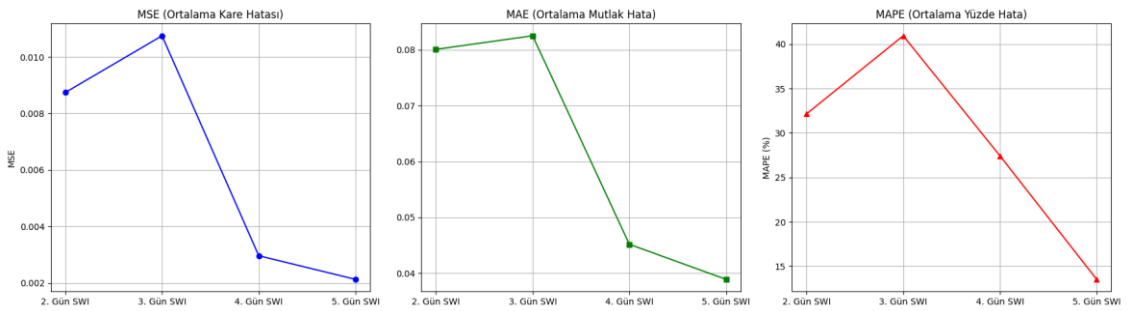
olduğunu göstermektedir. Ayrıca, bu özneliklerin farklı zaman dilimlerinde de tutarlı sonuçlar üretmesi, modelin genellenebilirliğini ve seçilen özneliklerin farklı günler arasında geçerliliğini desteklemektedir.

Çizelge 5.3. SWI Tahmin Performansı

| Hedef Değişken | MSE | MAE | MAPE | R ² | Düzeltilmiş R ² |
|----------------|--------|--------|-------|----------------|----------------------------|
| y ₂ | 0,0087 | 0,0800 | 32,14 | 0,64 | 0,49 |
| y ₃ | 0,0107 | 0,0825 | 40,92 | 0,65 | 0,50 |
| y ₄ | 0,0029 | 0,0451 | 27,43 | 0,72 | 0,61 |
| y ₅ | 0,0021 | 0,0388 | 13,53 | 0,85 | 0,79 |
| Ortalama | 0,0061 | 0,0616 | 28,50 | 0,72 | 0,60 |

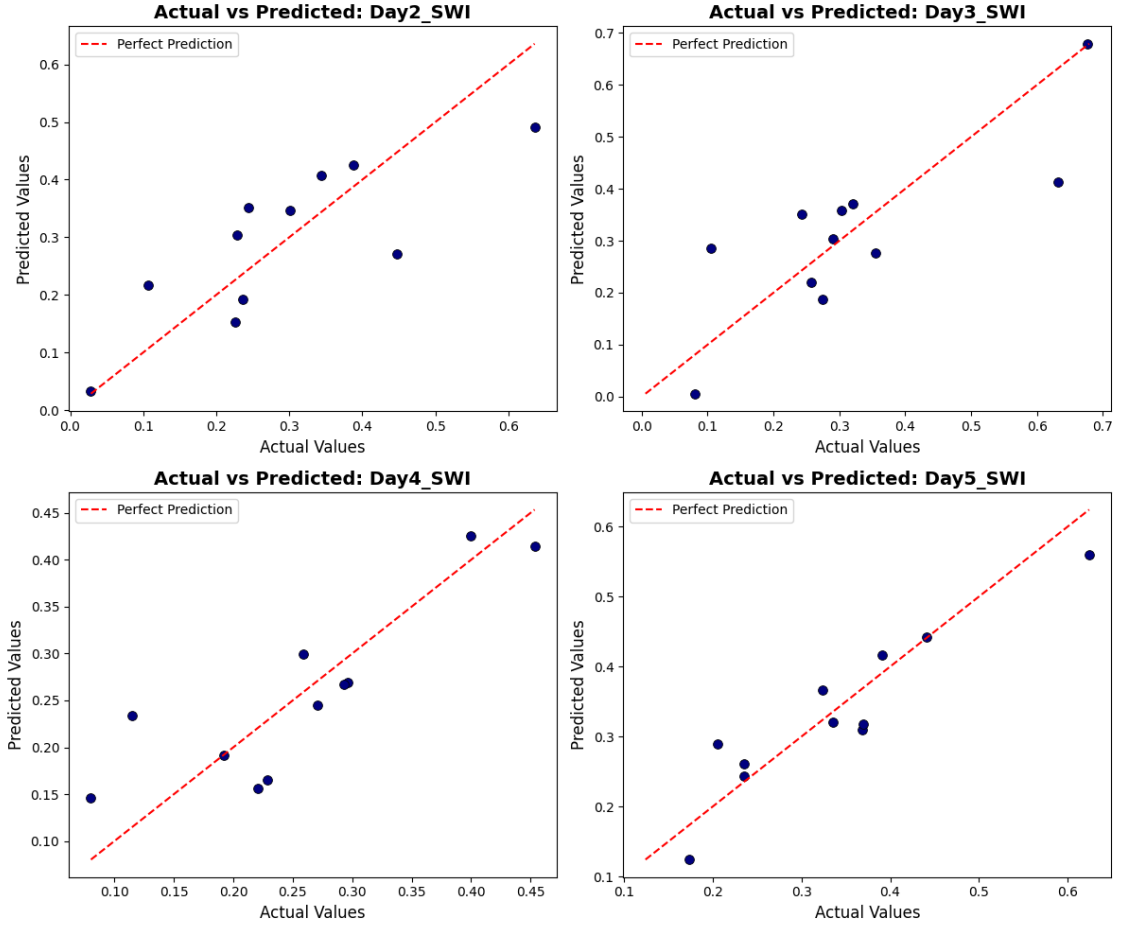


Şekil 5.2. R² ve Düzeltilmiş R² Zaman İçerisinde Değişimi



Şekil 5.3. MSE, MAE, MAPE'nin Zaman İçerisinde Değişimi

Son olarak Şekil 5.4'te gerçek ve tahmin edilen değerleri 1-1 çizgili nokta grafiğinde sunmaktayız. Şekillerde, çoğu noktanın mükemmel tahmin çizgisiyle yakın bir şekilde hizalandığını ve güçlü model performansına işaret ettiğini göstermektedir. Küçük sapmalar mevcut olsa da 1-1 çizgisi etrafında yer alma ve çizgi trendini takip etme, modelin altta yatan eğilimleri doğru bir şekilde yakaladığını göstermektedir.




Şekil 5.4. Gerçek ve Tahmin Edilen Değerler

5.2.1. Modelin Doğrulanması

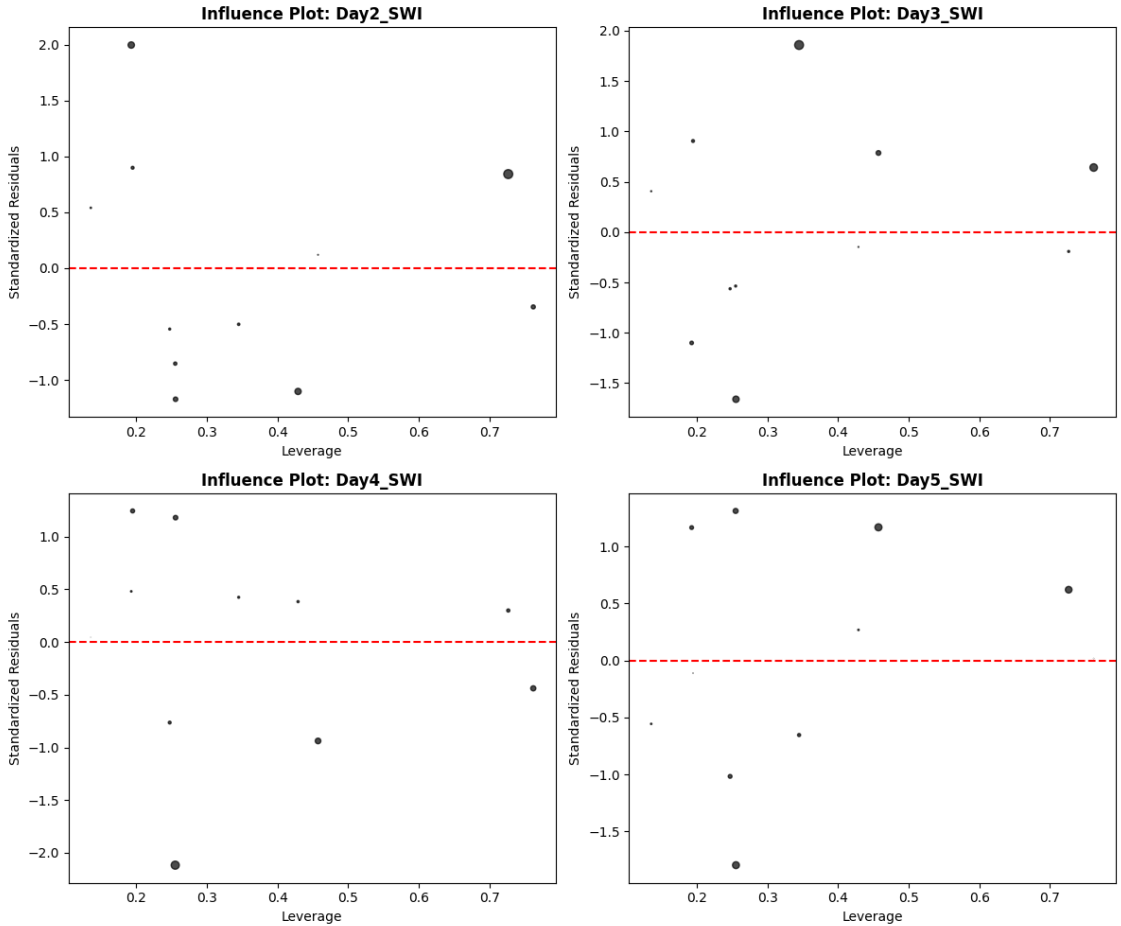
11 gözlemden oluşan sınırlı veri kümesi göz önüne alındığında, geleneksel regresyon teşhisleri için istatistiksel gücün doğası gereği sınırlı olduğunu kabul ediyoruz. Ancak, modele dahil edilen değişkenler güçlü teorik akıl yürütmeye dayanmaktadır. 1. Gün SWI, olaydan hemen sonraki aciliyeti yansıtarak, sonraki günler için mantıksal bir öngörücü haline getirir. Nüfus yoğunluğu, etkilenen nüfusun yoğunluğunu yansıtarak acil servis taleplerini etkiler. Son olarak, ortalama kat sayısı çok katlı binalarda yapısal kırılganlık ve potansiyel kaza oranları için bir vekil görevi görür. Bu teorik uyum, modelin güvenilirliğini yalnızca istatistiksel metriklerin ötesinde destekler.

Modelimize ait artık grafikleri Şekil 5.5.'te yer almaktadır. 2. Gün SWI, 3. Gün SWI, 4. Gün SWI, ve 5. Gün SWI için artık grafikleri doğrusal regresyon modellerinin SWI tahmininde makul bir geçerliliğe sahip olduğunu göstermektedir. Artıklar genellikle sıfır çizgisi etrafında simetrik olarak dağılmış olup belirgin sistematik desenler içermemektedir, bu durum doğrusal varsayımın geçerli olduğunu göstermektedir. Özellikle 2. Gün SWI ve 3. Gün SWI için artık dağılımında bazı değişkenlikler gözlemlense de güçlü bir eğrilik veya huni benzeri desenlerin olmaması, modellerin temel veri yapısını yeterince yakaladığını göstermektedir. Ayrıca, 5. Gün SWI'nın artıklarının sıfır etrafında sıkı bir şekilde kümelenmesi, modelin bu durumda sağlamlığını pekiştirmektedir. Birkaç aykırı değer bulunmasına rağmen, bunlar genel dağılımı önemli ölçüde bozmaz. Bu gözlemler doğrultusunda, doğrusal varsayım, bağımsızlık ve yaklaşık homoskedastisite varsayımlarının makul düzeyde sağlandığı ve bu çoklu çıktı tahminleme görevinde regresyon modellerinin geçerliliğini desteklediği sonucuna varılabilir.



Şekil 5.5. Artık Grafikleri

Etki grafikleri, bir regresyon modelinin tahminleri üzerinde orantısız bir etkiye sahip olan gözlemleri belirlemek için kullanılan teşhis araçlarıdır. Bu grafikler, standartlaştırılmış artıkları kaldıraç değerlerine karşı gösterir ve her noktanın boyutu, genellikle Cook'un mesafesi ile ölçülen etkisini temsil eder. Modelimize ait etki grafikleri Şekil 5.6.'da yer almaktadır. Day2_SWI, Day3_SWI, Day4_SWI ve Day5_SWI için etkililik grafikleri, çoğu veri noktasının düşük kaldıraç değerlerine ve sifıra yakın standartlaştırılmış artıklara sahip olduğunu göstermektedir; bu da regresyon modelleri üzerinde minimum etkiye sahip olduklarını ifade eder. Bazı noktalar daha yüksek kaldıraç veya artık değerler sergilemesine rağmen, hiçbiri modelin kararlılığını önemli ölçüde etkileyecek kadar aşırı değildir. Bu durum, regresyon modellerinin gürbüz (robust) olduğunu ve herhangi bir tekil gözleme aşırı bağımlı olmadığını göstererek SWI tahmini için geçerliliğini desteklemektedir.



Şekil 5.6. Etki Analizi Grafikleri

11 gözlemden oluşan küçük örneklem büyüklüğü nedeniyle, artıkların normalliği değerlendirilmemiştir. Modelin geçerliliği, artık analizi, etki grafikleri ve gerçek ile

tahmin edilen deęerlerin karřılařtırılması yoluyla desteklenmiřtir. Artıklar rastgele daęılım gstermiř, etki analizinde ařırı aykırı deęerler bulunmamıř ve tahmin izgisiyle gl bir hizalanma gzlemlenmiřtir. Makul uyum iyilięi metrikleriyle birlikte deęerlendirildięinde, bu sonular modelin saęlamlıęını ve gvenilirlięini doęrulamaktadır.

5.2.2. Ynetsel İgrler

Ynetimsel bir bakıř aısından, zneliklerin regresyon katsayıları kaynak tahsisi ve acil durum mdahale planlaması iin deęerli igrler sunar. 1. Gn SWI'nın tm gelecek gnler zerindeki gl olumlu etkisi, sosyal web etkinlięinin erken gstergelerinin acil yardım iin devam eden talebi tahmin etmek iin kritik olduęunu gstermektedir. Bu, ilk sorun sinyallerini hızla yakalamak ve bunlara yanıt vermek iin gerek zamanlı izleme sistemlerinin nemini vurgulamaktadır.

x_3 'in 4. Gn SWI ve 5. Gn SWI zerindeki nemli olumlu etkisi, yoęun nfuslu alanlarda acil ihtiyalarda muhtemelen kalabalık kentsel ortamların karmařıklıęı nedeniyle srekli veya gecikmeli artıřlar yařanabileceęini gstermektedir. Bu, yneticilerin yoęun nfuslu blgelere ilk kriz ařamasının tesinde srekli destek iin ncelik vermeleri gerektięini gstermektedir. Ek olarak, Ortalama Kat Sayısı'nın tm hedeflerle, zellikle 4. Gn SWI iin tutarlı olumlu iliřkisi, daha yksek binaların olduęu alanların muhtemelen tahliye zorlukları veya yapısal zayıflıklar nedeniyle daha byk zorluklarla karřılařabileceęini gstermektedir. Bu nedenle, acil mdahale stratejileri hem acil hem de uzun vadeli ihtiyaları gz nnde bulundurarak yksek katlı alanlara daha fazla kaynak tahsis etmelidir.

5.3. Tekli ıktı ile Her Hedefe zel Tahmin Modeli ve Sonular

Bu blmde, afet sonrası yardım talebini yansıtan SWI deęerlerini tahmin etmek iin tekli ıktı regresyon modellerimizi sunuyoruz. Her bir hedef gn (7–10 řubat) iin ayrı bir regresyon modeli kurarak, drt gn birbirinden baęımsız biimde tahmin etmeyi amalıyoruz. znelik olarak, bir nceki gnn SWI deęeriyle birlikte, her blgeye ait yapısal ve demografik zellikleri kullanıyoruz.

Bu yaklařımı tercih etmemizin temel nedeni, her gnn dinamięinin farklı olabileceęi varsayımdır. oklu ıktı modelleri tm hedefleri ortak bir yapı altında iřlerken, biz bu blmde her gn kendi kořullarıyla ele alıyoruz. Bylece, gnler arası farklılıkları daha

net yakalamayı ve her hedef için en uygun parametreleri modelin öğrenmesini amaçlıyoruz.

Her bir modelde yine Ridge regresyon kullanıyoruz ve çoklu çıktıda yaptığımız gibi verileri standardize ediyor, Bir Gözlemi Dışarıda Bırakarak Çapraz Doğrulama (LOOCV) stratejisini kullanıyor ve İleriye Doğru Değişken Seçimi yöntemiyle öznitelik seçimini yapıyoruz. Bu kez her hedef değişken için alfa (regülasyon) parametresini ayrı ayrı optimize ediyoruz. Model başarımını değerlendirmek için, daha önce kullandığımız metrikleri (R^2 , MAE, MAPE, MSE) kullanıyoruz.

5.3.1. İkinci Gün (7 Şubat) SWI Tahmini

Bu bölümde, 7 Şubat günü için afet sonrası yardım talebini temsil eden SWI değerini tekli çıktı regresyon modeli ile tahmin ediyoruz. Ridge regresyon uygulamamızda bu hedef için en iyi sonucu $\alpha = 0,001$ değeri ile elde etmekteyiz. İleriye doğru değişken seçimi sonucunda yalnızca iki öznitelik seçildi: bir önceki günün SWI değeri ve ortalama kat sayısı. Bu durum, ikinci günkü yardım talebinin büyük ölçüde bir önceki günkü talebe ve yapısal yoğunluğa bağlı olduğunu göstermektedir. Modelin tahmin ettiği regresyon denklemi aşağıda Denklem 12 olarak verilmektedir:

$$y_2 = -0,0443 + (0,9327 \times x_1) + (0,3435 \times x_4) \quad (12)$$

Modelin tekli çıktı yaklaşımıyla ve önceki bölümde de sunmuş olduğumuz çoklu çıktı yöntemiyle elde ettiği performans metrikleri Çizelge 5.4.'te sunulmaktadır.

Çizelge 5.4. İkinci Gün Performans Metrikleri

| Hedef | MSE | MAE | MAPE | R^2 | Düzeltilmiş R^2 |
|-------|--------|--------|--------|-------|-------------------|
| Tekli | 0,0048 | 0,0605 | 18,88% | 0,67 | 0,59 |
| Çoklu | 0,0087 | 0,0801 | 32,14% | 0,64 | 0,49 |

Bu karşılaştırma, tekli çıktı modelinin daha az değişkenle çalışmasına rağmen hem hata oranlarını düşürdüğünü hem de açıklayıcılık oranını artırdığını göstermektedir. Böylece, ikinci gün için özel olarak oluşturulan modelin, çoklu modele kıyasla daha başarılı

tahminler sunduğu söylenebilir. Bu sonuç, her hedef için ayrı model kurmanın, günlere özgü dinamikleri daha doğru yakalamayı mümkün kıldığını da ortaya koymaktadır.

5.3.2. Üçüncü Gün (8 Şubat) SWI Tahmini

Bu alt bölümde, 8 Şubat günü için afet sonrası yardım talebini temsil eden SWI değerini tekli çıktı regresyon modeli ile tahmin ediyoruz. Bu hedef için yapılan Ridge regresyon uygulamasında en uygun α değeri 0,162 olarak belirlenmiştir. Modelin tahmin ettiği regresyon denklemi aşağıda Denklem 13 olarak verilmektedir:

$$y_3 = -0,4849 + (0,7845 \times x_1) + (-1,0252 \times x_{30}) + (-0,2780 \times x_{21}) \quad (13)$$

İlk günün SWI değeri, ekonomik küme sınıflandırmasında birinci kümeye ait olma durumu (x_{30}) ve Eski Binalarda Oturan Hane Halkı Oranı'nın Nüfusla çarpımı (x_{21}) formülde yer almaktadır. Bu değişkenler, yapısal zayıflık ve sosyo-ekonomik kırılganlığın afet sonrası yardım çağrılarını üzerindeki etkisini göstermektedir. Tekli ve çoklu çıktı regresyon modellerinin üçüncü gün SWI tahmini için elde edilen denklemleri karşılaştırıldığında, her iki modelin de birinci gün SWI değişkenini güçlü bir şekilde kullandığı, ancak tekli modelin bunun yanı sıra ekonomik kırılganlığı (Ekonomi Kümesi_1) ve eski yapı yoğunluğunu (Nüfus x Eski Binalarda Oturan Hane Halkı Oranı) da içeren daha bağlamsal değişkenleri tercih ettiği görülmektedir. Çoklu çıktı modeli ise nüfus yoğunluğunu kübik terim olarak dahil edip ortalama kat sayısı ile tahmin yapmaktadır.

Modelin tekli ve çoklu çıktı yaklaşımı ile elde ettiği performans metrikleri Çizelge 5.5'te sunulmaktadır.

Çizelge 5.5. Üçüncü Gün Performans Metrikleri

| Model | MSE | MAE | MAPE | R ² | Düzeltilmiş R ² |
|-------|--------|--------|--------|----------------|----------------------------|
| Tekli | 0,0027 | 0,0384 | 13,22% | 0,82 | 0,74 |
| Çoklu | 0,0107 | 0,0825 | 40,93% | 0,65 | 0,50 |

Tekli modelde R² skoru 0,82'ye ulaşırken, çoklu modelde bu değer 0,65 seviyesinde kalmaktadır. Benzer şekilde, MSE değeri tekli modelde 0,0027 iken çoklu modelde

yaklaşık dört kat daha yüksek olan 0,0107'dir. MAE ve MAPE değerleri de tekli model lehine daha düşüktür; özellikle MAPE oranı %13 gibi oldukça düşük bir hata oranı sunarak, modelin tahmin gücünü vurgulamaktadır.

5.3.3. Dördüncü Gün (9 Şubat) SWI Tahmini

Bu bölümde, 9 Şubat tarihine ait SWI değerini tahmin etmeye yönelik tekli çıktı regresyon modelimizi sunuyoruz. Ridge regresyon uygulamamızda bu hedef için en iyi sonucu $\alpha = 0,336$ değeri ile elde etmekteyiz. Modelin tahmin ettiği regresyon denklemi aşağıda Denklem 14 olarak verilmektedir:

$$y_4 = -0,1479 + (0,5858 \times x_8) + (0,5898 \times x_{31}) + (0,4150 \times x_7) \quad (14)$$

Modelimiz dördüncü gün bölgesel yardım talebini açıklamak üzere üç değişken kullanmaktadır: Nüfus Yoğunluğunun Küpü (x_8), Ekonomik Küme Sınıflandırmasında İkinci Kümeye Ait Olma (x_{31}) ve Nüfusun Ters Dönüşümü (x_7). Bu seçilen öznitelikler, bölgenin yapısal ve ekonomik özelliklerini temsil etmekte ve bu bağlamda talep düzeyini belirlemede etkili olmaktadır. Çoklu model ile karşılaştırıldığında, tekli çıktı modelinin geçmiş gün SWI bilgisine ihtiyaç duymadan yalnızca yapısal-demografik özelliklerle yüksek açıklayıcılığa ulaşabildiği görülmektedir. İki modelde de Nüfus Yoğunluğunun Küpü ortak çıkmaktadır.

Modelin tekli ve çıktı yaklaşımı ile elde ettiği performans metrikleri Çizelge 5.6.'da sunulmaktadır.

Çizelge 5.6. Dördüncü Gün Performans Metrikleri

| Model | MSE | MAE | MAPE | R ² | Düzeltilmiş R ² |
|-------|----------|----------|-----------|----------------|----------------------------|
| Tekli | 0,002188 | 0,030105 | 12,458163 | 0,85 | 0,79 |
| Çoklu | 0,002964 | 0,045158 | 27,430754 | 0,72 | 0,61 |

Performans metrikleri açısından bakıldığında ise tekli model çok daha başarılıdır: R² değeri 0,85'e, düzeltilmiş R² ise 0,79'a ulaşmıştır. Buna karşılık çoklu modelin R² değeri 0,73 ve MAPE değeri %27,43 ile daha zayıf kalmaktadır. Tekli modelin MAPE değeri yalnızca %12,46 olup, bu gün özelinde yardım talebinin doğrudan bölgesel yapısal özelliklerle daha isabetli şekilde öngörülebildiğini göstermektedir. Bu durum, ilk gün verilerinin etkisinin azaldığı ve daha stabil bir tahmin zemininin oluştuğuna işaret edebilir.

5.3.4. Beşinci Gün (10 Şubat) SWI Tahmini

Son olarak, 10 Şubat tarihine ait SWI değerlerini tahmin etmeyi amaçlayan tekli çıktı regresyon modelimizi sunuyoruz. Bu model, önceki günlerdeki SWI değeri ile birlikte yapısal ve sosyoekonomik faktörleri bir araya getirerek tahmin yapmaktadır. Optimum regularizasyon parametresi olarak $\alpha = 0,018$ belirlenmiştir. Modelin tahmin ettiği regresyon denklemi aşağıda Denklem 15 olarak verilmektedir:

$$y_5 = 0,0533 + (0,7743 \times x_1) + (0,4575 \times x_8) + (0,5286 \times x_4) + (-0,3603 \times x_{26}) + (-0,3688 \times x_{32}) \quad (15)$$

Tekli ve çoklu modele ait formüller karşılaştırıldığında, tekli modelin çok daha fazla açıklayıcı değişkeni devreye sokarak SWI değerini tahmin ettiği görülmektedir. Özellikle gelir, yapı yoğunluğu ve afet küme bilgisi gibi faktörlerin bu gün özelinde etkili olduğu anlaşılmaktadır.

Modelin tekli ve çıktı yaklaşımı ile elde ettiği performans metrikleri Çizelge 5.8.'de sunulmaktadır.

Çizelge 5.7. Dördüncü Gün Performans Metrikleri

| Model | MSE | MAE | MAPE | R ² | Düzeltilmiş R ² |
|-------|----------|----------|-----------|----------------|----------------------------|
| Tekli | 0,001221 | 0,025205 | 9,235361 | 0,91 | 0,83 |
| Çoklu | 0,002128 | 0,038872 | 13,537045 | 0,85 | 0,79 |

Model performans metriklerine baktığımızda da bu derinleşmenin karşılığının alındığı açıktır. Tekli modelin R² değeri %91'e ulaşmakta, düzeltilmiş R² ise %83 ile oldukça yüksek bir seviyede kalmaktadır. MAPE değeri ise yalnızca %9,2 olup, tahminlerin oldukça düşük hata ile yapıldığını göstermektedir. Bu sonuçlar, afetin beşinci gününde yardım talebinin daha yerleşik bir yapıya kavuştuğunu ve daha geniş bir değişken setiyle başarılı şekilde modellenebildiğini göstermektedir. Ayrıca bu durum, tekli modelin gün spesifik öngörülerde güçlü olabileceğini doğrulamaktadır.

5.3.5. Yönetimsel İçgörüler

Yaptığımız analizler, hedef değişkenlerin tahmininde kullanılan özelliklerin günlere bağlı olarak değiştiğini ve her hedef için farklı bir özellik kümesi belirlemenin tahmin doğruluğunu artırdığını göstermektedir. İlk günün SWI değerleri, özellikle kısa vadeli

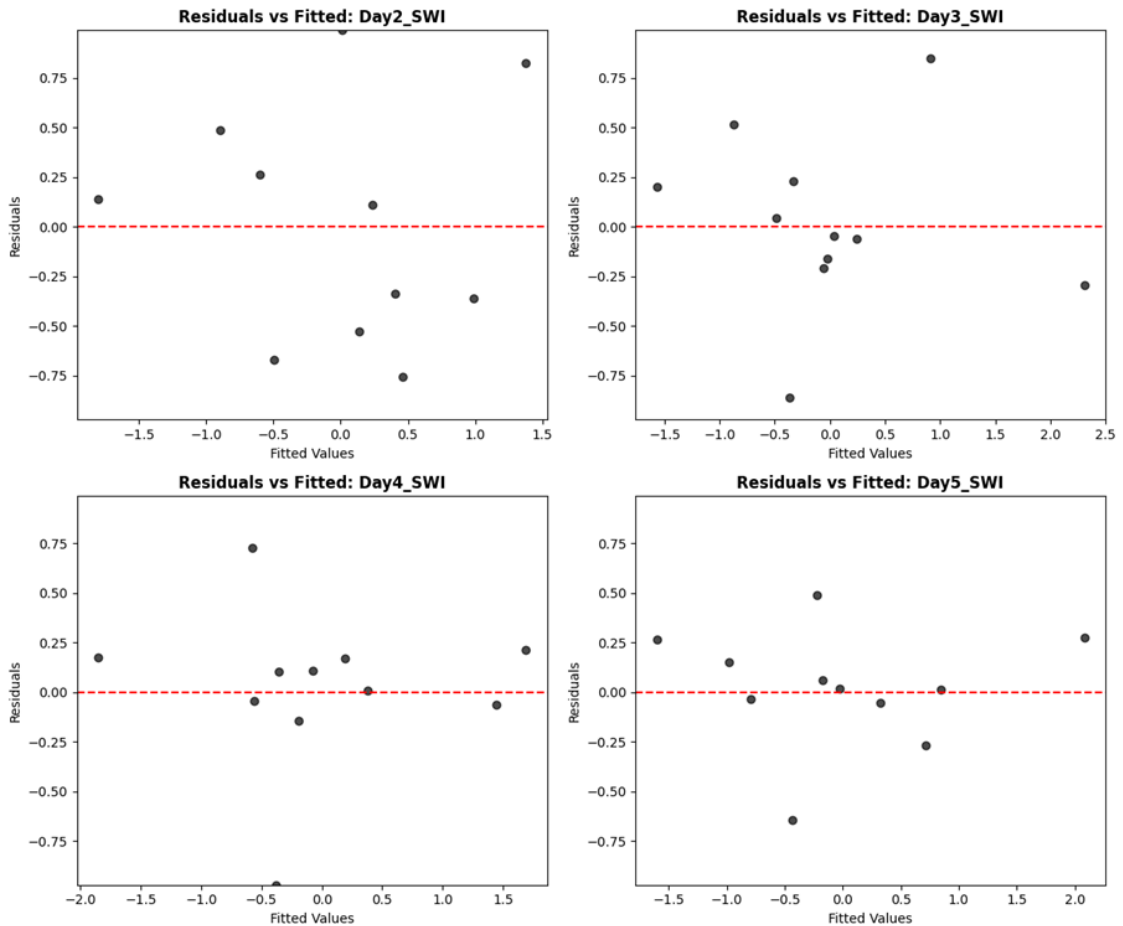
tahminlerde önemli bir değişken olarak kullanılmış olsa da ilerleyen günlerde modelde yer almaması, dijital hareketliliğin etkisinin zaman içinde kaybolduğunu söylemektedir. Günler geçtikçe farklı faktörlerin ön plana çıktığı görülmektedir. Özellikle, kısa vadeli tahminlerde (örneğin, 2. Gün SWI ve 3. Gün SWI) önceki günlerin SWI değerleri güçlü bir tahmin edici olurken, uzun vadede (4. Gün SWI ve 5. Gün SWI) ekonomik göstergeler, nüfus yoğunluğu ve yapısal risk faktörleri gibi daha stabil değişkenler daha baskın hale gelmektedir.

Sonuç olarak, her hedef değişken için özelleştirilmiş bir özellik seçimi yapmak, modelin tahmin gücünü önemli ölçüde artırmaktadır. Özellikle, ilk günlerdeki hareketlilik tahmin açısından önemli bir değişken olsa da ilerleyen günlerde bu etkinin yerini Nüfus Yoğunluğu, Gelir Seviyesi ve Yapısal Risk Faktörleri gibi değişkenlere bıraktığı görülmektedir. Bu bulgu, kısa vadeli tahminler için farklı, uzun vadeli tahminler için ise daha geniş ölçekli değişkenlerin dikkate alınması gerektiğini ortaya koymaktadır.

2.Gün SWI, 3.Gün SWI, 4.Gün SWI ve 5.Gün SWI için regresyon denklemleri, bir depremden sonra acil yardım ihtiyaçlarını etkileyen temel faktörleri vurgulamaktadır. x_1 (1.Gün SWI), sürekli olarak güçlü bir pozitif etki göstermektedir ve bu da başlangıçtaki acil ihtiyaçların sonraki talepleri tahmin ettiğini göstermektedir. x_4 (Ortalama Kat Sayısı) ve x_8 (Nüfus Yoğunluğu³) sürekli yardım ihtiyaçlarıyla pozitif olarak ilişkilidir ve yoğun nüfuslu, çok katlı alanlarda daha yüksek bir kırılma olduğunu göstermektedir. x_{30} (Ekonomi Kümesi_1), x_{21} (Nüfus x Eski Binalarda Oturan Hane Halkı Oranı) ve x_{32} (Risk Kümesi_1) için negatif katsayılar, belirli ekonomik veya tehlikeyle ilgili bağlamlarda zamanla azalan aciliyet anlamına gelir. Bu sonuçlar hem yapısal hem de sosyo-demografik faktörlerden etkilenen değişen ihtiyaçları yansıtmaktadır. x_1 'in tüm günlerdeki tutarlı etkisi, başlangıçta yüksek acil yardım gereksinimleri olan alanlarda sürekli desteğe olan ihtiyacı vurgulamaktadır. x_4 ve x_8 gibi öznitelikler, yoğun nüfuslu, çok katlı bölgelerin daha fazla kaynak gerektirebileceğini öne sürüyor. x_{30} ve x_{32} 'nin tam bileşimi belirsiz olsa da önemli etkileri, belirli sosyo-ekonomik ve tehlikeyle ilgili faktörlerin acil yardım ihtiyaçlarını şekillendirmede rol oynadığını gösteriyor. Bu kalıplar gerçek dünya afet müdahaleleriyle uyumlu ve modelin hedeflenen acil durum yönetimi stratejilerine rehberlik etmedeki pratik önemini destekliyor.

5.3.6. Modelin Doğrulanması

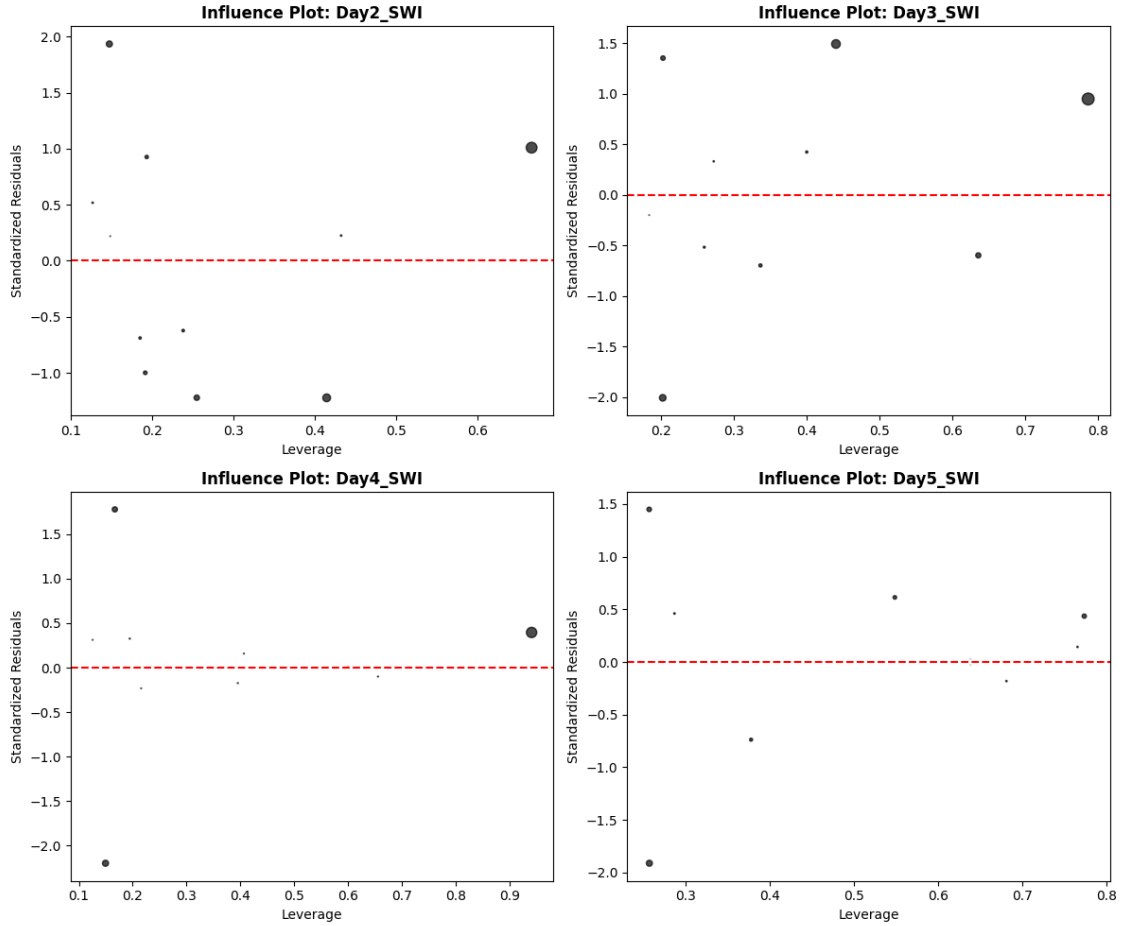
2.Gün SWI, 3.Gün SWI, 4.Gün SWI ve 5.Gün SWI için Şekil 5.7’de yer alan artık grafikleri, doğrusallık varsayımının genel olarak geçerli olduğunu gösteren sıfır çizgisinin etrafına dağılmış artıkları gösterir. Artıklar, belirgin desenler olmadan rastgele dağılmış gibi görünür ve doğrusal olmama veya model yanlış belirlenmesine dair güçlü bir kanıt olmadığını gösterir. Yayılmada bazı küçük değişiklikler mevcut olsa da varyans, uygun değerler arasında nispeten tutarlı kaldığı için, heteroskedastisiteye dair net bir işaret yoktur. Birkaç aykırı değer fark edilebilir, ancak bunlar artık dağılımına hâkim değildir. Genel olarak, bu grafikler regresyon modellerinin geçerliliğini destekler ve modellerin verilere makul ölçüde uyduğunu gösterir.



Şekil 5.7. Artık Grafikleri

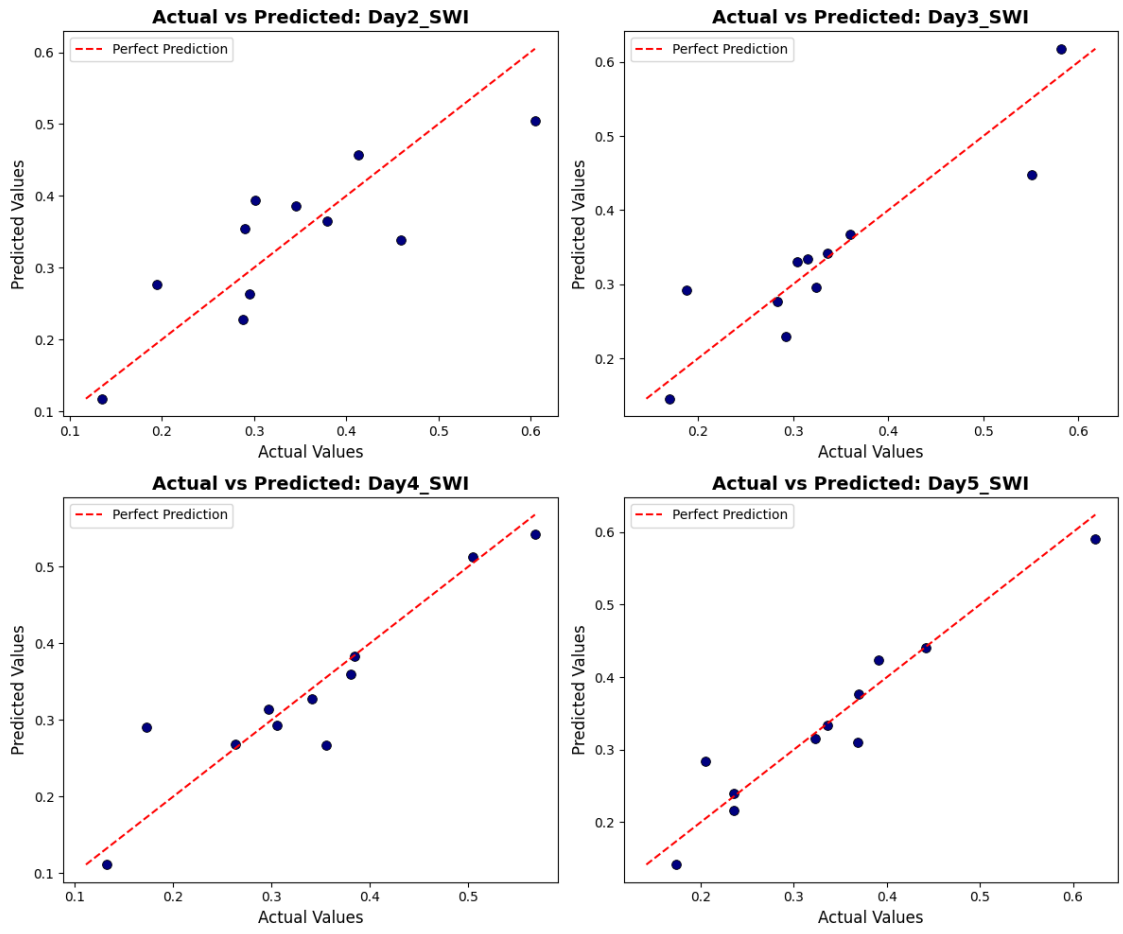
2.Gün SWI, 3.Gün SWI, 4.Gün SWI ve 5.Gün SWI için Şekil 5.8.’de yer alan etki grafikleri, çoğu gözlemin düşük kaldıraç ve kabul edilebilir bir aralıkta standartlaştırılmış artıklar sahip olduğunu gösteriyor ve bu da modelin bireysel veri noktalarından aşırı

etkilenmediğini gösteriyor. Daha yüksek kaldıraç ve daha büyük Cook mesafelerine sahip birkaç gözlem mevcut ancak bunlar modelin davranışına hâkim değil ve bu da sağlamlığı gösteriyor. Aşırı uç değerlerin ve etkili noktaların olmaması, modelin kararlılığını destekliyor ve regresyon sonuçlarının güvenilirliğini doğruluyor.



Şekil 5.8. Etki Grafikleri

Son olarak Şekil 5.9’da gerçek ve tahmin edilen değerleri 1-1 çizgili nokta grafiğinde sunmaktayız. Şekillerde, çoğu noktanın mükemmel tahmin çizgisiyle yakın bir şekilde hizalandığını ve güçlü model performansına işaret ettiğini göstermektedir. Küçük sapmalar mevcut olsa da 1-1 çizgisi etrafında yer alma ve çizgi trendini takip etme, modelin altta yatan eğilimleri doğru bir şekilde yakaladığını göstermektedir.



Şekil 5.9. Gerçek ve Tahmin Edilen Değerler

6. MATEMATİKSEL OPTİMİZASYON İLE KAYNAK TAHSİSİ

Afet sonrası yardım operasyonları zamanla yarışan, karmaşık ve kaynakların kısıtlı olduğu ortamlarda yürütülmektedir. Bu nedenle, doğru zamanda doğru yere doğru kaynağın yönlendirilmesi hem insan hayatını kurtarmak hem de yardım etkinliğini artırmak adına hayati öneme sahiptir. Bu tür karar problemleri, belirsizlik ve çok sayıda etkenin bulunduğu sistemlerde optimizasyon teknikleriyle daha etkin bir şekilde çözülebilir. Literatürde sıklıkla kullanılan yaklaşımlar arasında ağ akış modelleri, tesis yeri belirleme problemleri ve araç yönlendirme problemleri yer almakta olup, bu modeller yardımıyla kaynak tahsisi süreçleri sistematik hale getirilmektedir.

Biz bu çalışmada, önceki bölümlerde tahmin ettiğimiz SWI değerlerini girdi olarak kullanan bir matematiksel optimizasyon modeli geliştiriyoruz. Modelimizin amacı, afetin sonraki günlerinde ihtiyaç duyulacak yardım seviyelerini öngören SWI tahminlerine dayanarak, sınırlı sayıdaki kurtarma, sağlık ve lojistik ekiplerinin ve bunlara bağlı ekipmanların zaman ve mekân boyutunda dengeli bir şekilde tahsis edilmesini sağlamaktır. Bu kapsamda, karar değişkenleri ekiplerin nerede ve hangi günde görevlendirileceğini, kısıtlar ise ekip sayıları, hareket kabiliyetleri, akış dengeleri ve ekip bağımlılıkları gibi faktörleri içermektedir. Modelimiz deterministik bir ağ yapısı üzerinde çalışmakta ve tahmin aşamasında elde edilen bilgiyle beslenerek veriye duyarlı bir kaynak planlama mekanizması sunmaktadır.

6.1. Modelin Tanımı

Bu çalışmanın ikinci aşamasında, afet sonrası müdahale sürecine yönelik olarak geliştirdiğimiz kaynak tahsis optimizasyon modeli, Türkiye genelinde konumlanmış yedi temel ekip türünün (arama-kurtarma (R), medikal (M), ekipman (E), barınma (B), iletişim-enerji (IE), güvenlik (G) ve tıbbi malzeme (T)) 6–10 Şubat tarihleri arasında, 11 afet bölgesine zamansal ve mekânsal açıdan en uygun biçimde atanmasını hedeflemektedir.

Modelin amaç fonksiyonu, bu sınırlı kaynakları barındıran illerden yüksek öncelikli afet bölgelerine yapılan ilk tahsislerin yanı sıra, afet bölgeleri arasındaki saha içi transfer hareketlerini de göz önünde bulundurarak toplam lojistik maliyeti minimize etmektir. Bu yönüyle model, yalnızca doğrudan atamaları değil, aynı zamanda afet sahasındaki ikincil lojistik hareketliliği de dikkate alarak operasyonel gerçekliği daha doğru yansıtan bütüncül bir planlama aracı sunar.

Modelin dikkat çeken özelliklerinden biri, klasik nüfus-temelli sabit talep varsayımları yerine, çalışmamızın “tahmin et” aşamasında geliştirilen ve sosyal medya gönderileri ile arama motoru eğilimlerinden elde edilen SWI endeksini talep girdisi olarak kullanmasıdır. Bu endeks, afet anındaki dijital etkileşimleri (yardım çağrıları, bilgi aramaları vb.) analiz ederek, hangi bölgelerde yardıma öncelik verilmesi gerektiğini ve bölgeler arasındaki göreceli talep düzeylerini yansıtmaktadır. Böylece model hem dinamik sosyal sinyalleri hem de lojistik parametreleri dikkate alarak daha isabetli ve zamanında kaynak yönlendirmesi yapılmasına imkân tanımaktadır.

Geliştirdiğimiz model, doğrusal programlama formunda kurgulanmış bir ağ-akış modelidir. Bu sınıflandırma, modelin yapısal mantığından kaynaklanmaktadır: kaynak noktaları (ekiplerin konuşlandığı iller), hedef noktalar (afet bölgeleri) ve bu noktalar arasında ekiplerin hareketini temsil eden yönlü bağlantılar (gün ve bölge bazında) bir ağ (graph) yapısı oluşturur. Bu ağda, her bağlantı belirli bir kapasite ve maliyet ile tanımlanır. Karar değişkenleri, her ekip türünün, hangi gün, hangi bölgede ve hangi görevde yer alacağını belirlerken; modelde yer alan kısıtlar, kapasite sınırları, ekipman bağımlılıkları, hareket kısıtları ve sabit kalma zorunlulukları gibi çeşitli lojistik kuralları uygular. Modelimiz, afet ve acil durum yönetimi alanında bilimsel tabanlı planlamanın artırılması için katkı sunmaktadır.

6.2. Matematiksel Notasyonu

Kaynak tahsis optimizasyon modelimiz için kullandığımız matematiksel notasyonumuzu Çizelge 6.1’de sunuyoruz.

Çizelge 6.1. Kaynak Tahsis Optimizasyon Modeli Matematiksel Notasyon

| Kümeler | |
|--------------------|--|
| $G = (N, A)$ | Ağ yapısı, N düğüm kümesi, $A \subseteq N \times N$ bağlantı kümesidir. |
| I | Tedarik şehirleri kümesi |
| J | Talep (afet) şehirleri kümesi |
| N | Tüm düğüm kümesi, burada $N = I \cup J$ |
| T | Planlanama dönemindeki günler kümesi, $T = \{1, 2, \dots, t_{max}\}$ |
| K | Ekip Tipleri Kümesi, $K = R \cup M \cup E \cup B \cup T \cup IE \cup G$, burada R : Arama kurtarma ekipleri M : Sağlık ekipleri B : Barınma ekipleri T : Tıbbi malzeme ekipleri G : Güvenlik ekipleri E : Ekipman ekipleri IE : İletişim-Enerji altyapı ekipleri |
| Parametreler | |
| $s_{i,t,k}$ | $i \in I$ tedarik şehrinde, $t \in T$ gününde, $k \in K$ türünden mevcut ekip sayısı (başlangıç stoku). |
| $SWI_{j,t}$ | $j \in J$ talep şehrinin, $t \in T$ günündeki yardım talebi indeksi. |
| $d_{i,j}$ | i ve j düğümleri arasındaki coğrafi mesafe (km). |
| f_k | $k \in K$ türündeki ekiplerin afet bölgesi içindeki şehirlerarası yer değişiminde uygulanan sabit taşıma maliyeti. |
| Karar Değişkenleri | |
| $x_{i,j,t,k}$ | t günü itibarıyla, tedarik noktası $i \in I$ çıkışlı olup talep noktası $j \in J'$ de görev yapan $k \in K$ türündeki ekiplerin toplam sayısıdır. Önceki günlerde atanıp hâlâ görevde olan ekipleri de içerir. Dolayısıyla, sahada aktif olarak bulunan ekiplerin kümülatif varlığını temsil eder. |
| $y_{i,j,t,k}$ | t gününde, tedarik noktası $i \in I$ 'den talep noktası $j \in J'$ 'ye doğrudan ilk kez sevk edilen $k \in K$ türü yeni ekiplerin sayısıdır. Bu değişken, kaynak illerden afet bölgelerine yapılan ilk dağıtım kararlarını temsil eder. |
| $m_{i,j,j',t,k}$ | t günü sonunda, talep noktası $j \in J$ 'den başka bir talep noktası $j' \in J'$ 'ye, $j \neq j'$, transfer edilen $k \in K$ türündeki ekiplerin sayısıdır. Bu değişken, ekiplerin afet bölgeleri arasındaki yer değiştirme kararlarını temsil eder. |
| $\lambda_{t,k}$ | t gününde tüm bölgelerde geçerli olacak şekilde birim SWI başına tahsis edilmesi gereken ortalama $k \in K$ türündeki ekip sayısını gösterir. Bu değişken, modelin talep duyarlılığını kontrol eden orantılı tahsis katsayısını temsil eder. |

6.3. Optimizasyon Modeli

Çizelge 6.1.'deki notasyonu kullanarak formüle ettiğimiz matematiksel optimizasyon modelimiz aşağıdaki gibidir:

$$\begin{aligned} \min \sum_{i \in I} \sum_{j \in J} \sum_{t \in T} \sum_{k \in K} d_{i,j} \cdot y_{i,j,t,k} \\ + \sum_{i \in I} \sum_{j \in J} \sum_{\substack{j' \in J \\ j' \neq j}} \sum_{t \in T \setminus \{t_{max}\}} \sum_{k \in K \setminus \{E, IE\}} (d_{j,j'} + f_k \cdot 1_{j \neq j'}) \cdot m_{i,j,j',t,k} \end{aligned} \quad (16)$$

s. t.

$$\sum_{j \in J} x_{i,j,t,k} = \sum_{t'=1}^t s_{i,t',k} \quad \forall i \in I, t \in T, k \in K \quad (17)$$

$$\sum_{j \in J} y_{i,j,t,k} = s_{i,t,k} \quad \forall i \in I, t \in T, k \in K \quad (18)$$

$$\sum_{j \in J} m_{i,j,j',t,k} \leq x_{i,j,t,k} \quad \forall i \in I, j \in J, t \in T \setminus \{t_{max}\}, k \in K \setminus \{E, IE\} \quad (19)$$

$$x_{i,j',(t+1),k} = y_{i,j',(t+1),k} + \sum_{j \in J} m_{i,j,j',t,k} \quad \forall i \in I, j' \in J, t \in T \setminus \{t_{max}\}, k \in K \setminus \{E, IE\} \quad (20)$$

$$x_{i,j,(t+1),k} = x_{i,j,t,k} + y_{i,j,(t+1),k} \quad \forall i \in I, j \in J, t \in T \setminus \{t_{max}\}, k \in \{E, IE\} \quad (21)$$

$$\sum_{i \in I} x_{i,j,t,k} = \lambda_{t,k} \cdot SWI_{j,t} \quad \forall j \in I, t \in T, k \in K \setminus \{E, IE\} \quad (22)$$

$$\sum_{i \in I} x_{i,j,t,R} \leq 3 \sum_{i \in I} x_{i,j,t,M} \quad \forall j \in J, t \in T \quad (23)$$

$$\sum_{i \in I} x_{i,j,t,R} \leq 5 \sum_{i \in I} x_{i,j,t,E} \quad \forall j \in J, t \in T \quad (24)$$

$$\sum_{i \in I} \sum_{k \in K \setminus \{IE\}} x_{i,j,t,k} \leq 30 \sum_{i \in I} x_{i,j,t,IE} \quad \forall j \in J, t \in T \quad (25)$$

$$x_{ijtk}, y_{ijtk}, m_{ijj'tk} \geq 0 \quad \forall i \in I, j, j' \in J, t \in T, k \in K \quad (26)$$

$$\lambda_{t,k} \geq 0 \quad \forall k \in K \setminus \{E, IE\} \quad (27)$$

Arama kurtarma, medikal, ekipman, barınma, iletişim-enerji, güvenlik ve tıbbi malzeme ekipleri de dahil olmak üzere farklı afet müdahale ekiplerinin dağıtımını planlamak ve yönetmek için çok önemli doğrusal programlama modeli sunuyoruz. Modelimiz, her bölgedeki ihtiyaç seviyesini temsil etmek için sosyal medya verilerine dayalı makine öğrenimi yöntemleri kullanılarak hesaplanan SWI değerlerini kullanarak çalışmaktadır. Bu SWI değerleri, ekiplerin bölgelere nasıl atanacağını yönlendirir, böylece daha fazla yardım, daha fazla ihtiyaç duyulan bölgelere gönderilir. Modelimiz, kurtarma ekiplerinin ihtiyaç duyduğu ekipman, seyahat masrafları ve ekipman ekiplerinin dağıtıldıktan sonra

tek bir yerde kalma kuralı gibi önemli gerçek dünya faktörlerini içerir. Bir ağ akışı bakış açısından, model, her ekip türünün zaman içinde bir bölge ağında hareket eden ayrı bir akış olarak ele alındığı çok emtialı, zaman genişletilmiş bir ağ akışı sorunu olarak görülebilir. Bu model, ekip türleri, hareketsiz destek ekipleri ve gerçek zamanlı sosyal web verilerinden tahmin edilen talep seviyeleri arasında koordinasyon kuralları ekleyerek klasik kaynak planlamasını ve akış tabanlı optimizasyonu genişletir.

Amaç fonksiyonumuz iki bileşenden oluşur:

- a. İlk terim, yeni kullanılabilir ekiplerin kullanılabilir hale geldikleri günlerde tedarik şehirlerinden talep bölgelerine atanmasının toplam mesafesini hesaplar. Her atama için mesafe tedarik düğümü i ile talep düğümü j arasındaki $d_{i,j}$ mesafesinin çarpımı olarak hesaplanır ve atanan ekip sayısı $x_{i,j,t,k}$ ile çarpılır.
- b. İkinci terim, ekiplerin ardışık günlerde talep bölgeleri arasında yeniden atanmasının toplam mesafesini yakalar. Buna, d günü ile $d+1$ günü arasında j bölgesinden j' bölgesine taşınan her ekip için sabit bir yer değiştirme maliyeti f_k dahildir. “Ekipman” ekipleri ve “İletişim-Enerji” ekipleri, konuşlandırıldıktan sonra hareket etmelerine izin verilmediği için bu maliyete katlanmazlar. Modelin amacı, planlama ufku boyunca toplam oluşan maliyeti en aza indirirken ekipleri mümkün olduğunca verimli bir şekilde konuşlandırmak ve yeniden tahsis etmektir.

Kısıt (17), her bir tedarik noktası $i \in I$, gün $t \in T$ ve ekip türü $k \in K$ için, t gününe kadar i çıkışlı olarak sahaya gönderilen k tipi ekiplerin tüm talep noktalarındaki toplam varlığının, aynı döneme kadar ilgili tedarik noktasından sağlanan ekip sayısına eşit olmasını garanti eder. Başka bir deyişle, herhangi bir gün t 'de sahada aktif olan tüm i çıkışlı k tipi ekiplerin toplamı, o güne kadar yapılan i çıkışlı tedarik miktarlarının birikimli toplamına eşitlenmektedir.

Kısıt (18), her bir tedarik noktası $i \in I$, gün $t \in T$ ve ekip türü $k \in K$ için, ilgili günde i noktasında kullanılabilir durumda olan k tipi ekiplerin tamamının doğrudan talep noktalarına ilk kez sevk edilmesini zorunlu kılar. Başka bir deyişle, t gününde i kaynağında mevcut olan tüm yeni ekipler, aynı gün içerisinde afet bölgelerine ilk kez atanmakta ve bu sayede sistemde bekleyen hiçbir ekip kalmaksızın tüm kaynakların etkin biçimde kullanılması sağlanmaktadır.

Kısıt (19), her bir tedarik noktası $i \in I$, talep noktası $j \in J$, gün $t \in \{1, \dots, T - 1\}$ ve ekip türü $k \in K \setminus \{E, IE\}$ için, afet bölgeleri arasındaki ekip transferlerinin yalnızca hâlihazırda ilgili talep noktasında görev yapmakta olan ekipler üzerinden gerçekleştirilebileceğini garanti eder. Başka bir deyişle, gün t itibarıyla j noktasında aktif olarak bulunan i çıkışlı k tipi ekiplerin toplam sayısı, aynı gün sonunda başka bir talep noktasına transfer edilen ekiplerin toplamını karşılamalıdır. Böylece, sistemde olmayan ya da görevde bulunmayan ekiplerin transfer edilmesi engellenerek, kaynak hareketliliğinde operasyonel tutarlılık sağlanmaktadır. Bu kısıt E ve IE tipi takım için hiç yazılmaz, çünkü bu takımlarının gittikleri yerde tüm planlama dönemi boyunca konuşlanma şartı vardır ve afet bölgeleri arasında yer değiştirmesine izin verilmez.

Kısıt (20), her bir tedarik noktası $i \in I$, talep noktası $j \in J$, gün $t \in \{1, \dots, T - 1\}$ ve ekip türü $k \in K \setminus \{E, IE\}$ için, bir talep noktasında $(t + 1)$. gününde görev yapan ekiplerin güncellenmiş toplamını belirler. İlgili noktadaki ekip varlığı, doğrudan tedarik noktasından sevk edilen yeni ekipler ile bir önceki günde diğer afet bölgelerinden bu noktaya transfer edilen ekiplerin toplamından oluşur. Böylece, her bir talep noktasındaki ekip mevcudu dinamik biçimde izlenir ve ekip hareketliliği zaman ve mekâna bağlı olarak sistematik şekilde güncellenir.

Kısıt (21), her bir tedarik noktası noktası $i \in I$, talep noktası $j \in J$, gün $t \in \{1, \dots, T - 1\}$ ve ekip türü $k \in \{E, IE\}$ için, sahadaki ekip varlığının zamansal olarak nasıl güncellendiğini tanımlar. Buna göre, j talep noktasında $(t + 1)$ günü itibarıyla görevde bulunan i çıkışlı k tipi ekiplerin toplamı, önceki günün (t) görevdeki ekiplerine ek olarak $(t + 1)$ gününde doğrudan sevk edilen yeni ekiplerden oluşur. Bu ekip tipleri için talep bölgeleri arasında transfer mümkün olmadığından denklem bununla ilgili bir bileşen içermez.

Kısıt (22) bir adalet kısıtlamasıdır. Bir talep bölgesi j 'ye t gününde atanan ekip sayısının şiddet endeksi $SWI_{j,t}$ ile orantılı olmasını zorunlu kılar. Orantılılık faktörü $\lambda_{t,k}$ ekip türüne özgüdür ancak tüm günler ve bölgeler arasında paylaşılır. Bu, yüksek şiddetteki bölgelerin tüm sistem boyunca tutarlı ve orantılı bir şekilde daha fazla destek almasını sağlar. Bu yapı, ekip dağılımının veri temelli bir şekilde çevrimiçi davranış verilerinden türetilmiş görece ihtiyaçlara uyumlu olmasını garanti eder.

Kısıt (23), kurtarma ve tıbbi ekipler arasında bir bağımlılık ilişkisi yaratır. Belirli bir günde bir bölgeye atanan kurtarma ekibi sayısının, aynı bölgeye atanan tıbbi ekip

sayısının üç katını geçemeyeceğini belirtir. 3'e 1 oranı, tıbbi ekiplerin aktif kurtarma görevleri sırasında triyaj, tedavi ve kazazede yönetimini hesaba katarak birden fazla kurtarma operasyonu için merkezi destek sağladığı gerçekçi bir operasyonel ilişkiyi yansıtır.

Kurtarma ekipleri, bölgeye önceden yerleştirilmesi gereken özel ekipmanlara (örneğin, kesme aletleri, dronlar, kazı ekipmanı) ihtiyaç duyar. Kısıt (24), herhangi bir günde bir bölgede faaliyet gösteren kurtarma ekibi sayısının, o bölgeye konuşlandırılan ekipman ekibi sayısının beş katını geçemeyeceğini garanti eder. Ekipman ekibi konuşlandırmaları 1. günde sabitlenir ve bundan sonra hareket edemez. Bu, ekipmanı kurtarma operasyonlarını etkinleştiren sınırlı ancak paylaşılabılır bir kaynak olarak modeller.

Herhangi bir günde faaliyet gösterecek tüm ekipler iletişim ve enerjiye ihtiyaç duyar. Kısıt (25), tüm ekiplerinin toplamının ihtiyacını karşılayacak kadar iletişim ve enerji ekibinin ilgili bölgelere gönderilmesini sağlar. Buradaki varsayımımız bir iletişim-enerji ekibinin 30 ekibe hizmet verebileceğidir. Kısıt (26), değişkenlerin negatif olmaması ve bütünlüğünü tanımlar. Tüm dağıtım ve hareket karar değişkenleri, negatif olmayan sürekli sayılar olmalıdır.

Kısıt (27), orantılılık faktörlerinin negatif olmaması tanımıdır. Ekipler için birim önem derecesine göre atanan takımları temsil eden $\lambda_{t,k}$ parametreleri negatif olmamalıdır. Bu değerler model tarafından belirlenir ve SWI tabanlı tahsis kuralı kapsamında sistem genelindeki yanıt yoğunluğunu yansıtır.

6.4. Deneysel Kurulum

Optimizasyon çalışmalarımızı Intel Core i7 işlemci, 16 GB RAM donanımlı bir bilgisayar ile Gurobi 12.0.1, Python 3.11 yazılım ile gerçekleştirmekteyiz. Modelimizde kullandığımız parametreleri gerçek hayatı yansıtacak şekilde hazırlıyoruz. İller arası mesafeyi gösteren $d_{i,j}$ parametresini tüm şehir çiftleri arasındaki mesafe kilometre cinsinden olacak şekilde T.C. Karayolları Genel Müdürlüğü'nün yayımladığı "İller Arası Mesafe Cetveli" kullanarak belirlemekteyiz. $SWI_{j,t}$ parametresini önceki bölümler anlattığımız şekilde hesaplamakta, $s_{i,t,k}$ parametresini detayları aşağıda yer alan paragraftaki bir dizi matematiksel işlemlerden sonra hesaplamaktayız.

Deney senaryolarımızı yaratırken temel amacımız afet sonrası yardım için afet bölgesine görevlendirilecek ekiplerin, Türkiye genelindeki deprem öncesi konumlandırılmasının sonuçlar üzerindeki etkilerini görmektir. Daha detay vermek gerekirse, afetten etkilenen

11 bölgemiz olduğu için talep noktası sayısını her senaryoda 11 tutuyoruz. Talep noktaları olarak, 6 Şubat 2023 tarihinde meydana gelen ve merkez üssü Kahramanmaraş olan depremlerden doğrudan etkilenen 11 ili (Adana, Adıyaman, Diyarbakır, Elâzığ, Gaziantep, Hatay, Kahramanmaraş, Kilis, Malatya, Osmaniye ve Şanlıurfa) kullanılmaktadır. Tedarik noktası sayısını ise sırasıyla 30, 35, 40, 45, 50, 55, 60, 65, 70, 75 ve 81 tedarik ilini içerecek şekilde yapılandırıyoruz. Tüm senaryolarda, ekip türleri için tanımlanan toplam kaynak miktarını sabit tutuyoruz (R için 2400, M için 1800, B için 2000, T için 3000, G için 2000, E için 1000 ve IE için 500). Bu ekip sayılarını afet sonrası ilk günlerde sahada ihtiyaç duyulabilecek operasyonel kaynakları dikkate alınarak gerçek hayat şartlarına uygun olarak belirlemekteyiz. Ardından bu ekip sayılarını Türkiye genelindeki tedarik illerine, nüfus büyüklüğüne dayalı kategorik katsayılarla ağırlıklandırılarak dağıtıyoruz. İlleri; büyükşehir (B), orta ölçekli şehir (O) ve küçük şehir (K) olmak üzere üç kategoriye ayırdık ve her kategoriye sırasıyla 1,0, 0,7 ve 0,5 ağırlık katsayısı atıyoruz. Her il için, bulunduğu kategorinin katsayısı ile toplam katsayıların oranı alınarak, o il için düşen kaynak miktarını hesaplıyoruz. Bu yaklaşım ile aynı büyüklük sınıfındaki illerin eşit kaynak almasını sağlarken, farklı büyüklükteki iller arasında da orantılı bir dağılım sağlıyoruz.

Örneğin, Adana büyükşehir kategorisinde yer aldığı için katsayısını 1,0 olarak alıyoruz. Tüm illerin ağırlık katsayılarının toplamı 48,28 olduğunda ve toplam M ekibi kapasitesi 1800 olduğunda, Adana'nın alacağı M ekibi miktarını aşağıda yer alan Denklem 28 ile hesaplamaktayız:

$$\text{Adana ili } M \text{ ekip sayısı} = 1800 \times (1 \div 48,28) \approx 37 \quad (28)$$

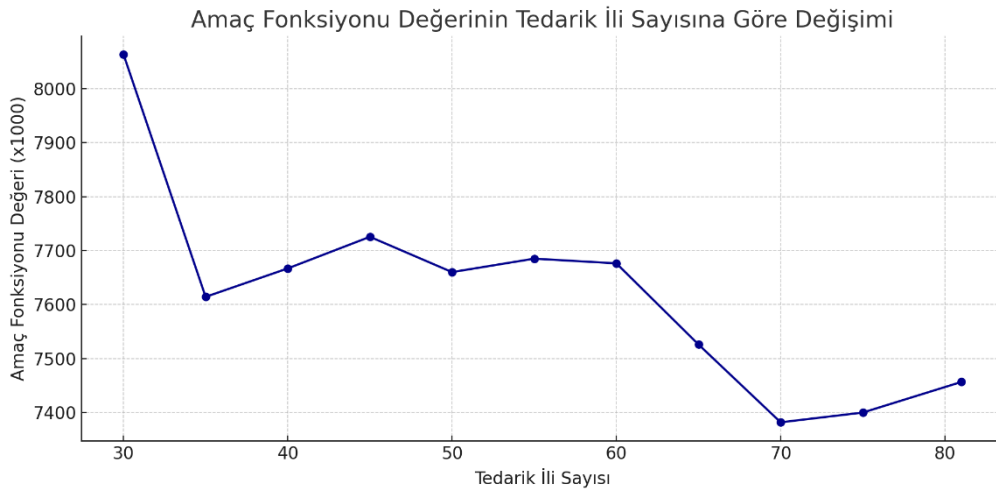
Modelimizin uygulanabilirliğini ve esnekliğini değerlendirebilmek amacıyla, farklı büyüklükteki afet senaryolarında kaynak tahsis stratejilerinin nasıl değiştiğini analiz etmeye yönelik çok sayıda vaka çalışması gerçekleştiriyoruz. Bu kapsamda, tedarik (kaynak) illerinin sayısı kademeli olarak artırılarak 11 farklı senaryo tanımlamaktayız. Her bir senaryo, afet sonrası müdahale kapasitesinin coğrafi kaynak yayılımına bağlı olarak nasıl değiştiğini gözlemlememize olanak sağlamaktadır.

6.5. Optimizasyon Sonuçları

Modelin performansı, her senaryo için elde edilen karar değişkeni değerleri ve optimum amaç fonksiyonu değeri üzerinden değerlendirilmekteyiz. Karar değişkenleri aracılığıyla,

hangi kaynak ilinden hangi afet bölgesine, hangi gün, hangi türde ve ne miktarda ekip yönlendirildiği belirlenmektedir.

Amaç fonksiyonu değeri, senaryoya özgü koşullar altında ulaşılabilecek en düşük toplam mesafe ve yer değiştirme maliyetlerini temsil etmektedir. Bu değer; ilk atamalarda oluşan mesafeler ile afet bölgesi içerisindeki ikincil yer değiştirme maliyetlerinin toplamından oluşmaktadır. Her senaryoda bu değer incelenmesiyle, tedarik altyapısının genişlemesinin amaç fonksiyonu üzerindeki etkisi incelenmektedir. Senaryoları bağlı olarak amaç fonksiyonunun değişimi Şekil 6.1.'de, Gurobi çözüm süresinin değişimi ise Şekil 6.2.'de sunmaktayız:



Şekil 6.1. Amaç Fonksiyonunun Senaryoları Göre Değişimi

Şekil 6.1'de görüldüğü üzere, amaç fonksiyonu değeri en düşük olan senaryo, 70 tedarik ili ile elde edilmiştir. Bu durum, modelin bu noktada en verimli kaynak tahsisini yaptığını ve sistem maliyetini minimum seviyeye çektiğini göstermektedir. 30 tedarik ili senaryosu, en yüksek amaç fonksiyonu değerini üretmiş ve bu da kaynakların az sayıda merkezden dağılmasının toplam maliyeti artırdığını göstermiştir. Bu tür senaryolarda, sınırlı erişim noktaları nedeniyle ekiplerin hedef bölgelere ulaşma süreleri veya koordinasyon yükü artmakta olabilir. 40–60 tedarik ili aralığında, amaç fonksiyonu değerleri nispeten dalgalı ancak daha düşük seviyelerdedir. Bu aralık, sistemin ölçeklenebilirliğinin ve denge arayışının sürdüğü bölgeyi temsil eder. 75 ve 81 il senaryolarında maliyet yeniden artış göstermektedir. Bu durum, tedarik ili sayısı arttıkça sistemde aşırı dağınıklığın ortaya çıkabileceğini, bunun da lojistik verimliliği azalttığını göstermektedir. Modelin amacı olan toplam maliyeti minimize etme doğrultusunda, tedarik ili sayısının çok az veya çok fazla olması dezavantajlıdır. Grafik, en uygun sonuçların orta seviyelerdeki tedarik ağı

genişliğinde (özellikle 65–70 il) elde edildiğini göstermektedir. Bu da dağıtımın dengeli biçimde merkezi ve yerel kaynaklarla yapılmasının sistem maliyetini en aza indirdiğini ortaya koymaktadır.

Şekil 6.2, Gurobi çözüm süresinin tedarik ili sayısına göre nasıl değiştiğini göstermektedir: Çözüm süreleri, genel olarak tedarik ili sayısı ile birlikte artmaktadır. Ancak, en yüksek süreli senaryoda bile (75 il senaryosu) çözüm süresi 10 saniyedir ve ihmal edilebilir. Bu nedenle modelimiz için çözüm süresiyle ve kalitesiyle ilgili bir endişe bulunmamaktadır.



Şekil 6. 2. Senaryolara Göre Çözüm Süresinin Değişimi

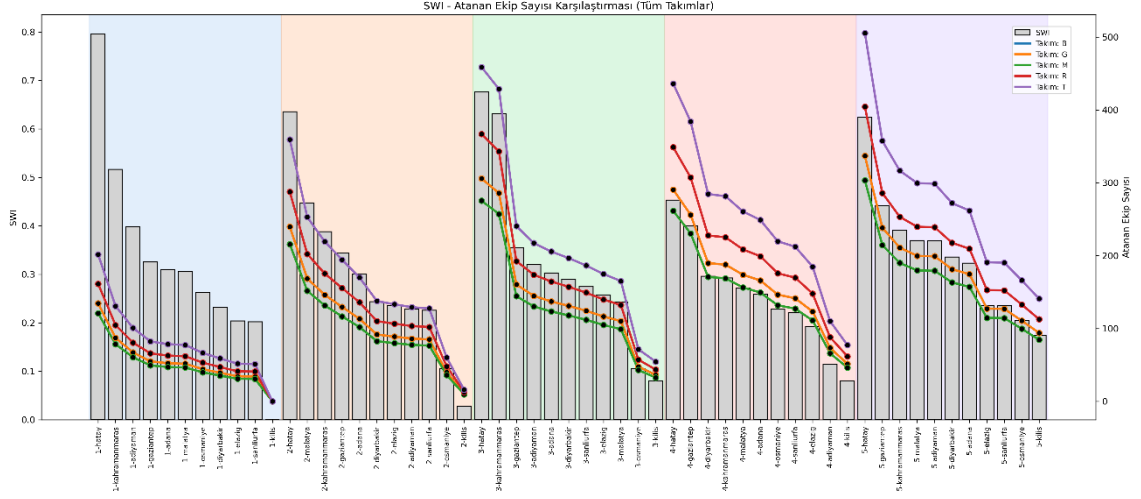
6.6. Matematiksel Model Sonuçları İle SWI'nın Değerlendirilmesi

Bu bölümde, $|I| = 30$ tedarik şehri senaryosunda, optimizasyon modelimizin raporladığı optimal çözümdeki dağıtım planının SWI değerleriyle uyumunu sunmaktayız. Sabit konumlu I ve IE ekipleri haricindeki tüm ekipler, 5 gün boyunca SWI değerlerine göre afet bölgelerine dağıtılmaktadır.

Şekil 6.3. depremde etkilenen 11 ilin her birine 5 gün boyunca tahsis edilen ekip sayılarını ve aynı günlerdeki SWI değerlerini karşılaştırmalı olarak göstermektedir. Şekil 6.3.'te yer alan beş renkli panel, sırasıyla 1. günden 5. güne kadar olan dönemleri temsil etmektedir. Her panelin içinde, iller o güne ait SWI değerlerine göre azalan sıralama ile yerleştirilmiştir.

- Sol Y eksen: Her ilin o gün için hesaplanan SWI değerini göstermektedir (0–1 aralığında).

- Sağ Y eksen: İllere ilgili günlerde tahsis edilen ekip sayısını ifade etmektedir.
- Gri çubuklar: SWI değerlerini temsil eder.
- Renkli çizgiler: Beş farklı ekip türü için (*R, M, B, T, G*) her ilde tahsis edilen ekip sayılarını göstermektedir. Her çizgi farklı bir renk ve işaretleyici ile belirtilmiştir.



Şekil 6.3. $|I|=30$ İçin Tahsis Edilen Ekip Sayıları ve SWI Değerleri

Şekil 6.3. tahsis edilen ekip sayılarının SWI değerleriyle genel olarak paralel bir dağılım gösterdiğini ortaya koymaktadır. Yani, yüksek SWI değerine sahip iller, çoğu zaman daha fazla sayıda ekip ile desteklenmiştir.

- Örneğin: Hatay, tüm günlerde en yüksek veya en yüksekler arasında SWI değerine sahip olmuş, buna karşılık her gün en fazla ekip bu ile tahsis edilmiştir.
- Kilis gibi düşük SWI değerine sahip illere ise çok daha az ekip gönderilmiştir; bu durum çizgilerin ve çubukların birlikte aşağıda yer almasıyla net biçimde gözlemlenmektedir.
- Farklı ekip türlerinin tahsis eğilimleri genel olarak birbirine paraleldir. Ancak bazı günlerde belirli ekip türlerinde (örneğin T ekipleri) farklılaşma gözlemlenmiştir. Bu durum, ekip türlerinin operasyonel kısıtları ya da ihtiyaçlara özgü farklılardan kaynaklanıyor olabilir.
- Bu şekil, modelin SWI temelli önceliklendirmeye uygun olarak dengeli ve ihtiyaç odaklı bir dağılım gerçekleştirdiğini görsel olarak doğrulamaktadır.

Şekilde sunulan sayıların daha detaylı hali 7-10 Şubat için Çizelge 6.2-6.5'te sırasıyla sunulmaktadır.

Çizelge 6.2, 7 Şubat günü için modelin önerdiği ekip dağılımlarını ve her afet şehrinin SWI değerlerini birlikte sunmaktadır. SWI, her bir talep şehri için görece öncelik seviyesini gösterdiğinden, tahsis edilen ekip sayılarının da bu değerlerle uyumlu olması beklenmektedir.

Çizelge 6.2. 7 Şubat'a İlişkin Tahsis Edilen Ekip Sayıları ve SWI Karşılaştırması

| Talep (Afet Şehri) | R | M | B | T | G | SWI Değeri |
|----------------------|-----|-----|-----|-----|-----|------------|
| Adana | 136 | 102 | 113 | 170 | 113 | 0,30 |
| Adıyaman | 103 | 78 | 86 | 129 | 86 | 0,23 |
| Diyarbakır | 110 | 83 | 92 | 138 | 92 | 0,24 |
| Elazığ | 107 | 80 | 89 | 133 | 89 | 0,24 |
| Gaziantep | 156 | 117 | 130 | 194 | 130 | 0,34 |
| Hatay | 288 | 216 | 240 | 359 | 240 | 0,64 |
| Kahramanmaraş | 176 | 132 | 146 | 219 | 146 | 0,39 |
| Kilis | 13 | 10 | 11 | 16 | 11 | 0,03 |
| Malatya | 202 | 152 | 169 | 253 | 169 | 0,45 |
| Osmaniye | 48 | 36 | 40 | 60 | 40 | 0,11 |
| Şanlıurfa | 102 | 77 | 85 | 128 | 85 | 0,23 |

Tablo incelendiğinde, Hatay en yüksek SWI değerine (0,64) sahip şehir olarak dikkat çekmektedir ve gerçekten de tüm ekip türleri için en fazla tahsis Hatay'a yapılmıştır (örneğin, 288 R ekibi, 359 T ekibi). Bu durum, modelin yüksek SWI'ya sahip şehirlere daha fazla kaynak tahsis ettiğini göstermektedir.

Malatya (SWI: 0,45) ve Kahramanmaraş (SWI: 0,39) gibi diğer yüksek SWI değerine sahip şehirlerin de yüksek sayıda ekip aldığı görülmektedir. Benzer şekilde, Kilis (SWI: 0,03) gibi düşük SWI değerine sahip şehirlerin çok sınırlı sayıda ekip aldığı (örneğin, sadece 13 R ekibi) dikkat çekmektedir. Bu da modelin, düşük öncelikli şehirlere kaynak tahsisini sınırlı tuttuğunu ortaya koymaktadır.

Bununla birlikte, Adıyaman, Diyarbakır, Elazığ ve Şanlıurfa gibi şehirlerin SWI değerleri birbirine oldukça yakın (0,23–0,24 aralığında) olmasına rağmen, ekip tahsislerinde küçük farklılıklar bulunmaktadır. Bu farklar modelin yalnızca SWI'ya değil, aynı zamanda ulaşılabilirlik, kapasite kısıtları ve ekip hareketliliği gibi diğer faktörleri de dikkate aldığını göstermektedir.

Genel olarak, modelin gerçekleştirdiği tahsisler ile SWI değerleri arasında güçlü bir pozitif ilişki olduğu görülmektedir. Bu da modelin amacına uygun biçimde, sosyal medya

temelli talep göstergelerini dikkate alarak afet bölgelerine dengeli ve öncelikli bir dağıtım gerçekleştirdiğini ortaya koymaktadır.

Çizelge 6.3, 8 Şubat günü için modelin önerdiği ekip dağılımlarını ve her afet şehrinin SWI değerlerini birlikte sunmaktadır.

Çizelge 6.3. 8 Şubat'a İlişkin Tahsis Edilen Ekip Sayıları ve SWI Karşılaştırması

| Talep (Afet Şehri) | R | M | B | T | G | SWI Değeri |
|--------------------|-----|-----|-----|-----|-----|------------|
| Adana | 165 | 123 | 137 | 206 | 137 | 0,30 |
| Adıyaman | 174 | 130 | 145 | 217 | 145 | 0,32 |
| Diyarbakır | 157 | 118 | 131 | 197 | 131 | 0,29 |
| Elazığ | 140 | 105 | 117 | 175 | 117 | 0,26 |
| Gaziantep | 192 | 144 | 160 | 241 | 160 | 0,35 |
| Hatay | 367 | 275 | 306 | 459 | 306 | 0,68 |
| Kahramanmaraş | 343 | 257 | 286 | 429 | 286 | 0,63 |
| Kilis | 44 | 33 | 36 | 54 | 36 | 0,08 |
| Malatya | 132 | 99 | 110 | 165 | 110 | 0,24 |
| Osmaniye | 57 | 43 | 48 | 72 | 48 | 0,11 |
| Şanlıurfa | 149 | 112 | 124 | 187 | 124 | 0,27 |

Hatay (SWI: 0,68) ve Kahramanmaraş (SWI: 0,63), en yüksek SWI değerine sahip iki il olarak öne çıkmaktadır. Model sonuçları bu önceliği açıkça yansıtmaktadır: her iki ile de tüm ekip türlerinden en yüksek tahsis yapılmıştır (örneğin, Hatay'a 459 T ekibi, Kahramanmaraş'a 429 T ekibi gönderilmiştir). Bu durum, modelin yüksek SWI değerine sahip bölgelere yoğun kaynak aktarımı yaptığını göstermektedir. Gaziantep (SWI: 0,35), Adıyaman (0,32) ve Adana (0,30) gibi orta düzey SWI'ya sahip iller de yüksek sayıda ekip ile desteklenmiştir. Bu illerdeki tahsisler de SWI değerleriyle orantılı olarak artmaktadır. Bu da modelin SWI farklarını hassas şekilde gözettiğini ortaya koymaktadır. Düşük SWI değerlerine sahip iller —örneğin Kilis (0,08), Osmaniye (0,11) ve Malatya (0,24)— daha sınırlı sayıda ekip tahsisi almıştır. Bu durum da kaynakların sınırlı olduğu bir ortamda modelin etkin önceliklendirme yaptığını teyit etmektedir.

Çizelge 6.4, 9 Şubat günü için 11 afet bölgesine tahsis edilen ekip sayılarını ve aynı günkü SWI değerlerini göstermektedir.

Çizelge 6.4. 9 Şubat'a İlişkin Tahsis Edilen Ekip Sayıları ve SWI Karşılaştırması

| Talep (Afet Şehri) | R | M | B | T | G | SWI Değeri |
|--------------------|-----|-----|-----|-----|-----|------------|
| Adana | 199 | 149 | 166 | 249 | 166 | 0,26 |

| Talep (Afet Şehri) | R | M | B | T | G | SWI Değeri |
|--------------------|-----|-----|-----|-----|-----|------------|
| Adıyaman | 88 | 66 | 73 | 110 | 73 | 0,11 |
| Diyarbakır | 228 | 171 | 190 | 285 | 190 | 0,30 |
| Elazığ | 148 | 111 | 123 | 185 | 123 | 0,19 |
| Gaziantep | 307 | 230 | 256 | 384 | 256 | 0,40 |
| Hatay | 349 | 262 | 291 | 436 | 291 | 0,45 |
| Kahramanmaraş | 225 | 169 | 188 | 282 | 188 | 0,29 |
| Kilis | 62 | 46 | 51 | 77 | 51 | 0,08 |
| Malatya | 209 | 156 | 174 | 261 | 174 | 0,27 |
| Osmaniye | 176 | 132 | 146 | 220 | 146 | 0,23 |
| Şanlıurfa | 170 | 127 | 142 | 212 | 142 | 0,22 |

En yüksek SWI değerine sahip iller Hatay (0,45) ve Gaziantep (0,40) olup, her iki şehir de en yüksek ekip tahsisini almıştır (örneğin Hatay’a 436 T ekibi, Gaziantep’e 384 T ekibi). Bu durum, modelin en yüksek önceliğe sahip şehirlere en yoğun tahsisi yaptığına işaret etmektedir. Diyarbakır (0,30), Kahramanmaraş (0,29), Malatya (0,27) ve Adana (0,26) gibi orta düzey SWI değerlerine sahip şehirlerde ekip tahsisleri benzer düzeylerde gerçekleşmiştir. Örneğin Diyarbakır’a 285 T ekibi, Malatya’ya 261 T ekibi gönderilmiştir. Bu tahsisler SWI sıralamasıyla genellikle uyumludur ve modelin adil ve dengeli dağıtım yaptığını gösterir. Düşük SWI değerine sahip şehirler arasında yer alan Adıyaman (0,11) ve Kilis (0,08), en az ekip alan şehirler olmuştur. Bu da modelin sınırlı kaynakları düşük öncelikli bölgelere daha az aktardığını doğrulamaktadır.

Sonuç olarak model, yüksek SWI değerlerine sahip şehirleri önceliklendirirken, diğer lojistik ve operasyonel faktörleri de göz önünde bulundurarak pratik ve dengeli bir dağılım gerçekleştirmiştir. Bu da karar destek sisteminin sadece “talep sinyallerini” değil, aynı zamanda saha gerçekliklerini dikkate alan bütünlük bir yapıya sahip olduğunu göstermektedir.

Çizelge 6.5, 10 Şubat tarihinde afet bölgelerine yapılan ekip tahsislerini ve bu illerin aynı güne ait SWI değerlerini birlikte sunmaktadır.

Çizelge 6.5. 10 Şubat’a İlişkin Tahsis Edilen Ekip Sayıları ve SWI Karşılaştırması

| Talep (Afet Şehri) | R | M | B | T | G | SWI Değeri |
|--------------------|-----|-----|-----|-----|-----|------------|
| Adana | 209 | 157 | 175 | 262 | 175 | 0,32 |
| Adıyaman | 239 | 179 | 199 | 299 | 199 | 0,37 |
| Diyarbakır | 218 | 163 | 181 | 272 | 181 | 0,34 |
| Elazığ | 153 | 115 | 127 | 191 | 127 | 0,24 |

| Talep (Afet Şehri) | R | M | B | T | G | SWI Değeri |
|---------------------------|----------|----------|----------|----------|----------|-------------------|
| Gaziantep | 286 | 214 | 238 | 357 | 238 | 0,44 |
| Hatay | 404 | 303 | 337 | 505 | 337 | 0,62 |
| Kahramanmaraş | 253 | 190 | 211 | 317 | 211 | 0,39 |
| Kilis | 113 | 85 | 94 | 141 | 94 | 0,17 |
| Malatya | 240 | 180 | 200 | 300 | 200 | 0,37 |
| Osmaniye | 133 | 100 | 111 | 166 | 111 | 0,21 |
| Şanlıurfa | 152 | 114 | 127 | 190 | 127 | 0,24 |

Hatay (0,62) en yüksek SWI değerine sahip şehir olarak öne çıkmakta ve model, buraya en fazla sayıda ekip göndermiştir (örneğin 505 T ekibi, 404 R ekibi). Benzer şekilde, Gaziantep (0,44) ve Kahramanmaraş (0,39) gibi yüksek SWI'lı iller de yüksek sayıda ekip tahsisi almıştır. Diyarbakır (0,34) ve Adana (0,32) gibi orta düzey SWI değerlerine sahip şehirler için de tutarlı ve dengeli ekip tahsisleri yapılmıştır. Örneğin, Diyarbakır'a 272 T ekibi, Adana'ya 262 T ekibi tahsis edilmiştir. Kilis (0,17), Osmaniye (0,21) ve Şanlıurfa (0,24) gibi daha düşük SWI değerlerine sahip şehirlerde ise ekip sayılarının daha az olduğu gözlemlenmektedir. Örneğin, Kilis'e 141 T ekibi gönderilmiştir; bu sayı Hatay'ın üçte birinden azdır ve SWI ile uyumludur. Modelin, 10 Şubat tarihli ekip tahsisleri ile SWI değerleri arasında güçlü bir korelasyon kurduğu görülmektedir. Yüksek SWI'ya sahip iller, istisnasız olarak yüksek sayıda ekip ile desteklenmiş; düşük öncelikli bölgelere ise kaynaklar daha sınırlı şekilde yönlendirilmiştir. Sonuç olarak, 10 Şubat'a ilişkin dağıtım planı, modelin SWI'yı etkili şekilde kullandığını ve sosyal medya verilerinden elde edilen talep sinyallerini karar sürecine başarıyla entegre ettiğini göstermektedir.

7. SONUÇ

Bu tez çalışmasında, afet sonrası acil yardım ekiplerinin etkin ve adil biçimde tahsisini sağlamak amacıyla veri odaklı bir karar destek modeli geliştirdik. Çalışma kapsamında, Google Trends arama verileri ile sosyal X gönderileri üzerinden elde edilen paylaşımlar analiz edilerek, afet sonrası talebi temsil eden SWI'yi geliştirdik. SWI aracılığıyla, iller düzeyinde ve gün bazında acil yardım ihtiyacını nicel olarak ortaya çıkardık. Literatürde, afet sonrası ihtiyaç genellikle sınırsız olarak varsayılmakta ve kaynak tahsisi bu doğrultuda yapılmaktadır oysa bu yaklaşım, gerçek yaşam koşullarını yansıtmaktan uzaktır. Bu yönüyle çalışmamız, talebi veriye dayalı biçimde sınırlı ve bölgesel olarak tanımlayarak mevcut literatüre önemli bir katkı sunmakta ve afet yönetimi uygulamalarına daha gerçekçi bir çerçeve kazandırmaktadır.

SWI'nın müteakip günlerdeki değerlerinin tahminlenmesi amacıyla Ridge regresyon modelleri kullandık. Başlangıçta sınırlı sayıda açıklayıcı özneliğimiz mevcutken, illerin demografik ve yapısal özellikleri dikkate alınarak öznelik mühendisliği uyguladık ve toplam 113 öznelik türettik. Bu öznelikler arasından varyans analizlerine dayalı seçim stratejileri ile modelin anlamlılığı ve genellenebilirliğini koruyacak şekilde 33 öznelik belirledik. Ridge regresyonun sunduğu L2 regülarizasyon sayesinde, yüksek boyutlu yapıda aşırı öğrenme riskini azaltıp ve SWI tahmin performansı güvenilir hale getirdik.

Tahmin edilen SWI değerleri, ardından ağ akış tabanlı optimizasyon modeli geliştirdik. Bu optimizasyon modeli ile farklı türdeki acil müdahale ekiplerinin afet bölgelerine en uygun şekilde tahsisi gerçekleştirdik. Modelde toplam 7 farklı ekip türünü (arama kurtarma, sağlık, ekipman, barınma, tıbbi malzeme, iletişim enerji ve güvelik) dikkate alarak, her biri için toplam kapasite kısıtları, şehir büyüklüklerine göre dağılım kuralları, belirli bölgelerde kalma zorunluluğu, ekip sıralama öncelikleri ve aynı günde aynı ekibin birden fazla bölgeye gitmemesi gibi gerçek hayata uygun lojistik ve operasyonel kısıtlar tanımladık. Bu sayede, teorik bir model yerine uygulamaya geçirilebilir bir çözüm yapısı hedefledik. Modelimizin çıktıları, yüksek SWI değerine sahip illere daha fazla kaynak yönlendirildiğini göstererek tahmin ve tahsis süreçlerimizin arasındaki tutarlılığı ortaya koymuştur.

Çalışmamızda geliştirdiğimiz modeli, doğrusal programlama yaklaşımıyla formüle ettik ve çözüm sürecini hızlandırmak adına karar değişkenlerini sürekli değişken olarak tanımladık. Gerçek uygulamalarda ekipler bölgelere tam sayı olarak gönderildiğinden,

modelin bu yönü pratikte sınırlılıklar oluşturabilir. Bu nedenle gelecek çalışmalarda, doğrusal programlama çerçevesi korunarak tam sayı programlama (mixed-integer linear programming, MILP) tekniklerinin uygulanması, çözümün gerçekçiliğini ve uygulanabilirliğini artıracak önemli bir gelişim alanı olarak değerlendirilmektedir.

8. KAYNAKLAR

- AFAD: İçişleri Bakanlığı Afet ve Acil Durum Yönetimi Başkanlığı. 06 Şubat 2023 Pazarcık (Kahramanmaraş) Mw 7.7 Elbistan (Kahramanmaraş) Mw 7.6 Depremleri Raporu, Ankara, 02.06.2023
- Alexander, D. (2018). *Natural disasters*. Routledge.
- Alexander, D. E. (2014). Social media in disaster risk reduction and crisis management. *Science and engineering ethics*, 20, 717-733.
- Alharm, A. O., veNaim, S. (2024). Enhancing natural disaster response: A deep learning approach to disaster sentiment analysis using bert and lstm. *Available at SSRN 4755638*.
- Arrar, D., vd. (2024). Implicit Sentiment Analysis of Hotel Comments for Disaster Management: A Comparative Study of Machine Learning, Deep Learning, and BERT Model. 2024 International Conference on Information and Communication Technologies for Disaster Management (ICT-DM),
- Cervantes, J., vd. (2020). A comprehensive survey on support vector machine classification: Applications, challenges and trends. *Neurocomputing*, 408, 189-215.
- Cheng, Z., vd. (2010). *You are where you tweet: a content-based approach to geolocating twitter users* Proceedings of the 19th ACM international conference on Information and knowledge management, Toronto, ON, Canada. <https://doi.org/10.1145/1871437.1871535>
- Chicco, D., vd. (2021). The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation. *Peerj computer science*, 7, e623.
- Devlin, J. (2018). Bert: Pre-training of deep bidirectional transformers for language understanding. *arXiv preprint arXiv:1810.04805*.
- Dolu, D. G., veŞen, A. (2024). Coğrafi referanslı sosyal medya verilerinden doğal dil işleme ve derin öğrenme kullanılarak duygu analizi: Kahramanmaraş depremleri örneği. *Jeodezi ve Jeoinformasyon Dergisi*, 11(1), 51-67.
- Dreiseitl, S., veOhno-Machado, L. (2002). Logistic regression and artificial neural network classification models: a methodology review. *Journal of biomedical informatics*, 35(5-6), 352-359.
- Dukkanci, O., vd. (2023). Drones for relief logistics under uncertainty after an earthquake. *European Journal of Operational Research*, 310(1), 117-132.
- Fiedrich, F., vd. (2000). Optimized resource allocation for emergency response after earthquake disasters. *Safety Science*, 35(1), 41-57. [https://doi.org/https://doi.org/10.1016/S0925-7535\(00\)00021-7](https://doi.org/https://doi.org/10.1016/S0925-7535(00)00021-7)
- Galindo, G., veBatta, R. (2013). Review of recent developments in OR/MS research in disaster operations management. *European Journal of Operational Research*, 230(2), 201-211.
- Han, Y., vd. (2011). Optimization based method for supply location selection and routing in large-scale emergency material delivery [Article]. *IEEE Transactions on Automation Science and Engineering*, 8(4), 683-693, Article 5937025. <https://doi.org/10.1109/TASE.2011.2159838>
- Imran, M., vd. (2013). *Practical extraction of disaster-relevant information from social media* Proceedings of the 22nd International Conference on World Wide Web, Rio de Janeiro, Brazil. <https://doi.org/10.1145/2487788.2488109>
- Khare, A., vd. (2023). Improving search for gasoline during a hurricane evacuation event using social media. *EURO Journal on Transportation and Logistics*, 100111.

- Khare, A., vd. (2020). Predicting gasoline shortage during disasters using social media. *Or Spectrum*, 42, 693-726.
- Kılıcı, F., vd. (2015). Locating temporary shelter areas after an earthquake: A case for Turkey. *European Journal of Operational Research*, 243(1), 323-332. <https://doi.org/https://doi.org/10.1016/j.ejor.2014.11.035>
- Kondaveti, R., ve Ganz, A. (2009, 3-6 Sept. 2009). Decision support system for resource allocation in disaster management. 2009 Annual International Conference of the IEEE Engineering in Medicine and Biology Society,
- Kryvasheyev, Y., vd. (2016). Rapid assessment of disaster damage using social media activity. *Science advances*, 2(3), e1500779.
- KTÜ: Karadeniz Teknik Üniversitesi. 6 Şubat 2023 Kahramanmaraş (Pazarcık Mw=7.7 ve Mw=7.6) Depremleri ve Artçılarını, Saha Gözlemlerini, Yapısal Hasarlarını ve İleriye Yönelik Önerileri İçeren Değerlendirme Raporu, Trabzon, Nisan 2023
- Kumar, A., ve Singh, J. P. (2019). Location reference identification from tweets during emergencies: A deep learning approach. *International journal of disaster risk reduction*, 33, 365-375.
- Lee, R., vd. (2024). Reclassifying historical disasters: From single to multi-hazards. *Science of the Total Environment*, 912, 169120.
- Li, L., vd. (2011). Sheltering network planning and management with a case in the Gulf Coast region. *International Journal of Production Economics*, 131(2), 431-440. <https://doi.org/https://doi.org/10.1016/j.ijpe.2010.12.013>
- Lin, Y.-H., vd. (2011). A logistics model for emergency supply of critical items in the aftermath of a disaster. *Socio-Economic Planning Sciences*, 45(4), 132-145.
- Majumder, R., vd. (2019, 18-20 Dec. 2019). Game Theory-Based Allocation of Critical Resources during Natural Disasters. 2019 Sixth Indian Control Conference (ICC),
- McDonald, G. C. (2009). Ridge regression. *Wiley Interdisciplinary Reviews: Computational Statistics*, 1(1), 93-100.
- Mete, H. O., ve Zabinsky, Z. B. (2010). Stochastic optimization of medical supply location and distribution in disaster management. *International Journal of Production Economics*, 126(1), 76-84. <https://doi.org/https://doi.org/10.1016/j.ijpe.2009.10.004>
- Middleton, S. E., vd. (2013). Real-time crisis mapping of natural disasters using social media. *IEEE Intelligent Systems*, 29(2), 9-17.
- Morstatter, F., vd. (2013). Is the sample good enough? comparing data from twitter's streaming api with twitter's firehose. Proceedings of the international AAAI conference on web and social media,
- Nazer, T. H., vd. (2017). Intelligent disaster response via social media analysis a survey. *ACM SIGKDD Explorations Newsletter*, 19(1), 46-59.
- Özcan, F., ve Işık, İ. (2023). Kahramanmaraş Depremi Çerçevesinde Sosyal Medya ve Kriz Yönetimi. *DİJİTAL ÇAĞDA*, 85.
- Özman, G. Ö., vd. (2024). Image classification on Post-Earthquake damage assessment: A case of the 2023 Kahramanmaraş earthquake. *Engineering Science and Technology, an International Journal*, 56, 101780.
- Pandey, R., ve Singh, J. P. (2023). BERT-LSTM model for sarcasm detection in code-mixed social media post. *Journal of Intelligent Information Systems*, 60(1), 235-254.
- Pradhananga, R., vd. (2016). An integrated resource allocation and distribution model for pre-disaster planning. *Computers & Industrial Engineering*, 91, 229-238. <https://doi.org/https://doi.org/10.1016/j.cie.2015.11.010>

- Qi, Y., veShabrina, Z. (2023). Sentiment analysis using Twitter data: a comparative application of lexicon-and machine-learning-based approach. *Social network analysis and mining*, 13(1), 31.
- Rath, S., veGutjahr, W. J. (2014). A math-heuristic for the warehouse location–routing problem in disaster relief. *Computers & Operations Research*, 42, 25-39. <https://doi.org/https://doi.org/10.1016/j.cor.2011.07.016>
- Saddam, M. A., vd. (2023). Sentiment analysis of flood disaster management in Jakarta on Twitter using support vector machines. *Sinkron: jurnal dan penelitian teknik informatika*, 7(1), 470-479.
- Sakaki, T., vd. (2010). Earthquake shakes twitter users: real-time event detection by social sensors. Proceedings of the 19th international conference on World wide web,
- Sampson, J., vd. (2015). Real-time crisis mapping using language distribution. 2015 IEEE International Conference on Data Mining Workshop (ICDMW),
- Sarma, D., vd. (2020). A cost minimization resource allocation model for disaster relief operations with an information crowdsourcing-based MCDM approach. *IEEE transactions on engineering management*, 69(5), 2454-2474.
- Shah, K., vd. (2020). A comparative analysis of logistic regression, random forest and KNN models for the text classification. *Augmented Human Research*, 5(1), 12.
- Starbird, K., veStamberger, J. A. (2010). Tweak the tweet: Leveraging microblogging proliferation with a prescriptive syntax to support citizen reporting. ISCRAM,
- Su, Z., vd. (2016). Multiple emergency resource allocation for concurrent incidents in natural disasters. *International journal of disaster risk reduction*, 17, 199-212.
- Şahin, G., vd. (2023). Bulanık AHP yöntemi ile afet sonrası ihtiyaçların önceliklendirilmesi: Pazarcık ve Elbistan depremleri örneği. *Türk Deprem Araştırma Dergisi*, 5(2), 314-330.
- Tofighi, S., vd. (2016). Humanitarian logistics network design under mixed uncertainty. *European Journal of Operational Research*, 250(1), 239-250.
- Wex, F., vd. (2014). Emergency response in natural disaster management: Allocation and scheduling of rescue units. *European Journal of Operational Research*, 235(3), 697-708.
- Zahera, H. M., vd. (2019). Fine-tuned BERT Model for Multi-Label Tweets Classification. TREC,