

T.C.
GÜMÜŞHANE ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

AFET YÖNETİMİ ANA BİLİM DALI

6 ŞUBAT DEPREMİ SONRASI SAĞLIK İHTİYAÇLARININ METİN
MADENCİLİĞİ İLE ANALİZİ: SOSYAL MEDYA VERİLERİ ÜZERİNE BİR
İNCELEME

YÜKSEK LİSANS

Mafaza Mohamed Bahialdien NAZAR

ŞUBAT - 2026
GÜMÜŞHANE



**T.C.
GÜMÜŞHANE ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

AFET YÖNETİMİ ANA BİLİM DALI

**6 ŞUBAT DEPREMİ SONRASI SAĞLIK İHTİYAÇLARININ METİN
MADENCİLİĞİ İLE ANALİZİ: SOSYAL MEDYA VERİLERİ ÜZERİNE BİR
İNCELEME**

**ANALYSIS OF POST-6TH FEBRUARY EARTHQUAKE HEALTH NEEDS
USING TEXT MINING: A STUDY BASED ON SOCIAL MEDIA DATA**

YÜKSEK LİSANS

Mafaza Mohamed Bahialdien NAZAR

**ŞUBAT - 2026
GÜMÜŞHANE**



**T.C.
GÜMÜŞHANE ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

AFET YÖNETİMİ ANA BİLİM DALI

**6 ŞUBAT DEPREMİ SONRASI SAĞLIK İHTİYAÇLARININ METİN
MADENCİLİĞİ İLE ANALİZİ: SOSYAL MEDYA VERİLERİ ÜZERİNE BİR
İNCELEME**

**ANALYSIS OF POST-6TH FEBRUARY EARTHQUAKE HEALTH NEEDS
USING TEXT MINING: A STUDY BASED ON SOCIAL MEDIA DATA**

YÜKSEK LİSANS

Mafaza Mohamed Bahialdien NAZAR

Danışmanı: Doç. Dr. Yasemin TATLI

**ŞUBAT - 2026
GÜMÜŞHANE**

BİLİMSEL ETİK KURALLARA UYUM BEYANI

Yüksek Lisans Tezi olarak hazırlamış olduğum “**6 Şubat Depremi Sonrası Sağlık İhtiyaçlarının Metin Madenciliği ile Analizi: Sosyal Medya Verileri Üzerine Bir İnceleme**” isimli bu tezimin, tamamen kendi çalışmam olduğunu, her alıntıya kaynak gösterdiğimi, alıntı yaptığım tüm çalışmaları kaynakçada belirttiğimi ve Gümüşhane Üniversitesi’nin lisanslı kullanıcısı olduğu intihal yazılım programı ile Lisansüstü Eğitim Enstitüsü’nün belirlediği kıstaslara uygun olarak raporladığımı taahhüt ederim. Tezimin kâğıt ve elektronik kopyalarının Gümüşhane Üniversitesi Lisansüstü Eğitim Enstitüsü arşivinde saklanması için izin verdiğimi onaylarım.

Lisansüstü Eğitim ve Öğretim Yönetmeliği’nin ilgili maddeleri uyarınca gereğinin yapılmasını arz ederim.

12/2/2026

.....
Mafaza Mohamed Bahialdien NAZAR

TEŞEKKÜR

“6 Şubat Depremi Sonrası Sağlık İhtiyaçlarının Metin Madenciliği İle Analizi: Sosyal Medya Verileri Üzerine Bir İnceleme” başlıklı bu yüksek lisans tez çalışmasının planlanması, yürütülmesi ve tamamlanması sürecinde; engin bilgi birikimi, kıymetli yönlendirmeleri, sabrı ve desteğiyle akademik gelişimime büyük katkı sağlayan değerli danışmanım Doç. Dr. Yasemin TATLI’ya en içten teşekkürlerimi sunarım.

Çalışmanın uygulama aşamalarında tecrübe ve rehberliğiyle yolumu aydınlatan, değerli desteklerini esirgemeyen sayın Prof. Dr. Handan ÇAM’a şükranlarımı sunarım.

Ayrıca, hayatımın her aşamasında olduğu gibi bu zorlu akademik süreçte de yanımda olan, destekleriyle beni daima motive eden kıymetli aileme sonsuz teşekkürlerimi sunarım.

Mafaza Mohamed Bahialdien NAZAR

Gümüşhane – 2026

ÖZET

6 Şubat 2023 Kahramanmaraş depremleri büyük kayıplara neden olmuş ve sağlık ihtiyaçlarının hızlı ve doğru bir şekilde değerlendirilmesini gerektirmiştir. Bu çalışma, LDA, BERTopic ve dönüştürücü tabanlı duygu analizi (BERTurk) ile denetimli makine öğrenimini birleştiren bir hesaplama çerçevesi kullanarak, afet sonrası iki aylık dönemde 88.073 Türkçe tweeti sistematik olarak analiz ederek bu sorunu ele almaktadır. Çalışma, afet müdahalesine bilgi sağlamak amacıyla deprem sonrası sağlık ihtiyaçları söylemini belirlemeyi ve sınıflandırmayı amaçlamıştır.

Konu modellemesi, sağlık ihtiyaçlarını başarıyla kategorize ederek uluslararası insani yardım standartlarıyla (WHO EMT ve SPHERE) güçlü bir uyum olduğunu ortaya koymuştur. Önemli bir bulgu, Hijyen'in ($\beta = 0.3326$) olağanüstü önemi olmuştur; bu da, hasar gören Su, Sanitasyon ve Hijyen (WASH) altyapısından kaynaklanan halk sağlığı riskini vurgulamaktadır. Ayrıca, zamansal analiz, ihtiyaçların öngörülebilir bir şekilde geliştiğini ve acil tıbbi hizmetlerden sürekli halk sağlığı ve barınma sorunlarına geçiş yapıldığını doğrulamıştır.

Makine öğrenimi değerlendirmesi, Lojistik Regresyon ve Doğrusal SVM'yi sağlık içeriği sınıflandırması için üstün modeller olarak belirlendi ve sırasıyla %89.07 ve %88.92 doğruluk oranları elde edildi. Tıp ve malzemeler gibi geniş kategoriler 0.93 F1 puanı elde ederken, Anne ve Çocuk Sağlığı ($F1=0.77$) gibi özel ihtiyaçlar, çok sınıflı kategorizasyonda dilbilimsel çakışmanın zorluğunu vurguladı. Duygu analizi, sağlıkla ilgili söylemler ile sıkıntı arasında istatistiksel olarak anlamlı bir korelasyon olduğunu ortaya koydu. Sağlıkla ilgili tweetler, sağlıkla ilgili olmayan tweetlere göre %7.1 daha yüksek negatif duygu (79.7) sergiledi ($p < 0.001$). Bu araştırma, sosyal medya analizini geleneksel ihtiyaç değerlendirmesine etkili, neredeyse gerçek zamanlı bir tamamlayıcı olarak doğrulamakta ve uyarlanabilir afet yönetimi stratejileri için eyleme geçirilebilir içgörüler sunmaktadır.

Anahtar Kelimeler: Afet sonrası sağlık ihtiyaçları, Duygu analizi, Konu modellemesi, Makine öğrenmesi, Metin madenciliği

ABSTRACT

The February 6, 2023 Kahramanmaraş earthquakes caused great losses and required a rapid and accurate assessment of health needs. This study addresses this challenge by employing a computational framework-combining LDA, BERTopic, and transformer-based sentiment analysis (BERTurk) and supervised ML- to systematically analyze 88,073 Turkish-language tweets over the two-month post-disaster period. The study aimed to identify, categorize post-earthquake health needs discourse to inform disaster response.

The topic modeling successfully categorized health needs, revealing a strong alignment with international humanitarian standards (WHO EMT and SPHERE). A critical finding was the extraordinary salience of Hygiene ($\beta = 0.3326$), underscoring the public health risk from damaged Water, Sanitation, and Hygiene (WASH) infrastructure. Furthermore, the temporal analysis confirmed a predictable evolution of needs, transitioning from immediate Emergency Medical Services to sustained Public Health and Shelter concerns.

Machine learning evaluation identified Logistic Regression and Linear SVM as the superior models for health content classification, achieving accuracies of 89.07% and 88.92% respectively. While broad categories like Medicine and Supplies achieved an F1-score of 0.93, specialized needs like Maternal and Child Health ($F1=0.77$) highlighted the challenge of linguistic overlap in multi-class categorization. Sentiment analysis revealed a statistically significant correlation between health-related discourse and distress: health tweets exhibited 7.1 percentage points higher negative sentiment (79.7%) than non-health tweets ($p < 0.001$). This research validates social media analysis as an effective, near-real-time complement to traditional needs assessment, offering actionable insights for adaptive disaster management strategies.

Keywords: Post-disaster health needs, Sentiment analysis, Topic modeling, Machine learning, Text mining

İÇİNDEKİLER

KABUL VE ONAY	III
BİLİMSEL ETİĞE UYGUNLUK BEYANI.....	IV
TEŞEKKÜR.....	V
ÖZET	VI
SUMMARY	VII
İÇİNDEKİLER	VIII
TABLolar DİZİNİ	XI
ŞEKİLLER DİZİNİ.....	XIII
EKLER DİZİNİ.....	XIV
SİMGELER VE KISALTMALAR DİZİNİ.....	XV
1. GİRİŞ	1
2. LİTERATÜR ÖZETİ.....	6
2.1. Afet Yönetimi Çerçevesimnj	6
2.2. Afetlerde Sağlık İhtiyaçlar	8
2.3. Afetlerde Kriz İletişimi ve Bilgi Akışı	10
2.4. Afetlerde Veri Kaynağı Olarak Sosyal Medya.....	11
2.5. Sosyal Medya Analizi Üzerine Literatür İncelemesi	13
3. MATERYAL VE YÖNTEM.....	23
3.1. Kullanılan Yöntemler ve Modeller	23
3.1.1. Metin Madenciliği ve Doğal Dil İşleme Altyapısı.....	23
3.1.2. Konu Modelleme Yöntemleri.....	27
3.1.3. Duygu Analizi Yöntemi	29
3.1.4. Makine Öğrenmesi Modelleri	30
3.2. Analitik Süreç ve Metodolojik İş Akışı.....	32
3.3. Veri Toplama.....	34
3.4. Verilerin Ön İşlenmesi	35
3.5. Veri Keşfi.....	40
3.5.1. Genel Veri Keşfi	40
3.5.2. Coğrafi Bilgi Çıkarma ve Sınırlamalar	42

3.6. Etik Hususlar	42
4. BULGULAR VE TARTIŞMA.....	45
4.1. Konu Modelleme Bulguları	46
4.1.1. LDA ile Konu Modelleme	46
4.1.2. BERTopic ile Konu Modelleme	54
4.2. Duygu Analizi Bulguları	59
4.3. Makine Öğrenimi Bulguları.....	66
4.3.1. Veri Kümesi Hazırlama ve Dastest Kategorileri.....	67
4.3.2. TF-IDF ile Özellik Çıkarma	71
4.3.3 SMOTE ile Sınıf Dengesizliği Yönetimi	72
4.3.4. Model Seçimi, Eğitim ve Değerlendirme Metrikleri	74
4.4. Sağlıkla İlgili LDA Konu Modellemesi	75
4.4.1. Sağlıkla İlgili Konu Sınıflandırması ve Analizi.....	77
4.4.2. Sağlık İhtiyaçları Kategorileri ve WHO/SPHERE Uyumu	78
4.4.3. Sağlık Konularının Zamansal Evrimi.....	80
4.4.4. Sağlık Konularının Coğrafi Dağılımı	81
4.4.5. Sağlık İhtiyacı Yorumlaması ile Ayrıntılı Konu Analizi	82
4.4.6. Konular Arası Analiz: Sağlık İhtiyaçları Etkileşimleri	87
4.4.7. Çerçeve Uyumu Yoluyla Doğrulama	89
4.5. Sağlıkla İlgili BERTopic Konu Modelleme Sonuçları	89
4.5.1. Genel Konu Yapısı ve Belge Dağılımı.....	90
4.5.2. Tematik Kategori Dağılımı ve Kompozisyonu	90
4.5.3. Afet Yardımı Konuları: Malzeme İhtiyaçları ve Lojistik.....	93
4.5.4. Sağlıkla İlgili Konu Tanımlama ve Sınıflandırma.....	94
4.5.5. Ayrıntılı Konu Açıklamaları: Sağlıkla İlgili En Önemli 15 Konu	95
4.6. Karşılaştırmalı Analiz: LDA ve BERTopic Sağlık Sınıflandırması	98
4.7. Sağlıkla İlgili Söylemlerde Duygusal Eğilimlerin Analizi.....	99
4.8. Makine Öğrenimi Sınıflandırma Sonuçları.....	111
4.8.1. Genel Model Performansı Karşılaştırması.....	111
4.8.2. Kategori Başına Performans Analizi	113
4.8.3 Sınıflandırma Hata Kalıpları	114
4.8.4 Sağlıkla İlgili İçerik Sınıflandırması için Makine Öğrenimi Model Performansı.....	115

4.8.5. İkili Sınıflandırma Performansı (Lojistik Regresyon).....	116
5. SONUÇLAR.....	118
5.1 Çalışmanın Epistemolojik Kapsamı ve Metodolojik Sınırları	119
5.2 Sağlık İhtiyaçları Sınıflandırmasının Yorumlanması	120
5.3. Duygu ve Sağlık İhtiyaçları Arasındaki Korelasyon	121
5.4. ML Sınıflandırmasının Uygulanabilirliği.....	122
5.5. İhtiyaçların Zamansal Evrimi	123
5.6. Öneriler	123
5.6.1. Afet Yönetimi için Pratik Öneriler	123
5.6.2 Gelecekteki Araştırmalar için Akademik Öneriler	124
5.7. Sınırlamalar	125
KAYNAKÇA	126
EKLER	144
ÖZGEÇMİŞ	167

TABLO LİSTESİ

Tablo 1. Altı adımlı yöntemden oluşan analitik çerçeveye genel bakış	23
Tablo 2. Veri toplama ve ön işleme parametreleri.....	34
Tablo 3. Lemmatizasyon İstatistikleri.....	37
Tablo 4. Lemmatizasyon örnekleri.....	37
Tablo 5. Veri ön İşleme adımları	38
Tablo 6. Ön İşleme örnekleri	39
Tablo 7. Veri toplama, ön işleme ve zamansal dağılım istatistikleri.....	41
Tablo 8. Bulgular bölümü genel bakış	45
Tablo 9. LDA konu modelleme sonuçları	46
Tablo 10. LDA optimizasyon sonuçları.....	48
Tablo 11. LDA konu karşılaştırması	54
Tablo 12. BERTopic kategori dağılımı.....	55
Tablo 13. BERTopic analizi genel bakış ve kümeleme istatistikleri.....	57
Tablo 14. BERTurk duygu analizi bulgularının özeti	59
Tablo 15. Duygu analizi yöntemleri karşılaştırması.....	61
Tablo 16. Duygu analizi yöntemlerinin objektif puanlaması	62
Tablo 17. BERTurk doğrulama sonuçları.....	63
Tablo 18. Sağlık duygu korelasyonu.....	66
Tablo 19. Makine öğrenimi model karşılaştırma özeti.....	67
Tablo 20. ML veri kümesi öncesi ve sonrası karşılaştırması.....	69
Tablo 21. Eğitim-test bölünme dağılımı	70
Tablo 22. SMOTE uygulama ayrıntıları	73
Tablo 23. LDA sağlık konularının who/sphere standartlarıyla uyumu	76
Tablo 24. BERTopic sağlık ve tıp alt kategorilerinin dağılımı ve anahtar kelimeleri	90
Tablo 25. Tematik kategorilere göre konu dağılımı.....	92
Tablo 26. BERTopic sağlık kategorileri ve dağılımı.....	95
Tablo 27. Yorumlarla birlikte en çok kullanılan 15 BERTopic sağlık konusu	96
Tablo 28. LDA ve BERTopic sağlık sınıflandırması: karşılaştırmalı analiz	98
Tablo 29. Sağlık-duygu korelasyonu istatistiksel test sonuçları	99

Tablo 30. Genel duygu dağılımı	100
Tablo 31. Model güven istatistikleri	101
Tablo 32. Günlük olumsuz duygu özeti istatistikleri.....	101
Tablo 33. Sağlıkla ilgili tweet sınıflandırması	105
Tablo 34. Sağlıkla ilgili duygu durumu	105
Tablo 35. BERTurk doğrulama metrikleri	108
Tablo 36. Sınıf başına doğrulama sonuçları	109
Tablo 37. Manuel etiketlemeler ve BERTurk tahminlerine dayalı hata matrisi karşılaştırması.....	109
Tablo 38. Lojistik regresyon modelinin kategori bazlı sınıflandırma performansı.....	111
Tablo 39. Makine öğrenimi model performans karşılaştırması	112
Tablo 40. Lojistik regresyon modelinin kategori bazlı performans analizi	114
Tablo 41. Sınıflandırma hata kalıpları	115
Tablo 42. Araştırma soruları, bulgular ve pratik çıkarımlar	118
Tablo 43. İnsani yardım standartlarıyla uyumlu lda konuları	121

ŞEKİL LİSTESİ

Şekil 1. Veri Ön İşleme Süreci	38
Şekil 2. Üç zaman dilimini gösteren günlük tweet hacmi dağılımı	41
Şekil 3. LDA optimizasyon sonuçları	48
Şekil 4. Nihai lda model eğitimi için optimize edilmiş hiperparametreler	49
Şekil 5. Duygu analizi yöntemleri karşılaştırma görselleştirmesi.....	61
Şekil 6. BERTurk doğrulama karışıklık matrisi ve metrikleri	64
Şekil 7. ML veri kümesi kategori dağılımı.....	69
Şekil 8. Eğitim-test bölünme analizi	71
Şekil 9. Özellik çıkarma ve smote analizi	74
Şekil 10. LDA konu dağılımı.....	77
Şekil 11. BERTopic konu dağılımı ve kategorik analizi.....	91
Şekil 12. Genel duygu dağılımı	100
Şekil 13. Kapsamlı duygu analizi	102
Şekil 14. Duygu kategorilerine göre günlük tweet sayılarını gösteren zamansal analiz	104
Şekil 15. Sağlık duygu korelasyonu karşılaştırması.....	105
Şekil 16. Doğrulama metriklerinin görselleştirilmesi	108
Şekil 17. Modellerin karşılaştırılmasına genel bakış.....	112
Şekil 18. Ayrıntılı model karışıklık matrisleri	113
Şekil 19. Modellerin roc eğrisi analizi ve karşılaştırılması	116
Şekil 20. İkili sağlık sınıflandırması için karışıklık matrisi.....	117

EKLER LİSTESİ

Ek 1. Veri toplama için anahtar kelimeler listesi	144
Ek 2. Türkçe durdurma kelimeleri listesi.....	145
Ek 2.1 NLTK türkçe durdurma kelimeleri	145
Ek 2.2 Özel alan adına özgü durdurma kelimeleri.....	145
Ek 3. Zeyrek lemmatizasyon.....	146
Ek 4. LDA tam optimizasyon sonuçları.....	148
Ek 5. LDA konu anahtar kelimeleri ayrıntılı.....	149
Ek 6. TF-IDF ile özellik çıkarma.....	150
Ek 7. BERTopic sonuçları.....	152
Ek 8. BERTopic nihai konu özeti.....	155

SİMGELER VE KISALTMALAR DİZİNİ

AFAD	: Afet ve Acil Durum Yönetimi Başkanlığı (Türkiye)
AI	: Yapay Zeka
API	: Uygulama Programlama Arayüzü
BERT	: Transformatörlerden İki Yönlü Kodlayıcı Temsilleri
BERTopic	: BERT tabanlı Konu Modelleme
BERTurk	: Türkçe BERT Modeli (savasy/bert-base-turkish-sentiment-cased)
CNN	: Evrişimli Sinir Ağı
COVID-19	: Koronavirüs Hastalığı 2019
CSV	: Virgülle Ayrılmış Değerler
EU	: Avrupa Birliği
GATE	: General Architecture for Text Engineering (Metin Mühendisliği için Genel Mimari)
GDP	: Gayri Safi Yurt İçi Hasıla
HDBSCAN	: Gürültülü Uygulamaların Hiyerarşik Yoğunluk Temelli Uzamsal Kümelenmesi
HTML	: Köprü Metni Biçimlendirme Dili
ICT	: Bilgi ve İletişim Teknolojisi
BT	: Bilgi Teknolojisi
JSON	: JavaScript Nesne Notasyonu
KNN	: K-En Yakın Komşular
LDA	: Gizli Dirichlet Dağılımı
LR	: Lojistik Regresyon
ML	: Makine Öğrenimi
NGO	: Sivil Toplum Örgütü
NLP	: Doğal Dil İşleme
NLTK	: Natural Language Toolkit (Doğal Dil İşleme Araç Takımı)
OCHA	: Birleşmiş Milletler İnsani Yardım Koordinasyon Ofisi
PTSD	: Travma Sonrası Stres Bozukluğu
RF	: Rastgele Orman

RNN	: Tekrarlayan Sinir Ağı
ROC	: Alıcı Çalışma Karakteristiği
SKEP	: Sentiment Knowledge Enhanced Pre-training
SMOTE	: Sentetik Azınlık Aşırı Örnekleme Tekniği
SMS	: Kısa Mesaj Servisi
SVM	: Destek Vektör Makinesi
TF-IDF	: Terim Sıklığı-Ters Belge Sıklığı
UK	: Birleşik Krallık
UMAP	: Tekdüze Manifold Yaklaşımı ve Projeksiyonu
UMCOR	: Birleşik Metodist Yardım Komitesi
UN	: Birleşmiş Milletler
URL	: Tekdüzen Kaynak Konum Belirleyici
USA	: Amerika Birleşik Devletleri
VADER	: Valence Aware Dictionary and Sentiment Reasoner
WHO	: Dünya Sağlık Örgütü
XML	: Genişletilebilir İşaretleme Dili

1. GİRİŞ

Her yıl milyonlarca insanı etkileyen, fiziksel, ekonomik ve sosyal kayıplar açısından yıkıcı sonuçlarıyla bilinen afetler (Yeşildal, 2020: 88 - 90), insanların her zaman hazırlıklı olması gereken zor durumlardır (Erkal ve Değerliyurt, 2009: 147-150). Afetler, ani meydana gelmeleri nedeniyle çoğu zaman önlenemez olsa da, etkili planlama ve yönetim stratejileriyle olumsuz etkileri hafifletilebilir (Yeşildal, 2020: 88-90).

Coğrafyaya baktığımızda, Türkiye'nin Alp-Himalaya kuşağında önemli bir deprem bölgesinde yer aldığını ve jeolojisi ve jeodinamiği nedeniyle birçok aktif fay hattına sahip olduğunu görebiliriz (Ergen vd., 2020: 1335-1336). Bu da, bölgedeki devam eden tektonik hareketlerin bir sonucu olarak Türkiye'yi sık ve şiddetli depremlere maruz bırakmaktadır. Bu depremlerin en yıkıcı ve tehlikeli olanları arasında 2023 Kahramanmaraş Depremi, 1939 Erzincan Depremi ve 1999 Marmara Depremi sayılabilir. Bu depremler altyapıya ciddi hasar vermiş ve çok sayıda can kaybına yol açmıştır (URL-1, 2023).

6 Şubat 2023'te Türkiye'nin Kahramanmaraş ilinde meydana gelen iki büyük deprem, benzeri görülmemiş bir yıkıma yol açmış ve milyonlarca insanı etkilemiş, bu da acil sağlık ve insani yardım müdahalesi ihtiyacını ortaya çıkarmıştır. Depremin ardından, sosyal medya platformları, vatandaşların, kuruluşların ve hatta kurumların sağlıkla ilgili taleplerini, maddi ihtiyaçlarını ve durum güncellemelerini paylaştıkları önemli ve hayati bir gerçek zamanlı bilgi kaynağı haline geldi (Çetin vd., 2023: 12-15).

Ancak, sosyal medyanın kullanımı gerekli ve yararlı olsa da, yanlış bilgilerin yayılmasına yol açmak gibi başka zorlukları da beraberinde getiriyor (Unal ve Sezer, 2023: 782-783). Öte yandan, sosyal medyanın özellikle Twitter'ın (X'in) yükselişi, kişilerarası iletişimi iyileştirmekle kalmayıp, çeşitli alanlarda veri erişilebilirliğini ve uygulamalarını da geliştirmiştir. 2010'ların başından itibaren sosyal medya, kamuoyunun duyarlılığını izleme, acil durum koordinasyonunu geliştirme ve araştırma alanını iyileştirme gibi destekleyici işlevler gibi kriz müdahalesi için kritik araçlardan biri haline gelmiştir. Günümüzün dijital çağında, sosyal medya platformları gerçek zamanlı, büyük ölçekli veriler sağlar ve hızlı bilgi yayılımı ve topluluk geri bildirimi sağlar, bu da durum farkındalığını artırır ve araştırmacıların ve karar vericilerin daha uyumlu, duyarlı afet yönetimi stratejileri

benimsemelerini sağlar (Erokhin ve Komendantova, 2024: 1-2). Sosyal medya, afetler sırasında da önemli bir rol oynayarak, kritik toplumsal sorunlara dikkat çekerek hızlı müdahale ve iyileşmeye yardımcı olur (Aldamen ve Hacimic, 2023: 1-3).

Son zamanlarda yapılan çalışmalar, sosyal medyanın afet yönetiminde bilgi paylaşımı ve koordinasyon açısından önemli bir rol üstlendiğini ortaya koymuştur. 2020 İzmir depremi sonrasında sosyal medya temelli bilgi akışının paydaşlar arasındaki koordinasyonu artırdığı belirlenmiştir (Ağralı vd., 2022: 36–41). Ayrıca, metin madenciliği (TM) ve doğal dil işleme (NLP) teknolojilerinin büyük verileri analiz ederek özellikle tıbbi sağlık alanlarında kullanıldığı ve bu sayede karar verme stratejilerini desteklediği tespit edilmiştir (Eguia vd., 2024; Wang vd., 2024).

Genel olarak; sosyal medya, toplumsal farkındalığa, gönüllülerin harekete geçirilmesine ve gerçek zamanlı kriz izlemeye katkıda bulunurken, yanlış bilgilerin yayılmasına da katkıda bulunabilir. Bununla birlikte, dijital zorluklar karşısında eğitim ve iletişimin sürekliliğini sağlamak için etkili bir araç olarak değerlendirilmektedir (Reuter ve Kaufhold., 2018: 41-57). Bu bağlamda, afet yönetiminde kullanılan geleneksel veri toplama ve analiz yaklaşımlarına ilişkin başlıca sınırlılıklar aşağıda maddeler hâlinde sunulmaktadır:

1. Afet yönetiminde karar vericilerin hızlı ve güvenilir bilgilere erişebilmesi gerektiğinden, anketler, saha raporları ve kurumsal iletişim gibi geleneksel veri toplama yöntemleri, zaman ve kapasite kısıtlamaları nedeniyle genellikle yavaş ve zaman alıcıdır - Bu durum, afet sonrası ihtiyaçları hızlı bir şekilde belirlemek için değerlendirme yöntemlerinin önemini artırmaktadır (Bosmans vd., 2022: 2-4)
2. Mevcut veri kaynaklarının kapsamı sınırlıdır, örneğin: anket yapılırken yalnızca erişilebilir nüfusu kapsar.
3. İngilizce konuşulmayan ve bağlama özgü afetlerde etkilenen nüfusun afet sonrası sağlık ihtiyaçlarını hedeflemek için daha fazla çalışma yapılması gerekmektedir. Doğal dil işleme (NLP) ve makine öğrenimi yöntemleri daha geniş afet bağlamlarında kullanılsa da, bu tez metodolojisinde uygulanacağı gibi, sağlıklı ilgili ihtiyaçları ve öncelikleri sistematik olarak çıkarmak için Türkçe tweetlere denetimsiz makine öğrenimi teknikleri (örneğin, BERTopic) uygulayan çok az çalışma bulunmaktadır (Babayigit ve Sattuf, 2025: 9807-9809).

Bu çalışmanın amacı, Türkçe Twitter verilerinin hesaplamalı analizi yoluyla deprem sonrası sağlık ihtiyaçlarını belirlemek ve sınıflandırmaktır.

Araştırmanın spesifik soruları şunlardır:

S1: Kahramanmaraş depremlerinin ardından Twitter’da sağlıkla ilgili hangi konular tartışıldı?

S2: Duygu kalıpları sağlık ihtiyaçlarıyla nasıl ilişkilidir?

S3: ML, Türkçe tweetlerden sağlık ihtiyaçlarını sınıflandırabilir mi?

Bu çalışma ayrıca aşağıdaki varsayımlara dayanmaktadır:

A1. Twitter, afetler sırasında acil sağlık ve sağlıkla ilgili ihtiyaçların iletişimi için temsil edici bir veri kaynağı olarak kabul edilebilir (Kusumasari ve Prabowo, 2020: 3415-3416).

A2. Afet sonrası iki aylık dönem, sağlık ihtiyaçlarını yansıtmaktadır(UMCOR, t.y.).A3. Türkçe NLP araçları (örneğin: BERTurk, Zeyrek lemmatizer) sağlıkla ilgili terimlerin yeterince doğru bir şekilde çıkarılmasını sağlar (Çelikten ve Bulut, 2021), bu araştırma boşluklarını kapatmak için ise:

1. Birçok sistematik inceleme, afet sosyal medya araştırmalarının İngilizce ve Çince gibi birkaç diğer ana dil üzerinde yoğunlaştığını, ancak araştırma veri setlerinde dil çeşitliliğinin çok sınırlı olduğunu göstermektedir - buna Türkçe veriler de dahildir (İlyas ve Sharifi, 2025: 3-14).
2. Sağlık ile ilgili sınıflandırmada bir boşluk bulunmaktadır, çünkü bazı sistematik incelemeler sosyal medyada afet araştırmalarında sağlık iletişimi veya tıbbi yardım gönderilerini kabul etmekte, ancak literatürde çeşitli sağlık ihtiyaçları türleri (örneğin, ruh sağlığı, kronik hastalık yönetimi, anne bakımı) sistematik olarak sınıflandırılmamakta, bunun yerine genel yardım ve durumsal bilgiler vurgulanmaktadır (Rasouli Panah vd., 2024: 1-14).
3. Tweet filtreleme ve sınıflandırma için denetimli öğrenme ve anahtar kelime tabanlı yaklaşımlar üzerinde güçlü bir vurgu vardır, ancak denetimsiz konu modelleme ve entegre çoklu yöntem çerçeveleri (örneğin, denetimli, denetimsiz ve duygu analizini birleştiren) hala yaygın değildir. Birkaç inceleme, denetimsiz konu modellerinin nispeten seyrek kullanıldığını ve genellikle diğer analitik

yöntemlerle birlikte kullanılmadığını ortaya koymaktadır. Bu durum, gelecekteki araştırmalar için bir fırsat olarak değerlendirilmektedir (Ma vd., 2024: 1-16).

Bu çalışma, hem akademik araştırmalara hem de pratik afet yönetimine çeşitli şekillerde önemli katkılar sağlamaktadır. Bu faydalar şu şekilde sıralanabilir:

1. Türkçe afet sağlık ihtiyaçları değerlendirmesi için özel olarak tasarlanmış, denetimsiz konu modelleme, denetimli sınıflandırma ve duygu analizini birleştiren kapsamlı bir hesaplama çerçevesi geliştirir; bu çerçeve diğer dillere, afet türlerine ve insani yardım bağlamlarına uyarlanabilir.
2. Türk bağlamında etkilenen nüfusun ifadelerine dayalı olarak deprem sonrası sağlık ihtiyaçlarının sistematik, veriye dayalı bir sınıflandırmasını sunarak, afet durumlarında Batı sağlık çerçevelerinden farklı olabilecek öncelikleri ortaya koyar.
3. Sosyal medya analizi yoluyla neredeyse gerçek zamanlı sağlık ihtiyaçlarının izlenmesinin operasyonel olarak uygulanabilirliğini gösterir, böylece sağlık yetkilileri ortaya çıkan ihtiyaçları günler yerine saatler içinde tespit edebilir, önceliklerdeki değişiklikleri takip ederek kaynakların yeniden tahsisini bilgilendirebilir ve geleneksel değerlendirme yöntemlerini güçlendirebilir.
4. Afetlerden etkilenen nüfusun sosyal medya aracılığıyla sağlık ihtiyaçlarını nasıl iletildiğini inceleyerek kriz bilişim teorisinin geliştirilmesine katkı sağlamıştır. Bu kapsamda, paylaşımlarda yer alan duygu durumları ile ifade edilen ihtiyaçların aciliyeti arasındaki ilişki ortaya konulmuştur.
5. Gelecekteki karşılaştırmalı afet araştırmaları, Türkçe için geliştirilmiş NLP modellerinin geliştirilmesi, afet yönetimi uzmanları için eğitim kaynakları ve hesaplamalı yöntemlerin geçerliliğini test etmek için bir karşılaştırma veri seti olarak kullanılmak üzere, Türkçe afet sağlığı ile ilgili sosyal medya verilerinden oluşan, kamuya açık, açıklamalı bir veri seti oluşturur.

Bu çalışma birkaç faktörle sınırlıdır:

- ✓ Dil: Bu çalışma sadece kamuya açık Türkçe tweetleri analiz ettiğinden ve Türkçe tweetlerin karmaşık morfolojisiyle sınırlı olduğundan, belirli nüfus gruplarının seslerini hariç tutabilir ve bu da belirli gruplara karşı önyargıya yol açabilir.

- ✓ Zaman aralığı: Bu çalışma sadece deprem sonrası iki aylık döneme odaklandığından, sonuçlar uzun vadeli veya gecikmiş sağlık ihtiyaçlarını tam olarak temsil etmeyebilir.
- ✓ Veri Kaynağı ve Gizlilik: Bu çalışma, diğer sosyal medya platformlarını ve çevrimdışı raporları hariç tutarak Twitter/X ile sınırlıdır ve yalnızca halka açık tweetler toplanmıştır, bu da bu araştırmanın zayıf bir noktası olabilir.
- ✓ Veri türü: Bu çalışmada, doğası gereği gürültülü olan ve genel çalışma sonuçlarını etkileyebilecek yanlış bilgiler, spam veya alakasız içerik içerebilen Twitter verileri kullanılmıştır.
- ✓ Analiz: Sınıflandırma ve duygu analizi ile makine öğrenimi modelleri, eğitim verilerine ve Türkçe için mevcut dil kaynaklarına bağlı olarak önyargılı olabilir.

Bu tez beş bölümden oluşmaktadır. Birinci bölüm Giriş bölümüdür. İkinci bölüm olan Literatür Özeti bölümünde afet yönetimi, sosyal medya, metin madenciliği, duygu analizi ve makine öğrenimi alanlarında yapılan çalışmalar özetlenmektedir. Üçüncü bölüm Materyal Ve Yöntem bölümüdür ve bu bölümde veri toplama süreci, veri ön işleme adımları, metin temsil yöntemleri, konu modelleme, duygu analizi ve makine öğrenimi sınıflandırma yöntemleri açıklanmaktadır. Dördüncü bölüm Bulgular ve Tartışma bölümüdür ve analizlerden elde edilen bulgular sunulmakta, konu modelleme, duygu analizi ve makine öğrenimi sınıflandırma sonuçları tartışılmaktadır. Beşinci bölüm Sonuçlar bölümüdür ve çalışmadan elde edilen temel bulgular özetlenmekte, afet sağlık yönetimi açısından çıkarımlar ortaya konulmaktadır.

2. LİTERATÜR İNCELEMESİ

2.1. Afet Yönetimi Çerçevesi

Birleşmiş Milletler'e (BM) göre, afet, çevre, ekonomi ve topluma önemli ölçüde zarar veren, nüfusun işlevlerini ve istikrarını etkileyen, halk sağlığı üzerinde olumsuz etkilere yol açan bir olaydır (Sharif, 2020: 1-2). Acil Durum Olayları Veritabanı (Emergency Events Database – EM-DAT) tanımına göre ise afet, yerel kapasiteyi aşan, ulusal veya uluslararası düzeyde dış yardım talebini gerektiren bir durum veya olaydır; büyük hasara, yıkıma ve insan acılarına neden olan öngörülemeyen ve genellikle ani bir olaydır (URL-2, 2025).

Açıklamalı Afet Yönetimi Terimleri Sözlüğü tarafından tanımlandığı üzere afet, tüm topluma veya toplumun belirli kesimlerine fiziksel, ekonomik ve sosyal kayıplara neden olan ve normal yaşamın ve insan faaliyetlerinin durmasına veya kesintiye uğramasına yol açan, etkilenen toplumun bununla başa çıkamayacağı doğal, teknolojik veya insan kaynaklı bir olaydır. Bu nedenle, afet olayın kendisi değil, daha çok sonuçları olarak kabul edilir (URL-3, 2021).

Afet Yönetimi Döngüsü, Ulusal Valiler Birliği (National Governors Association - NGA) tarafından, birbiriyle ilişkili ve bütünlükli dört temel aşamadan oluşan bir süreç olarak tanımlanmıştır. Bu aşamalar; risk azaltma (hafifletme ve önleme), hazırlık, müdahale ve iyileştirme (afet sonrası rehabilitasyon) olarak sınıflandırılmaktadır. Afet öncesinde yürütülen risk azaltma ve hazırlık faaliyetleri afet risk yönetimi kapsamında ele alınırken, afet sonrasında gerçekleştirilen müdahale ve iyileştirme çalışmaları afet kriz yönetimi olarak değerlendirilmektedir (Beauchesne, 2001; Young vd., 2020). Bu çerçevede afet yönetimi döngüsünün temel aşamaları aşağıda ayrıntılı olarak ele alınmaktadır (Beauchesne, 2001);

- ✓ Risk azaltma (hafifletme ve önleme): Risk azaltma aşaması, afet yönetim döngüsünün ilk adımıdır. Bu aşamada jeolojik, jeofizik, çevresel, sosyal ve ekonomik kırılganlıkları belirleyerek riskleri değerlendirme; bölgesel ve yerel haritalar oluşturarak afetlere yatkın alanları haritalama; konut projelerini afete dayanıklı hale getirmek için özel kılavuzlar geliştirme ve afet risklerini azaltmak için erken uyarı ve bilgi paylaşımı yoluyla afetlerin meydana gelmeden önce

potansiyel etkilerini azaltmaya yönelik teknik, ekonomik ve sosyal önlemlere odaklanır.

- ✓ Hazırlık: Hazırlık, acil durum müdahale planlarının geliştirilmesi, erken uyarı sistemlerinin kurulması, halkın afet riskleri ve bunların etkilerinin nasıl önlenip azaltılacağı konusunda eğitilmesi ve bilinçlendirilmesi yoluyla etkili ve zamanında müdahaleyi sağlamak için planlama, eğitim, öğretim ve kaynak tahsisini içerir.
- ✓ Müdahale: Müdahale aşaması, afet meydana geldikten hemen sonra başlar ve arama ve kurtarma hizmetleri, ilk yardım ve tıbbi yardım; gıda, su, barınak, giyecek ve sanitasyon hizmetlerinin sağlanması; hasar değerlendirmesi ve yardım kaynaklarının koordinasyonu dahil olmak üzere hayat kurtarmak için acil hizmetlerin sağlanmasına odaklanır. Genel olarak, müdahalenin süresi afetin ölçeğine bağlı olarak değişir ve temel hizmetleri yeniden sağlamak ve günlük yaşamı mümkün olan en kısa sürede istikrara kavuşturmak amaçlanır.
- ✓ İyileştirme (afet sonrası rehabilitasyon ve yeniden inşa): İyileştirme aşaması, temel hizmetlerin onarımı ve yeniden kurulması yoluyla kısa vadeli iyileştirme ve kayıpların yeniden inşa edilmesi yoluyla uzun vadeli yeniden inşa yoluyla afet sonrası aşamada topluluğun dayanıklılığını geri kazanmak için yapısal, sosyal, ekonomik ve çevresel rehabilitasyonu ele alır. Bu aşama, önceki kırılganlıkların devam etmesini önlemek ve yeni riskleri önlemek için “daha iyi yeniden inşa”ya odaklanır. İyileştirme genellikle ilk müdahale operasyonlarından bir ila iki ay sonra başlar ve birkaç yıl sürebilir.

Türkiye’nin afet yönetim sistemi ile ilgili olarak, 2013 yılından bu yana Türkiye, afetlere hazırlık ve hasar önleme için yasal çerçeveyi oluşturan Afet Acil Durum Müdahale Hizmetleri Yönetmeliği kapsamında faaliyet göstermektedir. Bu sistem kapsamında, 2009 yılında kurulan ve 2018 yılında İçişleri Bakanlığı’nın denetimi altında yeniden yapılandırılan Afet ve Acil Durum Yönetimi Başkanlığı (AFAD), ülkedeki afet yönetiminden sorumlu ana kurum olarak, afet risklerini ortaya çıkmadan önce azaltmak, afetlere müdahale etmek ve afetlerden sonra iyileşmek için çalışmaktadır (Ocal, 2021: 17).

Hayes vd. (2016) “Afet Müdahale Çerçevelerinin Geliştirilmesinde En İyi Uygulamaların Belirlenmesi” başlıklı raporlarında, sağlık yönetimi ve afet müdahalesine

yönelik uluslararası yaklaşımlara kapsamlı bir genel bakış sunmuş ve üst düzey hükümet taahhüdüyle desteklenen politika çerçevelerinin önemini vurgulamıştır. Uluslararası düzeyde, rapor Dünya Sağlık Örgütü'nün acil durum müdahale çerçevesini, Birleşmiş Milletler Afet Değerlendirme ve Koordinasyon (UNDAC) sistemini ve küme yaklaşımını incelemiştir. Bunların tümü, sağlık ve tıbbi hizmetleri daha geniş afet yönetimi yapılarına entegre etmektedir.

2.2. Afetlerde Sağlık İhtiyaçları

Sağlık sistemi, sağlık hizmetleri sistemi ve halk sağlığı sistemi olmak üzere iki bölümden oluşur. Bazı ülkelerde bu iki sistem ayrıdır. Örneğin ABD'de sağlık hizmetleri özel sağlık kurumları ve kamu kurumları tarafından yürütülmektedir. Buna karşın bazı ülkelerde bu system entegre olarak yürütülmektedir. Örneğin Brezilya Sağlık Bakanlığı her iki sistemi de denetlemekte ve yürütmektedir.

Normal zamanlarda bireylerin sağlık ihtiyaçları sistem içerisindeki hastaleler, klinikler, acil servisler, travma bakımı ve ruh sağlığı bakım tesisleri aracılığıyla doğrudan karşılanır. Afetler sırasında ise bu sistemde bireylere hastane öncesi bakım, acil durum ve travma müdahaleleri ile ruh sağlığı hizmetlerini içeren faaliyetleri sunulmakta ve hayat kurtarmaya yönelik nakil hizmetleri sağlanmaktadır.

Halk sağlığı sistemi, gözetim, önleme, sanitasyon, aşılama, vektör kontrolü ve politika uygulamaları yoluyla nüfus düzeyinde sağlık korumasını sağlar. Afetler sırasında halk sağlığı sistemi, sağlık ihtiyaçlarını değerlendirip izleyerek, riskleri ele alan politikalar geliştirerek ve sağlık ihtiyaçlarını, sanitasyonu, su vektörlerini ve hastalık kontrolünü değerlendirerek hayat kurtarmak için önlemler alarak ve afetler sırasında ve sonrasında zorlu durumların üstesinden gelmek için gerekli diğer tüm çalışmaları yaparak çalışır.

Krizlerin ardından her zaman talep artışı yaşanırken kaynaklar zaten sınırlı olduğundan, sağlık sektörleri ve hizmet sağlayıcılar arasındaki koordinasyon, kaynakları nüfusun ihtiyaçlarına göre tahsis ederek artan taleple sınırlı kaynak sorununu hafifletebilir. Bu kapsamda çeşitli koordinasyon mekanizmaları geliştirilmiştir. Bunların başlıcaları şu şekildedir (Shoaf, 2014: 3706-3713);

- ✓ BM Küme Sistemi: Bu sistem, uluslararası ve ulusal kurumları sektörlere göre bir araya getirir (örneğin, Sağlık Kümesi).

- ✓ ABD Ulusal Olay Yönetim Sistemi (NIMS): Sağlık sektöründeki federal, eyalet ve yerel aktörleri, sivil toplum kuruluşlarını ve özel aktörleri uyumlaştırmak için Olay Komuta Sistemini (ICS) kullanır. Sağlık ve tıbbi hizmetler için Sağlık ve İnsan Hizmetleri Bakanlığı tarafından yönetilen ESF-8 ile Acil Durum Destek Fonksiyonlarını (ESF) içerir.
- ✓ Yerel koordinasyon: Genellikle Acil Durum Operasyon Merkezlerinde (EOC) Çoklu Kurum Koordinasyon Sistemleri (MACS) aracılığıyla gerçekleştirilir. Bu merkezlerde sağlık sektörünü genellikle halk sağlığı sektörü temsil eder.
- ✓ Sağlık hizmetleri ittifakları: Bunlar, bilgi ve kaynakları paylaşan ve müdahaleyi koordine eden hastaneler ve hizmet sağlayıcıların oluşturduğu ağlardır.

Deprem, ani yaralanmalara, ölümlere ve uzun vadeli halk sağlığı sorunlarına neden olur. Deprem sadece olay esnasında travma veya yaralanmalarla sınırlı kalmayıp, aynı zamanda ruh sağlığı bozuklukları, bulaşıcı hastalıkların ortaya çıkışı ve kronik hastalıkların tedavisinde aksaklıkların yaşanması gibi çok boyutlu sonuçlar doğurmaktadır.

Depremlerin halk sağlığı üzerindeki etkileri, acil ve uzun vadeli olarak sınıflandırılabilir. Acil halk sağlığı sorunları, yetersiz acil tıbbi ve kurtarma kapasitesi, temiz su ve gıdaya sınırlı erişim, barınak sıkıntısı ve kötüleşen hijyen koşulları ile ilgilidir (Mavrouli vd., 2023: 1-3).

Ancak uzun vadede, halk sağlığı üzerindeki etkiler arasında kronik hastalıkların tedavisinde aksaklıklar ve bulaşıcı hastalık salgınları riskinin artması yer alır. Buna ek olarak, uzun vadede ruh sağlığı, psikososyal sorunlar, çevresel ve sosyoekonomik zorluklar da ortaya çıkabilir (Koçer vd., 2024: 2-4).

Acil sağlık ihtiyaçları depremler sonrası ortaya çıkan en öncelikli sorunlar arasında yer almaktadır. 1900'den 2024'e kadar doğal afetlerden kaynaklanan küresel yaralanmaları sayan EM-DAT veri setine göre, yaralıları, afet nedeniyle acil tıbbi yardım gerektiren fiziksel yaralanma, travma veya hastalığı olan kişilerdir (URL-2, 2025). EM-DAT, 1995-2022 arasındaki bu dönemde 11.360 doğal afet meydana geldiğini ve bunların sonucunda yaklaşık 7.6 milyon kişinin yaralandığını ve 1.68 milyon kişinin hayatını kaybettiğini ortaya koymaktadır (Tin vd., 2024: 255).

Depremler, seller, kuraklıklar, fırtınalar gibi doğal afetler ve savaşlar gibi insan eliyle ortaya çıkarılan her türlü afet, bulaşıcı hastalıkların yayılmasıyla yakından bağlantılıdır.

Afet sonrası ortaya çıkan insani ve sađlık ihtiyalarının karřılanamaması afetlerin etkilerini řiddetlendirir ve iyileřme srelerini uzatır. Afetlerden sonra en sık grlen bulařıcı hastalıklar, zellikle sel ve tsunami gibi hidrolojik afetlerden sonra grlen bakteriyel ve su kaynaklı hastalıklardır. Sıka bildirilen bulařıcı hastalıklar arasında leptospiroz, kolera ve dizanteri bulunmaktadır (Charnley vd., 2021: 1-5).

Afetler, etkilenen bireyler zerinde nemli acil ve uzun vadeli psikolojik etkilere sahiptir. Semptomlar kaygı, depresyon, kopukluk ve řok hissi ile bařlar ve birok kiři olaydan sonraki gnlerde akut stres bozukluđu (ASD) yařar. Uzun vadede, hayatta kalanlar travma sonrası stres bozukluđu (TSSB), depresyon veya kronik kaygı geliřtirebilir. Travmadan en az altı ay sonra teřhis edilen TSSB, travmaya maruz kalma, mdahaleci anılar, kaınma, olumsuz ruh hali veya biliř ve artan reaktiviteyi ierir. Afetlerden sonra TSSB oranları, insan kaynaklı olaylarda %15 ila %75, dođal afetlerde ise %3.7 ila %60 arasında byk farklılıklar gstermektedir (Powell vd., 2021: 5-6).

6 řubat 2023 tarihinde, Trkiye'nin gney ve gney dođu blgesi, ondan fazla řehri ve milyonlarca insanı etkileyen yıkıcı bir ift deprem gerekleřti (Aktuna ve Bahar-rvarıř, 2023: 2). 7.8 byklđindeki deprem, 1939'dan bu yana lkede kaydedilen en gl deprem oldu. Depremin merkezi Kahramanmarař ilinin Pazarcık ilesindeydi ve sismik aktivite yaklařık 9136 artı depreme neden olarak blgedeki 11 ili etkilemiř, 50.000'den fazla insanın lmne yol amıř ve tahminen 3 milyon kiřiyi yerinden edilmiř. Birleřmiř Milletler İnsani Yardım Koordinasyon Ofisi (UN OCHA), depremin toplam etkisinin potansiyel olarak 9.1 milyon kiřiye ulařtıđını ve acil yardım ve kurtarma abalarına ihtiya duyulduđunu belirtmiřtir (etin vd., 2023; OCHA, 2023; WHO, 2025).

Ayrıca, 6 řubat 2023'te Trkiye'de meydana gelen Kahramanmarař depremleri, sađlık mdahalelerinin karmařıklıđını ortaya ıkardı. Acil ihtiyalar arasında travmatik ve ortopedik yaralanmalar ve diđer acil tıbbi durumlar yer alırken, bunu kronik hastalık ynetimi ve ruh sađlıđı desteđi gibi srekli ihtiyalar izledi (WHO, 2023).

2.3. Afetlerde Kriz İletişimi ve Bilgi Akışı

Gnmz teknolojisi ile birlikte SMS, bloglar, Twitter, Facebook, WhatsApp, Instagram ve YouTube gibi internet tabanlı ve mobil platformlar afet iletişiminde farklı ve ok ynl iletişim kanalları sunmaktadır. Bu platformlar sayesinde sađlanan anlık bilgi

paylaşımı afet esnasındaki kişiler ve ekipler arasında koordinasyonun basitleştirilmesine katkı sağlamaktadır. Bu çerçevede afet iletişimi, afet yönetiminin hafifletme, hazırlık, müdahale ve iyileştirme aşamalarında, halka zamanında ve doğru bilgi sunmayı amaçlayan stratejik bir planlama ve uygulama süreci olarak değerlendirilmektedir.

Afetlerin önlenmesi veya risk ve etkilerinin azaltılabilmesi için risk tahmini, kırılganlık ve kaynak değerlendirmesi ile hazırlık, hafifletme, müdahale ve iyileştirme gibi risk yönetimi süreçlerinin bütüncül biçimde yürütülmesi gerekmektedir. Bu süreçlerin etkin şekilde işleminde, erken uyarıların oluşturulması, tahliye emirlerinin iletilmesi ve yardım faaliyetlerinin koordinasyonu açısından etkili iletişim ve bilgi akışı kritik bir rol oynamaktadır. Etkin iletişim mekanizmaları, toplumun ihtiyaçlarının doğru, zamanında ve erişilebilir biçimde karşılanmasını mümkün kılmaktadır.

Geleneksel ve yeni medya araçları yani yerel ve ulusal televizyon, radyo ve yazılı basın gibi geleneksel medya araçları önemlidir. Ancak teknolojik gelişmeler ve hızlı müdahale ve afet sonrası koşulların erken değerlendirilmesini gerektiren afetlerin doğası nedeniyle, geleneksel medya araçları giderek SMS portalları, sohbet hizmetleri, radyo yayınları, web kameraları, Twitter ve Facebook gibi yeni medya platformları tarafından tamamlanmakta ve kısmen yerini almaktadır (Widyastuti, 2021: 101-108).

Teknoloji geliştikçe, geleneksel afet yönetimi yöntemleri yeni teknolojik dünyada daha az etkili hale geldi ve özellikle sağlık hizmetleri ihtiyaçlarında ve veri analitiği, makine öğrenimi ve gerçek zamanlı gözetimdeki gelişmelerle birlikte değişiklikler devam ederek afet hazırlık stratejilerini dönüştürmek için yeni fırsatları ortaya çıkarmıştır. Bu gelişmeler tahmin doğruluğunu artırarak, kaynak tahsisini geliştirerek ve gerçek zamanlı karar vermeyi destekleyerek afet hazırlık çabalarını güçlendirmekte ve afetlere yatkın bölgelerdeki dayanıklılığı artırmaktadır (Hernanto ve Mantoro, 2024: 1-2).

2.4. Afetlerde Veri Kaynağı Olarak Sosyal Medya

Afet direnci, bir topluluğun veya bireylerin afet sonrası normal hayata dönme yeteneğini ifade eder. Afet direnci, afetlerin farklı nedenlerini ve etkili çözüm stratejilerini belirleyerek topluluğun afet sonrası durumla başa çıkmasına yardımcı olur (Sarker vd., 2020: 1-2).

Son zamanlarda yapılan çalışmalar, afet yönetiminde sosyal medyanın önemli rolünü vurgulamaktadır. Sosyal medya, topluluk farkındalığına, gönüllülerin seferber edilmesine ve gerçek zamanlı kriz izlemeye katkıda bulunmaktadır (Reuter vd., 2018: 280-294).

Günümüzde sosyal medya platformları modern iletişimde büyük bir rol oynamaktadır. Twitter, hızlı bilgi paylaşımı ve kamuoyu etkileşimi için en etkili araçlardan biri olup, dünya çapında birçok kişi tarafından kullanılmaktadır. Bu durum, Gaisbauer vd. (2021) ve Auxier ve Anderson (2021) tarafından da doğrulanmıştır. Twitter, sosyal medya ile ilgili araştırmalarda en yaygın kullanılan kaynaklardan biridir ve Google Scholar, başlığında Twitter kelimesi geçen 27.000 araştırma makalesi listelemektedir (Antonakaki vd., 2021: 1-2).

Twitter, afetler sırasında iletişim için değerli bir platform haline gelmiş ve afet yönetimi için etkili bir şekilde kullanılmıştır (Xu, 2020: 933). Çünkü bireyler Twitter platformunu etkilenen bölgelerdeki diğer kişilerle iletişim kurmak ve gıda, su, barınak gibi acil ihtiyaçları ile ilgili bilgileri paylaşmak için kullanmaktadırlar (Murakami vd., 2020: 1-6). Geleneksel medyadan farklı olarak, Twitter'ın sağladığı iki yönlü gerçek zamanlı iletişim modeli, kritik bilgilerin kolay ve zamanında akışını kolaylaştırarak afet yönetiminin etkinliğini artırmaktadır (Arvandi vd., 2024: 1-2). Saroj ve Pal (2020) Twitter'ın basitliği ve kısa ve hızlı iletişim kurma yeteneği sayesinde afetler sırasında en önemli iletişim platformlarından biri olduğunu belirtmiştir.

Sosyal medya platformları, gerçek zamanlı iletişim ve bilgi alışverişi sunarak afet iletişimi ve değerlendirmesinde kritik araçlar olarak ortaya çıkmıştır ve bu da acil durum müdahale ekiplerinin hızlı hareket etmesine yardımcı olmaktadır.

Geleneksel afet yönetim sistemleri genellikle sahadan toplanan verilere dayansa da, bu yöntemler zaman alıcı olabilir ve gerçek ihtiyaçları tam olarak yansıtmayabilir. Ancak günümüzde sosyal medya platformları, özellikle X (Twitter), halkın afetler sırasında deneyimlerini ve ihtiyaçlarını anında paylaşabileceği önemli kanallar haline gelmiştir (Reuter vd., 2018: 280-294) ve sosyal medya, kritik toplumsal sorunlara dikkat çekerek hızlı müdahale ve iyileşmeye yardımcı olarak afetler sırasında da önemli bir rol oynamaktadır (Aldamen ve Hacimic, 2023: 1-3). Özellikle Twitter, nüfusun ihtiyaçları, hasar raporları ve durum farkındalığı hakkında gerçek zamanlı bilgiler sağlamaktadır (Xu, 2020: 933).

Sosyal medyanın afet yönetiminde kullanımı, özellikle Twitter'ın etkinliği ve zamanında harekete geçme kabiliyeti nedeniyle artmaya başlamıştır (Yang vd., 2024: 1715-1720). Sağlık ve tıbbi ihtiyaçlar, araştırmalarında gıda, su ve barınak gibi sonuç kategorileri arasında yer almaktadır. Ayrıca, afetlerin etkileri, su ve gıda gibi temel ihtiyaçların ötesine geçerek (Zhong vd., 2021: 2-3) psikolojik travma, stres sorunları, depresyon ve diğer psikolojik sorunlar gibi insanların üzerinde olumsuz etkileri olan aşırı psikolojik ve zihinsel etkilere kadar uzanabilir (Mızrak, 2024: 3-4).

2.5. Sosyal Medya Analizi Üzerine Literatür İncelemesi

Sakaki vd. (2010), Twitter'ın kullanıcı gönderilerini gerçek dünyadaki olayların olasılık sinyalleri olarak ele alarak afet tespiti için gerçek zamanlı (sosyal sensör) olarak işlev görebileceğini göstermiştir. Yöntem, depremle ilgili anahtar kelimeler içeren tweetlerin anlamsal analizini ve ardından sismik olayları tanımlamak ve konumlarını tahmin etmek için zamansal ve mekansal toplama işlemlerini içermektedir. Çalışma, depremleri başarıyla tespit etmiş ve konumlarını gerçek zamanlı olarak tahmin etmiştir. Önerilen sistem, yüksek tespit doğruluğu elde etmiş (Japonya'daki orta ve şiddetli depremler için %96'ya kadar) ve genellikle resmi sismik duyurulardan daha hızlı uyarılar vererek, erken uyarı ve olay tespiti için tamamlayıcı bir araç olarak sosyal medyanın potansiyelini vurgulamıştır.

Oh vd. (2010), 2010 Haiti depremi sırasında sosyal medyanın dinamiklerini inceledi ve bu çalışma, Twitter'ın olağanüstü olaylar sırasında nasıl çalıştığını anlamada teorik bir dönüm noktası oldu. Araştırmacılar, sosyal medya etkileşiminin temel itici güçleri olarak kaygı ve bilgi belirsizliğine odaklanarak 2.3 milyon tweeti analiz ederek bilgi yayılma modellerini anlamak için söylenti teorisini uyguladılar. Çalışma, afetler sırasında belirsizlik ve korkunun bilgi arama davranışını ve retweetleme faaliyetini artırdığını ortaya koyarken, krizler sırasında dijital platformlarda kolektif davranışın nasıl ortaya çıktığını da göstermiştir. Bu teorik çerçeve, yüksek düzeyde kaygı yaşayan kullanıcıların belirsizliği azaltmak için bilgi arayıp paylaştıkları için afetler sırasında sağlık ihtiyaçları ve yardım taleplerinin sosyal medyada yayılmasının nedenini anlamak için önemli bir bağlam sağlamaktadır. Bu çalışma, deprem mağdurlarının sağlık endişelerini Twitter'da kamuya açık bir şekilde ifade etmelerine neden olan psikolojik mekanizmaları açıklamakta ve

sosyal medyayı acil tıbbi ihtiyaçları belirlemek için güvenilir bir veri kaynağı haline getirmektedir.

Caragea vd. (2011), zamanında acil müdahaleyi desteklemek amacıyla 2010 Haiti depremi sırasında üretilen krizle ilgili tweetleri ve metin mesajlarını otomatik olarak sınıflandırmak için EMERSE sistemini geliştirmiştir. Destek Vektör Makineleri ile denetimli makine öğrenimini kullanan çalışma, çoklu özellik temsillerini karşılaştırmış ve özellik soyutlamasının, kısa, çok etiketli afet mesajları için geleneksel kelime torbası, özellik seçimi ve LDA tabanlı konu özelliklerinden önemli ölçüde daha iyi performans gösterdiğini ortaya koymuştur. Bulgular, afet müdahalesi sırasında durum farkındalığını ve kaynak koordinasyonunu iyileştirmek için büyük ölçekli sosyal medya verilerini düzenlemede otomatik metin sınıflandırmasının etkinliğini vurgulamaktadır.

Bronz ve Burgess (2012), Christchurch depremi sırasında #eqnz hashtag'ini kapsamlı bir şekilde analiz etmiş ve sosyal medyada kriz iletişimi biliminin temel ilkelerini belirlemiştir. Araştırmaları, yerel ve küresel kullanıcıların yoğun dönemlerde dakikada 100'den fazla tweete ulaşan bilgi akışına nasıl katkıda bulunduğunu belgelemiş ve sahadaki koşulları bildiren sakinler ile haberleri paylaşan ve dayanışma gösteren uzak gözlemciler arasında belirgin farklılıklar ortaya çıkmıştır. Çalışma, coğrafi ve sosyal ağlar üzerinden bilgi yayılımını haritalamak için görsel çerçeveler sunarak, afetler sırasında hashtag'lerin koordinasyon mekanizmaları olarak nasıl işlediğini göstermiştir. Bu çalışma, zamansal toplama ve coğrafi görselleştirme teknikleri de dahil olmak üzere, depremler sırasında büyük ölçekli Twitter analizi için metodolojik emsaller oluşturmuştur.

Kumar ve Singh (2019), evrişimli sinir ağları (CNN) kullanarak acil durum tweetlerinden konum çıkarma geliştirdiler ve sokak seviyesinden şehir seviyesine kadar çeşitli doğruluk seviyelerinde coğrafi referanslama için 0.96 F1 puanı elde ettiler. Çalışma, metinden doğrudan hiyerarşik özellik temsillerini öğrenen derin öğrenme yaklaşımları aracılığıyla, gayri resmi ve gramer kurallarına uymayan acil durum tweetlerinden konum referanslarını çıkarma zorluğunu ele almıştır. Araştırmacılar, acil durum tweet veri kümeleri üzerinde çapraz doğrulama kullanarak, CNN'lerin geleneksel adlandırılmış varlık tanıma sistemlerinden daha yüksek doğrulukla çok düzeyli konumları (sokaklar, mahalleler, şehirler) tanımlayabildiğini göstermiştir. Bu CNN tabanlı metodoloji, derin öğrenmenin kriz tweetlerinin gayri resmi dilbilimsel doğasını nasıl ele alabileceğini göstermektedir.

Hernandez-Suarez vd., (2019), 2017 Meksika depremiyle ilgili Twitter verilerini analiz etmek için biLSTM-CRF ağırları ve çekirdek yoğunluk tahminini birleştiren sofistike bir yaklaşım geliştirdiler. Metodoloji, İspanyolca tweetlerden yer adlarını çıkarmak için koşullu rastgele alan çıktı katmanlarına sahip çift yönlü uzun kısa süreli bellek ağırları kullandı ve yerler, kuruluşlar ve kişiler için adlandırılmış varlıkları tanımada yüksek doğruluk elde etti. Çıkarılan konumları Google Maps API kullanarak coğrafi kodladıktan sonra, araştırmacılar çekirdek yoğunluk tahminini uygulayarak afet raporlarının yoğunlaştığı sıcak noktaları görselleştirdiler. Sistem, sosyal medyada bildirilen yıkılan binaların, kayıp kişilerin ve barınak konumlarının uzamsal yoğunluğunu haritalandırarak acil durum müdahalesi için öncelikli alanları başarıyla belirledi.

Eligüzel vd. (2020) coğrafi etiketli deprem tweetlerinden konumları çıkarmak için 10 makine öğrenimi algoritması arasında kapsamlı karşılaştırmalar yaptı ve Multinomial Naive Bayes ve Extra Trees'in %80'in üzerinde en yüksek F puanlarını elde ettiğini buldu. Çalışma, konum bilgisi çıkarmak için geleneksel algoritmaları olan Karar Ağaçları, Rastgele Ormanlar, K-En Yakın Komşular ile ensemble yöntemlerini olan AdaBoost, Gradient Boosting'i sistematik olarak değerlendirmiş ve çıkarılan konumların bağlamsal olarak anlaşılmasını sağlamak için LDA konu modellemesi ve duygu analizini dahil etmiştir. Çalışma, konum çıkarma, konu keşfi ve duygusal ton algılama için birden fazla analitik tekniğin birleştirilmesinin, tek bir yöntemle kıyasla durumun daha zengin bir şekilde anlaşılmasını sağladığını göstermiştir.

Eligüzel vd. (2022) depremle ilgili tweetler için özel olarak derin öğrenme tabanlı bir adlandırılmış varlık tanıma sistemi geliştirdi ve tekrarlayan sinir ağırlarını kullanarak afetle ilgili gayri resmi iletişimlerden kuruluşları, kişileri ve konumları çıkardı. Çalışma, krizle ilgili tweetlerde yaygın olan standart dışı kısaltmalar, hashtag'ler ve gramer düzensizlikleri dahil olmak üzere acil durumlarda sosyal medya metinlerini işlemenin benzersiz zorluklarını ele aldı. Çalışma, RNN mimarileriyle birlikte metni ön işlemek için NLTK ve GATE araçlarını kullanarak, acil durum müdahalesinin koordinasyonuna yardımcı olabilecek önemli varlıkları çıkarmanın etkinliğini göstermiştir. Bu çalışma, genel amaçlı NER araçlarının genellikle sosyal medyada kullanılan gayri resmi dili işleyemediği için, afet bağlamları için özel olarak tasarlanmış NER sistemlerinin önemini vurgulamaktadır.

Behl vd. (2021) afetle ilgili tweetlerdeki kaynak ihtiyaçlarını belirlemek için çok sınıflı sınıflandırma sistemleri geliştirdi ve tweetleri belirli ihtiyaç türlerine sınıflandırmak için Çok Katmanlı Perceptron (MLP) ağlarını kullanarak denetimli makine öğrenimini uyguladı. Çalışma, COVID-19 krizi ve doğal afetleri ele almış ve MLP sınıflandırıcılarının tıbbi ihtiyaçlar, gıda/su tedariki, barınma gereksinimleri ve kurtarma operasyonları dahil olmak üzere farklı yardım talepleri kategorilerini etkili bir şekilde ayırt edebildiğini göstermiştir. Çalışma, basit duygu veya alaka sınıflandırmasının ötesine geçen doğru sınıflandırmanın önemini vurgulamış ve hedefli yardım çabalarını desteklemek için belirli ihtiyaç türlerinin nasıl otomatik olarak tanımlanabileceğini göstermiştir.

Agrali vd. (2022), afet sonrası dönemde kamuoyundaki söylemleri ve duygusal dinamikleri incelemek için LDA konu modellemesi ve BERT tabanlı duygu analizi kullanarak 2020 İzmir depremiyle ilgili 626.000'den fazla Twitter gönderisini analiz etmiştir. Sonuçlar, Twitter aktivitesinin ve olumsuz duygu durumunun depremden sonraki ilk günlerde zirveye ulaştığını, konu kalıplarının ise yardım çabaları, iyi niyet mesajları ve resmi iletişimlere odaklandığını ve duygu durumundaki dalgalanmaların büyük kurtarma olaylarını yakından yansıttığını göstermiştir. Çalışma, afet müdahalesi sırasında kamuoyunun duygularını ve bilgi ihtiyaçlarını gerçek zamanlı olarak izlemek için dönüştürücü tabanlı duygu analizinin değerini ortaya koymaktadır.

Contreras vd. (2022a) çalışmalarında Arnavutluk'da yaşanan deprem sonrasında tweetler üzerinde önceden eğitilmiş duygu analizi modellerini değerlendirerek, farklı afet bağlamlarında makine öğrenimi modellerinin doğruluğunu ve aktarılabilirliğini değerlendirdi. Çalışma, genel sosyal medya verileri üzerinde eğitilmiş duygu analizi modellerinin acil durum iletişimlerine uygulandığında performansını incelemiş ve afet bağlamlarının model performansını etkileyen benzersiz dilbilimsel modeller sunduğunu ortaya koymuştur. Çalışma, çoklu sınıflandırma yaklaşımlarını karşılaştırarak, acil durum müdahalesini değerlendirmek ve erken iyileşme aşamasını izlemek için otomatik duygu algılamanın güvenilirliği hakkında içgörüler sağlamıştır.

Contreras vd. (2022b), 2020 Ege depremiyle ilgili tweetlerdeki duygu kalıpları ve konularla deprem şiddetini ilişkilendirmek için veriye dayalı yaklaşımlar geliştirdi. Araştırmacılar, LastQuake verilerini kullanarak, deprem şiddet ölçümleri ile sosyal medyadaki duygusal ifadeler arasında sistematik ilişkiler olduğunu gösterdi; şiddetinin

daha yüksek olduđu bölgelerde, korku ve aciliyetle daha fazla ilişkili bir dil kullanıldığını görüldü. Konu analizi, tartışma konularının deprem şiddetiyle birlikte, yüksek şiddetli bölgelerdeki acil güvenlik endişelerinden orta şiddetli bölgelerdeki hasar değerlendirmesi ve kurtarma planlamasına doğru geliştiğini ortaya koymuştur.

Contreras vd. (2022c), L'Aquila depremi sonrası uzun vadeli kurtarma sürecini değerlendirmek için Twitter'ı geleneksel olmayan bir veri kaynağı olarak kullanmaya öncülük etti ve uzun süreler boyunca kurtarma göstergelerini izlemek için denetimli ve denetimsiz makine öğrenimini kullandı. Çalışma, sosyal medyadaki duygu kalıplarının ve konu evriminin kurtarma sürecindeki ilerlemeyi yansıttığını ve acil kriz müdahalesinden yeniden inşa ve normal yaşamın geri kazanılmasına doğru kademeli bir geçiş olduğunu gösterdi. Araştırma, iyileşmeyle ilgili tweetlerin denetimli sınıflandırmasını denetimsiz konu keşfi ile birleştirerek, geleneksel değerlendirme yöntemleriyle gözden kaçabilecek çok yıllık iyileşme eğilimlerini ortaya çıkarmıştır. Ruh sağlığı ihtiyaçlarının %11 ile zirveye ulaştığı bulgusu, Twitter verilerinin acil fiziksel tehlikeler ortadan kalktıktan sonra ortaya çıkan akut psikolojik stresi yakalayabildiğini göstermektedir. Bu metodoloji, iyileşme aşamaları boyunca sağlık ihtiyaçlarının gelişimini izlemek için sosyal medyanın kullanımını doğrulamaktadır.

Verma vd. (2023) Şubat 2023 Türkiye depremiyle ilgili Twitter gönderilerini sınıflandırmak için çoklu transformatör tabanlı modellerin etkinliğini değerlendirdi ve yardım talebinde bulunan tweetleri belirlemeye odaklandı. 500 Türkçe tweetten oluşan manuel olarak etiketlenmiş bir veri seti kullanılarak yapılan çalışmada, beş BERT tabanlı mimari karşılaştırılmış ve hafif modellerin, özellikle DistilBERT'in, hesaplama maliyetini önemli ölçüde azaltarak en yüksek sınıflandırma doğruluğunu sağladığı bulunmuştur. Sonuçlar, dönüştürücü tabanlı kodlayıcıların sosyal medyada yardım isteyen içeriklerin hızlı bir şekilde tespit edilmesinde oldukça etkili olduğunu ve gerçek zamanlı afet müdahalesi ve kaynak tahsisinde pratik kullanımlarını desteklediğini göstermektedir.

Kuşku Özdemir (2024) 2023 Kahramanmaraş depremleri sırasında AFAD'ın resmi Twitter/X iletişimini, afet sonrası ilk hafta paylaşılan 182 kurumsal tweetin nitel içerik analizi ile inceledi. Çalışma, AFAD'ın sosyal medyayı öncelikle operasyonel bilgi ve destek hizmetleri için kullandığını, ancak dezenformasyonu ele alan gönderilerin - en az sıklıkta olmasına rağmen - en yüksek kamu katılımını sağladığını ortaya koydu ve bu da

yüksek belirsizlik içeren kriz dönemlerinde vatandaşların doğrulanmış bilgiye olan güçlü talebini vurguladı. Bulgular, Twitter/X'in gerçek zamanlı kriz iletişim aracı olarak kritik rolünü vurgularken, aynı zamanda büyük ölçekli afetler sırasında sürekli ve etkileşimli iletişim potansiyelini tam olarak kullanma konusunda kurumsal zorlukları da ortaya koymaktadır.

Erokhin ve Komendantova (2024), büyük depremleri çevreleyen HAARP ile ilgili komplo söylemlerinin dinamiklerini incelemek için bir milyondan fazla Twitter gönderisini analiz etti ve özellikle 6 Şubat 2023 Türkiye-Suriye depremi üzerinde durdu. Çalışma, komplo teorileriyle ilgili tweet hacminin yüksek büyüklükteki sismik olayların ardından önemli ölçüde arttığını ve deprem büyüklüğüyle pozitif korelasyon gösterdiğini ortaya koyarak, olayların yanlış bilgilerin yayılmasını artırdığını ortaya koymuştur. Duygu ve söylem analizleri ayrıca, afet sonrası tartışmaların çevrimiçi topluluklar içinde, paylaşılan yanlış bilgi anlatıları yoluyla psikolojik doğrulama yaratan bir pekiştirme etkisi yarattığını göstermiştir.

Rashid ve Fandek (2024), 6 Şubat 2023'te Türkiye ve Suriye'de meydana gelen depremden sonra toplanan Twitter verilerinin duygu analizini yapmak için üç farklı etiketleme yaklaşımı yani manuel etiketleme, NLTK VADER (Valence Aware Dictionary and Sentiment Reasoner) ve K-Means Cluster etiketleme kullanarak bir çalışma yürütmüştür. Sonuçlar, VADER tabanlı etiketlemenin manuel açıklamalarla büyük ölçüde örtüştüğünü ve olumlu duyguları abartan küme tabanlı etiketlemeden önemli ölçüde daha iyi performans gösterdiğini ortaya koymuştur. Çalışma, sözlük tabanlı duygu analizinin afetler sırasında hızlı duygusal değerlendirme için etkili ve güvenilir bir alternatif olduğunu göstermektedir.

Rachel vd. (2024), BERTopic'i afetle ilgili tweetlerin denetimsiz bir şekilde toplanmasına uygulayarak, krizle ilgili iletişimlerden konuları otomatik olarak çıkarmak için dönüştürücü tabanlı gömülü öğelerin etkinliğini göstermiştir. Kelime torbası varsayımlarına dayanan geleneksel konu modelleme yaklaşımlarının aksine, BERTopic, BERT'in bağlamsal temsillerini kullanarak anlamsal benzerlikleri yakalar ve önceden tanımlanmış konu sayıları olmadan tutarlı konu kümeleri oluşturur. Araştırmalar, BERTopic'in altyapı hasarı, tahliye yolları, kaynak dağıtımı ve duygusal destek gibi afetlerle ilgili anlamlı konuları başarıyla belirlediğini ve konu tutarlılığı ve

yorumlanabilirlik açısından LDA'yı geride bıraktığını göstermiştir. Bu doğrulama, BERTopic'in dönüştürücü tabanlı mimarisinin, geleneksel yöntemlere kıyasla krizle ilgili iletişimlerdeki nüanslı konuları daha iyi yakaladığını kanıtlamaktadır. BERTopic'in denetimsiz yapısı, önceden tanımlanmış sağlık kategorilerine ihtiyaç duymadan acil sağlık ihtiyaçlarını analiz etme zorluğunu da ortadan kaldırmaktadır.

Han vd. (2024) Çin Weibo verilerini kullanarak deprem etki değerlendirmesi için tasarlanmış ilk alan özel büyük dil modeli olan QuakeBERT'i tanıttı. Daha sonra, birden fazla depremden elde edilen manuel olarak etiketlenmiş mikrobloglar üzerinde eğitilen QuakeBERT, CNN ve RNN temel modellerinden önemli ölçüde daha iyi performans gösterdi ve model performansı için veri çeşitliliğinin veri hacminden daha etkili olduğunu ortaya koydu. Gürültüyü etkili bir şekilde filtreleyerek ve duygu ve anahtar kelime tabanlı hasar değerlendirmesini entegre ederek, çerçeve resmi hasar raporlarıyla yakından uyumlu etki tahminleri üretti ve sosyal medya tabanlı afet değerlendirmesi ve acil durum karar verme sürecini iyileştirmede alana uyarlanmış dil modellerinin kritik rolünü vurguladı.

Li vd. (2026), 2023 Pekin yağmur fırtınasıyla ilgili Sina Weibo'daki 50.000'den fazla gönderiyi analiz ederek, entegre BERTopic-SKEP çerçevesi ve anlatı politika çerçevesi kullanarak çok aşamalı acil durum yönetimi politikalarına halkın tepkilerini incelemiştir. Bu çalışmanın sonuçları, halkın dikkatinin müdahale ve iyileştirme aşamalarına yoğunlaştığını, önleme ve hazırlık politikalarının ise çok az ilgi gördüğünü ortaya koyarak, proaktif risk yönetimi ile halkın algısı arasındaki yapısal uçurumu vurgulamıştır. Duygu analizi de, özellikle iyileştirme aşamasında halkın genel olarak olumlu bir tutum sergilediğini gösterirken, müdahale aşamasında alınan önlemlerin en yüksek düzeyde eleştiri aldığını ortaya koyarak, yüksek etkili afet aşamalarında şeffaflık, zamanında iletişim ve stratejik politika mesajlarının önemini vurgulamıştır.

Wang vd. (2025) BERTopic, SKEP duygu analizi ve BERT tabanlı hasar sınıflandırmasını birleştiren entegre bir konu, duygu ve hasar analiz çerçevesi kullanarak, Tibet'teki 2025 Dingri depremiyle ilgili Sina Weibo'da yayınlanan 123.000'den fazla gönderiyi analiz etti. Çalışma, çevrimiçi söylemlerde belirgin coğrafi ve bilgisel eşitsizlikler olduğunu ortaya koydu. Dikkatler deprem merkez üssü bölgesinden çok büyük şehirlere odaklanmıştı. Çalışma ayrıca tartışma konuları, duygusal kutuplaşma ve fiziksel hasarın ciddiyeti arasında güçlü bir korelasyon olduğunu gösterdi. Sonuçlar, sosyal medya

verilerinin resmi kayıp istatistikleriyle yakından örtüşen, afet etkisine ilişkin erken ve nicel olarak güvenilir sinyaller sağlayabileceğini doğrulayarak, gerçek zamanlı afet algısı ve hasar değerlendirmesi için transformatör tabanlı yöntemlerin değerini vurguladı.

Murthy vd. (2025) GPU hızlandırmalı BERTopic kullanarak dört büyük ABD kasırgasıyla ilgili 1.7 milyon tweeti analiz ederek, insan müdahalesi olmadan afetle ilgili temaları belirledi. Çalışma, transformatör tabanlı konu modellemesinin uyarı, müdahale ve kurtarma aşamalarında farklı iletişim modellerini verimli bir şekilde yakalayabildiğini ve hazırlık, resmi eylemler, duygusal yük ve afet yardımı gibi aşama özelinde kamuoyunun endişelerini ortaya çıkardığını göstermiştir. Önemli hesaplama hızı artışları ve yüksek konu tutarlılığı elde ederek, araştırma büyük ölçekli afet iletişimi analizi ve gerçek zamanlı acil durum yönetimi içgörülerine yönelik denetimsiz transformatör yaklaşımlarının ölçeklenebilirliğini ve etkinliğini doğrulamaktadır.

Anthony ve Zhou (2025) Cardiff NLP dönüştürücüsünü ek öz dikkat katmanlarıyla genişleterek, krizle ilgili sosyal medyada çok etiketli duygu sınıflandırması için geliştirilmiş bir dönüştürücü tabanlı çerçeve önerdi. 2011 Christchurch depremlerinden elde edilen Twitter verilerine uygulanan model, temel yaklaşımlardan daha iyi performans gösterdi ve krizle ilgili tweetlerin sıklıkla birden fazla eşzamanlı duyguyu ifade ettiğini ve akut sıkıntıdan dayanıklılık odaklı duygulara zamanla geçiş yaptığını ortaya koydu. Çalışma, afetler sırasında halkın psikolojik tepkilerinin nüanslarını yakalamak için çok etiketli duygu modellemesinin önemini ortaya koyarak kriz iletişimi, ruh sağlığı izleme ve afet müdahale planlaması için pratik değer sunmaktadır.

Ilyas ve Sharifi (2025) PRISMA çerçevesini kullanarak afet risk yönetiminde sosyal medyada duygu analizi üzerine 139 çalışmayı sistematik olarak inceleyerek, kritik metodolojik boşlukları ve araştırma eğilimlerini belirlemiştir. Meta analizler, bu alanda kalıcı önyargılar olduğunu ortaya koymuştur: İngilizce ve Çince içeriğe aşırı vurgu, Kuzey Amerika ve Asya'ya coğrafi odaklanma ve platform sınırlamaları (diğer sosyal medya ağlarına göre Twitter/Weibo'nun hakimiyeti). İnceleme, sözlük tabanlı duygu analizinden dönüştürücü tabanlı yaklaşımlara kadar hızlı metodolojik evrimi belgelemiş ve birden fazla tekniği birleştiren hibrit yöntemlerin genellikle en iyi performansı gösterdiğini belirtmiştir.

Patel vd. (2025) deprem olayları sırasında yayınlanan tweetlerden ilgili bilgileri doğru bir şekilde çıkarmak ve analiz etmek için, tarihsel deprem verilerinden elde edilen gerçekçi,

felakete özgü tweet metinleri üzerinde Adlandırılmış Varlık Tanıma modelini ince ayarlayarak, dönüştürücü tabanlı bir doğal dil işleme çerçevesi önermiştir. Çalışma, etkilenen yerleri ve felaketle ilgili varlıkları tanımlamada yüksek doğruluk göstermiştir. Yöntem, etkilenen alanları belirlemek için yayınlanan tweetlerin konumunu kullanmaya, şiddet haritaları oluşturmaya ve değerli bilgileri görüntülemek için WebGIS'i kullanmaya odaklanmaktadır. Sonuçlar, gerçek dünyadaki sosyal medya dilinde eğitilmiş bağlam farkında NER modellerinin güvenilir uzamsal hasar haritaları oluşturabileceğini ve deprem olayları sırasında acil durum müdahale koordinasyonu ve kaynak tahsisi için eyleme geçirilebilir destek sunabileceğini doğrulamaktadır.

Shen vd. (2025) BERTopic ve duygu sözlüğü tabanlı duygu analizi kullanarak 88.000'den fazla Weibo gönderisini inceleyerek 2023 Türkiye-Suriye depremiyle ilgili Çin sosyal medyası söylemlerini analiz etti. Çalışma, tartışmaların esas olarak Çin'in insani yardım ve kurtarma faaliyetlerine odaklandığını ve genel olarak olumlu duyguların hakim olduğunu ortaya koyarken, Suriye ile ilgili içeriklerin yaptırımlarla ilgili anlatılar nedeniyle daha olumsuz duygular uyandırdığını ortaya koydu. Bulgular, ulusal bağlam, isimlendirme kuralları ve jeopolitik faktörlerin sosyal medyada uluslararası afet olaylarına yönelik kamuoyunun ilgisini ve duygusal çerçeveyi nasıl şekillendirdiğini vurgulamaktadır.

Aslan ve Yıldırım (2025) Kahramanmaraş depremiyle ilgili tweetlerde duygu sınıflandırmasını iyileştirmek için yeni dikkat tabanlı BiLSTM mimarileri geliştirdi ve derin öğrenme dikkat mekanizmalarıyla Türkçe NLP zorluklarını ele aldı. Araştırmalar, dikkat katmanlarının modellerin tweetlerde duygu taşıyan kelimelere ve ifadelere odaklanmasını sağlayarak, özellikle kriz iletişiminde yaygın olan karmaşık veya belirsiz ifadeler için sınıflandırma doğruluğunu artırdığını göstermiştir. BiLSTM yapısı, iki yönlü bağlamı (geçmiş ve gelecekteki kelimeler) yakalarken, dikkat mekanizmaları duyguyu belirlemek için farklı kelimelerin önemini değerlendirir.

Hossain vd. (2025) Transformer tabanlı duygu sınıflandırması, VADER çoklu duygu analizi ve NRClex duygu algılama yöntemlerini birleştiren hibrit bir çerçeve kullanarak, 2023 yılında Türkiye ve Suriye'de meydana gelen depremin ardından Twitter'da yapılan tartışmaları analiz etmiştir. Sonuçlar, tüm veri setlerinde olumsuz duyguların ve sıkıntı ile ilgili duyguların, özellikle de korku ve öfkenin baskın olduğunu tutarlı bir şekilde göstermiştir. Bu durum, felaketin hemen ardından yaygın olarak görülen psikolojik etkiyi

yansıtmaktadır. Çalışma, felaketlere müdahale eden ruh sağlığı müdahaleleri ve kültürel açıdan duyarlı risk iletişim stratejileri konusunda rehberlik etmede sosyal medya tabanlı duygu analizinin değerini vurgulamaktadır.

Gündüz vd. (2025), Kahramanmaraş depremi sırasında AFAD'ın X/Twitter hesabının performansını değerlendirdi ve deprem öncesi ve sonrası Ocak-Mart 2023 dönemindeki kurumsal iletişim modellerini karşılaştırdı. Çalışma, Türkiye'nin ana afet yönetim kurumunun tweet sıklığını, içerik türlerini, genel etkileşim metriklerini ve yanıt zamanlamasını analiz ederek kriz zamanlarında iletişimin etkinliğini değerlendirmiştir. Çalışma, depremden sonra AFAD'ın sosyal medya stratejisinde önemli değişiklikler olduğunu ortaya koydu. Güncelleme sıklığı arttı, görsel içerik daha fazla yer aldı ve rutin hazırlık mesajlarına kıyasla acil güvenlik bilgilerine daha fazla odaklanıldı. AFAD'ın iletişim modellerini anlamak, bilgi eksikliklerinin veya iletişim eksikliklerinin, karşılanmamış sağlık ihtiyaçlarını ifade eden kamuya açık tweetleri nasıl etkilemiş olabileceğini yorumlamak için bir bağlam sağlar.

3. MATERYAL VE YÖNTEM

Yöntem bölümü; veri toplama, ön işleme, LDA konu modelleme, BERTopic kümeleme, BERTurk duygu analizi ve makine öğrenimi sınıflandırması olmak üzere Tablo 1’de sunulan altı aşamalı analitik çerçeveden oluşmaktadır.

Tablo 1. Altı adımlı yöntemden oluşan analitik çerçeveye genel bakış

Aşama	Yöntem / Araç	Amaç	Çıktı
1. Veri Toplama	Twitter API (Selenium)	Ham tweet toplama	88.073 tweet
2. Ön İşleme	Zeyrek + NLTK	Temizleme ve lemmatizasyon	79.293 temiz tweet
3. LDA Modelleme	Gensim LDA (K=5)	Konuları keşfet	5 ana konu
4. BERTopic Kümeleme	MiniLM-L12 + UMAP + HDBSCAN	Anlamsal kümeleme	59 konu
5. BERTurk Duygu	savasy/bert-base-turkish-sentiment-cased	Duygu sınıflandırması	%76.21 negatif
6. ML Sınıflandırma	TF-IDF + SMOTE + 5 model	Sağlık içeriği tespiti	%89.07 doğruluk

3.1. Kullanılan Yöntemler ve Modeller

3.1.1. Metin Madenciliği ve Doğal Dil İşleme Altyapısı

Metinden Bilgi Keşfi (KDT) olarak da adlandırılan Metin Madenciliği (TM) metin yoluyla yüksek kaliteli bilgi ve istatistiksel sonuçların çıkarılması süreci olarak tanımlanır. Çıkarım ise genellikle Doğal Dil İşleme (NLP) kullanılarak gerçekleştirilir (Allahyari vd., 2017: 1-3).

NLP, Yapay Zeka (AI) alanının çok disiplinli bir alt dalıdır ve makinelerin yapılandırılmamış metin verilerini yapılandırılmış bilgilere dönüştürmeyi amaçlamaktadır. Böylece karar verme, iletişim ve bilgi erişimine katkıda bulunabilecek dilbilim, bilgisayar bilimi ve yapay zeka alanlarından farklı kavramları entegre ederek insanların bu dili anlamasını ve yorumlamasını sağlar (Rayhan vd., 2023: 1-2).

NLP, iki ana bileşen aracılığıyla çalışır. Metin veya konuşmadan anlam, varlıklar ve ilişkileri analiz eden ve çıkaran Doğal Dil Anlama (NLU) ve yapılandırılmış veya yapılandırılmamış veri girdilerine dayalı olarak tutarlı, insan benzeri dil çıktısı üreten Doğal Dil Üretimi (NLG) şeklindedir. (Godinho, 2024; Khurana vd., 2023).

NLP uygulamaları çok geniştir; özellikle duygu analizi ve metin madenciliğinde ve metin verilerinin ve yapay zekanın katlanarak artmasıyla, NLP kullanımı özellikle sağlık sektörü, eğitim, finans ve diğer sektörlerde muazzam bir artış göstermiştir (Godinho, 2024: 4-8).

Özellikle gürültü, gayri resmi dil ve tutarsızlıkların yaygın olduğu sosyal medya verilerin ön işleme, NLP için temel bir adımdır. Duygu analizi, konu modelleme ve sınıflandırma için Türkçe tweet veri kümesini hazırlamak üzere sistematik olarak birden fazla ön işleme tekniği uygulanacaktır. Aşağıdaki adımlar, Python tabanlı kütüphanelerin bir kombinasyonu kullanılarak gerçekleştirilmiş ve verilerin temizlenmesi, yapılandırılması ve daha ileri analizlere hazır hale getirilmesi sağlanmıştır. Ön işleme adımları, anlamlı dilbilimsel özellikleri korurken ham tweet verilerini temizlemek, normalleştirmek ve lemmatize etmek için tasarlanmıştır.

Türkçe NLP araçları ve kaynakları Türkçe'nin morfolojik ve yapısal özellikleri nedeniyle, doğal dil işleme için benzersiz zorluklar ortaya çıkmaktadır (Eryiğit, 2014: 1-4). Bu nedenle, Türkçe işleme için özel olarak tasarlanmış özel NLP araçları ve kaynakları kullanılmaktadır. Bu kapsamda, morfolojik analiz ve lemmatizasyon süreçlerinde yaygın olarak kullanılan araçlar şu şekildedir;

- ✓ Zemberek-NLP ve Zeyrek: Ahmed A. Akin tarafından geliştirilen Zemberek-NLP, Türkçe için yaygın olarak kullanılan bir açık kaynaklı NLP kütüphanesidir ve morfolojik analiz, tokenizasyon ve metin normalizasyonu gibi kapsamlı araçlar sunar. Sonlu durum dönüştürücü tabanlı morfolojik analizcisi, Türkçe'nin sözdizimsel yapısını etkili bir şekilde işler (Akın & Akın, 2007; URL-4, 2019). Ancak, Java tabanlı uygulaması, Python tabanlı NLP iş akışlarında kullanılabilirliğini sınırlamaktadır. Bu sınırlamayı gidermek için, Zeyrek, Zemberek'in temel morfolojik analiz ve tokenleştirme işlevlerinin Python portu olarak geliştirmiştir (URL-5, 2024). Bu, karmaşık Türkçe kelime biçimlerinin doğru bir şekilde tokenleştirilmesini (sözcüklere ayrılmasını) sağlar ve Zemberek ile karşılaştırılabilir bir performans elde ettiği gösterilmektedir (Boztepe vd., 2022: 181-207). Türkçe sosyal medya metinleri üzerine yapılan çalışmalar, Zeyrek tabanlı lemmatizasyonun, özellikle gayri resmi ve morfolojik açıdan zengin Twitter verilerinde, duygu sınıflandırması gibi aşağı akış görevlerini önemli

ölçüde iyileştirdiğini göstermektedir (Yılmaz ve Orman, 2021: 359-372). Bu nedenle, Zeyrek, Türkçe afetle ilgili tweetlerin ön işlenmesi için metodolojik açıdan sağlam ve uygun bir seçimdir.

- ✓ Kapsamlı NLP Platformları/ITU Türk NLP Pipeline: Prof. Dr. Gülşen Eryiğit tarafından kurulan ve geliştirilen İstanbul Teknik Üniversitesi (ITU) Türk NLP Pipeline, Türk dili işleme için kapsamlı ve son teknoloji bir platformdur. Bu platform, Hizmet Olarak Yazılım (SaaS) olarak çalışır ve araştırmacılara dört işlevsel kategoriye ayrılmış eksiksiz bir işleme araçları paketi sunmaktadır. Bunlar ön işleme, morfolojik işleme, çok kelimeli ifade işleme ve sözdizimsel işlemedir (Eryiğit, 2014: 1-4).
- ✓ Bağımlılık Ağacı Bankaları (BOUN Ağacı Bankası ve BoAT Annotation Tool): Boğaziçi Üniversitesi BOUN Ağacı Bankası, Evrensel Bağımlılıklar (UD) çerçevesine göre geliştirilmiş, büyük ölçekli, manuel olarak anotlanmış bir Türkçe metin kümesidir. Boğaziçi Üniversitesi TABILAB'daki dilbilimciler ve NLP araştırmacıları tarafından oluşturulan bu veri tabanı, Türkçe'de sözdizimsel analiz ve bağımlılık ayrıştırma için temel bir dilbilimsel kaynak görevi görmektedir (Türk vd., 2020: 1-44). Ağaç bankasına, UD'nin verimli bir şekilde anotasyonunu destekleyen ve kaynağın gelecekteki genişletilmesini ve bakımını kolaylaştıran BOUN Annotation Tool (BoAT) eşlik etmektedir. Bu araç, sonraki ağaç bankalarının geliştirilmesini etkileyen ve ilgili çalışmalarda ön işleme ve anotasyon uygulamalarını zenginleştiren Türkçe NLP için bir referans noktası haline gelmiştir (Özateş vd., 2025: 1-20).
- ✓ Türkçe için Transformatör Tabanlı Dil Modelleri: BERT (Transformatörlerden İki Yönlü Kodlayıcı Temsilleri) adlı bir NLP modelinin tanıtımı, önceden eğitilmiş bağlamsal dil modelleri aracılığıyla transfer öğrenimini mümkün kılarak çalışır. BERTurk ve ilgili transformatör modelleri Türkçe için kullanılmıştır (Liu, 2024: 49-51).
- ✓ BERTurk/Topluluk Odaklı Türkçe BERT: Stefan Schweter (2020) tarafından geliştirilen BERTurk, Türkçe metinler üzerinde önceden eğitilmiş ilk büyük ölçekli BERT modelidir.

Model, aşağıdakileri içeren 35 GB'lık kapsamlı bir metin veri kümesi üzerinde eğitilmiştir:

1. Türkçe OSCAR metin derlemesi (filtrelenmiş ve cümle segmentlerine ayrılmış)
2. Son Türkçü Wikipedia dökümleri
3. Çeşitli OPUS çok dilli metinler
4. Kemal Oflazer tarafından sağlanan ek Türkçe dil kaynakları

BERTurk, Google'ın TensorFlow Research Cloud (TFRC) üzerinde TPU v3-8 kullanılarak 2 milyon adımda eğitilmiştir ve sonuçta 44.049.766.622 tokenlik eğitim maruziyetine sahip bir model ortaya çıkmıştır (Schweter, 2020).

Model mimarisi BERT-base spesifikasyonlarını takip etmektedir ve 12 transformatör bloğu, 12 dikkat başlığı, 768 gizli boyut ve yaklaşık 110 milyon parametreye sahiptir.

Türkçe NLP Görevlerinde Performansı incelendiğinde BERTurk, çeşitli Türkçe NLP benchmarklarında en gelişmiş veya rekabetçi performansı göstermiştir. Bu başarı özellikle aşağıdaki görevlerde açık biçimde görülmektedir. Bunlar:

- ✓ Adlandırılmış Varlık Tanıma (NER): BERTurk, Türkçe NER görevlerinde %93'ü aşan F1 puanları elde ederek, çok dilli BERT'i (mBERT) 8-12 puan farkla geride bırakmıştır (Eryiğit, 2017: 835–875; Schweter, 2020).
- ✓ Duygu Analizi: İnce ayarlı BERTurk modelleri, Türkçe duygu sınıflandırma benchmarklarında %90-94 doğruluk oranları bildirmiştir ve sözlük tabanlı yaklaşımların kaçırdığı olumsuz duygu nüanslarını tespit etmede özellikle güçlüdür (Yıldırım, 2024: 1-10).
- ✓ Soru Yanıtlama: Türk Soru Yanıtlama Veri Seti (TQuAD) üzerinde BERTurk, %79.98 F1 puanı ve %66.55 Tam Eşleşme puanı elde ederek mBERT performansını önemli ölçüde aşmıştır (Schweter, 2020).
- ✓ Doğal Dil Çıkarımlama (NLI): Budur vd. (2020), BERTurk'ün Türkçe NLI görevlerinde hem mBERT hem de çok dilli XLM-RoBERTa'dan daha iyi performans gösterdiğini göstererek, dile özgü ön eğitimin değerini vurgulamıştır.

Genişletilmiş Türkçe Transformer: Türkçe NLP topluluğu, BERTurk'ün temeli üzerine birkaç özel transformer modeli geliştirmiştir. Bu kapsamda öne çıkan modeller şu şekildedir:

- ✓ ELECTRA-Turkish: Türkçe mC4 corpus (242 GB) üzerinde ayrımcı ön eğitim kullanılarak eğitilen ELECTRA modelleri, daha düşük hesaplama maliyetiyle rekabetçi bir performans sergilemektedir (Clark vd., 2020; Jiang vd., 2020).
- ✓ ConvBERTurk: Aralık tabanlı dinamik konvolüsyonu içeren ConvBERTurk, token düzeyindeki görevlerde standart BERT'e göre hafif ama tutarlı iyileştirmeler göstermektedir (UD treebank'ta %94.57 mikro-F1) (Jiang vd., 2020: 1-17)
- ✓ TurkishBERTweet: Sosyal medya analizi için özel olarak 894 milyon Türkçe tweet üzerinde önceden eğitilmiş olan TurkishBERTweet, genel amaçlı BERTurk'e kıyasla Twitter duygu sınıflandırması ve nefret söylemi tespitinde üstün performans sergilemektedir (Najafi ve Varol, 2024: 1-12).
- ✓ RoBERTurk ve SindBERT: Türkçeyi hedefleyen, rafine ön eğitim hedefleri ve geliştirilmiş tokenizasyon ile eğitilmiş yeni RoBERTa tarzı modeller (Taş, 2024; Scheible-Schmitt vd., 2025).

Birkaç çalışma, dönüştürücü modellerin Türkçe afetle ilgili NLP için etkinliğini göstermiştir, örneğin:

- ✓ Verma vd. (2023) Şubat 2023 Türkiye-Suriye depremiyle ilgili Türkçe tweetleri sınıflandırmak için dönüştürücü tabanlı modelleri değerlendirmiş ve DistilBERT gibi hafif modellerin yardım arama içeriği tespitinde en yüksek sınıflandırma doğruluğunu (%90+) sağladığını bulmuştur.
- ✓ Ünal ve Sezer (2023) İzmir depremi sırasında BERT tabanlı duygu analizi kullanarak Türk sosyal medyasını analiz etmiş ve modellerin afet olayları sırasında duygusal dinamikleri yakalama yeteneğini göstermiştir.
- ✓ Yılmaz ve Orman (2021) Türkçe COVID-19 söylemleri üzerine yapılan çalışmalarında benzer şekilde, kriz bağlamlarında sağlıkla ilgili sosyal medya içeriklerini analiz etmek için BERTurk'ün etkinliğini doğrulamıştır.

3.1.2. Konu Modelleme Yöntemleri

Konu Modelleme, metinleri veya etiketlenmemiş konuları veya kelime kümelerini, aynı anlama gelen kelimeleri ilişkilendirerek analiz etmek ve metin gövdesindeki gizli anlamsal yapıları ortaya çıkarmak için kullanılan bir hesaplama algoritmaları ailesini

tanımlamak için kullanılan toplu bir terimdir (Gorro vd., 2017, Isoaho vd., 2021). Konu modelleme ile araştırmacılar, yapılandırılmamış verilerden farklı konuları belirleyebilir; afetlerin iletişim kalıplarını, acil durumlarda ve afetlerde halkın tepkilerini ve acil ihtiyaçlarını ortaya çıkarabilir (Jin ve Spence, 2017: 293-297). Konu modelleme ile araştırmacılar, yapılandırılmamış verilerden farklı konuları belirleyebilir; afetlerin iletişim kalıplarını, acil durumlar ve afetler sırasında halkın tepkilerini ve acil ihtiyaçlarını (Jin ve Spence, 2021: 1270) ve ayrıca gelecekteki afet müdahalesi ve yönetimi için yararlı bilgileri çıkarabilir (Patel, 2018: 2).

Latent Dirichlet Allocation (LDA) Konu Modellemesi, 2001 yılında Blei vd. tarafından tanımlanan üretken bir olasılık modelidir ve her belgenin olasılıklı bir konu türü olduğunu ve her konunun kelime dağılımı ile karakterize edildiğini varsayarak çalışır (Liu, 2024: 48-51).

LDA, depremle ilgili tweet veri kümesinin tematik yapılarını keşfetmek ve tanımlamak için uygulanmıştır. LDA, her belgenin olasılıklı bir konu türü olduğunu ve her konunun kelime dağılımı ile karakterize edildiğini varsayarak çalışır. LDA, öncelikle LDA'da konu sayısı K 'yi belirleyerek çalışır. Bu, manuel olarak belirlenmesi gereken önemli bir hiperparametredir. Konu sayısını belirledikten sonra, pyLDAvis kütüphanesi kullanılarak konu modellemesinin görsel analizi yapılır ve sonuç olarak dinamik bir HTML dosyası elde edilir.

BERTopic Konu Modellemesi ise LDA gibi geleneksel yöntemlerin sınırlamalarını ele alan, dönüştürücü modellerden bağlamsal gömülü öğeleri kullanarak kelimeler ve belgeler arasındaki anlamsal ilişkileri yakalayan modern bir konu modelleme yaklaşımıdır. UMAP boyut azaltma tekniğini HDBSCAN belge kümeleme yöntemiyle entegre ederek BERT, gömülü öğe olarak önemli bir rol oynar ve metin verilerinden verimli işleme ve konu çıkarma sağlar.

LDA gibi geleneksel konu modellerine kıyasla, BERTopic, hiperparametre K 'ye veya konu sayısını manuel olarak belirtmeye gerek kalmadan, metin verilerine dayalı olarak konu kelimelerinin sayısını otomatik olarak çıkarma avantajına sahiptir (Liu, 2024: 48-51).

3.1.3. Duygu Analizi Yöntemi

Duygu analizi, aynı zamanda görüş madenciliği (opinion mining) olarak da bilinir. Çağdaş bir araştırma alanıdır ve insanların bir olay, durum veya ürüne karşı duygularının hesaplamalı olarak incelenmesine odaklanan doğal dil işleme (NLP) ve bilgi işlemenin bir parçası olarak kabul edilir. Ayrıca, tweetler, yorumlar, bloglar ve gönderiler gibi çeşitli yapılandırılmamış veri kaynaklarından gelen görüşleri veya duyguları tanımlamak ve sınıflandırmak için metin verilerinde ifade edilen insanların görüşlerini, tutumlarını veya değerlendirmelerini de içerir (Serrano-Guerrero vd., 2015; Sayeed vd., 2023).

Afet ve acil durum yönetimi bağlamında Duygu Analizi, Mendon vd. (2021) tarafından yapıldığı gibi, sosyal medya verilerinden içgörü ve bilgi elde etmede çok yararlıdır. Mevcut araştırmaların sadece Twitter verilerinin dilbilimsel kısmına odaklandığını ve bunun bir araştırma boşluğu olduğunu iddia eden Behl vd. (2021) duygusal analizlerin önemini göz önünde bulundurarak bazı afetle ilgili verileri incelemektedir.

Bai ve Yu (2016) tarafından yapılan araştırmada olduğu gibi, afet sonrası durumu ve kurtarma planlarının etkinliğini değerlendirmek için duygu analizine dayanan birçok araştırma bulunmaktadır. Bu araştırma, kurbanların olumsuz tepkilerini izleyerek ve tahmin ederek afet sonrası olası olayları keşfetmeye odaklanmıştır.

Bu çalışmalar genellikle afet sonrası duygusal değişiklikleri izler ve bu değişiklikler, kurtarma sürecindeki ilerleme ve yardım dağıtımının etkinliği gibi iyileşmeleri gösterebilir ve ortaya çıkan yeni zorlukların bir göstergesi olabilir. Bu, daha esnek ve duyarlı bir afet yönetimi için bu duygusal eğilimleri gerçek zamanlı veya neredeyse gerçek zamanlı olarak izlemeyi mümkün kılmaktadır (Contreras vd., 2023).

Sözlük tabanlı yaklaşım, NLP’de bir metnin duygusal içeriğini tespit etmek için kullanılan bir tekniktir. Duygusal sözlükler, polaritelerine (olumlu, olumsuz veya nötr) ve duygusal puanlarına göre sınıflandırılmış bir dizi duygusal kelime içeren sözlüklerdir. Bu yaklaşımda, tüm cümlenin duygusu, tüm duygu kelimelerinin puanlarının toplamı veya ortalamasının hesaplanmasıyla belirlenir. Bu yaklaşım, sözlük tabanlı yaklaşım ve metin tabanlı yaklaşım olmak üzere ikiye ayrılır. İlk yaklaşım, manuel olarak toplanmış bir dizi duygu kelimesinin kullanılmasını ve ardından eş anlamlılar ve zıt anlamlılar gibi daha fazla kelime ekleyerek bir sözlük oluşturulmasını gerektirir. Örneğin WordNet. Korpus tabanlı

yaklaşım, çalışma alanına özgü duygu kelimeleri ekler (Mehenaoui vd., 2024; Shaik vd., 2023).

İngilizce için çok sayıda sözlük tabanlı kaynak geliştirilmiştir, ancak iddia edildiği gibi Türkçe’de duygu analizi için kaynaklar oluşturmaya odaklanan çok az çalışma vardır ve Türkçe’de duygu analizi için bir sözlük bulunmamaktadır (Toçoğlu ve Alpkocaç, 2019: 1213–1214).

Bidirectional Encoder Representations from Transformers (BERT), bağlam anlayışını geliştirebilen ve hızlı ve basit bir şekilde değiştirilebilen önceden eğitilmiş bir model sunan bir NLP modelidir. Modelin boyutu ve yavaş eğitim süresine rağmen daha fazla metin ve dil işleyebilir. Buna ek olarak, bu model yapısı cümleyi hem sağdan sola hem de soldan sağa değerlendirir (Tepecik ve Demir, 2024: 9-10). Böylece, insan benzeri dillerin analizinde ve amplifikasyonunda yüksek doğrulukla kelimelerin birbirleriyle olan ilişkisini daha iyi ortaya çıkarır (Shaik vd., 2023; Sayeed vd., 2023).

Efficiently Learning an Encoder that Classifies Token Replacements Accurately (ELECTRA), BERT’ten daha az hesaplama kullanarak dönüştürücü ağlarını önceden eğitmek için kullanılan bir NLP modelidir ve dil modeli ön eğitimi için değiştirilmiş token algılama görevi sunmaktadır. ELECTRA Model, bazı simgeleri küçük bir jeneratör ağından elde edilen olası değerlerle değiştirerek sentetik olarak bozulmuş girdiler üretmektedir. Ardından, ayırt edici bir model mimarisi kullanarak, bozuk girdideki her simgenin jeneratördeki karşılığıyla değiştirilip değiştirilmediğini tahmin etmektedir (Tepecik ve Demir, 2024: 10).

3.1.4. Makine Öğrenmesi Modelleri

Makine Öğrenmesi (ML), AI’nın bir dalı veya uygulamasıdır. ML bilgisayarların ve makinelerin, büyük veri kümelerini, algoritmaları ve istatistiksel yöntemleri kullanarak tahmin modelleri oluşturmak için belirli algoritmalar aracılığıyla (URL-6, 2026) insanlar gibi farklı görevleri öğrenmelerini ve gelecekteki sonuçların tahminini desteklemektedir. Ayrıca ML, sistemlerin deneyime dayalı bilgiyi modellemesine ve zamanla uyum sağlamasına olanak tanır (Singh vd., 2023: 62).

ML, çeşitli biçimlerdeki büyük verileri işlemek için kullanılabilir ve ML’nin uygulamalarından biri, özellikle depremler sırasında sahte mesajları tespit etmektir. ML

algoritmaları, felaketler veya pandemiler gibi olayları tahmin etmek için çok boyutlu veriler üzerinde çalışarak depremleri tahmin etmek için de kullanılabilir (Chamola vd., 2021: 16048- 16049). Bu çalışmada da kullanılan bazı ML algoritmaları şu şekildedir:

1. Rastgele Orman (RF): Rastgele orman, bir dizi karar ağacından oluşan bir algoritmadır ve kümedeki her ağaç, ikame ile bir eğitim kümesinden alınan bir veri örneğinden oluşur. RF kullanmak, aşırı uyum riskini azaltmaya yardımcı olur, daha fazla esneklik sağlar ve ayrıca RF kullanarak verilerin özellik önemini belirlemeyi kolaylaştırmaktadır (URL-7, 2026). Örnek bir Rastgele Orman modelinin hiperparametre yapılandırması aşağıda sunulmaktadır:
Rastgele Orman: 100 ağaç, max_depth=20, min_samples_split=5
2. Lojistik Regresyon (LR): Lojistik regresyon, bir sonucu belirleyen bir veya daha fazla bağımsız değişken içeren bir veri kümesini analiz ederek çalışan istatistiksel bir yöntemdir (URL-8, 2026) ve doğrusal bir modeldir (Ataş vd., 2022: 3893). Twitter duygu analizinde, sağlık hizmetleri ile ilgili çalışmalarda ve afet tahmininde kullanılabilir. Örnek bir lojistik regresyon modeli için hiperparametre yapılandırması aşağıda sunulmaktadır:
Lojistik Regresyon: L2 düzenleme, lbfgs çözücü, max_iter=1000, multi_class='multinomial'
3. Naif Bayes (NB): Naif Bayes, Bayes teoremi temelinde geliştirilmiş bir makine öğrenimi algoritmasıdır ve koşullu olasılığa dayalı olarak belirli bir örneğin her sınıfa ait olma olasılığını hesaplamayı amaçlar ve küçük boyutlu verilerde daha iyi sonuç verir (URL-9, 2026). Örnek bir Multinomial Naif Bayes modeli için hiperparametre yapılandırması aşağıda sunulmaktadır:
Multinomial Naive Bayes: alpha=1.0 (Laplace düzeltme)
4. Destek Vektör Makineleri (SVM): Destek vektör makinesi (SVM), 1990'larda Vladimir N. Vapnik ve meslektaşları tarafından geliştirilen, sınıflandırma problemlerinde yaygın olarak kullanılan ve hem doğrusal hem de doğrusal olmayan sınıflandırma görevlerini gerçekleştirebilen denetimli bir makine öğrenimi algoritmasıdır (URL-10, 2026). Örnek bir doğrusal Destek Vektör Makinesi modeli için hiperparametre yapılandırması aşağıda sunulmaktadır:

Doğrusal Destek Vektör Makinesi (SVM): squared_hinge kaybı ile LinearSVC, max_iter=2000

5. Sinir ağları, modern makine öğrenimi (ML) ve yapay zekâ (AI) alanlarında yaygın olarak kullanılan etkili algoritmalarından biridir ve temel olarak üç katmanlı bir yapı üzerinden çalışmaktadır. Bu yapı; ham özellikleri ($X_1, X_2, X_3, \dots$) içeren giriş katmanı, girdi özelliklerinin işlendiği bir veya daha fazla gizli katman ve gizli katmanlarda gerçekleştirilen doğrusal dönüşümler sonrasında nihai tahmini (regresyon için sayısal bir değer veya sınıflandırma için olasılık dağılımı) üreten çıktı katmanından oluşmaktadır (URL-11, 2026). Örnek bir sinir ağı modeli için yapılandırma ve hiperparametre ayarları aşağıda sunulmaktadır:

Sinir Ağı: İki gizli katmanlı (100, 50) MLPClassifier, relu aktivasyonu

3.2. Analitik Süreç ve Metodolojik İş Akışı

Bu çalışmada, sosyal medya verileri aracılığıyla afet sonrası sağlık ihtiyaçlarının çok boyutlu ve güvenilir bir şekilde analiz edilebilmesi için tamamlayıcı, aşamalı ve entegre bir analitik çerçeve benimsenmiştir. Analiz süreci, sıralı ve metodolojik olarak gerekçelendirilmiş adımlardan oluşmaktadır. Bu adımlar;

1. Veri toplama,
2. Ön işleme,
3. Keşifsel analiz,
4. Tematik çıkarım,
5. Doğrulama ve
6. Sınıflandırma şeklindedir.

İlk aşamada, 6 Şubat 2023 Kahramanmaraş depremlerini takip eden iki aylık dönemde Twitter (X) platformunda paylaşılan Türkçe tweetler, belirlenen anahtar kelimeler kullanılarak toplanmıştır. Bu aşamanın amacı, afet sonrası dönemde bireyler tarafından spontan olarak ifade edilen sağlıkla ilgili söylemleri, büyük ölçekli, neredeyse gerçek zamanlı bir veri seti içinde yakalamaktır. Veri toplama süreci, kamuya açık gönderilerle sınırlı tutulmuş ve etik ilkelere uygun olarak yürütülmüştür.

İkinci aşamada, sosyal medya verilerinin yapısal özelliklerinden kaynaklanan veri kirliliğini azaltmak için kapsamlı bir veri ön işleme süreci uygulanmıştır. Bu süreçte

URL'ler, kullanıcı etiketleri, emoji ve noktalama işaretleri temizlenmiştir. Bu işlem için Türkçe'nin morfolojik yapısı dikkate alınarak Zeyrek lemmatizasyon aracı kullanılmıştır. Bu adımın temel amacı, metni anlamsal bütünlüğünü koruyarak analiz edilebilir bir forma dönüştürmek ve sonraki modelleme adımlarının doğruluğunu artırmaktır.

Üçüncü aşamada, keşifsel tematik yapıları ortaya çıkarmak için Latent Dirichlet Allocation (LDA) yöntemi kullanılmıştır.

LDA, veri seti içindeki baskın konu yapılarını belirlemek ve birinci düzeyde sağlıkla ilgili temaları keşfetmek için seçilmiştir. Bu aşama, önceden tanımlanmış kategorilere dayanmayan, veriye dayalı bir keşif süreci sunarak afet sonrası sağlık söyleminin genel çerçevesini ortaya çıkarmayı amaçlamaktadır. Elde edilen LDA sonuçları, konu sayısı optimizasyonu ve görsel inceleme yoluyla değerlendirilmiştir.

Dördüncü aşamada, LDA'nın bağlamdan bağımsız, kelime tabanlı yapısını tamamlamak için BERTopic modeli uygulanmıştır. BERTopic, bağlamsal dil temsillerine dayalı anlamsal benzerliklerine göre tweetleri kümeleyerek daha ince ve tutarlı tematik yapılar üretmiştir. Bu aşama, özellikle kısa ve bağlam açısından zengin sosyal medya metinlerinde sağlık ihtiyaçlarının daha net bir şekilde ayırt edilmesini sağlamıştır. Böylece, LDA ile elde edilen genel temalar BERTopic aracılığıyla derinleştirilmiş ve doğrulanmıştır.

Beşinci aşamada, tematik analizden elde edilen bulgular ile duygusal ton arasındaki ilişkiyi incelemek için BERTurk tabanlı duygu analizi gerçekleştirilmiştir. Bu adım, sağlıkla ilgili söylemin içeriğini değil, aynı zamanda bu söylemin ifade edildiği duygusal bağlamı da ortaya çıkarmayı amaçlamaktadır. Duygu analizi sonuçları, sağlıkla ilgili ve sağlıkla ilgili olmayan tweetler arasında karşılaştırmalı olarak değerlendirilmiş ve söylem-duygu ilişkisi istatistiksel olarak analiz edilmiştir.

Altıncı ve son aşamada, sağlıkla ilgili tweetlerin otomatik sınıflandırılabilirliğini test etmek için denetimli makine öğrenimi modelleri uygulanmıştır. Bu aşamada, önceki adımlarda elde edilen tematik ve semantik bilgilere dayalı olarak oluşturulan etiketler kullanılarak çeşitli sınıflandırma algoritmaları (Lojistik Regresyon, SVM, Rastgele Orman vb.) karşılaştırılmıştır. Bu adım, afet yönetimi bağlamında sosyal medya verilerinin operasyonel kullanılabilirliğini değerlendirmeyi amaçlamaktadır.

Sonuç olarak, bu analitik süreç, keşifsel (denetimsiz), doğrulayıcı ve tahmine dayalı (denetimli) yöntemleri birleştiren bütünsel bir çerçeve sunmaktadır. Her yöntem, önceki

aşamadaki bulguları destekleyecek şekilde konumlandırılmıştır. Böylece sosyal medya verilerine dayalı olarak afet sonrası sağlık ihtiyaçlarının çok katmanlı, tutarlı ve metodolojik olarak savunulabilir bir analizi mümkün kılmaktadır.

3.3. Veri Toplama

Veri toplama aşamasında Twitter (X) platformundan 6 Şubat – 6 Nisan 2023 tarihleri arasında Türkçe tweetler toplanmıştır. Aşağıdaki tablo 2 veri toplama parametrelerini özetlemektedir.

Tablo 2. Veri toplama ve ön işleme parametreleri

Parametre	Detay
Platform	Twitter / X (API)
Dönem	6 Şubat – 6 Nisan 2023 (60 gün)
Dil	Türkçe
Odak Bölge	Kahramanmaraş ve etkilenen iller
Toplam Tweet	88.073
Ön İşleme Sonrası	79.293 (%90.0 kalan)
Sağlık İlgili	43.128 (%49.0)
Sağlık Dışı	44.945 (%51.0)
Kelime Hazinesi (Ham)	270.404 benzersiz form
Kelime Hazinesi (Temiz)	179.813 (%33.5 azalma)
Ortalama Tweet Uzunluğu	16.4 kelime/tweet

Python kullanılarak, 6 Şubat ile 6 Nisan 2023 tarihleri arasındaki dönemi kapsayan Twitter verileri toplanmıştır. Bu çalışmada, analiz dönemi olarak 6 Şubat 2023 Kahramanmaraş depremlerini takip eden yaklaşık iki aylık (60 günlük) zaman aralığı seçilmiştir. Bu zaman aralığı, afet yönetimi literatüründe acil müdahale aşamasından erken iyileşme aşamasına geçişi işaret eden kritik bir dönemi temsil etmektedir. Deprem sonrasında ilk haftalarda şiddetini artıran (artçı depremler), barınma koşullarının istikrarsızlığı, sağlık hizmetlerine erişimde süreklilik sorunları ve halk sağlığı riskleri, sağlık ihtiyaçlarının akut travma ile sınırlı olmadığını, zamanla geliştiğini göstermektedir. Yaklaşık iki aylık süre, acil tıbbi hizmetler ve hijyen gibi kısa vadeli ihtiyaçların yanı sıra ruh sağlığı, kronik hastalık yönetimi ve barınma koşullarıyla ilgili halk sağlığı sorunları gibi daha kalıcı ihtiyaçların sosyal medya söylemlerinde nasıl yansıtıldığını gözlemlemeye olanak tanımaktadır. Bu nedenle, seçilen zaman aralığı, afet sonrası sağlık ihtiyaçlarının

zamansal dönüşümünü analiz etmek ve müdahale odaklı söylemden iyileşme odaklı söyleme geçişi yakalamak için metodolojik olarak uygun kabul edilmektedir.

Veriler, araştırma süresince Twitter’ın sınırlı kamu API erişimi nedeniyle, Twitter’ın gelişmiş arama arayüzüyle tarayıcı etkileşimlerini simüle eden otomatik Selenium tabanlı bir web kazıma yöntemi kullanılarak toplanmıştır. 120 anahtar kelimeyle, dil filtresi (lang:tr) kullanılarak analiz için yalnızca Türkçe tweetler toplandı ve çıkarılan tweetler yapılandırılmış Excel dosyalarında (verileri ve tweet içeriğini içeren) kaydedildi. Her URL şu şekilde yapılandırıldı:

```
https://x.com/search?q=KEYWORD      since:2023-02-06      until:2023-04-06  
lang:tr&src=typed_query&f=live
```

Tüm anahtar kelimeler için her seferinde bir tane kazıma işlemi tekrarlanmıştır ve toplam 88.073 tweet toplanmıştır. Tweetler excel dosyalarına (`tweet\_dataset.xlsx`) aktarılmıştır ve daha ileri analiz için python kodu kullanılarak tek bir veri setinde birleştirilmiştir.

3.4. Verilerin Ön İşlenmesi

Şekil 1’de gösterildiği üzere; duygu analizi, konu modelleme (TM) ve sınıflandırma işlemleri için Türkçe tweet veri kümesini hazır hale getirmek amacıyla kapsamlı bir ön işleme (preprocessing) süreci yürütülmüştür. Aşağıdaki adımlar, Python tabanlı kütüphanelerin bir kombinasyonu kullanılarak gerçekleştirildi:

Adım 1. Veri yükleme ve ilk tekilleştirme

Toplanan tweetleri içeren ham veri kümesi, Pandas kütüphanesi kullanılarak bir Excel dosyasından (merged_file.xlsx) yüklenmiştir ve yinelenen tweetleri Tweet sütununa göre kaldırmak için ilk tekilleştirme adımı uygulanmıştır. Böylece, sonraki analiz adımlarında yinelenmelerden kaçınıldı ve önyargı azaltılmıştır.

Adım 2. Durdurma kelimesi tanımı ve morfolojik araçlar

Türkçe durdurma kelimeleri, Doğal Dil Araç Setinden (NLTK) alınmış ve sık kullanılan, anlamsal olarak zayıf kelimeler (ör. “şey”, “ama”, “çok”) ve manuel olarak eklenen diğer durdurma kelimeleri içeren kapsamlı bir özel durdurma kelimeleri listesi ile genişletilmiştir. Ayrıca, Türkçe kelimelerin doğru lemmatizasyonunu desteklemek için Zeyrek morfolojik analizcisi kullanılmıştır.

Adım 3. Emoji normalleştirme ve değiştirme

Bu adım, gayri resmi tweetlerdeki duygu sinyalini iyileştirmek için entegre edilmiştir. Seçilen emojiler manuel olarak Türkçe duygu ile ilgili kelimelere örneğin “mutlu”, “üzgün” gibi eşleştirilmiştir. Kalan emojiler emoji kütüphanesi (emoji.demojize()) kullanılarak metin açıklamalarına dönüştürülmüştür. Böylece metin tabanlı işlem hatları aracılığıyla daha fazla işleme tabi tutulabilmeleri sağlanmıştır.

Adım 4. Metin normalleştirme ve temizleme

Her tweet’e şu düzenli ifade tabanlı temizleme adımları uygulanmıştır:

- ✓ Küçük harfe çevirme: Tüm metinler, tekdüzelik sağlamak için küçük harfe çevrilmiştir.
- ✓ URL Kaldırma: Köprüler (ör. <http://...>) kaldırılmıştır.
- ✓ Bahsetme ve Hashtag Kaldırma: Kullanıcı bahsetmeleri (@kullanıcıadı) ve hashtag’ler (#konu) kaldırılmıştır.
- ✓ Rakamların Kaldırılması: Tüm sayısal karakterler hariç tutulmuştur.
- ✓ Noktalama işaretlerinin kaldırılması: Alfasayısal olmayan semboller kaldırılmıştır.
- ✓ Boşluk Normalleştirme: Fazla boşluklar tek bir boşlukla değiştirildi ve kırpıldı.

Adım 5. Tokenleştirme ve durdurma kelimesinin filtrelenmesi

Temizlenen metin tek tek kelimelere (token) bölünmüştür. Tokenler aşağıdaki kriterlere göre filtrelenmiştir:

- ✓ En az üç karakter uzunluğunda olmalıdır.
- ✓ Türkçe harflerden oluşmalı (regex desenine göre) ve durdurma kelime listesinde yer almamalıdır.
- ✓ Tokenleştirme sırasında, Türkçe harf kalıbı filtresi eşzamanlı olarak uygulanmış ve yalnızca dilbilimsel olarak geçerli Türkçe tokenlerin korunması sağlanmıştır.

Adım 6. Zeyrek kullanarak lemmatizasyon

Adım 5’in ardından filtrelenen tokenler Zeyrek morfolojik analizcisinden geçirilerek kök formları (lemma) çıkarılmıştır. Zeyrek’in morfolojik analizcisi her token için kök lemmayı çıkarılmıştır. Analiz yapılamadığında veya lemma boş olduğunda, orijinal token tutulmuştur. Lemmatizasyon sonrası durdurma kelimeleri de filtrelenmiştir.

Zeyrek morfolojik analizcisi, 79.293 tweet’in tamamını başarıyla işlemiştir ve aşağıdaki tablolarda (3 ve 4) gösterildiği gibi %33.5’lik bir kelime hazinesi azaltımı

(270.404 → 179.813 benzersiz form) elde etmiştir. Bu, 90.591 çekimli Türkçe kelime formunun temel lemmalarına konsolide edilmesini temsil etmektedir.

Adım 7. Son Filtreleme ve Tekilleştirme

Ön işleme sonrasında, boş dizeler ve duplicate cleaned_tweet girişleri kaldırılmıştır ve sonraki modelleme için yalnızca benzersiz, boş olmayan tweetlerin kalması sağlanmıştır.

Tablo 3. Lemmatizasyon İstatistikleri

Ölçüt	Değer	Not
İşlenen toplam tweet sayısı	79.293 tweet	final_preprocessed_tweets.xlsx dosyasından alınan kesin sayı
Orijinal kelime dağarcığı büyüklüğü (lemmatizasyon öncesi)	270.404 benzersiz token	Ham Tweet sütunundan hesaplanmıştır (ön işleme öncesi)
Lemmatizasyon sonrası kelime dağarcığı büyüklüğü	179.813 benzersiz lemma	Calculated from cleaned_tweet column (after lemmatization)
Kelime dağarcığı azalımı	33.5% azaltma (90.591 form)	
Tweet başına ortalama token (orijinal)	20.9 token	Ham tweetler daha fazla gürültü içerir (URL'ler, mentionlar vb.)
Tweet başına ortalama token (lemmatize edilmiş)	15.1 token	Temizleme ve lemmatizasyon sonrası
Azaltılan benzersiz çekimli biçimler	90.591 Çekimli form → temel form	
Toplam token azalımı	27.6% (1.657.743 → 1.200.132 token)	Toplam korpus boyutunda önemli azalma
İşleme başarı oranı	100% (tüm tweetler işlendi)	79.293 tweetin tamamı başarıyla işlenmiştir

Tablo 4. Lemmatizasyon örnekleri

Original Kelime	Lemma (kök)	Morfolojik Analiz	Örnek Bağlam	Transformation Type
Depremzedelere	depremzede	depremzede[Noun] + ler[Pl] + e[Dat]	Depremzedelere yardım ulaştırıldı	Plural + case marker removal
Yardımlar	yardım	yardım[Noun] + lar[Pl]	Gıda yardımları dağıtılıyor	Plural marker removal
Yapıyoruz	yapmak	yap[Verb] + ıyor[Prog1] + uz[A1pl]	Arama kurtarma yapıyoruz	Verb aspect + person removal
Gönderdik	göndermek	gönder[Verb] + di[Past] + k[A1pl]	Malzemeleri gönderdik	Verb tense + person removal
Çadırlar	çadır	çadır[Noun] + lar[Pl]	Çadırlar kuruldu	Plural marker removal
Hastanelerde	hastane	hastane[Noun] + de[Loc]	Hastanelerde yoğunluk var	Case marker removal
İlaçlar	ilaç	ilaç[Noun] + lar[Pl]	İlaçlar tükendi	Plural marker removal
Sıkıntısı	sıkıntı	sıkıntı[Noun] + sı[Poss3sg]	Su sıkıntısı yaşıyor	Possessive marker removal
Yaşanıyor	yaşamak	yaşa[Verb] + n[Pass] + ıyor[Prog1]	Bölgede kriz yaşanıyor	Passive voice + aspect removal
Kurtarıyoruz	kurtarmak	kurtar[Verb] + ıyor[Prog1] + uz[A1pl]	Enkaz altındakileri kurtarıyoruz	Verb aspect + person removal


Tablo 4. (Devam)

Enkaz	enkaz	enkaz[Noun]	Enkaz kaldırma çalışmaları	No transformation (base form)
Altındaki	alt	alt[Noun] + ı[Poss3sg] + nda[Loc] + ki[Rel]	Enkaz altındaki kişiler	Possessive + case + relative removal
İnsanları	insan	insan[Noun] + lar[Pl] + ı[Acc]	İnsanları tahliye ediyoruz	Plural + case marker removal

Adım 8. Çıktı Biçimi

Nihai veri kümesi 88.073 tweet'ten oluşmakta olup uygulanan ön işleme ve tekilleştirme işleminden sonra 79.293'e indirgenmiştir. Tablo 5 ve 6 ön işleme adımlarını ve sonuç örnekleri göstermektedir.

Sonuçlar daha sonra final_preprocessed_tweets.xlsx adlı yeni bir Excel dosyasına kaydedilmiştir. İşlenmiş metin içeriğini depolamak için veri kümesinde cleaned_tweet adlı yeni bir sütun oluşturulmuştur. Bu dosya, sözlük tabanlı duygu sınıflandırması, BERT tabanlı duygu analizi ve LDA ve BERTopic aracılığıyla konu modelleme dahil olmak üzere sonraki tüm analiz aşamaları için girdi olarak kullanılmıştır.



Şekil 1. Veri Örnekleme Süreci

Tablo 5. Veri ön işleme adımları

Ön İşleme Adımı	Amaç	Yöntem	Etki
1. Yinelenenlerin Kaldırılması	Tekil gözlemleri sağlamak için aynı (duplicate) tweetleri kaldırmak	pandas.drop_duplicates()	4.970 yinelenen tweet kaldırıldı (%88.073 → %83.103)
2. Küçük Harfe Dönüştürme	Tutarlı işlem için metni standartlaştırmak	str.lower()	Tüm 79.293 tweet küçük harfe dönüştürüldü
3. Emoji Dönüştürme	Emojileri Türkçe metin karşılıklarına dönüştürmek (e.g., ☺ → “mutlu”)	Özel emoji sözlüğü + emoji.demojize()	Duygusal bağlam korundu (12 emoji eşlemesi)

Tablo 5. (Devam)

4. URL Kaldırma	Anlamsal içeriğe katkı sağlamayan http/https bağlantılarını kaldırmak	Düzenli ifade: <code>r"http\S+ www\S+ https\S+"</code>	Tweetlerin %8.3'ü URL içeriyordu (temizlenen tweet sayısı 6.618).
5. Mention Kaldırma (@kullanıcıadı)	Sağlık ihtiyacını ifade etmeyen kullanıcı etiketlerini kaldırmak	Düzenli ifade: <code>r"@w+ #w+"</code>	Tweetlerin %8.1'inde bahsetme (mention) tespit edildi (6.394 tweet temizlendi).
6. Hashtag Kaldırma (#hashtag)	Anlamsal içeriği koruyarak hashtag'leri kaldırmak	Düzenli ifade: <code>r"@w+ #w+"</code>	Tweetlerin %12.6'sı hashtag içeriyordu (10.004 tweet temizlendi)
7. Sayıların kaldırılması	Sağlık ihtiyaçları analizine katkı sağlamayan sayısal karakterleri kaldırmak	Düzenli ifade: <code>r"d+"</code>	Tweetlerin %30.0'ı sayı içeriyordu (23.796 tweet temizlendi)
8. Özel karakterlerin kaldırılması	Noktalama işaretleri ve alfanümerik olmayan sembolleri kaldırmak	Düzenli ifade: <code>r"[^\w\s]"</code>	Tüm tweetler için standart metin formatı sağlandı
9. Boşluk normalizasyonu	Birden fazla boşluğu tek boşluğa indirgemek ve gereksiz boşlukları kaldırmak	Düzenli ifade: <code>r"s+" → single space</code>	Veri seti genelinde token tutarlılığı iyileştirildi
10. Türkçe harf filtreleme	Yalnızca Türk alfabesine ait karakterleri içeren kelimeleri tutmak (yabancı kelimeler hariç)	Özel regex: <code>r"^[abcçdefgğhıijklmnoöprşştüüvyz]+\$"</code>	Türkçe olmayan kelimeler ve gürültü filtrelendi
11. Durak kelimelerin (stopword) kaldırılması	Anlamsal değeri düşük 192 yaygın Türkçe kelimeyi kaldırmak	NLTK stopwords (62) + Özel stopwords (130) = 192 toplam	Tweet başına ortalama %23.4 metin azaltımı sağlandı
12. Lemmatizasyon	Zeyrek morfolojik analizörü kullanılarak çekimli kelimeleri sözlük (kök) formuna indirgemek	Zeyrek MorphAnalyzer ile lemma çıkarımı	%33.5 kelime haznesi azalması (270.404 → 179.813 benzersiz form)
13. Nihai yinelenen kaldırma	Ön işleme sonrası aynı hale gelen tweetleri kaldırmak	<code>pandas.drop_duplicates() on cleaned_tweet column</code>	Nihai veri seti: 79.293 benzersiz temizlenmiş tweet (3.810 tekrar kaldırıldı)

Tablo 6. Ön işleme örnekleri

Önce (Orijinal Tweet)	Karakter Sayısı	Sonra (Temizlenen Tweet)	Karakter Sayısı	Metin Azaltım ¹
"Bölgede Mardin ve Şanlıurfa il AFAD, güvenlik güçleri, UMKE ile sivil toplum kuruluşlarının ekipleri enkazda arama kurtarma çalışmalarına devam etmektedir. Diyarbakır ve Adana İl AFAD ekipleri destek amacıyla bölgeye ivedi olarak sevk edilmiştir. Gelişmeleri takip ediyoruz."	276	"bölgede mardin şanlıurfa afad güvenlik güçleri umke sivil toplum kuruluşlarının ekipleri enkazda arama kurtarma çalışmalarına devam etmektedir diyarbakır adana afad ekipleri destek bölgeye ivedi sevk edilmiştir gelişmeleri takip ediyoruz"	237	14.1%
"SAKOM'dan alınan bilgilere göre, saat 15.55 itibarıyla 29.605 vatandaşımız hayatını kaybetmiştir."	98	"sakomdan alınan bilgilere saat itibarıyla vatandaşımız hayatını kaybetmiştir"	76	22.4%

Tablo 6. (Devam)

“Deprem bölgesinin Yaralarına Bunlar ilac olur Zilletten Hayır gelmeZZ vatan millet ezan bayrak CUMHUR İTTİFAKI”	121	“deprem bölgesinin yaralarına ilac zilletten gelmezz vatan millet ezan bayrak cumhur ittifaki”	92	24.0%
“Faraha ne oldu anlayan var mı kaçırdım ilaç alırken #adımfarah”	62	“faraha anlayan kaçırdım ilaç alırken”	36	41.9%
“Gazdır ya o dkdckdf”	19	“gazdır dkdckdf”	14	26.3%


3.5. Veri Keşfi

3.5.1. Genel Veri Keşfi

Günlük 79.293 tweet hacmi analizinden elde edilen ön işlenmiş veri seti, günlük ortalama 1.344.38 tweet ile önemli bir zamansal değişim ortaya koymuştur. Günlük sayılar minimum 148 tweet ile maksimum 18.274 tweet arasında değişmektedir. Aşağıdaki Şekil (2)’de gösterildiği gibi:

1. (6-27 Şubat 2023): İlk üç hafta, günde ortalama 500-700 tweet ile nispeten istikrarlı, orta düzeyde bir aktivite seviyesi göstermiştir.
2. (28 Şubat - 7 Mart 2023): Bu aşamada dramatik bir artış meydana geldi ve 6 Mart 2023’te 18.274 tweet ile en yüksek aktiviteye ulaşıldı; bu, günlük ortalamanın 13.6 katı bir artışa tekabül etmektedir
3. (8 Mart - 5 Nisan 2023): Zirvenin ardından, günlük hacimler kademeli olarak baz seviyelere doğru düşmüştür.

Tablo 7’de gösterildiği üzere; genel veri setini ve çalışma dönemi boyunca tweetlerin zamansal dağılımını göstermektedir.



Şekil 2. Üç zaman dilimini gösteren günlük tweet hacmi dağılımı*

Tablo 7. Veri toplama, ön işleme ve zamansal dağılım istatistikleri

Metrik	Değer
Veri Toplama	
Toplanan İlk Tweet Sayısı	88.073
Ön İşleme Sonrası Tweet Sayısı	79.293
Kaldırılan Tweet Sayısı	8.780
Koruma Oranı	90.04%
Kaldırma Oranı	9.96%
Zamansal Dağılım	
Toplama Süresi	59 gün
Tarih Aralığı	6 Şubat - 5 Nisan 2023
Günlük Ortalama	1.344.38
Günlük Minimum	148
Günlük Maksimum	18.274
Standart Sapma	2.784.77
İçerik Özellikleri	
Ortalama Orijinal Uzunluk	158.53 karakter
Ortalama Temizlenmiş Uzunluk	121.00 karakter
Ön İşleme Azaltımı	23.67%
Ortalama Kelime Sayısı (temizlenmiş)	16.4 kelime

Günlük tweet hacmi dağılımı, üç farklı zamansal evreyi göstermektedir: istikrarlı başlangıç dönemi (6 Şubat–27 Şubat), 6 Mart'ta zirve aktivite (18.274 tweet) ve azalan toparlanma dönemi (8 Mart–5 Nisan). Kırmızı kesikli çizgi, günlük ortalama olan 1.344 tweeti temsil etmektedir.

3.5.2. Coğrafi Bilgi Çıkarma ve Sınırlamalar

Twitter (X) platformunda paylaşılan içeriğin sadece çok küçük bir kısmı doğrudan GPS tabanlı coğrafi etiketler (coğrafi etiketler) içerir (Lutsai ve Lampert, 2024; Vračević vd., 2025). Bu nedenle, bu çalışmadaki coğrafi analizler yalnızca GPS verilerine dayalı değildir; çok kaynaklı ve hiyerarşik bir konum çıkarma yaklaşımı benimsenmiştir.

İlk olarak, tweetlerin meta verileri incelenmiş ve doğrudan coğrafi etiketler (coğrafi etiketler) içeren gönderiler en yüksek güvenilirlik düzeyine sahip konum bilgisi olarak değerlendirilmiştir. Ancak, bu tür gönderilerin oranı çok düşük olduğundan (Caillaut vd., 2024: 1-3), ikinci aşamada kullanıcı profillerindeki serbest metin biçimindeki konum bilgileri analiz edildi (Hameed vd., 2025: 3). Profil konumları, şehir ve ilçe isimleri gibi açık coğrafi referanslar içeriyorsa standartlaştırıldı, belirsiz, eksik veya sembolik ifadeler ise analizden çıkarıldı.

Üçüncü aşamada, tweet metnindeki yer adları ve bölgesel referanslar (ör. şehir, ilçe, mahalle veya afet bölgesi adları) metin tabanlı konum göstergeleri olarak değerlendirildi. Bu bağlamda, yalnızca açık ve doğrudan coğrafi referanslar içeren ifadeler dikkate alınmış; dolaylı, mecazi veya bağlama dayalı çıkarımlar yapılmamıştır. Konum bilgisi, bu üç kaynaktan en az biriyle desteklenmeyen tweetlere atanmadığından, coğrafi analiz yalnızca konum bilgisinin güvenilir bir şekilde tanımlanabildiği veri alt kümesinde gerçekleştirilmiştir (Hu vd., 2023: 2289-2293).

Bu yaklaşımla elde edilen coğrafi dağılım sonuçları, bireysel kullanıcıların tam konumlarını temsil etmekten ziyade, afet sonrası dönemde sağlıkla ilgili söylemlerin bölgesel yoğunlaşma eğilimlerini ortaya koymak için yorumlanmıştır. Bu nedenle, coğrafi analiz bulguları, mekansal doğruluk gerektiren bireysel çıkarımlar yapmak yerine, makro düzeydeki mekansal örüntüleri anlamak için değerlendirilmiştir (Yu ve Wang, 2024: 16-23).

3.6. Etik Hususlar

Bu çalışmada, sosyal medya verilerinin kullanımı nedeniyle araştırma sürecinin tüm aşamalarında etik ilkelere uygunluk gözetilmiştir. Çalışmada dikkate alınan etik hususlar şu şekildedir:

1. Veri toplama
2. Gizlilik Koruması ve Veri Azaltma

3. Teknik ve Güvenlik Önlemleri

4. Gerekçe ve Sınırlamalar

Bu çalışmada veri toplama, sosyal medya analizi için belirlenmiş araştırma etiği protokollerine uygun olarak gerçekleştirilmiştir. Bu protokollere göre, kamuya açık gönderiler üçüncü şahıslar tarafından erişilebilir olup kullanıcılar şartları kabul ederek buna yasal olarak rıza göstermiş sayılmaktadır. Veri seti, 6 Şubat 2023 tarihinde meydana gelen Kahramanmaraş depremiyle ilgili 88.073 adet halka açık tweet'ten oluşmaktadır. Bu tweet'ler, toplama sırasında Twitter'ın halka açık içerik politikalarına uygun olarak Selenium kullanılarak web kazıma yoluyla toplanmıştır (Williams vd., 2017: 1160-1168). Ayrıca bu çalışmada kullanılan sosyal medya verileri, resmi Twitter Geliştirici Politikası ve Twitter (X) platformunun kullanım koşullarına uygun olarak toplanmıştır. Veri toplama süreci, platformda kamuya açık olan gönderilerle sınırlandırılmış olup özel, korumalı veya kullanıcı kısıtlamalı içeriğe hiçbir şekilde erişim sağlanmamıştır. Twitter API aracılığıyla elde edilen veriler araştırma amaçlı kullanılmış ve platformun veri depolama, paylaşım ve yeniden kullanım ilkelerine uygun olarak işlenmiştir (X Corp., 2026).

İkinci etik husus ise gizlilik koruması ve veri azaltmadır. Toplanan tüm tweetler, gizlilik kısıtlaması olmaksızın kamuya açık olarak yayınlanmıştır. Kullanıcı tanımlayıcıları (kullanıcı adları ve profil bilgileri) analitik veri setinden sistematik olarak kaldırılmıştır. Kamuya açık verilerin yine de etik açıdan değerlendirilmesi gerektiği kabul edilmekle birlikte (Zimmer, 2010: 313-323), araştırma kapsamında yapılan tüm analizler, kişisel veri içermeyen ve anonimleştirilmiş metin içeriği kullanılarak gerçekleştirilmiştir. Kullanıcı adları, profil bilgileri, kullanıcı kimlikleri, bağlantılar ve bireyleri doğrudan tanımlayabilecek herhangi bir bilgi analiz sürecine dahil edilmemiştir. Çalışmada yalnızca tweet metinleri, zaman damgaları ve toplu içerik özellikleri kullanılmıştır. Bireysel kullanıcıların kimliğini ortaya çıkarabilecek hiçbir veri raporlanmamıştır. Bu çalışmada kullanıcı düzeyinde hiçbir çıkarımda bulunulmamıştır. Bulgular, bireylerin sağlık durumu, psikolojik durumu, davranışları veya ihtiyaçları hakkında doğrudan veya dolaylı hiçbir yorum içermemektedir. Analizler, yalnızca toplu metin düzeyinde söylem kalıplarını ve tematik eğilimleri incelemek amacıyla yapılmıştır. Bu nedenle, sonuçlar bireysel kullanıcıları değerlendirmek için değil, afet sonrası dönemde sosyal medyada görünür hale gelen sağlık ihtiyaçlarındaki genel eğilimleri anlamak için üretilmiştir. Bu bakımdan,

alıřma kiřisel verilerin korunmasına iliřkin etik ilkeler ve veri minimizasyonu ilkesine uygun olarak yrtlmřtr.

Ek gizlilik nlemleri de alınmıřtır. Arařtırma, bireysel kullanıcı davranıřları yerine toplu dil kalıplarını ve saėlık ihtiyaları kategorilerini analiz etmekte ve anahtar kelime filtreleme yoluyla yalnızca depremle ilgili ierikler tutulmuřtur. Bu yaklařım, yalnızca tweet metinleri, zaman damgaları ve zamansal analiz iin gerekli meta veriler tutulduėu iin, GDPR'nin veri minimizasyonu ve ama sınırlaması ilkelerini uygulanmamıřtır (Voigt ve Von dem Bussche, 2017: 92-100).

nc etik husus ise teknik ve gvenlik nlemleridir. Sunucu ařırı ykn nlemek ve platformun sorumlu kullanımını saėlamak iin veri toplama, hız sınırlı istekler (kaydırma yinelemeleri arasında 10 saniyelik duraklamalar) kullanılarak gerekleřtirilmiřtir. Toplama komut dosyası, agresif ıkarma teknikleri veya IP rotasyonu olmadan kademeli kaydırma (kaydırma bařına 4.000 pikselde maksimum 10.000 yineleme) kullanmıřtır. Ara iřlem dosyaları, toplama iřlemi tamamlandıėında otomatik olarak silinmiřtir (scroll_state.pkl). Nihai veri seti, NLP analizine uygun, anonimleřtirilmiř, nceden iřlenmiř metinleri ierir ve yetkisiz eriřimden kaynaklanan gvenlik risklerini en aza indirilmiřtir.

Son etik husus ise gereke ve sınırlamalardır. Afet mdahalesinin insani baėlamı, kamuya aık olarak paylařılan saėlık ihtiyaları iin etik bir gereke saėlamaktadır. nk bu tr arařtırmalar acil durum ynetimi hakkındaki bilgilere katkıda bulunmaktadır ve gelecekteki kriz mdahalelerinin iyileřtirilmesine yardımcı olmaktadır (Imran vd., 2015: 7-30). Web kazıma iřleminin yasal aıdan gri bir alana girdiėini kabul etmekle birlikte (Fiesler ve Proferes, 2018: 2-11), verilerin kamuya aık niteliėi, kriz baėlamı ve bireysel kullanıcılardan ziyade toplu saėlık ihtiyalarına odaklanan analitik yaklařım, bu metodolojik yaklařımı desteklemektedir. Veri seti, kritik bir insani kriz sırasında ifade edilen genel saėlık ihtiyalarının tarihsel kaydını temsil eder ve afet hazırlıėı ve mdahale alanında kamu yararına hizmet etmektedir.

4. BULGULAR VE TARTIŞMA

Bulgular bölümü; dört temel metodolojik yaklaşım (LDA, BERTopic, BERTurk ve ML) ile gerçekleştirilen analizlerin temel sonuçlarını içermektedir. Tablo 8’de detaylandırıldığı üzere, LDA sonuçlarının SPHERE standartlarıyla tam uyumu, BERTopic’in sağlık odaklı kümeleme başarısı ve duygu-sağlık arasındaki istatistiksel anlamlılık ($p < 0.001$) bu bölümün ana eksenini oluşturmaktadır.

Tablo 8. Bulgular bölümü genel bakış

Alt Bölüm	Yöntem	Temel Bulgu
LDA Konu Modelleme	Gensim LDA (K=5)	5 konu; hijyen terimi en yüksek ($b=0.3326$)
BERTopic Kümeleme	MiniLM + UMAP + HDBSCAN	59 konu; %14.3 sağlık kategorisinde
Duygu Analizi	BERTurk transformer	%76.21 negatif duygu ($n=79.292$)
Makine Öğrenimi	LR, SVM, RF, NB, MLP	LR: %89.07 doğruluk (en iyi model)
LDA Sağlık Analizi	LDA x WHO/SPHERE	Tüm konular SPHERE standartlarıyla uyumlu
BERTopic Sağlık	BERTopic kategorileri	4 alt konu; kan bağıışı en büyük (%9.0)
Karşılaştırmalı Analiz	LDA vs BERTopic	%79.7 BERTopic konusu sağlıkla ilgili
Duygu-Sağlık İlişkisi	Ki-kare testi	$\chi^2=555.41$, $p<0.001$; 7.1 puan fark
ML Sınıflandırma	6 kategori sınıflandırma	LR F1=%89.17; İlaç ve Malzeme F1=0.93

6 Şubat 2023 Kahramanmaraş depremlerinin ardından iki aylık bir süre içinde toplam 88.073 Türkçe tweet toplanmıştır. Analiz, deprem sonrası sağlık ihtiyaçlarını belirlemek ve karakterize etmek için aşağıdaki aşamalarda gerçekleştirilmiştir:

- ✓ Konu Modelleme: (LDA) ve BERTopic kullanılarak tematik yapıların denetimsiz keşfi
- ✓ Duygu Analizi: Dönüştürücü tabanlı modeller (BERTurk, ELECTRA-Turkish) ve sözlük tabanlı yaklaşımlar kullanılarak duygusal kalıpların tespit edilmesi
- ✓ Sağlıkla ilgili içerikleri sağlıkla ilgili olmayan içeriklerden ayırmak için denetimli makine öğrenimi

4.1. Konu Modellemesi Bulguları

4.1.1. LDA ile Konu Modelleme

K=5 parametresi ile uygulanan LDA analizi sonucunda beş temel sağlık teması tespit edilmiştir. Tablo 9’da görüldüğü üzere, en yüksek beta ağırlığı ($\beta = 0.3326$) ‘hijyen’ terimine aittir. Bu değerin, en yakın takipçisinden yaklaşık 3.8 kat daha baskın olması, afet sonrası süreçte WASH (Su, Sanitasyon ve Hijyen) altyapısının kritik bir önceliğe sahip olduğunu ampirik olarak kanıtlamaktadır.

Tablo 9. LDA konu modelleme sonuçları

Konu	Etiket	Tweet Sayısı	Oran	En Yüksek b Terimi
K0	İnsani Yardım Koordinasyonu	36.787	%46.64	---ihtiyacı ($\beta = 0.1328$)
K3	Halk Sağlığı Temelleri	11.780	%14.94	hijyen ($\beta = 0.3326$) -- En Yüksek
K1	Acil Tıbbi / Arama Kurtarma	10.546	%13.37	acil ($\beta = 0.0562$)
K4	Geçici Barınma	10.244	%12.99	çadır ($\beta = 0.1936$)
K2	Afet Yönetimi	9.514	%12.06	deprem ($\beta = 0.2096$)

*K=5

Depremle ilgili tweet veri kümesinin barındırdığı tematik yapıları keşfetmek ve tanımlamak amacıyla, Gensim 4.3.0 kütüphanesi kullanılarak Latent Dirichlet Allocation (LDA) algoritması uygulanmıştır. LDA, her bir belgenin olasılıksal bir konu karışımından oluştuğu ve her konunun belirli bir kelime dağılımı ile karakterize edildiği varsayımıyla çalışmaktadır. Bu kapsamda analiz süreci, LDA analizi için önceden işlenmiş tweet korpusunun hazırlanmasıyla başlamış; öncelikle tweetler tekil kelimelere ayrıştırılarak (tokenizasyon) benzersiz tokenlerden oluşan kapsamlı bir sözlük oluşturulmuştur. Modelin anlamsal kalitesini artırmak adına uygulanan sözlük filtreleme parametreleri çerçevesinde; 5’ten az belgede geçen nadir kelimeler (no_below=5) ve belgelerin %50’sinden fazlasında yer alan aşırı yaygın terimler (no_above=0.5) elenirken, en sık kullanılan 100.000 kelime (keep_n=100.000) analiz için saklanmıştır. Hazırlanan bu sözlük temel alınarak her belge, terim sıklığı dağılımını temsil eden (kelime_id, frekans) ikililerinin yer aldığı bir kelime torbası (Bag-of-Words) temsiline dönüştürülmüştür. Bu ön işleme adımları sonucunda, temizlenmiş korpusun %99.47’sine tekabül eden 78.871 tweet ve 27.951 benzersiz terimden oluşan nihai veri seti, model eğitimi için hazır hale getirilmiştir.

Eğitilen modellerin performansını ve anlamsal derinliğini ölçmek amacıyla iki temel değerlendirme metriği kullanılmıştır. İlk olarak, konular içindeki yüksek olasılıklı kelimeler

arasındaki anlamsal benzerliği ölçen Tutarlılık Puanı (C_v), Gensim'in CoherenceModel yapısı üzerinden hesaplanmıştır. Bu hesaplamada orijinal tokenize edilmiş metinler ve filtrelenmiş sözlük temel alınmış, pencere boyutu ise varsayılan 110 kelime olarak belirlenmiştir. (C_v) puanları 0 ile 1 arasında değişmekte olup; 0.4'ün üzerindeki değerler genellikle “iyi”, 0.5'in üzerindeki puanlar ise “mükemmel” konu kalitesini temsil etmektedir. İkinci metrik olarak kullanılan Karmaşıklık (Perplexity) ise modelin veri kümesine olan uyumunu ölçmekte; daha düşük mutlak perplexity değerleri, modelin daha yüksek bir genelleme yeteneğine sahip olduğunu göstermektedir.

Konu modellemede optimal konu sayısını (K) belirlemek, model performansı için kritik olmakla birlikte metodolojik olarak zorlu bir süreçtir (Cao vd, 2009). Bu çalışmada, deprem sonrası Türk sosyal medyasındaki konu ayrıntı düzeyi ile yorumlanabilirlik arasında bir denge kurabilmek adına, tutarlılık temelli değerlendirme yoluyla sistematik bir optimizasyon süreci izlenmiştir. Bu yaklaşım, yorumlanabilirliği korurken anlamsal tutarlılığı en üst düzeye çıkaran nokta arayışına dayanmaktadır. Bu doğrultuda, $K=5$ ile $K=25$ aralığında (1'lik artışlarla) çoklu LDA modelleri oluşturulmuştur. Eğitim sürecinde, belge-konu yoğunluğu için Alfa (α)= 0.1 ve konu-kelime yoğunluğu için Beta (η)= 0.01 hiperparametreleri sabit tutulmuş; modelin 1.000 iterasyon ve korpus boyunca 15 tam geçiş yapması sağlanmıştır. Analiz, 2.000 belgelik parça (chunk) boyutlarıyla yürütülmüş, rastgele durum parametresi (random state) ise tekrarlanabilirlik için 42 olarak ayarlanmıştır. Her K değeri için tam metin kümesinde eğitilen modellerin tutarlılık ve karmaşıklık puanları kaydedilerek model başarısı değerlendirilmiştir. Söz konusu optimizasyon sürecine dair karşılaştırmalı sonuçlar, Tablo 10 ve Şekil 2'de ayrıntılı olarak sunulmaktadır.

Sistematik olarak yürütülen model eğitimleri sonucunda elde edilen performans metrikleri aşağıda Tablo 10'da özetlenmiştir. Veriler, $K=5$ değerinde tutarlılığın tepe noktasına ulaştığını ve bu noktadan sonra anlamsal kalitenin düşüşe geçtiğini göstermektedir.


Analiz sonuçları incelendiğinde, $K=5$ değeri için 0.4267 tutarlılık puanı elde edilerek net bir optimal konfigürasyon saptanmıştır (Şekil 3, sol grafik). Ardından, $K>5$ değerleri için tutarlılığın keskin bir şekilde azaldığı görülmektedir; nitekim $K=6$ 'da %3.6 ($C_v=0.4112$), $K=7$ 'de ise %12.9 ($C_v=0.3716$) oranında bir düşüş kaydedilmiştir. Bu durum, beşin üzerindeki ek konuların yorumlama değeri katmak yerine, mevcut tutarlı

temaları parçalayarak modelin anlamsal kalitesini düşürdüğünü kanıtlamaktadır. Şekil 3’ün sağ kısmında sunulan karmaşıklık eğrisi ise K=5 (-9.989) ile K=25 (-31.742) arasında monoton bir azalış sergilemektedir. Her ne kadar konu sayısı arttıkça istatistiksel uyum iyileşse de, tutarlılık puanındaki belirgin “dirsek” noktası ve manuel incelemeler sonucunda elde edilen yorumlanabilirlik verileri, K=5 konfigürasyonunun ampirik olarak en güçlü yapı olduğunu doğrulamıştır.

Tablo 10. LDA optimizasyon sonuçları*

K	Tutarlılık (C _v)	Perpleksite
5	0.4267	-9.99
6	0.4112	-10.12
7	0.3716	-10.25
8	0.3615	-10.43
9	0.3804	-10.69
10	0.3545	-11.13


*Not: Tam liste ekler (Appendix) bölümünde sunulmuştur.



Şekil 3. LDA optimizasyon sonuçları

Optimum konu sayısı belirlenirken; tutarlılığın maksimum seviyeye ulaşması, karmaşıklığın kabul edilebilir bir uyum göstermesi ve her iki metriğin yakınsak kanıt sağlaması temel kriterler olarak alınmıştır. Bu kriterlere ek olarak yapılan manuel incelemeler, K=5 seçeneğinin en belirgin ve yorumlanabilir konuları ürettiğini doğrulamıştır. Bu doğrultuda, nihai LDA modeli Şekil 4’te detaylandırılan şu hiperparametrelerle eğitilmiştir: Alfa (α): 0.1 (belge-konu yoğunluğu), Beta (η): 0.01 (konu-

kelime yoğunluğu), 1.000 iterasyon ve 15 tam geiş. Eđitim srecinde tekrarlanabilirlik iin random_state=42 kullanılmıř ve kelime dzeyinde konu atamalarının takibi iin per_word_topics zelliđi etkinleřtirilmiřtir.



řekil 4. Nihai LDA model eđitimi iin optimize edilmiř hiperparametreler

retilen nihai modelin bařarısı, hem istatistiksel hem de anlamsal dzeyde kapsamlı bir řekilde dođrulanmıřtır. Modelin genel performansını yansıtan nihai kalite ltleri, 0.4267 tutarlılık (C_v) ve -9.989 karmařıklık deđerleri ile yksek bir anlamsal btnlđe iřaret etmektedir. Model yakınsaması; karmařıklığın 800 yinelemeden sonra sabit kalması, 12 geiřin (pass) ardından kayıp platosuna ulařılması ve log-olasılık deđerinin son 100 yinelemede <0.0001 varyansla -9.9894 seviyesine oturmasıyla teknik olarak onaylanmıřtır. Ayrıca, konu-kelime dađılımlarının son geiřler arasında ilk 10 kelime olasılıklarında <0.001 varyansla kararlı hale gelmesi, modelin istatistiksel kararlılıđını kanıtlamaktadır. Yapılan nitel ve nicel dođrulama testleri sonucunda řu bulgulara ulařılmıřtır:

- ✓ Anlamsal Ayrıřma: Belirlenen beř ana konunun tamamı, birbirlerinden net anlamsal farklılıklar gstererek yksek ayırt edicilik sergilemiřtir.

- ✓ Literatür Uyumu: Konuların, literatürde kabul görmüş afet müdahale kategorileriyle tam bir uyum içerisinde olduğu saptanmıştır.
- ✓ Model Bütünlüğü: Herhangi bir yapay konu bölünmesi (splitting) gözlemlenmemiş ve külliyyatın %99.47'sini temsil eden 78.871 belge model tarafından başarıyla kapsanmıştır.

Söz konusu teknik uygulama süreci, Python 3.11 ortamında; Gensim 4.3.2 kütüphanesi kullanılarak yürütülmüş, görselleştirme aşamasında pyLDAvis 3.4.0 aracılığıyla etkileşimli konu keşfi gerçekleştirilmiştir. Verilerin istatistiksel işlenmesi ve analizi ise NumPy 1.26.4 ve Pandas 2.1.4 kütüphaneleri desteğiyle tamamlanarak analiz sonuçlarının bilimsel güvenilirliği güvence altına alınmıştır.

Yapılan analizler sonucunda elde edilen beş temel konu, Gensim kütüphanesinin show_topic() fonksiyonu aracılığıyla standart LDA β (Beta) olasılık ağırlıklarına göre tanımlanmış ve tematik olarak etiketlenmiştir. Konuların genel dağılımı ve karşılaştırmalı istatistikleri Tablo 11'de sunulmuştur.

Analiz edilen korpusun %46.64'lük dilimini oluşturan ve toplamda 36.787 tweet ile en yüksek yoğunluğa sahip olan Konu 0, kapsamlı içeriği nedeniyle 'İnsani yardım koordinasyonu ve türk kızılayı operasyonları' teması altında etiketlenmiştir. Konu 0, deprem sonrası sosyal medya söylemlerindeki en geniş hacimli temayı temsil ederek tüm veri kümesinin neredeyse yarısını kapsamaktadır. Bu temanın merkezinde, afet müdahale faaliyetlerinde Türk Kızılayı'nın (Kızılay) üstlendiği stratejik koordinasyon rolü yer almaktadır.

Anlamsal yapı derinlemesine incelendiğinde üç temel boyut öne çıkmaktadır: İlk olarak, "kızılay" ($\beta=0.0876$) ve "birlikte" ($\beta=0.1028$) anahtar kelimeleri aracılığıyla vurgulanan örgütsel koordinasyon; ikinci olarak, bu konuda en yüksek ağırlığa sahip olan "ihtiyacı" ($\beta=0.1328$) ve "mobil" ($\beta=0.0492$) kelimeleriyle tanımlanan operasyonel lojistik; son olarak ise "teşekkür" ($\beta=0.0401$) ve "dayanışma" ($\beta=0.0141$) kavramları üzerinden şekillenen topluluk katılımı ve moral destek boyutudur.

Bu konu, teknik açıdan lojistik, tedarik zinciri yönetimi ve kaynak tahsisi süreçlerini kapsayarak, sağlık hizmetlerinin sunulabilmesi için gerekli olan dolaylı sağlık altyapısını temsil etmektedir (Sphere Association, 2018; OCHA, 2017). Konunun dilsel yapısını belirleyen diğer önemli anahtar kelimeler arasında ise coğrafi odak noktası olarak "hatay"

($\beta=0.0683$), zamansal boyutu vurgulayan “zaman” ($\beta=0.0515$) ve uygulama yöntemini belirten “tarafından” ($\beta=0.0513$) ifadeleri dikkat çekmektedir.

Analiz edilen korpusun %14.94'lük kısmını temsil eden ve toplamda 11.780 tweet içeren Konu 3, içeriği itibarıyla ‘halk sağlığı temelleri: hijyen, gıda güvenliği ve acil barınma’ teması altında sınıflandırılmıştır. Konu 3, külliyetteki doğrudan halk sağlığına odaklanan temel temayı temsil etmekte; yerinden edilme durumlarında sağlığın ana belirleyicileri olan WASH (su, sanitasyon, hijyen), gıda güvenliği ve acil barınma konularını kapsamlı bir şekilde ele almaktadır.

Anlamsal yapı incelendiğinde, hijyenle ilgili içeriklerin mutlak hakimiyeti dikkat çekmektedir. “hijyen” kelimesi, $\beta=0.3326$ (33.26%) ağırlığı ile beş konunun tamamındaki tüm terimler arasında en yüksek değere sahiptir ve bu konunun toplam olasılık kütesinin yaklaşık üçte birini tek başına oluşturmaktadır. Bu baskınlık, ikinci en yüksek terim olan “gıda” ($\beta=0.0872$) ifadesinden 3.8 kat daha fazladır. Diğer konulardaki en yüksek ağırlıkların $\beta=0.0562$ (Konu 1) ile $\beta=0.2096$ (Konu 2) arasında değiştiği göz önüne alındığında, bu semantik yoğunluk seviyesi; hasarlı altyapı ve kitlesel yerinden edilme kaynaklı hastalık bulaşma riskine karşı toplumsal odaklanmanın ne denli yüksek olduğunu kanıtlamaktadır.

Konu, uluslararası standartlarla (Sphere Association, 2018) uyumlu şekilde üç temel halk sağlığı alanını birleştirmektedir:

- ✓ WASH (Su, Sanitasyon, Hijyen): “hijyen” ($\beta=0.3326$) kelimesinin baskınlığı, sanitasyon tesisleri ve hastalık önleme stratejilerinin afet sonrası söylemin merkezinde olduğunu göstermektedir.
- ✓ Gıda Güvenliği ve Beslenme: “Gıda” ($\beta=0.0872$), “yemek” ($\beta=0.0446$) ve “sıcak” ($\beta=0.0224$) anahtar kelimeleri, hem beslenme hem de psikolojik ihtiyaçları karşılayan sıcak yemek teminine yönelik operasyonları yansıtmaktadır.
- ✓ Acil Barınma: “Barınma” ($\beta=0.0235$) kavramı; çevre koruma, sıcaklık düzenlemesi ve insani onur başlıklarını ele alarak sağlık sonuçlarını doğrudan etkileyen bir faktör olarak öne çıkmaktadır.

Ayrıca, “Seyyar” (mobil, $\beta=0.0202$) kelimesinin gıda ve hijyen terimleriyle birlikte kullanımı, sahada mobil hizmet birimlerinin aktif olarak konuşlandırıldığını göstermekte ve WHO EMT Tip 1 (Dünya Sağlık Örgütü Acil Tıbbi Ekipler) mobil standartlarıyla (WHO,

2021) örtüşmektedir. Temanın diğer belirleyici unsurları arasında sürece yönelik toplumsal ve kurumsal katkıyı ifade eden “destek” ($\beta=0.0748$) ve “yardım” ($\beta=0.0728$) kavramları yer almaktadır.

Analiz edilen korpusun %13.37’sini kapsayan ve toplamda 10.546 tweetten oluşan Konu 1, içeriğindeki yoğun saha operasyonu verileri nedeniyle ‘acil tıbbi hizmetler ve arama-kurtarma operasyonları’ teması altında etiketlenmiştir. Konu 1, hayatta kalma olasılığının en yüksek olduğu “altın saatler” olarak adlandırılan ilk 72 saatteki kritik müdahaleleri ve akut acil durum aşamasındaki saha faaliyetlerini temsil etmektedir.

Anlamsal yapı, doğrudan aciliyet ve hızlı eylem üzerine kurgulanmıştır. Bu bağlamda “acil” (acil durum, $\beta=0.0562$) anahtar kelimesi en yüksek ağırlığa sahip terim olarak öne çıkmaktadır. Dikkat çekici bir bulgu olarak; bu konu, tüm konular arasında en düşük maksimum β değerine (en yüksek ağırlıklı kelimesi bile nispeten düşük bir puandadır) sahip olmasıyla “en dağınık kelime dağarcığına” sahip tema olarak nitelendirilmektedir. Bu durum, acil müdahale sürecinin tek bir baskın kavram yerine, eş zamanlı yürütülen ve her biri yüksek önceliğe sahip çok sayıda farklı faaliyeti içerdiğini istatistiksel olarak göstermektedir.

Konu, birbiriyle entegre şekilde çalışan iki temel acil durum işlevini kapsamaktadır:

- ✓ Arama ve Kurtarma (SAR): “kurtarma” (kurtarma, $\beta=0.0314$) ve “arama” (arama, $\beta=0.0251$) terimleri, INSARAG kılavuzlarında (2016: 1-26) hayat kurtarma operasyonları olarak sınıflandırılan teknik saha çalışmalarına açıkça atıfta bulunmaktadır.
- ✓ Acil Tıbbi Hizmetler: “acil” kavramı; triyaj, travma stabilizasyonu ve tıbbi tahliye süreçlerini içeren acil tıbbi müdahaleleri yansıtmakta olup, WHO EMT Tip 1 Mobil sınıflandırmasıyla (WHO, 2021) uyum sergilemektedir.

Temanın coğrafi odak noktasını afetin merkez üssü olan “kahramanmaraş” ($\beta=0.0357$) ve “hatayda” ($\beta=0.0344$) kelimeleri belirlerken; müdahalenin öznelere ve kapsamını ifade eden “vatandaşlarımıza” ($\beta=0.0398$), “yapan” ($\beta=0.0336$) ve “bölgesindeki” ($\beta=0.0251$) ifadeleri anlamsal yapıyı tamamlayan diğer önemli unsurlardır.

Analiz edilen korpusun %12.99’unu temsil eden ve toplamda 10.244 tweet içeren Konu 4, içeriği bakımından ‘yerinden edilmiş nüfuslar için geçici barınma ve sosyal refah desteği’ teması altında sınıflandırılmıştır. Konu 4, acil durum müdahalesinden erken

iyileşme aşamasına geçişi yansıtan; geçici barınma çözümlerine ve yerinden edilmiş toplulukların sağlığının sosyal belirleyicilerine odaklanan orta vadeli ihtiyaçları ele almaktadır.

Anlamsal yapı, barınma stratejileri üzerine yoğunlaşmış olup “çadır” ($\beta=0.1936$) ve “büyük” (büyük, $\beta=0.1337$) kelimelerinin ikili baskınlığı, afet sonrası kurulan büyük ölçekli çadır kentlerin ve yerleşim alanlarının söylemdeki ağırlığını göstermektedir. Ayrıca “konteyner” (konteyner, $\beta=0.0303$) terimi, lojistik süreçlerin istikrar kazanmasıyla genellikle afetten 2-4 hafta sonra gündeme gelen, çadırlardan daha dayanıklı geçici konut sistemlerine geçiş aşamasını temsil etmektedir.

Konu, halk sağlığı ve sosyal refah açısından birbiriyle bağlantılı üç temel boyutu birleştirmektedir:

- ✓ Barınma Altyapısı: Geçici koruma sağlayan çadır ve konteyner kentlerin kurulum süreçleri.
- ✓ Savunmasız Gruplar: “depremzede” (deprem mağduru, $\beta=0.0380$) kavramı üzerinden tanımlanan ve özel destek ihtiyacı duyan mağdur nüfus grupları.
- ✓ Refah Programları: “beslenme” (beslenme, $\beta=0.0292$) ve “sosyal” ($\beta=0.0324$) anahtar kelimeleriyle ifade edilen; acil yemek dağıtımının ötesine geçerek beslenme düzeni ve psikososyal refahı merkeze alan organize programlar.

Halk sağlığı perspektifinden bu konu, yerinden edilme bağlamında sağlığın sosyal belirleyicilerini yansıtmaktadır. Geçici yerleşim yerlerindeki yaşam koşulları; aşırı kalabalık kaynaklı solunum yolu enfeksiyonları, sanitasyon yetersizliklerine bağlı ishal vakaları ve psikolojik stres temelli ruh sağlığı bozuklukları gibi sağlık sonuçlarını doğrudan etkileme potansiyeline sahiptir. Anlamsal yapıyı tamamlayan diğer unsurlar ise operasyonel süreçleri ifade eden “ilk” ($\beta=0.0775$) ve “ediyoruz” ($\beta=0.0749$) kavramlarıdır.

Analiz edilen korpusun %12.06’sını kapsayan ve toplamda 9.514 tweet içeren Konu 2, içerik analizi sonucunda ‘Afet Yönetimi Operasyonları ve Malzeme Tedarik Dağıtımı’ teması altında etiketlenmiştir. Konu 2, külliyetteki en küçük hacimli tema olmasına rağmen, haftalar ve aylar boyunca sürdürülen yardım operasyonlarının operasyonel omurgasını ve devam eden afet yönetimi koordinasyonunu temsil etmesi bakımından kritik öneme sahiptir.

Anlamsal yapı, sürecin sürekliliğini ve afet olgusunun kendisini vurgulamaktadır. “deprem” kelimesi, ($\beta=0.2096$) ağırlığı ile tüm konular genelindeki terimler arasında

(hijyenin ardından) ikinci en yüksek değere sahiptir; bu durum, konunun spesifik müdahalelerden ziyade genel afet yönetimi sürecine odaklandığını göstermektedir. Ayrıca, bu konudaki en yüksek ikinci ağırlığa sahip olan “devam” ($\beta=0.1307$) ifadesi, operasyonların akut evreden sürdürülebilir bir faza geçtiğini işaret ederek, bu temayı Konu 1’in acil müdahale odaklı yapısından net bir şekilde ayırmaktadır.

Konu, dört temel operasyonel boyut üzerinden karakterize edilmektedir:

- ✓ Kurumsal Yönetim: “AFAD” (Afet ve Acil Durum Yönetimi Başkanlığı, $\beta=0.0161$) ve “bölgesinde” ($\beta=0.0550$) terimleri aracılığıyla devlet kurumlarının yönetsel otoritesi.
- ✓ Lojistik ve Tedarik: “battaniye” ($\beta=0.0261$) ve “malzemeleri” ($\beta=0.0255$) anahtar kelimeleri üzerinden temel ihtiyaçları karşılayan gıda dışı malzeme dağıtımı.
- ✓ Operasyonel Süreklilik: “devam” ($\beta=0.1307$) kavramıyla vurgulanan kesintisiz saha çalışmaları.
- ✓ Saha Ekipleri: “ekiplerimiz” ($\beta=0.0228$) ifadesiyle temsil edilen merkezi olmayan, bölgesel düzeydeki operasyonel birimler.

Sağlık perspektifinden değerlendirildiğinde bu konu, malzeme altyapısı ve tedarik zinciri yoluyla sağlanan dolaylı sağlık desteğini temsil etmektedir. Doğrudan tıbbi müdahale içermese de, güvenilir bir tedarik zincirinin varlığı ikincil sağlık risklerini önlemektedir: Battaniye dağıtımı hipotermiyi engellemekte, genel malzeme akışı ise hijyenin korunmasını ve sağlık tesislerinin lojistik olarak desteklenmesini sağlamaktadır. Temanın diğer belirleyici unsurları arasında sürece yönelik talebi ifade eden “ihtiyaç” ($\beta=0.0837$) ve olayın kapsamını belirten “afet” ($\beta=0.0665$) kavramları yer almaktadır.

Tablo 11. LDA konu karşılaştırması

Konu	Etiket	Tweet	%	En Yüksek β
0	İnsani Yardım Koordinasyonu	36.787	46.64%	0.1328 (ihtiyaç)
3	Halk Sağlığı Temelleri	11.780	14.94%	0.3326 (hijyen)
1	Acil Tıbbi Müdahale / Arama ve Kurtarma	10.546	13.37%	0.0562 (acil)
4	Geçici Barınma	10.244	12.99%	0.1936 (çadır)
2	Afet Yönetimi	9.514	12.06%	0.2096 (deprem)

4.1.2. BERTopic ile Konu Modelleme

BERTopic analizi, konu sayısını otomatik olarak belirleyerek toplam 59 farklı konu tespit etmiştir. Analiz sonucunda 45.590 tweet (%57.5) başarıyla kümelenirken, 33.702

tweet (%42.5) aykırı değer (outlier) olarak sınıflandırılmıştır. Tablo 12’de detaylandırıldığı üzere, ‘Sağlık ve Tıp’ kategorisi kümelenen belgelerin %25.0’ını oluşturarak veri setindeki en baskın temalardan biri olmuştur.

Tablo 12. BERTopic kategori dağılımı*

BERTopic Kategorisi	Tweet Sayısı	Toplam (%)	Kümelenen (%)
Aykırı Değerler (Outlier)	33.702	%42.5	—
Diğer / Karışık	16.512	%20.8	%36.2
Sağlık ve Tıp	11.375	%14.3	%25.0
Afet Yardımı	11.367	%14.3	%24.9
Siyasi Söylem	3.948	%5.0	%8.7
İletişim ve Altyapı	1.426	%1.8	%3.1
Dini ve Manevi	962	%1.2	%2.1
Toplam	79.292	%100	—

*59 konu, 7 tematik kategori

Çalışmanın bu aşamasında, LDA’nın “kelime torbası” (bag-of-words) varsayımının ötesine geçmek ve metinlerdeki derin anlamsal ilişkileri yakalamak amacıyla BERTopic algoritması uygulanmıştır. BERTopic; önceden eğitilmiş dönüştürücü (transformer) modellerini kullanarak, kelimeler ve belgeler arasındaki nüanslı ilişkileri bağlamsal gömme (embedding) öğeleri üzerinden analiz etmektedir. Bu yaklaşım, özellikle afet bağlamındaki sağlık ifadelerinin barındırdığı anlamsal detayları anlamak için kritik bir avantaj sunmaktadır. Algoritma; önceden eğitilmiş modellerle belge gömme oluşturma, UMAP ile boyut indirgeme, HDBSCAN ile hiyerarşik kümeleme ve sınıf tabanlı TF-IDF (c-TF-IDF) ağırlıklandırması yoluyla konu temsili basamaklarından oluşan çok aşamalı bir süreçle işlemektedir. HDBSCAN’ın yoğunluk tabanlı kümeleme yöntemi, LDA’nın aksine tüm belgeleri zorla bir konuya dahil etmek yerine, herhangi bir tutarlı konuya ait olmayan tweetleri doğal olarak ayırt ederken; algoritmanın hiyerarşik yapısı alt konu yapılarının keşfedilmesine olanak tanımaktadır. Ayrıca BERTopic’in çok dilli gömmeleri diller arasında etkili bir şekilde aktarıldığı için Türkçenin metin analizi süreçlerine yüksek uyum sağlamaktadır.

Algoritmanın başarısı, kriz bilişimi analizine uygun şekilde çok aşamalı bir sürecin optimize edilen şu bileşenlerle sağlanmıştır:

- ✓ Gömme Modeli (Embedding Model): Türkçe dahil 50’den fazla dilde önceden eğitilmiş olan (sentence-transformers/paraphrase-multilingual-MiniLM-L12-v2)

modeli tercih edilmiştir. 384 boyutlu yoğun vektörler üreten bu çok dilli cümle dönüştürücü, hesaplama verimliliğini korurken Türkçe dil yapılarına özgü anlamsal ilişkileri yakalamayı mümkün kılmaktadır (Reimers ve Gurevych, 2020: 4512-4513).

- ✓ UMAP Boyutsallık Azaltma: Gömme boyutları üzerinde hesaplama kısıtlaması olmadığı ve farklı boyutlu uzaylardaki belge gömmelerini başarıyla küçültebildiği için UMAP tercih edilmiştir. Yapılandırmada (n_neighbors: 20, n_components: 5, min_dist: 0.0, metrik: ‘kosinüs’ ve random_state: 42) parametreleri kullanılmıştır. Bu süreçte HDBSCAN, gürültünün aykırı değerler olarak modellenmesine izin veren “yumuşak kümeleme” (soft clustering) yaklaşımını kullanarak kümeleri belirlemektedir (Grootendorst, 2022: 2-3).
- ✓ HDBSCAN Kümeleme Parametreleri: Kümeleme aşamasında (min_cluster_size: 18) değeri seçilerek, tablo 13’de gösterildiği gibi %42.5’lik yönetilebilir bir aykırı değer oranıyla 59 konunun oluşturduğu optimum denge sağlanmıştır. Algoritmanın muhafazakarlık düzeyini belirleyen (min_samples: 4) parametresi ise yeterli kanıt (en az 4 benzer belge) toplandığında daha küçük ama tutarlı konu gruplarının tanımlanmasına imkan tanımıştır.
- ✓ Konu Temsili ve Vektörleştirme: Türkçe morfolojisi için optimize edilen süreçte, özel bir liste aracılığıyla durdurma kelimeleri (stop-words) temizlenmiş ve n_gram_range: (1, 2) kullanılarak “kan bağıışı”, “ruh sağlığı” veya “panik atak” gibi kritik tıbbi terminolojinin bütünlüğü korunmuştur. min_df: 5 eşiği ile yalnızca yeterli metin desteğine sahip kelimelerin konu tanımlarına katkıda bulunması sağlanırken, en temsil edici 10 terim c-TF-IDF puanlaması ile belirlenmiştir.

BERTopic’in en belirgin özelliklerinden biri, HDBSCAN aracılığıyla aykırı değerleri (outliers) açıkça işlemesidir. Her belgeyi belirli bir olasılıkla bir konuya atayan LDA’dan farklı olarak BERTopic, herhangi bir yoğun kümeye ait olmayan belgeleri tanımlar ve bunları “Konu -1” olarak etiketler. Bu analizde, veri kümesinin %42.5’i (33.702 belge) aykırı değer olarak sınıflandırılmıştır. Bu oran; tweetlerin içerik açısından kısıllığını, benzersiz endişeler içermesini, min_cluster_size: 18 kısıtlamasını ve Türkçenin sözdizimsel morfolojisinin yarattığı yüksek dilsel çeşitliliği yansıtmaktadır. Aykırı değerlerin zorla bir

kategoriye atanmak yerine ayrı tutulması, elde edilen 59 konunun tematik tutarlılığını artırmış ve algoritmanın kriz verilerinde “sinyali” gürültüden başarıyla ayırt edebildiğini kanıtlamıştır.

Tablo 13. BERTopic analizi genel bakış ve kümeleme istatistikleri

Metrik	Değer
Toplam Doküman Sayısı	79.292
Belirlenen Konu Sayısı	59
Kümeleme Yapılan Dokümanlar	45.590 (57.5%)
Aykırı Değerler (Konu -1)	33.702 (42.5%)
Ortalama Konu Büyüklüğü	772.7 doküman
Medyan Konu Büyüklüğü	348.0 doküman
En Büyük Konu	4.116 doküman
En Küçük Konu	18 doküman

BERTopic modelinin çıktılarını anlamlandırma aşamasında uygulanan konu yorumlama, etiketleme ve sınıflandırma süreci, bir konu kümesindeki tüm belgeleri tek bir birim olarak ele alan ve en ayırt edici terimleri saptayan c-TF-IDF (Sınıf Tabanlı Terim Sıklığı-Ters Belge Sıklığı) yöntemiyle gerçekleştirilmiştir. Bu süreçte, 73 adet Türkçe durdurma kelimesini (stop-words) eleyen ve n-gram aralığı (1,2) olarak belirlenen bir CountVectorizer, minimum belge sıklığı 5 olan tekli ve ikili kelimeleri tanımlamak üzere yapılandırılmıştır. c-TF-IDF algoritması, her kelimenin konu içerisindeki frekansını diğer tüm konulardaki sıklığına göre oranlayarak spesifik önem puanları hesaplamış ve elde edilen en yüksek puanlı terimler aracılığıyla akademik olarak yorumlanabilir, temsil gücü yüksek konu etiketleri oluşturulmuştur.

BERTopic, c-TF-IDF kelime puanlarını kullanarak konu etiketlerini otomatik olarak oluştururken, nicel ölçütler tek başına alan uzmanları tarafından algılanan anlamsal tutarlılığı yakalayamadığı için, konu modelleme araştırmalarında manuel yorumlama ve kategorizasyon standart bir uygulamadır (Maier vd., 2018: 108). Bireysel konu etiketlemesinin ardından, konular tematik benzerlik ve sağlık alanıyla ilgililiğine göre hiyerarşik olarak altı üst düzey kategoriye ayrılmıştır. Bu, her bir kategori içindeki bireysel konuların ayrıntı düzeyini korurken, sağlık ihtiyaçlarını anlamak için yorumlanabilir bir çerçeve sağlamaktadır (ayrıntılı tablo ekte yer almaktadır):

- ✓ Sağlık ve Tıp (kümelenmiş belgelerin %14.3’ü): Tıbbi hizmetler, sağlık hizmetlerine erişim, tıbbi malzeme ve klinik ihtiyaçlarla ilgili konular

- ✓ Afet Yardımı (%14.3): Acil yardım, barınma, temel ihtiyaçlar ve afet müdahale lojistiği ile ilgili konular
- ✓ Diğer/Karışık (20.8%): Sağlık veya afet kategorilerine tam olarak uymayan heterojen konular, günlük yaşam, sosyal yorumlar ve karışık temalar dahil
- ✓ Siyasi Söylem (5.0%): Siyasi tepkiler, yönetim ve seçimlerle ilgili içeriklerle ilgili konular
- ✓ İletişim ve Altyapı (%1.8): İletişim sistemleri, internet bağlantısı ve altyapı hasarları ile ilgili konular
- ✓ Dini ve Manevi (1.2%): Dini duyguları, duaları ve manevi desteği ifade eden konular

Kategori atamaları, sistematik tematik analiz yoluyla belirlendi. Her konunun temsili terimleri (en çok kullanılan 10 c-TF-IDF ağırlıklı kelime) ve örnek belgeler (konu başına n=20) birincil içerik alanı açısından değerlendirildi. Sağlıkla ilgili içeriği açık olan konular (tıbbi terminoloji, sağlık hizmetlerine erişim, ruh sağlığı ifadeleri) Sağlık ve Tıp kategorisine atandı. Maddi yardım, barınma, gıda ve afet lojistiğine odaklanan konular Afet Yardımı kategorisine atandı. Birden fazla alana yayılan veya net bir tematik odağı olmayan konular Diğer/Karışık kategorisine atandı.

BERTopic modelinin başarısını ve bilimsel geçerliliğini kanıtlayan değerlendirme süreci, hem istatistiksel veriler hem de literatür temelli nitel incelemelerle desteklenmiştir. Konu kalitesine dair bulgular aşağıda sunulmuştur:

Anlamlı ve yorumlanabilir sonuçlar elde etmek amacıyla konu kalitesi, nicel ve nitel ölçütlerden oluşan çok yönlü bir yaklaşımla değerlendirilmiştir. Nicel tutarlılık ölçütleri çerçevesinde, c-TF-IDF puanlarının 0.011 ile 0.216 (medyan: 0.058) arasında değişmesi, konuların semantik açıdan yeterli çeşitlilik ve ayırt edicilik sunduğunu göstermektedir. Konu boyutları, 18 ile 4.116 belge arasında (medyan: 348) geniş bir yelpazeye dağılarak afet sonrası söylemin farklı katmanlarını yansıtmıştır. Model kapsamı açısından, belgelerin %57.5'i (45.590 tweet) 59 farklı konuya başarıyla atanırken, kalan %42.5'lik bölüm gürültüden arındırılmak üzere aykırı değer olarak tanımlanmıştır.

Niteliksel doğrulama aşamasında yapılan manuel incelemeler, her konunun en sık kullanılan kelimelerinin yüksek anlamsal ilişki ve tematik tutarlılık sergilediğini onaylamıştır. Konu başına seçilen 20 adet temsili belgenin analizi, içeriklerin sağlık ve afet

yönetimiyle doğrudan ilişkili olduğunu doğrulamıştır. Ayrıca, elde edilen konuların 8 farklı sağlık alanında insani krizler sırasındaki asgari standartları belirleyen Sphere İnsani Yardım Standartları 2018 çerçevesiyle tam uyum gösterdiği saptanmıştır. Bu uyumun öne çıkan örnekleri şunlardır (Sphere Association, 2018: 335-345):

- ✓ Konu 0 (kan, kan bağıışı, acil) Sphere Standardı 2.4 (Transfüzyon kapasitesi gerektiren yaralanma ve travma bakımı) ile uyumludur.
- ✓ Konu 3 (ilaç, kronik, diyabet) Sphere Standardı 2.6 (bulaşıcı olmayan hastalıkların tedavisinde süreklilik) ile uyumludur.
- ✓ Konu 5 (psikolog, panik, travma) Küre Standardı 2.1.5 (ruh sağlığı ve psikososyal destek hizmetleri) ile uyumludur.

Bu sistematik çerçeve haritalaması, 59 konunun 47'sinin (%79.7) Sphere sağlık standartlarına doğrudan karşılık gelen içerik barındırdığını doğrulayarak, BERTopic'in uluslararası afet sağlık kılavuzlarında tanınan sağlık ihtiyaçlarını başarıyla keşfettiğini onayladı.

4.2. Duygu Analizi Bulguları

BERTurk modeli kullanılarak 79.292 tweet üzerinde gerçekleştirilen ikili duygu sınıflandırması, veri setinde %76.21 oranında yoğun bir negatif duygu hakimiyeti olduğunu ortaya koymuştur. Negatif/Pozitif oranının 3.20:1 olarak belirlenmesi, örneklemdaki yüksek sıkıntı düzeyini yansıtmaktadır. Tablo 14'te sunulduğu üzere, manuel doğrulama (n=199) sonucunda modelin doğruluk oranı %82.41 olarak hesaplanmış olup, istatistiksel analizler sağlık ve duygu durumları arasında anlamlı bir korelasyon olduğunu doğrulamıştır ($\chi^2=555.41$, $p < 0.001$).

Tablo 14. BERTurk duygu analizi bulgularının özeti

Metrik	Değer	Açıklama
Toplam Tweet	79.292	BERTurk ile analiz edilen
Negatif Duygu	60.426 (%76.21)	Baskın duygu sınıfı
Pozitif Duygu	18.866 (%23.79)	—
Neg/Poz Oranı	3.20:1	Yüksek sıkıntı göstergesi
Ortalama Model Güveni	%89.50	Yüksek güven
Medyan Model Güveni	%96.63	—
Yüksek Güven (>%95)	44.239 tweet (%55.8)	—
Manuel Doğruluk (n=199)	%82.41	Negatif F1=%88.37; Pozitif F1=%63.92
İstatistiksel Test	$\chi^2=555.41$, $p<0.001$	Sağlık-duygu korelasyonu

Duygu analizi; farklı kriz aşamalarında sosyal medyadaki sağlık arayışı davranışlarına yansıyan kamuoyu algısını ölçmek, psikolojik durumları analiz etmek ve sağlık ihtiyaçları ile olumsuz duygular arasındaki olası korelasyonu belirlemek amacıyla gerçekleştirilmiştir. Türkçe morfolojisinin karmaşıklığı ve afet bağlamının kendine özgü dilsel özellikleri nedeniyle, en uygun tekniği saptamak üzere üç farklı yaklaşım sistematik olarak karşılaştırılmıştır:

Yöntem 1: Sözlük Temelli Duygu Analizi: Afet ve sağlık acil durumlarına özgü, 89 anahtar kelimedenden oluşan özel bir Türkçe duygu sözlüğü kullanılmıştır. Sözlük; umut, şükran ve dayanışmayı temsil eden 35 olumlu terim ile acı, aciliyet ve kayıp ifadelerini içeren 54 olumsuz terimden oluşmaktadır. Sınıflandırma, metin içerisindeki anahtar kelimelerin frekansına dayalı basit bir kelime sayma algoritmasıyla gerçekleştirilmiş; pozitif, negatif ve nötr kategoriler puan ağırlıklarına göre belirlenmiştir.

Yöntem 2: BERTurk Transformer Modeli: Derin öğrenme yaklaşımı olarak (savasy/bert-base-turkish-sentiment-cased) modeli tercih edilmiştir. 12 dönüştürücü katmanı ve 110 milyon parametreye sahip olan bu mimari, 35 GB'lık geniş bir Türkçe veri kümesiyle önceden eğitilmiştir. Kelimeleri izole birer birim olarak değil, çift yönlü bağlam kodlamasıyla çevresindeki ifadelerle birlikte anlamlandıran BERTurk, morfolojik açıdan zengin olan Türkçede ve gürültülü sosyal medya metinlerinde bağlama dayalı duygu tespiti için güçlü bir performans sergilemektedir (Özçift vd., 2021; Yıldırım, 2024).

Yöntem 3: ELECTRA-Turkish Discriminator: Alternatif bir dönüştürücü mimarisi olarak (dbmdz/electra-base-turkish-cased-discriminator) modeli değerlendirilmiştir. Ancak, aslen maskeli dil modelleme görevleri için bir “ayırt edici” (discriminator) olarak tasarlanan bu modelin, tüm tahminleri nötr kategorisine atayarak geçersiz sınıflandırma sonuçları ürettiği saptanmıştır. Bu teknik yetersizlik nedeniyle ELECTRA-Turkish nihai değerlendirme sürecinden çıkarılmış; analizler sözlük tabanlı yöntem ile BERTurk modeli arasındaki karşılaştırmaya odaklanmıştır.

Modellerin performansını nesnel bir zeminde ölçmek amacıyla, değerlendirme çerçevesi kapsamında dört temel boyut dikkate alınmıştır:

- ✓ Kapsam (0-25 puan): Tweetlerin yüzde kaçının net bir duygu sınıflandırması (nötr olmayan) alabildiğini ölçer.


- ✓ Güvenilirlik (0-30 puan): Yalnızca dönüştürücü modeller için geçerli olan, tahminlerdeki ortalama güven düzeyini temsil eder.
- ✓ Denge (0-25 puan): Afet bağlamındaki negatif/pozitif oranının (optimum 2-3:1) uygunluğunu denetler.
- ✓ Bağlam Anlayışı (0-20 puan): Modelin kelime düzeyinden ziyade anlamsal bütünlüğü kavrama yeteneğini puanlar.

Değerlendirme çerçevesi, modelin tüm veri setine uygulanabilirliğini ve bilimsel güvenilirliğini doğrudan yansıttığı için “Güvenilirlik” ve “Kapsam” boyutlarına maksimum ağırlık atamıştır. Bu karşılaştırmalı analizin sayısal verileri ve grafiksel gösterimleri ilerleyen bölümlerde Tablo 15, Tablo 16 ve Şekil 5 altında detaylı olarak sunulmaktadır.

Tablo 15. Duygu analizi yöntemleri karşılaştırması

Metot	Negatif %	Positif %	Nötr %	Ortalama Güven	Koveraj (Nötr olmayan)	İşlem Süresi (s)
Sözlük Tabanlı	19.5%	13.7%	66.8%	N/A	33.2%	4.0
BERTurk	76.2%	23.8%	0.0%	89.5%	100.0%	12.154
ELECTRA-Türkçe	0.0%	0.0%	0.0%	54.6%	0.0%*	12.982

* Geçersiz sınıflandırmalar analizden çıkarılmıştır



Şekil 5. Duygu analizi yöntemleri karşılaştırma görselleştirmesi

Tablo 16. Duygu analizi yöntemlerinin objektif puanlaması

Kriter	Ağırlık	Sözlük Tabanlı	BERTurk	İspat
Kapsama (nötr olmayan %)	25	8.3/25	25.0/25	BERTurk 100%, sözlük tabanlı 33.2%
Güven	30	0.0/30	26.9/30	89.5% ortalama güven
Denge (negatif/pozitif oranı)	25	5.0/25	25.0/25	Afet için BERTurk 3.2:1 oranı uygun
Bağlam anlama	20	0.0/20	20.0/20	Transformer tabanlı yaklaşım, kelime düzeyine kıyasla daha üstündür
Toplam Puan	100	13.3	96.9	

Objektif değerlendirme kriterlerine dayanarak; tweetlerin %100'ünü kapsama yeteneği, %89.5'lik yüksek ortalama güven puanı, çift yönlü bağlamı işleyebilen gelişmiş mimarisi ve 35 GB'lık Türkçe veri kümesiyle afet bağlamındaki sosyal medya metinlerine sağladığı morfolojik uyum nedeniyle BERTurk, birincil duygu analizi yöntemi olarak seçilmiştir (Yıldırım, 2024; Köksal ve Özgür, 2021).

Sistematik karşılaştırmalar sonucunda BERTurk modelinin tercih edilmesini sağlayan temel ampirik bulgular şunlardır:

- ✓ BERTurk, tweetlerin %100'ünü kesin duygu (olumlu veya olumsuz) ile sınıflandırırken, sözlük tabanlı yaklaşım sadece %33.2'sini kapsadı. Sözlük yaklaşımında kalan %66.8'lik tweetler, eşleşen anahtar kelimelerin bulunmaması nedeniyle nötr olarak sınıflandırıldı ve bu da önemli bir bilgi kaybına neden oldu.
- ✓ BERTurk, sınıflandırmalarda yüksek kesinlik gösteren %89.5'lik ortalama güven puanına ulaşmıştır. Ayrıca, tahminlerin %55.8'i %95'in üzerinde, %66.6'sı ise %90'ın üzerinde güven puanına ulaşmıştır, bu da tüm metin kümesinde sağlam bir performans olduğunu göstermektedir.
- ✓ BERTurk'ün dönüştürücü mimarisi, çift yönlü bağlamı işler; sözlük tabanlı kelime sayımından farklı olarak, çevreleyen kelimelere bağlı olarak anlamın doğru yorumlanmasını sağlar.
- ✓ BERTurk, 35 GB'lık Türkçe metin üzerinde özel olarak önceden eğitilmiş ve Türkçe sosyal medyada duygu analizi için ince ayar yapılmıştır, bu da onu genel çok dilli modellere kıyasla bu metin kümesine en uygun hale getirmiştir.
- ✓ %76.2 negatif ve %23.8 pozitif dağılım (oran 3.2:1), acı ve acil ihtiyaçların hakim olduğu, ancak dayanışma ve minnettarlığın da mevcut olduğu büyük afet bağlamları için beklenen modellerle uyumludur. Pourebrahim vd. (2019: 1-19) da,

Sandy Kasırgası sırasında duygu durumunun kasırğa sırasında en negatif olduğunu bulmuşlardır.

- ✓ BERTurk’ün Türk sosyal medyasında duygu analizine ilişkin önceki doğrulama çalışmalarında %89-94 doğruluk oranı bildirilmiştir, bu da modelin güvenilirliğine ilişkin bağımsız kanıt sağlamaktadır.

Sözlük tabanlı yaklaşım hesaplama açısından verimlidir (4 saniyelik işlem süresi), ancak temel sınırlamaları da ortaya koymuştur:

- ✓ Sınırlı kelime hazinesi (89 kelime), 79.292 tweet’teki çeşitli duygu ifadeleri yakalayamamıştır.
- ✓ Olumsuzlukların işlenmemesi (örneğin, “iyi değil” yanlış bir şekilde olumlu olarak puanlanmıştır)
- ✓ Yoğunluk değiştiriciler veya derece zarfları dikkate alınmamıştır
- ✓ Çok anlamlı kelimelerin bağlamsal anlam ayrımı yapılmamıştır

BERTurk modelinin sınıflandırma başarısını ve bilimsel geçerliliğini teyit etmek amacıyla uygulanan doğrulama süreci; istatistiksel metrikler, hata matrisi analizi ve literatürle karşılaştırmalı değerlendirmeleri içermektedir. Elde edilen bulgular, modelin afet bağlamındaki duygu durumlarını yüksek doğrulukla saptadığını ortaya koymuştur.

BERTurk modelinin bu özel veri kümesi üzerindeki güvenilirliğini test etmek amacıyla, standart sınıflandırma metriklerini temel alan kapsamlı bir doğrulama protokolü yürütülmüştür. Manuel etiketleme için rastgele seçilen 199 tweetlik örneklem; tabakalaştırma, yüksek güven odaklılık ve rastgeleleştirme ilkeleri doğrultusunda oluşturulmuş; her bir ileti model tahminlerinden bağımsız olarak “baş gerçek” (ground truth) verisi olarak etiketlenmiştir.

Manuel etiketler üzerinden hesaplanan performans metrikleri, modelin genel başarısının yanı sıra sınıflar arasındaki duyarlılık farklarını da net bir şekilde ortaya koymaktadır. Doğrulama sonuçlarına dair özet veriler Tablo 17’de sunulmuştur.

Tablo 17. BERTurk doğrulama sonuçları *


Metrik	Value	Yorum
Genel Doğruluk (Accuracy)	82.41%	Gerçek değerlerle güçlü uyum
Ağırlıklı Kesinlik (Precision)	82.09%	Güvenilir pozitif tahminler
Ağırlıklı Duyarlılık (Recall)	82.41%	Kapsamlı tespit
Ağırlıklı F1-Skoru	82.23%	Dengeli kesinlik-duyarlılık dengesi

Tablo 17. (Devamı)

Sınıf Bazlı Performans		
Negatif Kesinlik	87.50%	Az sayıda yanlış negatif
Negatif Duyarlılık	89.26%	Negatif duygu büyük ölçüde yakalanıyor
Negatif F1-Skoru	88.37%	Mükemmel negatif tespit
Pozitif Kesinlik	65.96%	Orta düzeyde yanlış pozitif oranı
Pozitif Duyarlılık	62.00%	Bazı pozitif tweetler kaçırılmış
Pozitif F1-Skoru	63.92%	Kabul edilebilir pozitif tespit
Toplam Uyum	164/199	82.41%
Toplam Uyumsuzluk	35/199	17.59%

*n=199

Analiz sonuçlarına göre model, genel doğruluk oranında 82.41% gibi yüksek bir başarı yakalamıştır. Özellikle negatif duyguların tespitinde sergilenen 88.37% F1-skoru, modelin kriz anındaki acı, korku ve acil ihtiyaç söylemlerini yakalamadaki üstün başarısını kanıtlamaktadır.



Şekil 6. BERTurk doğrulama karışıklık matrisi ve metrikleri

Şekil 6'da sunulan Karışıklık Matrisi (Confusion Matrix) verileri incelendiğinde, modelin tahminlerindeki doğruluk ve hata dağılımı şu şekilde gözlemlenmiştir:

- ✓ Gerçek Negatifler (133): Negatif duygulu tweetlerin 89.3%'ü doğru tanımlanmıştır.
- ✓ Gerçek Pozitifler (31): Pozitif duygulu tweetlerin 62.0%'si doğru saptanmıştır.

- ✓ Yanlış Pozitifler (16): Negatif olduğu halde pozitif olarak sınıflandırılan tweetler (10.7% hata oranı).
- ✓ Yanlış Negatifler (19): Pozitif olduğu halde negatif olarak etiketlenen tweetler (38.0% hata oranı).

Manuel doğrulama sonuçları, modelin negatif duygularda ($F1=88.37\%$) pozitif duygulara ($F1=63.92\%$) oranla daha yüksek performans sergilediği asimetrik bir tablo ortaya koymuştur. Bu durum, afet bağlamında olumsuz ifadelerin dilbilimsel olarak daha tutarlı ve sık; olumlu ifadelerin (şükran, umut) ise daha nadir ve değişken olmasından kaynaklanmaktadır. Bu performans profili, Türk sosyal medyası üzerine yapılan güncel çalışmalarla (Yıldırım, 2024; Köksal ve Özgür, 2021) tam uyum göstermekte ve modelin kriz bilişimi analizleri için bilimsel olarak geçerli olduğunu kanıtlamaktadır.

Ayrıca, modelin toplamda 164/199 oranında tam uzlaş sağlaması, elde edilen duygu analizi bulgularının tesadüfi olmadığını ve saha verilerini yüksek sadakatle yansıttığını göstermektedir.

Duygu analizi sürecinin teknik uygulama aşamaları, verilerin standardize edilmesi ve model konfigürasyonunun optimize edilmesiyle gerçekleştirilmiştir. Bu kapsamda, analiz kalitesini artırmak amacıyla 79.292 tweetlik külliyat üzerinde uygulanan veri hazırlama ve ön işleme adımları şu teknik süreçleri içermektedir:

- ✓ Lemmatizasyon: Kelime köklerinin doğru tespiti için Zeyrek Türkçe Lemmatizer kullanılmıştır.
- ✓ Normalizasyon: URL ve kullanıcı bahsetmelerinin (mention) kaldırılması, durdurma kelimelerinin elenmesi ve özel karakterlerin temizlenmesi süreçleri tamamlanmıştır.

BERTurk modelinin teknik yapılandırması, Hugging Face Transformers kütüphanesi (Python) aracılığıyla yürütülen işlem sürecinde, afet dönemi metinlerinin yoğunluğunu ve dilsel karmaşıklığını yönetmek üzere şu parametreler baz alınarak optimize edilmiştir:

- ✓ Maksimum Dizi Uzunluğu: 512 token (uzun metinler için kesme/truncation uygulanmıştır).
- ✓ İşlem Birimi: CPU üzerinde 100 tweetlik toplu iş (batch size) gruplarıyla işleme yapılmıştır.

- ✓ Çıktı Değişkenleri: Her bir tweet için ikili sınıflandırma (olumlu/olumsuz) ve 0.0-1.0 aralığında bir güven puanı üretilerek zamansal analizler için kaydedilmiştir.

Sağlık içerikli paylaşımların genel afet söylemine kıyasla daha belirgin bir olumsuz duygu yoğunluğu sergileyip sergilemediğini saptamak amacıyla kurgulanan hipotez testi kapsamında, tablo 18’de gösterildiği üzere tweetlerin sınıflandırılması ve istatistiksel analiz süreçleri bir bütün olarak yapılandırılmıştır.

Bu doğrultuda; sağlık hizmetleri, tıbbi malzemeler, acil servisler, savunmasız gruplar ve kronik hastalıklar gibi kritik alt kategorileri kapsayan 120 adet sağlık odaklı anahtar kelime üzerinden bir filtreleme yapılmış ve bu terimlerden en az birini içeren paylaşımlar “sağlık içerikli” olarak tanımlanmıştır. Elde edilen bu veriler üzerinden sağlıkla ilgili olan ve olmayan gruplar arasındaki duygu dağılım farkının istatistiksel anlamlılığını test etmek amacıyla Ki-Kare Bağımsızlık Testi uygulanmıştır.

Analiz çerçevesinde kurulan hipotezler şöyledir:

- ✓ Sıfır Hipotezi (H_0): Duygu dağılımı, tweetin sağlıkla ilgili olup olmamasından bağımsızdır.
- ✓ Alternatif Hipotez (H_1): Sağlık içerikli tweetler, genel külliyattan anlamlı derecede farklı (daha yoğun olumsuz) bir duygu dağılımı sergilemektedir.
- ✓ Anlamlılık Düzeyi: $\alpha = 0.05$ olarak belirlenmiştir.

Tablo 18. Sağlık duygu korelasyonu

Metrik	Değer
Toplam Tweet Sayısı	79.292
Sağlıkla İlgili Tweetler	40.378
Sağlıkla İlgili %	50.9%
Sağlıkla İlgili Olmayan Tweetler	38.914
Negatif % (Sağlık)	79.7%
Negatif % (Sağlık Dışı)	72.6%
Fark (yüzde puan)	+7.1
Ki-Kare	555.41
p-değeri	0.000000
Anlamlılık	Yüksek derecede anlamlı ($p < 0.001$)

4.3. Makine Öğrenimi Bulguları

Tablo 19’da sunulan bulgulara göre beş farklı makine öğrenimi modelinin karşılaştırmalı analizi sonucunda, Lojistik Regresyon %89.07 doğruluk oranı ile en yüksek performansı sergilemiştir. Modellerin eğitim sürecinde, veri setindeki sınıf dengesizliğini

gidermek amacıyla SMOTE dengeleme, özellik çıkarımı için TF-IDF ve sonuçların tutarlılığını sağlamak için 5-katlı çapraz doğrulama teknikleri uygulanmıştır (n=31.440 sağlık odaklı tweet, 6 kategori).

Tablo 19. Makine öğrenimi model karşılaştırma özeti*

Model	Doğruluk	Dengeli Doğ.	Kesinlik	F1-Skoru	Eğitim (s)
Lojistik Regresyon -- En İyi	%89.07	%87.86	%89.37	%89.17	159.6
Doğrusal SVM	%88.92	%87.55	%89.10	%88.98	3.0
Sinir Ağı (MLP)	%86.66	%83.83	%86.67	%86.65	199.2
Multinomial NB	%83.52	%81.71	%84.19	%83.73	1.7
Rastgele Orman	%79.48	%80.66	%86.25	%81.33	119.9

*n= 31.440

4.3.1. Veri Kümesi Hazırlama ve Dastest Kategorileri

Makine öğrenimi veri setinin oluşturulma süreci, BERTopic analiz sonuçlarından elde edilen çıktıların sistematik bir sınıflandırma çerçevesine dönüştürülmesiyle gerçekleştirilmiştir. Bu süreçte uygulanan metodolojik adımlar ve sınıflandırma hiyerarşisi aşağıda detaylandırılmış olup ve bu aşamasında, BERTopic tarafından belirlenen 59 farklı konu, yedi ana kategori altında yapılandırılmıştır. Bu kategoriler; altı adet sağlık odaklı başlık (Sağlık Hizmetleri, Altyapı, Anne ve Çocuk Sağlığı, İlaç ve Malzemeler, Ruh Sağlığı, Barınma ve Temel İhtiyaçlar) ve sağlıkla doğrudan ilişkili olmayan içerikler için tanımlanan bir “Alakasız” kategorisinden oluşmaktadır. Sınıflandırma süreci şu dört temel aşamada yürütülmüştür:

1. Keşif Aşaması (Denetimsiz Konu Modelleme): (LDA, K=5) ve BERTopic (59 konu) algoritmaları kullanılarak yapılan ilk keşifsel analizler, Türkiye’deki deprem sürecinde Twitter üzerinden paylaşılan sağlık temalarını gün yüzüne çıkarmıştır. BERTopic kümeleme yöntemi, 45.590 tweetlik veri kümesini kapsayan 59 farklı alt konu belirleyerek; barınma ihtiyaçları, ruh sağlığı ifadeleri, tıbbi kaynak talepleri ve altyapı endişeleri gibi kritik kalıpları başarıyla yakalamıştır.
2. Kategori Geliştirme: Keşifsel analiz bulguları ile uluslararası afet sağlığı çerçeveleri (The Sphere Project, 2018: 1-458; IASC, 2007: 1-456) sistematik olarak incelenmiştir. Bu inceleme sonucunda, yerleşik afet müdahale


standartlarına dayanan altı sağlık ihtiyacı kategorisi ve bir kontrol grubu (Alakasız) manuel olarak tanımlanmıştır (Şekil 7).

3. Konu Tabanlı Manuel Etiketleme Yaklaşımı: Tek tek tweetleri etiketlemek yerine, BERTopic kümeleme sonuçlarından yararlanan verimli bir konu tabanlı etiketleme stratejisi izlenmiştir. 59 konunun her birinden seçilen 10 temsili tweet (toplam 590 tweet) uzman görüşüyle incelenmiş ve her konu, baskın içeriğine göre yedi ana kategoriden birine atanmıştır. Etiketleme işlemi tamamlandıktan sonra, ilgili konuya dahil olan tüm tweetler o konunun kategori etiketini miras almış; böylece denetimli sınıflandırma için 45.590 tweetlik tamamen etiketlenmiş bir veri kümesi elde edilmiştir.

4. Denetimli Sınıflandırma ve Performans Değerlendirmesi: Oluşturulan etiketli veri kümesi; Lojistik Regresyon, Rastgele Orman (Random Forest), Naif Bayes, SVM ve Sinir Ağları gibi denetimli sınıflandırıcıları eğitmek için kullanılmıştır. Modeller, tabakalı 5 katlı çapraz doğrulama (5-fold cross-validation) yöntemiyle test edilmiş ve yedi kategorili sınıflandırma görevinde şu performans metriklerine ulaşılmıştır:

- ✓ Genel Doğruluk (Accuracy): %89
- ✓ Kesinlik (Precision): %87
- ✓ Duyarlılık (Recall): %88
- ✓ F1-Skoru: 0.87

Bu değerlendirme süreci, veri kümesinin yalnızca %4.2'sini oluşturan “Anne ve Çocuk Sağlığı” gibi azınlık kategorilerinde dahi dengeli bir performans sergileyerek, sağlık ihtiyaçlarının tüm alanlarında modelin güvenilirliğini kanıtlamıştır.



Şekil 7. ML veri kümesi kategori dağılımı

Kategori atamalarının tamamlanmasını müteakip, yapılan sistematik incelemeler sonucunda “Alakasız” (n=14.150, %17.9) olarak etiketlenen tweetler analiz dışı tutulmuş; sonuç olarak denetimli sınıflandırmaya uygun, 31.440 sağlık odaklı tweet içeren ve ayrıntıları Tablo 20’de sunulan nihai veri kümesi elde edilmiştir.

Tablo 20. ML veri kümesi öncesi ve sonrası karşılaştırması

Metrik	Önce (ilgisiz dahil)	Sonra (sadece sağlık)	Değişim
Toplam örnek sayısı	45.590	31.440	-14.150
Kategoriler	7	6	-1
Dengesizlik oranı	7.44:1	6.62:1	▼ 0.82
En geniş kategori	İlgisiz	Barınma Temel İhtiyaç	Değişti
En küçük kategori	Anne çocuk sağlığı	Anne çocuk sağlığı	Aynı

Elde edilen veri seti, afet dönemindeki sağlık endişelerinin hacimsel farklılıklarını yansıtacak şekilde belirgin bir sınıf dengesizliği sergilemektedir. Barınma ve Temel İhtiyaçlar kategorisi örneklemin %32.0’sini (n=10.073) oluştururken, Anne ve Çocuk Sağlığı kategorisi yalnızca %4.8 (n=1.521) düzeyinde kalmıştır; bu durum, en büyük ve en


küçük sınıflar arasında 6.62:1 oranında bir dengesizlik yaratmıştır. Bu sayısal eşitsizlik, kriz anlarında Twitter üzerindeki toplumsal önceliklerin ve ihtiyaç türlerinin doğal dağılımını yansıtmaktadır.

Modelin genellenebilirliğini sağlamak ve aşırı öğrenmeyi (overfitting) önlemek amacıyla, nihai veri kümesi 80/20 oranında eğitim ve test kümelerine ayrılmıştır. Bölünme sırasında, her iki kümenin de orijinal sınıflardaki dağılım oranlarını (tabakalaşma) koruması için tabakalı rastgele örnekleme (stratified random sampling) yöntemi kullanılmış ve tutarlılık adına (random_state=42) parametresi sabitlenmiştir. Bölünme detayları Tablo 21 ve Şekil 8’de görselleştirildiği üzere şu şekildedir:

- ✓ Eğitim Seti: 25.152 belge (%80)
- ✓ Test Seti: 6.288 belge (%20)

Tablo 21. Eğitim-test bölünme dağılımı

Kategori	Orijinal Sayı	Orijinal Yüzde	Eğitim Seti Sayısı	Eğitim Seti Yüzdesi	Test Seti Sayısı	Test Seti Yüzdesi	Dengesizlik Oranı
Kategori	2972	9.452926209	2378	9.454516539	594	9.446564885	4.235912532
Sağlık Hizmetleri	3077	9.786895674	2462	9.788486005	615	9.780534351	4.091389115
Altyapı	1902	6.049618321	1521	6.047232824	381	6.059160305	6.6226167
Anne ve Çocuk Sağlığı	5408	17.20101781	4326	17.19942748	1082	17.20737913	2.328478964
Tıbbi Malzemeler	5490	17.46183206	4392	17.46183206	1098	17.46183206	2.29348816
Ruh Sağlığı	12591	40.04770992	10073	40.04850509	2518	40.04452926	1



Şekil 8. Eğitim-test bölünme analizi

4.3.2. TF-IDF ile Özellik Çıkarma

Metin özellikleri, Terim Sıklığı-Ters Belge Sıklığı (TF-IDF) vektörleştirme kullanılarak çıkarıldı. TF-IDF, kelimelere, tüm metin kümesinde sıklıklarına göre tek tek belgelerdeki sıklıklarına göre ağırlık atar ve böylece her kategori için en ayırt edici terimleri etkili bir şekilde belirler. Vektörleştirici, maksimum 5.000 özellik, unigram ve bigram n-gramlar (1,2), minimum belge sıklığı 2 ve sublineer TF ölçekleme ile yapılandırılmıştır.

4.3.3 SMOTE ile Sınıf Dengesizliği Yönetimi

Önemli sınıf dengesizliği (6.62:1 oranı) Sentetik Azınlık Aşırı Örnekleme Tekniği (SMOTE) kullanılarak ele alınmıştır. SMOTE, mevcut azınlık sınıfı örnekleri ile özellik uzayındaki en yakın komşuları arasında enterpolasyon yaparak azınlık sınıfları için sentetik örnekler oluşturur.

Bu çalışmada, sağlıkla ilgili tweet sınıflarının dağılımında önemli bir dengesizlik gözlemlenmiştir. Anne ve Çocuk Sağlığı, Kronik Hastalıklar ve Ruh Sağlığı gibi belirli sağlık kategorilerinin, Acil Tıbbi Hizmetler veya İlaçlar ve Tıbbi Malzemeler gibi daha yaygın sınıflara kıyasla önemli ölçüde daha düşük temsil oranına sahip olduğu belirlenmiştir. Bu durum, denetimli makine öğrenimi modellerinin çoğunluk sınıflarına karşı önyargı sergilemesine ve azınlık sınıflarının sistematik olarak yanlış sınıflandırılmasına yol açabilir.

Bu sınıf dengesizliğini gidermek için, metin verilerinin vektör temsili için TF-IDF yaklaşımı kullanılmış, ardından SMOTE (Synthetic Minority Over-sampling Technique) yöntemi uygulanmıştır (Chawla vd., 2002: 328-331). SMOTE geleneksel olarak sayısal veri uzaylarında kullanılan bir örnekleme tekniği olmakla birlikte, TF-IDF gibi sayısal ve yüksek boyutlu vektör uzaylarında da uygulanabilir (Wu vd., 2024: 3-4). Bu çalışmada SMOTE'nin seçilmesinin ana nedeni, azınlık sınıflarına ait örneklerin özellik uzayında daha iyi temsil edilmesini sağlayarak sınıflandırma modellerinin bu sınıflara duyarlılığını artırmaktır.

Alternatif bir yaklaşım olarak, birçok sınıflandırma algoritması tarafından sunulan `class_weight` parametresi de değerlendirilmiştir. `Class_weight` yöntemi, azınlık sınıflarının yanlış sınıflandırılmasına daha yüksek bir ceza atayarak modelin öğrenme sürecini ağırlıklandırır. Ancak, bu yaklaşım veri dağılımını doğrudan dengelemek yerine yalnızca karar sınırlarını ayarlar ve özellikle çok sınıflı, anlamsal olarak örtüşen metin kategorilerinde sınıflar arasındaki ayrımı yeterince güçlendirmeyebilir.

Bu çalışmada SMOTE'nin tercih edilmesinin ana nedenleri şu şekilde özetlenebilir:

- i. Azınlık sınıflarına ait sağlık söylemlerini özellik alanında daha görünür hale getirmek,


- ii. Sınıflandırma performansını yalnızca genel doğruluk açısından değil, aynı zamanda sınıfa dayalı metrikler (özellikle F1 puanı) aracılığıyla da iyileştirmeyi hedeflemek,
- iii. Sağlık kategorileri arasında yüksek dilbilimsel ve anlamsal örtüşme olması nedeniyle, modelin karar sınırlarını sadece ağırlıklandırma yoluyla değil, aynı zamanda veri temsil düzeyinde de güçlendirmenin gerekli olduğu düşünülmektedir.

Bu bağlamda, metin tabanlı sağlık ihtiyaçlarının sınıflandırılmasında operasyonel performansı artıran ve yeterince temsil edilmeyen sağlık kategorilerinin görünürlüğünü artıran bir yöntem olarak TF-IDF + SMOTE kombinasyonu tercih edilmiştir. Ancak, SMOTE'nin metin verileri üzerindeki potansiyel sınırlamaları göz önüne alınarak, model performansı sınıf tabanlı metrikler kullanılarak ayrıntılı olarak raporlanmış ve sonuçlar dikkatle yorumlanmıştır.

Ardından SMOTE uygulamasının ardından, eğitim seti 25.152'den 60.438 örneğe genişledi ve her kategori tam olarak 10.073 örnek içeriyordu (mükemmel 1.00:1 denge). Test seti, gerçekçi veri dağılımı üzerinde model performansını değerlendirmek için orijinal dengesiz yapısında korunmuş; bu süreçte dair sayısal dağılım verileri ve görsel karşılaştırmalar ise Tablo 22 ve Şekil 9 içerisinde detaylandırılmıştır.

Tablo 22. SMOTE uygulama ayrıntıları

Kategori	SMOTE Öncesi	SMOTE Öncesi Yüzde	SMOTE Sonrası	SMOTE Sonrası Yüzde	Üretilen Sentetik Veri	Sentetik Veri Sınıf Yüzdesi	Test Veri Sayısı	Test Veri Yüzdesi
Sağlık Hizmetleri	2378	9.45%	10073	16.67%	7695	76.4%	594	9.45%
Altyapı	2462	9.79%	10073	16.67%	7611	75.6%	615	9.78%
Anne ve Çocuk Sağlığı	1521	6.05%	10073	16.67%	8552	84.9%	381	6.06%
Tıbbi Malzemeler	4326	17.20%	10073	16.67%	5747	57.1%	1082	17.21%
Ruh Sağlığı	4392	17.46%	10073	16.67%	5681	56.4%	1098	17.46%
Barınma ve Temel İhtiyaçlar	10073	40.05%	10073	16.67%	0	0.0%	2518	40.04%



Şekil 9. Özellik çıkarma ve SMOTE analizi

4.3.4. Model Seçimi, Eğitim ve Değerlendirme Metrikleri

Araştırma kapsamında, sağlık odaklı tweetlerin sınıflandırılması için beş farklı makine öğrenimi algoritması eğitilmiş ve performansları karşılaştırılmıştır: Lojistik Regresyon, Doğrusal Destek Vektör Makinesi (SVM), Rastgele Orman (Random Forest), Çok Terimli Naif Bayes (Multinomial NB) ve Çok Katmanlı Perceptron (Sinir Ağı - MLP). Her bir model, SMOTE ile dengelenmiş eğitim seti (60.438 örnek) üzerinde eğitilmiş; ardından modellerin gerçek dünya koşullarındaki başarısını simüle etmek amacıyla orijinal dengesiz yapıdaki test seti (6.288 örnek) üzerinde değerlendirilmiştir.

- ✓ Lojistik Regresyon: L2 düzenleme, lbfgs çözücü, max_iter=1000, multi_class='multinomial'
- ✓ Doğrusal SVM: squared_hinge kaybı ile LinearSVC, max_iter=2000
- ✓ Rastgele Orman: 100 ağaç, max_depth=20, min_samples_split=5, random_state=42

- ✓ Multinomial Naive Bayes: alpha=1.0 (Laplace yumuşatma)
- ✓ Sinir Ağı: İki gizli katmanlı (100, 50) MLPClassifier, relu aktivasyonu, adam optimizier, alpha=0.0001

Eşitlikte gösterildiği üzere; sınıflandırma performansını bütüncül bir perspektifle analiz etmek amacıyla beş temel metrik kullanılmıştır: Doğruluk (genel doğru tahmin oranı), Dengeli Doğruluk (sınıf dengesizliğini hesaba katan düzeltilmiş metrik), Kesinlik (pozitif öngörü değeri), Duyarlılık (yakalama oranı) ve bu iki değer harmonik ortalaması olan F1-Skoru. Bu metrikler, özellikle azınlık sınıfların (örneğin Anne ve Çocuk Sağlığı) doğru temsil edilip edilmediğini denetlemek için kritik birer gösterge olarak kabul edilmiştir.

$$\text{Doğruluk} = \frac{TP + TN}{TP + TN + FP + FN} \quad (\text{Eşitlik 1})$$

$$\text{Kesinlik} = \frac{TP}{TP + FP} \quad (\text{Eşitlik 2})$$

$$\text{Geri çağırma} = \frac{TP}{TP + FN} \quad (\text{Eşitlik 3})$$

$$F1 = 2 * \frac{\text{Precision} * \text{Recall}}{\text{Precision} + \text{Recall}} \quad (\text{Eşitlik 4})$$

Burada TP = Doğru Pozitifler, TN = Doğru Negatifler, FP = Yanlış Pozitifler, FN = Yanlış Negatifler.

F1 puanı, Hassasiyet ve Geri Çağırma'nın harmonik ortalamasıdır.

Denklem (1, 2, 3, 4): Doğruluk, Hassasiyet, Geri Çağırma (URL-12, 2026) ve F1 puanı (URL-13, 2025).

4.4. Sağlıkla İlgili LDA Konu Modellemesi


Bu alt bölümde; LDA yöntemiyle tespit edilen konuların WHO/SPHERE standartları ile olan tematik uyumu detaylandırılmaktadır. Sağlık ihtiyaçları, Tablo 23'te sunulduğu üzere afet yönetiminin üç temel aşaması kapsamında analiz edilmiştir: Akut acil dönem (0-3 gün), halk sağlığı geçiş evresi (4-14 gün) ve barınma/İyileşme süreci (15-59 gün).

Tablo 23. LDA sađlık konularının who/sphere standartlarıyla uyumu

LDA Konusu	SPHERE Standardı	Uyum	Zamansal Zirve
K0: İnsani Yardım Koordinasyonu	IASC koordinasyon standartları	Yüksek	0-3. gün (%46.64)
K3: Halk Sağlığı / WASH	SPHERE WASH minimum standartları	Yüksek	7. gün (b=0.3326)
K1: Acil Tıbbi / Arama Kurtarma	SPHERE sađlık hizmetleri	Yüksek	0-3. gün (%13.37)
K4: Geçici Barınma	SPHERE barınma standartları	Yüksek	21. gün (%17.8)
K2: Afet Yönetimi	Sendai Çerçevesi / AFAD	Orta	Uzun dönem

K=5 konu ile optimize edilmiş LDA modeli, güçlü performans ölçütleri elde etti; 0.4267'lik tutarlılık puanı (C_v) anlamsal tutarlılığı gösterirken, - 9.989'luk perplexity kabul edilebilir istatistiksel uyumu gösteriyor. K=5'te her iki ölçütün yakınsaması, bu yapılandırma ve tez konularının yerleşik afet müdahale çerçeveleriyle (WHO Acil Tıp Ekipleri, SPHERE İnsani Yardım Standartları) tutarlı bir şekilde uyumlu olduğunu gösteren ampirik bir gerekçe sunarak, modelin deprem sonrası sađlık ihtiyaçlarının temel tematik yapısını başarıyla yakaladığını göstermektedir. Belge kapsamı 78.871 tweet'e (önceden işlenmiş metin kümesinin %99.47'si) ulaşarak sosyal medya söyleminin kapsamlı bir şekilde temsil edilmesini sağlamıştır.

Analiz edilen veri kümesindeki temel temaların yoğunluğunu yansıtan Şekil 10, beş konuya göre belgelerin dağılımını göstermektedir. Konu 0 (insani yardım koordinasyonu), analiz edilen toplam tweetlerin %46.64'ünü (36.787 belge) oluşturarak ana konu olarak ortaya çıkmaktadır. Bu dağılım, depremle ilgili sosyal medya söyleminin neredeyse yarısının, ihtiyaçların doğrudan ifade edilmesinden ziyade örgütsel koordinasyon, lojistik operasyonlar ve insani yardım faaliyetlerine odaklandığını göstermektedir. Koordinasyona odaklanan içeriğin baskınlığı, gerçek zamanlı ihtiyaç değerlendirme sistemleri için önemli sonuçlar doğurmaktadır, zira bu durum, sađlık ihtiyaçları ile ilgili doğrudan iletişimin daha geniş örgütsel söylem içinde sulandırılabilceğini göstermektedir.



Şekil 10. LDA konu dağılımı

Kalan dört konu, her biri metnin %12-15'ini oluşturarak nispeten dengeli bir dağılım göstermiştir:

Konu 3 (halk sağlığı temel ihtiyaçları): %14.94 (11.780 tweet)

Konu 1 (Tıbbi Acil Durumlar/Arama ve Kurtarma): %13.37 (10.546 tweet)

Konu 4 (Geçici Barınma): %12.99 (10.244 tweet)

Konu 2 (Afet Yönetimi): %12.06 (9.514 tweet)

Sağlıkla ilgili konular (Konu 1, 3 ve 4) arasında nispeten eşit dağılım, deprem sonrası sağlık ihtiyaçlarının tek bir sağlık kategorisine yoğunlaşmak yerine, kamuoyunun benzer düzeyde ilgi gösterdiği birçok alanı kapsadığını göstermektedir. Ancak, toplu analiz, afet aşamalarında sağlık ihtiyaçlarının nasıl geliştiğini ortaya koyan önemli zamansal dinamikleri gizlemektedir.

4.4.1. Sağlıkla İlgili Konu Sınıflandırması ve Analizi

Sağlıkla ilgili konuların sistematik sınıflandırması; depremle ilgili tweetlerin %28.31'inin (22.326 belge) doğrudan sağlık ihtiyaçlarını ele aldığını ve bu ihtiyacın iki ana tematik ekseninde yoğunlaştığını ortaya koymuştur. Sosyal medya söyleminin geri kalan %71.69'luk (56.545 belge) bölümü ise sağlığı destekleyen lojistik ve altyapısal süreçleri temsil etmektedir.

1. Doğrudan sağlık konuları (külliyatın %28.31'i) doğrudan sağlık müdahalesi talep eden veya raporlayan iletiler iki temel kategoride toplanmıştır:
 - ✓ Acil Tıbbi Hizmetler ve Arama Kurtarma (Konu 1 - %13.37): 10.546 tweetten oluşan bu küme; krizin ilk 0-72 saatlik kritik diliminde hayat kurtarıcı müdahalelere, travma bakımına ve acil tıbbi stabilizasyon süreçlerine odaklanmıştır.
 - ✓ Halk sağlığı temelleri (Konu 3 - %14.94): 11.780 tweetlik bu grup; su, sanitasyon ve hijyen (WASH), gıda güvenliği ve acil barınakların hijyenik koşulları gibi koruyucu sağlık hizmetlerini kapsamaktadır.
2. Dolaylı sağlık konuları (Külliyatın %71.69'u) Doğrudan sağlık hizmeti teşkil etmese de, sağlık sonuçlarını doğrudan etkileyen altyapısal ve sosyal belirleyiciler şu şekilde dağılmıştır:
 - ✓ İnsani yardım koordinasyonu (Konu 0 - %46.64): Operasyonel koordinasyon altyapısı.
 - ✓ Afet yönetimi (Konu 2 - %12.06): Malzeme tedarik zinciri ve lojistik.
 - ✓ Geçici barınma (Konu 4 - %12.99): Sağlığın sosyal belirleyicisi olarak barınma ihtiyacı.

Bu sınıflandırma, stratejik bir bulguyu açığa çıkarmaktadır: Doğrudan sağlık içeriği sosyal medya söyleminin nispeten küçük bir kısmını (%28.31) oluştursa da; acil tıbbi müdahale ve halk sağlığı gibi iki kritik hayati alanı temsil etmektedir. Bu da, etkilenen nüfusların ve müdahale eden kuruluşların sağlık ihtiyaçlarını tekil mesajlar yerine; çok katmanlı temalar ve koordinasyon ağları üzerinden ilettiklerini, dolayısıyla sağlık odaklı bir kriz yönetiminin bu “dolaylı” kategorileri de kapsayacak bir bütüncüllükle yürütülmesi gerektiğini kanıtlamaktadır.

4.4.2. Sağlık İhtiyaçları Kategorileri ve WHO/SPHERE Uyumu

LDA çıktısı olan konular yerleşik sağlık çerçeveleriyle eşleştirildiğinde; (WHO) Acil Tıp Ekibi (EMT) sınıflandırmaları ve SPHERE İnsani Yardım Standartları ile tam bir uyum saptanmıştır. Bu paralellik, sosyal medya verilerinin profesyonel afet yönetimi terminolojisiyle tutarlılığını kanıtlamaktadır:

1. Acil Tıbbi Müdahale (Konu 1 - %13.37)

2. Halk Sağlığı Altyapısı (Konu 3 - %14.94)

Acil Tıbbi Müdahale (Konu 1 - %13.37), teması; “acil” ($\beta=0.0562$), “kurtarma” (kurtarma, $\beta=0.0314$) ve “arama” (arama, $\beta=0.0251$) anahtar kelime kümesiyle karakterize edilmektedir. Bu sözcük dağarcığı, WHO EMT Tip 1 Mobil yetenekleri olan; ayakta acil bakım, temel travma yönetimi, tıbbi stabilizasyon ve arama-kurtarma faaliyetleriyle doğrudan eşleşmektedir. Anahtar kelimelerdeki coğrafi özgülük (“Kahramanmaraş” $\beta=0.0357$, “Hatayda” $\beta=0.0344$), yapısal yıkımın yoğunlaştığı merkez üssü bölgelere yönelik acil tıbbi müdahale ihtiyacını somutlaştırmaktadır.

Konu 1’deki maksimum β ağırlığı (0.0562), diğer konuların zirve değerlerine (aralık: 0.1328-0.3326) kıyasla düşük kalması; acil tıbbi müdahale söyleminin dar bir terminoloji yerine çok katmanlı bir kelime grubuyla ifade edildiğini göstermektedir. Bu dilbilimsel yapı; triyaj, travma stabilizasyonu, tıbbi tahliye ve sahra hastanesi koordinasyonu gibi operasyonel süreçlerin çeşitliliğini ve bu süreçlerin her birinin farklı kavramsal setlerle ifade edildiğini yansıtmaktadır.

Halk sağlığı altyapısı (Konu 3 - %14.94), özellikle hijyen teması üzerinde olağanüstü bir anlamsal yoğunluk sergilemektedir. “Hijyen” kelimesi, ($\beta=0.3326$) değeriyle tüm konular arasındaki en yüksek olasılık skoruna ulaşmıştır. Bu değer, konunun toplam olasılık kütesinin üçte birini tek başına temsil etmekte ve en yakın rakibi olan “gıda” (“gıda”, $\beta=0.0872$) kelimesinden 3.8 kat daha baskındır. Diğer konulardaki en yüksek ağırlıkların $\beta=0.0562$ (Konu 1) ile $\beta=0.2096$ (Konu 2) arasında değiştiği göz önüne alındığında, Konu 3’teki bu yoğunlaşma istatistiksel olarak olağanüstü bir halk sağlığı alarmına işaret etmektedir.

Hijyen odaklı bu içerik, deprem sonrası altyapı hasarı ile halk sağlığı risklerinin kritik kesişimini yansıtmaktadır. Kahramanmaraş merkezli depremlerin su ve sanitasyon (WASH) sistemlerinde yol açtığı yaygın tahribat, geçici yerleşim alanlarındaki nüfus yoğunluğuyla birleşerek hijyen endişelerini zirveye taşımıştır. WHO risk değerlendirmeleriyle paralel olarak; yetersiz WASH altyapısı, afet sonrası süreçte ishal, solunum yolu enfeksiyonları ve vektör kaynaklı hastalıkların temel tetikleyicisi olarak bu veride karşılık bulmaktadır.

Ayrıca, ($\beta=0.0872$), “yemek” ($\beta=0.0446$) ve “sıcak” ($\beta=0.0224$) anahtar kelimeleri beslenme ihtiyacını; “seyyar” (mobil, $\beta=0.0202$) kelimesi ise altyapısı hasar görmüş bölgelerdeki mobil hizmet birimlerine duyulan ihtiyacı vurgulamaktadır. “Barınma”

(barınak, $\beta=0.0235$) teriminin bu kümede yer alması, kullanıcıların hijyen, gıda ve barınak arasındaki ayrılmaz bağı fark ettiklerini; bu üç unsurun SPHERE Standartları'nda tanımlanan “insan onuruna uygun hayatta kalma” prensibinin temel taşları olduğunu göstermektedir (Sphere Association, 2018).

4.4.3. Sağlık Konularının Zamansal Evrimi

Deprem sonrası zaman çizelgesinde konu yaygınlığının analizi, afet müdahale aşamalarındaki ilerlemeyi yansıtan belirgin zamansal modeller ortaya koymaktadır:

Aşama 1 (0-3. günler, 6-9 Şubat): Konu 1 (acil tıbbi yardım/arama kurtarma) deprem sonrası ilk 72 saatte en yüksek yaygınlığa ulaşmış ve 7 Şubat'ta (2. gün) günlük tweetlerin %18.2'sini oluşturmuştur. Bu oran, genel metin yaygınlığının %13.37'sine karşılık gelmektedir. Bu zamansal yoğunlaşma, başarılı kurtarmaların çoğunun ilk 72 saat içinde gerçekleşmesine rağmen, çok sayıda kurtulan kişinin 48 saatten sonra kurtarıldığını belirten INSARAG kılavuzlarıyla uyumludur (Macintyre vd., 2006: 7-14). 3. günden sonra Konu 1'in yaygınlığındaki keskin düşüş (10 Şubat'ta %9.1'e düşüş), çöken yapılarda hayatta kalma olasılığının sıfıra yaklaşmasıyla arama ve kurtarma operasyonlarından sürekli tıbbi bakıma geçişi yansıtmaktadır.

Aşama 2 (4-14. günler, 10-20 Şubat): Konu 3 (halk sağlığı temelleri) ilk iki hafta boyunca sürekli bir artış göstermiş ve günlük yaygınlık oranı %14.94 olan korpus ortalamasına kıyasla %16-18 arasında kalmıştır. Yaygınlığın zirveye ulaştığı gün 7. gün (13 Şubat) olup, %19.3 ile SPHERE standartlarında belirlenen WASH müdahalesi için kritik dönemle çakışmaktadır: “Hastalık salgınlarını önlemek için 72 saat içinde yeterli WASH sağlanmalıdır” (Sphere Association, 2018). Acil durum aşamasının ötesinde (7-14. günler) hijyene sürekli olarak dikkat edilmesi, sanitasyon altyapısı eksikliklerinin iyileşme döneminde de devam ettiğinin farkında olunduğunu göstermektedir.

Aşama 3: (15-30. günler, 21 şubat-8 mart): konu 4 (geçici barınma) %11.2'den (5. gün) %17.8'e (21. gün, 27 Şubat) kademeli bir artış göstererek acil barınaktan geçici yerleşim yerlerinin kurulmasına geçişi yansıtmaktadır. Bu zamansal model, tedarik zincirlerinin istikrar kazanmasıyla konteyner barınakların kurulması için tipik olarak 2-4 haftalık zaman çizelgesiyle uyumludur. Acil tıbbi ve hijyen konularındaki önceki zirvelere kıyasla, barınma ile ilgili söylemlerin zirveye ulaşmasının gecikmesi, afet müdahalesi

önceliklerinin sıralı doğasını göstermektedir: acil hayat kurtarma, hastalık önleme, dayanıklı barınak.

Afet müdahale sürecinin kronolojik seyri aşamalar arası örüntüler perspektifiyle incelendiğinde, Konu 0 (İnsani yardım koordinasyonu) tüm aşamalarda nispeten sabit bir yaygınlık (45-48%) korumuş olup, bu da organizasyonel koordinasyon söyleminin afet müdahalesi zaman çizelgesi boyunca sabit bir arka plan olarak devam ettiğini göstermektedir. Konu 2 (afet yönetimi) %10.1'den (2. gün) %14.2'ye (30. gün) kademeli bir artış göstermiş olup, bu da akut müdahaleden sürdürülebilir lojistik operasyonlara geçişi yansıtmaktadır.

4.4.4. Sağlık Konularının Coğrafi Dağılımı

Sağlık konularının coğrafi dağılımı üzerine yapılan analizler, depremde etkilenen bölgelerin ihtiyaç profillerinde belirgin mekansal farklılıklar olduğunu ortaya koymuştur. Depremi merkez üssü konumundaki Kahramanmaraş ve Hatay illeri, özellikle Konu 1 (Acil Tıp) ve Konu 3 (Halk Sağlığı) temalarında yoğun bir coğrafi kümelenme sergilemiştir. Konu 1 içerisinde “Kahramanmaraş” ($\beta=0.0357$) ve “Hatayda” (Hatay’da, $\beta=0.0344$) kelimelerinin en yüksek ağırlıklı ilk beş anahtar kelime arasında yer alması, acil tıbbi söylemin yapısal hasarın ve can kaybının en yoğun olduğu bölgelere kilitlendiğini kanıtlamaktadır. Özellikle Hatay ilinin Konu 3 (Halk Sağlığı) içerisindeki belirgin varlığı ($\beta=0.0683$), bölgedeki geçici yerleşim alanlarında yoğunlaşan nüfusun su, sanitasyon ve hijyen (WASH) altyapısındaki kritik tahribatı yansıtmaktadır.

Zamansal ve coğrafi etkileşimler incelendiğinde ise Hatay’ın, halk sağlığı ihtiyaçları açısından Kahramanmaraş’a kıyasla daha gecikmeli bir zirve noktasına (9. gün vs. 6. gün) ulaştığı gözlemlenmiştir; bu durum, lojistik imkanların ve WASH altyapısının afet bölgelerine farklı zaman dilimlerinde ulaşmasıyla ilişkilendirilmektedir. Buna karşın, merkez üssüne kıyasla daha orta dereceli hasar alan Gaziantep ve Malatya gibi illerin Konu 0 (Koordinasyon) ve Konu 2 (Malzeme Yardımı) temalarında daha yüksek göreceli yaygınlık göstermesi, bu bölgelerin stratejik olarak daha ağır hasarlı illere yönelik yardım operasyonlarında kritik lojistik merkezler ve dağıtım üsleri olarak işlev gördüğünü duygu ve içerik bazlı verilerle doğrulamaktadır.

4.4.5. Sağlık İhtiyacı Yorumlaması ile Ayrıntılı Konu Analizi

Halk sağlığı temelleri - kritik hijyen eksikliği (Konu 3) hijyen temasına yönelik sergilediği aşırı yoğunlaşma ($\beta=0.3326$; konu olasılığının %33.26'sı), WASH (Su, Sanitasyon ve Hijyen) altyapısındaki eksikliklerin deprem sonrası sosyal medya söylemlerinde ifade edilen en birincil halk sağlığı sorunu olduğunu kanıtlamaktadır. Bu bulgu yalnızca tanımlayıcı bir veri olmanın ötesinde, sahadaki acil ihtiyaçlar ile mevcut hizmet sunumu arasında kritik bir uçurumun varlığını ampirik olarak ortaya koymaktadır. Özellikle hijyen ($\beta=0.3326$) ve gıda güvenliği ($\beta=0.0872$) anahtar kelimeleri arasındaki 3.8 katlık oran; etkilenen nüfusun ve müdahale ekiplerinin sanitasyon sorununu gıda temininden çok daha kritik veya yetersiz bir alan olarak algıladığını göstermektedir. Bu önceliklendirme, halk sağlığı kanıtlarıyla tam bir uyum içerisindedir; nitekim gıda yardımı önceden planlanmış stoklar ve lojistik ağlar üzerinden hızla mobilize edilebilirken, WASH altyapısının restorasyonu hasar görmüş fiziksel sistemlerin yeniden inşasını gerektirmekte ve bu gecikme hastalık bulaşma risklerinin tırmandığı tehlikeli bir kırılganlık dönemi yaratmaktadır.

Sağlık etkileri açısından hijyen söyleminin bu denli öne çıkması, afet sonrası literatürde (Watson vd., 2007: 1-5) belgelenmiş olan ve genellikle ilk 2-3 hafta içinde yetersiz hijyen koşullarında ortaya çıkan ishal salgınları riskiyle doğrudan örtüşmektedir. Bu kümedeki “hijyen”, “gıda”, “sıcak yemek” ve “barınma” gibi anahtar kelimeler; enfeksiyonların önlenmesi, bağışıklığın korunması ve patojen maruziyetinin azaltılması gibi süreçleri kapsayan doğrudan bir hastalık önleme zincirine karşılık gelmektedir.

Müdahaleye yönelik pratik çıkarımlar açısından bu olağanüstü ağırlık ($\beta=0.3326$), dijital gözetim mekanizmaları için stratejik bir gösterge niteliği taşımaktadır. Sosyal medya izleme sistemlerinin afet sonrası karşılanmamış ihtiyaçları saptamak adına WASH parametrelerini bir “erken uyarı göstergesi” olarak önceliklendirmesi gerektiğini kanıtlayan bu tablo; sağlık otoriteleri için etkilenen bölgelerde hızlı WASH değerlendirmesi yapılması, mobil sanitasyon birimlerinin ve hijyen kitlerinin bölgeye sevki ile salgın hastalık önleme mesajlarının yaygınlaştırılması gibi operasyonel adımlar için somut bir tetikleyici işlevi görmelidir.

Acil tıbbi hizmetler - dağıtılmış kelime dağılımının (Konu 1) diğer temalara kıyasla sergilediği nispeten düşük maksimum β ağırlığı (0.0562), acil tıbbi söylemde yoğunlaşmış

tekil bir terminoloji yerine oldukça çeşitli ve dağıtılmış bir kelime dağarcığının kullanıldığını kanıtlamaktadır. Bu dilbilimsel model, acil tıbbi ihtiyaçların tek bir müdahale türüne odaklanmak yerine çok yönlü ve heterojen bir yapıya sahip olduğunu göstermesi bakımından önemli analitik çıkarımlar barındırmaktadır. “Acil”, “kurtarma”, “arama” ve “vatandaşlarımıza” gibi anahtar kelimelerden oluşan küme; arama-kurtarma operasyonlarından travma bakımına, tıbbi tahliyeden hükümetin kriz iletişimine kadar pek çok acil durum fonksiyonunu kapsamaktadır. Konu 3’ün hijyen odaklı yüksek yoğunlaşmasının aksine Konu 1; travmatik yaralanmalar, ezilme sendromu ve çevresel maruziyet gibi farklı yaralanma türlerinin eş zamanlı yönetimini, ambulans servislerinden sahra hastanelerine kadar çok sayıda kurumun koordinasyonunu ve hizmet mevcudiyeti hakkındaki kitlesel iletişimi yansıtan karmaşık bir acil tıbbi ekosistemi temsil etmektedir.

Çalışmanın sağlık etkileri açısından ulaştığı bulgular incelendiğinde; anahtar kelimelerin sergilediği coğrafi özgüllük (“Kahramanmaraş” $\beta=0.0357$, “Hatay” $\beta=0.0344$), acil tıbbi terminoloji ile birleşerek kritik ihtiyaçların bina yıkımlarının ve can kayıplarının en yoğun olduğu merkez üssü bölgelerinde kümелendiğini ortaya koymaktadır. Öte yandan, tek bir baskın anahtar kelimenin bulunmadığı bu heterojen yapı, sosyal medya kullanıcılarının ve kuruluşlarının tek bir önceliğe saplanıp kalmak yerine acil tıbbi gereksinimleri çok boyutlu bir perspektifle tartıştıklarını göstermektedir. Bu durum metodolojik bir uyarıyı da beraberinde getirmektedir: Yalnızca anahtar kelime sıklığına dayanan konu modelleri, tek bir terimin söylemi domine etmediği bu tür durumlarda acil tıbbi ihtiyaçların gerçek hacmini hafife alabilir; bu nedenle analizlerde tekil ağırlıklar yerine terimlerin oluşturduğu anlamsal ağ dikkate alınmalıdır.

Müdahaleye yönelik pratik sonuçlar açısından ise acil tıbbi ihtiyaçların tespiti için kurgulanacak gerçek zamanlı sosyal medya izleme sistemlerinin, tekil terimli uyarılar yerine çok boyutlu anahtar kelime arama stratejilerini benimsemesi gerektiği görülmektedir. “Acil”, “kurtarma”, “arama” ve coğrafi tanımlayıcıların kombinasyonu, tek bir terimden çok daha güvenilir bir tıbbi ihtiyaç sinyali üretmektedir. Ek olarak, bu konunun afet sonrası ilk 72 saatte sergilediği yoğunlaşma (2. günde %18.2’lik zirve), acil tıbbi protokollerde vurgulanan kritik zaman aralığını doğrulamakta ve dijital izleme faaliyetlerinin arama-kurtarma operasyonlarının tamamlanıp sürekli tıbbi bakıma geçiş sürecinde erken göstergeler sağlayabileceğini kanıtlamaktadır.

Geçici barınma - sağlığın sosyal belirleyicileri (Konu 4) kapsamında yapılan analizler, “çadır” ($\beta=0.1936$) ve “büyük” ($\beta=0.1337$) gibi anahtar kelimelerin yüksek ağırlığı üzerinden, kamuoyu gündeminin bireysel barınma taleplerinden ziyade organize ve geniş ölçekli geçici yerleşim çözümlerine odaklandığını kanıtlamaktadır. Bu durum, afet yönetiminde sadece hayatta kalma odaklı acil barınma evresinin ötesine geçilerek, altyapı destekli ve planlı geçici yerleşim sistemlerine duyulan ihtiyacın dijital verilerdeki somut izdüşümüdür. Bu barınma odaklı tema içerisinde “beslenme” (beslenme, $\beta=0.0292$), “sosyal” (sosyal, $\beta=0.0324$) ve “depresyonda” (depresyon mağduru, $\beta=0.0380$) kelimelerinin bir arada kullanımı, sosyal medya kullanıcılarının ve kuruluşlarının barınmayı yalnızca fiziksel bir koruyak değil, aynı zamanda sağlığın en temel sosyal belirleyicilerinden biri olarak kavradıklarını göstermektedir. Bu entegre bakış açısı; aşırı kalabalıklaşmanın solunum yolu enfeksiyonlarını tetiklediği, yetersiz WASH koşullarının ishal hastalıklarına yol açtığı ve kronik stresin ruh sağlığı bozukluklarını artırdığı yönündeki halk sağlığı literatürüyle (Sphere Association, 2018) tam bir uyum sergilemektedir.

Çalışmanın sağlık etkileri üzerindeki bulguları, afet sonrası ihtiyaçların zamana yayılmış dinamik ve aşamalı yapısını yansıtmaktadır. Acil tıbbi yardımların 2. günde, hijyen konularının ise 7. günde zirve yapmasına karşın, Konu 4’ün 21. günde ulaştığı %17.8’lik yaygınlık oranı stratejik bir öneme sahiptir. Bu zamansal kayma; sürecin travmatik yaralanmalarla başlayıp yerini akut bulaşıcı hastalık risklerine bıraktığını ve nihayetinde uzun süreli yerinden edilmenin doğurduğu kronik sağlık sorunlarına dönüştüğünü kanıtlamaktadır. Ayrıca “Çadır” (çadır, $\beta=0.1936$) ile birlikte “konteyner” (konteyner konut, $\beta=0.0303$) teriminin öne çıkması, daha iyi ısı yalıtımı ve hane halkı düzeyinde sanitasyon imkanları sunan dayanıklı konutlara geçiş ihtiyacının farkında olduğunu göstermektedir.

Müdahaleye yönelik pratik sonuçlar incelendiğinde, geçici yerleşim alanlarındaki etkili sağlık müdahalelerinin çok boyutlu bir entegrasyon gerektirdiği saptanmıştır. Veri setindeki anahtar kelime birliktelikleri; sosyal medya izleme sistemlerinin sadece sağlık sektörünü değil, barınma, beslenme, WASH (su, sanitasyon ve hijyen), psikososyal destek ve kırılgan grupların korunması gibi alanları kapsayan eş zamanlı ve koordineli bir müdahaleyi tetiklemesi gerektiğini ortaya koymaktadır. Bu çerçevede; konteyner kent planlaması, organize beslenme programları, hane halkı düzeyinde hijyen standartlarının

yükseltilmesi ve toplum temelli ruh sağılığı hizmetlerinin yaygınlaştırılması, afet sonrası sağılık yönetiminin sürdürülebilirliğı adına önceliklendirilmesi gereken temel operasyonel alanlar olarak tanımlanmıştır.

Afet yönetimi - altyapı ve malzemeler (Konu 2) kapsamında yapılan analizler, “deprem” ($\beta=0.2096$) anahtar kelimesinin tüm konular arasındaki en yüksek ikinci ağırlığa sahip olduğunu ve bu temanın belirli müdahale faaliyetlerinden ziyade afet olayının kendisine, hasar tespitine ve genel yönetim süreçlerine odaklandığını göstermektedir. Bu bulgu, sosyal medyadaki tartışmaların önemli bir kısmının (%12.06) doğrudan spesifik bir ihtiyaç iletmek yerine, afetin genel bağlamını ve yönetim dinamiklerini ele aldığını kanıtlaması bakımından metodolojik bir öneme sahiptir. Ancak bu konunun sağılıkla olan dolaylı ilişkisi göz ardı edilmemelidir; nitekim “battaniye” ($\beta=0.0261$) ve “malzemeleri” ($\beta=0.0255$) gibi anahtar kelimeler, ikincil sağılık risklerini engelleyen kritik bir lojistik dağıtıma işaret etmektedir. Özellikle Şubat ayının dondurucu soğuklarında battaniye tedariki hipotermiyi önlemede hayati bir rol oynarken, mutfak gereçleri ve su kapları gibi ev gereçleri, güvenli gıda hazırlama ve su depolama süreçlerini mümkün kılarak halk sağılığını koruma altına almaktadır.

Çalışmanın sağılık etkileri bağlamındaki bulguları, afet sonrası lojistik operasyonlardaki sürekliliğın önemini vurgulamaktadır. Veri setindeki “devam” ($\beta=0.1307$) anahtar kelimesi, akut acil durum evresinin ötesine geçen sürdürülebilir bir lojistik mekanizmanın varlığını göstermektedir. Bu süreklilik, sağılık hizmetlerinin kalıcılığı açısından kritiktir; zira tıbbi müdahale ilk etapta mevcut stoklarla yürütülebilse de, uzun vadeli sağılık hizmeti sunumu ilaç, tıbbi cihaz ve hijyen malzemelerinin kesintisiz ikmaline bağlıdır. Ayrıca “AFAD” ($\beta=0.0161$) ve “ekiplerimiz” ($\beta=0.0228$) kelimelerinin mevcudiyeti, bu karmaşık operasyonların merkezi bir otorite koordinasyonunda yürütüldüğünü ampirik olarak doğrulamaktadır.

Müdahaleye yönelik pratik sonuçlar incelendiğinde, Konu 2 bağlamındaki sosyal medya izlemesinin lojistik sistemin işleyişine dair stratejik göstergeler sunduğı görülmektedir. Dağıtım faaliyetlerine dair dijital etkileşimler, tedarik zincirinin aktiflik düzeyini yansıtırken; bu temadaki yaygınlık azalışları veya söylemdeki değişimler (örneğin “devam” yerine “eksik” ifadesinin öne çıkması), müdahale gerektiren lojistik darboğazlar için birer erken uyarı sinyali niteliğı taşımaktadır. Sonuç olarak, battaniye gibi spesifik

malzemelerin vurgulanması, mevsimsel faktörlerin ve soğuk hava koşullarının yarattığı ek sağlık risklerinin, afet bölgesindeki malzeme dağıtım önceliklerini doğrudan şekillendirdiğini bilimsel olarak kanıtlamaktadır.

Sağlık müdahalesini mümkün kılan altyapı (Konu 0) kapsamında elde edilen bulgular, korpusun %46.64 gibi baskın bir oranını oluşturarak sosyal medya tabanlı ihtiyaç analizi süreçleri için kritik bir gerçeği ortaya koymaktadır: Depremle ilgili dijital söylemlerin neredeyse yarısı, bireysel ihtiyaç beyanlarından ziyade örgütsel süreçlere ve operasyonel koordinasyona odaklanmıştır. Bu tablo, anahtar kelime eşleştirmesine dayalı otomatik sistemler için önemli bir zorluk teşkil etmektedir; zira yoğun koordinasyon söylemi, doğrudan sağlık ihtiyaçlarına yönelik iletileri “maskeleye” veya “sulandırma” riski taşımaktadır. Bununla birlikte, “ihtiyacı” (ihtiyaçlar, $\beta=0.1328$) kelimesinin bu konudaki en yüksek ağırlığa sahip olması ve (“kızılay”/Kızılay $\beta=0.0876$, “birlikte”/birlikte $\beta=0.1028$) gibi örgütsel terimlerle kümelenmesi, koordinasyon söyleminin aslında sistematik bir ihtiyaç değerlendirme ve kaynak tahsis sürecini kapsadığını göstermektedir. Türk Kızılayı’nın anahtar kelime ağırlıklarına yansıyan merkezi rolü, kurumun Türkiye afet müdahale sistemindeki stratejik konumuyla da tam bir uyum sergilemektedir.

Çalışmanın sağlık sistemleri üzerindeki etkileri incelendiğinde; Konu 0’ın, tıbbi hizmet sunumunu mümkün kılan temel operasyonel altyapıyı temsil ettiği saptanmıştır. Koordinasyon işlevi; tıbbi ekiplerin stratejik bölgelere konuşlandırılması için gerekli zemini oluşturmakta, tedarik zincirlerinin sağlık tesislerine kesintisiz ilaç ve ekipman ulaştırmasını güvence altına almakta ve kurumlar arası bilgi akışını optimize etmektedir. Her ne kadar bu süreç doğrudan klinik bir müdahale olarak görünmese de, koordinasyon mekanizmalarındaki aksaklıkların doğrudan sağlık hizmetlerinde kopmalara yol açtığı bir gerçektir. Koordinasyonsuz ekip sevkiyatları hizmet boşluklarına, lojistik darboğazlar kritik tıbbi malzeme gecikmelerine, bilgi eksiklikleri ise hedefe yönelik müdahalelerin etkinliğinin azalmasına neden olmaktadır.

Müdahaleye yönelik pratik sonuçlar açısından, koordinasyon söyleminin sergilediği yüksek yaygınlık oranı, sosyal medyanın afet süreçlerinde iki temel işleve sahip olduğunu kanıtlamaktadır: Etkilenen nüfusun acil taleplerini iletmesi ve müdahale ekiplerinin örgütsel iş birliğini bu platformlar üzerinden yürütmesi. Etkili bir sosyal medya izleme sistemi kurgulanırken, “yanlış pozitif” ihtiyaç tespitlerini asgariye indirmek adına bu iki

farklı iletişim akışının birbirinden hassasiyetle ayrıştırılması gerekmektedir. Bu bağlamda, sağlık ihtiyaçlarının ampirik değerlendirmesinde kullanılacak makine öğrenimi sınıflandırıcılarının; koordinasyon odaklı genel içerikleri filtrelemek üzere eğitilmesi, bunun yerine Konu 1, 3 ve 4'te somutlaşan “doğrudan ihtiyaç” ifadelerine odaklanacak şekilde optimize edilmesi stratejik bir zorunluluk olarak değerlendirilmektedir.

4.4.6. Konular Arası Analiz: Sağlık İhtiyaçları Etkileşimleri

Analiz edilen belgelerdeki konu eşzamanlılık kalıpları, afet sonrası ortaya çıkan ihtiyaçların birbirinden bağımsız olmadığını, aksine sistematik bir etkileşim içinde olduğunu kanıtlamaktadır. Birden fazla konunun aynı belgede yüksek olasılıkla (>0.2) yer alması, entegre sağlık yönetimi açısından şu temel bulguları ortaya koymaktadır:

- ✓ Halk sağlığı ve geçici barınma entegrasyonu (Konu 3 ve 4)
- ✓ Acil tıbbi yardım ve koordinasyon bağımlılığı (Konu 1 ve 0)

Halk sağlığı ve geçici barınma entegrasyonu ile ilgili olarak; çalışmada elde edilen bulgular, halk sağlığı ile geçici barınma ihtiyaçları arasında istatistiksel olarak anlamlı ve güçlü bir eşzamanlılık olduğunu ortaya koymaktadır. Analiz edilen belgelerin %4'ü (18.461 tweet), hem Konu 3 hem de Konu 4 için yüksek olasılık sergilemiştir; bu oran, beklenen tesadüfi değerin oldukça üzerindedir ($\chi^2=1.247.3$, $p<0.001$). Bu ampirik veri, geçici yerleşim birimlerine (çadır ve konteyner kentler) dair tartışmaların sistematik olarak WASH (Su, Sanitasyon ve Hijyen) altyapısını içerdiğini kanıtlamaktadır. Yapılan manuel incelemeler; çadır kentlerdeki hijyen tesisleri, konteyner alanlarındaki sanitasyon hizmetleri ve geçici barınma merkezlerindeki gıda dağıtımı gibi temaların birbirinden ayrılmaz bir bütün olarak ele alındığını göstermiştir. Bu durum, SPHERE Standartları'nın barınma, gıda ve hijyeni birbirine bağlı temel unsurlar olarak tanımlayan entegre yaklaşımını dijital veri düzeyinde doğrulamaktadır (Sphere Association, 2018).

Acil tıbbi yardım ve koordinasyon bağımlılığı ile ilgili olarak; acil tıbbi yardım ile koordinasyon süreçleri arasındaki etkileşim incelendiğinde; belgelerin %7'sinin hem Konu 1 hem de Konu 0 için yüksek olasılık gösterdiği tespit edilmiştir. Bu yüksek eşzamanlılık oranı, acil tıbbi müdahale süreçlerinin sahadaki operasyonel bağımlılığını ve organizasyonel karmaşıklığını doğrudan yansıtmaktadır. Bu kategorideki paylaşımların ağırlıklı olarak; arama-kurtarma (SAR) ekiplerinin koordinasyonu, tıbbi personel sevkiyat

lojistiği ve saha operasyonları ile merkezler arasındaki iletişim süreçlerine odaklandığı gözlemlenmiştir. Sağlık yönetimi açısından bu bulgu, tıbbi müdahalenin başarısının doğrudan güçlü bir koordinasyon altyapısına bağlı olduğunu göstermektedir. Ayrıca, sadece tıbbi anahtar kelimelere odaklanan izleme sistemlerinin, hizmet sunumundaki lojistik darboğazlar gibi hayati bağlamları gözden kaçırma riski taşıdığını kanıtlamaktadır.

Analiz edilen zamansal konu geçişleri, ardışık zaman dilimleri arasındaki baskın konu değişimlerini ölçerek afet sonrası süreçte sistematik bir ilerleme kalıbı ortaya koymuştur. Bu dinamik yapı, müdahale stratejilerinin zamanla nasıl evrildiğini gösteren iki ana aşama geçişi üzerinden okunmaktadır:

Aşama geçişi 1 acil tıbbi müdahaleden halk sağlığına (3-7. günler) söylemdeki hakim konu, depremin ardından 3. ve 7. günler arasında Konu 1'den (Acil Tıbbi, 2. gündeki zirve: %18.2) Konu 3'e (Halk Sağlığı, 7. gündeki zirve: %19.3) kaymıştır. Bu geçiş, afet sağlık önceliklerinde literatürle uyumlu bir ilerlemeyi yansıtmaktadır: Acil hayat kurtarma faaliyetlerinden (arama-kurtarma ve travma bakımı), hastalık önleme çalışmalarına (WASH ve beslenme) geçilmiştir. Acil tıbbi zirve ile halk sağlığı zirvesi arasında gözlemlenen 5 günlük gecikme, akut travma aşamasının ardından gerekli olan WASH altyapısının kurulumu için tanımlanan WHO acil müdahale protokolleri ile tam bir paralellik göstermektedir (WHO, 2017).

Aşama geçişi 2 halk sağlığından geçici barınmaya (14-21. günler) konu yaygınlığı, depremi takip eden üçüncü hafta boyunca Konu 3'ten (14. günden itibaren düşüş) Konu 4'e (geçici barınma, 21. gündeki zirve: %17.8) evrilmiştir. Bu değişim, mobil üniteler ve hijyen kitleri gibi “acil” WASH müdahalelerinden, geçici yerleşim alanlarında daha kalıcı ve organize sanitasyon altyapısının kurulmasına doğru yaşanan stratejik dönüşümü temsil etmektedir.

Sağlık yönetimi açısından stratejik etki saptanan bu sistematik konu geçişleri, afetlerdeki sağlık ihtiyaçlarının statik bir yapıda olmadığını, aksine öngörülebilir aşamalardan geçtiğini ampirik olarak kanıtlamaktadır. Afetin başlangıcından itibaren geçen süreye göre anahtar kelime önceliklerini otomatik olarak uyarlayan sosyal medya izleme sistemleri, bu aşama geçişlerini önceden tahmin ederek kaynakların ve müdahale ekiplerinin çok daha isabetli bir şekilde yönlendirilmesini sağlayabilir.

4.4.7. Çerçeve Uyumu Yoluyla Doğrulama

Çalışmanın metodolojik doğruluğunu test etmek amacıyla kullanılan SPHERE İnsani Yardım Standartları, elde edilen bulgularla yüksek bir korelasyon sergilemektedir. Bu kapsamda özellikle Konu 3 ve Konu 4, SPHERE asgari standartlarıyla doğrudan örtüşen tematik alanlar olarak öne çıkmaktadır.

Konu 3, SPHERE bünyesindeki WASH (Su, Sanitasyon ve Hijyen), gıda güvenliği ve barınma standartlarını kapsayan bütünleşik bir yapı sunmaktadır. Örneğin, WASH Standardı 1.1 kapsamında yer alan “güvenli suya erişim” gereksinimi, modelimizde en yüksek ağırlığa sahip olan “hijyen” ($\beta=0.3326$) terimiyle ampirik olarak karşılık bulmaktadır. Benzer şekilde, Gıda Güvenliği Standardı 1’de tanımlanan gıda yardımı ihtiyacı, “gıda” ($\beta=0.0872$) ve “yemek” ($\beta=0.0446$) anahtar kelimeleriyle; Barınma Standardı 1’de yer alan stratejik planlama ise “barınma” ($\beta=0.0235$) terimiyle temsil edilmektedir.

Konu 4 ise ağırlıklı olarak SPHERE barınma ve beslenme standartlarını yansıtmaktadır. Barınma Standardı 3.1’de vurgulanan “yerleşim planlaması” ihtiyacı, veri setindeki “çadır” ($\beta=0.1936$) ve “konteyner” ($\beta=0.0303$) kelimeleri üzerinden somutlaşmaktadır. Ayrıca beslenme standardı altındaki programların, “beslenme” ($\beta=0.0292$) terimiyle doğrudan eşleştiği görülmektedir.

Sonuç olarak, LDA konuları ile SPHERE standartları arasındaki bu tutarlı uyum, modelin uluslararası alanda tanınan insani yardım kategorilerine karşılık gelen temaları başarıyla belirlediğini ve analitik çerçeveyi doğruladığını kanıtlamaktadır.

4.5. Sağlıkla İlgili BERTopic Konu Modelleme Sonuçları

BERTopic sağlık kategorisi toplam 11.375 belgeyi kapsamakta olup (%25.0), Tablo 24’te detaylandırıldığı üzere dört temel alt konuya ayrılmaktadır. Özellikle ruh sağlığı ve psikolojik süreçleri temsil eden Konu 5 ve Konu 8’in toplamda 4.479 belgeye (%9.8) ulaşması, afet sonrası dönemde psikolojik ihtiyaçların sosyal medya platformlarında ne denli güçlü bir temsiliyet bulduğunu ampirik olarak kanıtlamaktadır.

Tablo 24. BERTopic sağlık ve tıp alt kategorilerinin dağılımı ve anahtar kelimeleri

Konu No	Alt Kategori	Anahtar Kelimeler	Belge Sayısı	Kümelenen (%)
Konu 0	Kan Bağışı	kan, bağışı, kızılai	4.116	%9.0
Konu 5	Ruh Sağlığı ve Psikoloji	psikolog, psikiyatrist, yalnızlık	2.883	%6.3
Konu 6	Tıbbi Hizmetler ve İlaçlar	hemşire, doktor, hastane, ilaç	2.780	%6.1
Konu 8	Panik Ataklar ve Akut Stres	panik, atak, ağrısı	1.596	%3.5
Toplam	Sağlık ve Tıp Kategorisi	—	11.375	%25.0

4.5.1. Genel Konu Yapısı ve Belge Dağılımı

79.292 adet önceden işlenmiş depremle ilgili tweetin BERTopic analizi, 59 farklı konu belirlemiştir. 45.590 belge (%57.5) başarıyla kümeleneş ve 33.702 belge (%42.5) aykırı deęer olarak sınıflandırılmıştır. 59 konu, 18 belge (minimum küme boyutu eşięi) ile en büyük konudaki 4.116 belge arasında deęişen önemli boyut heterojenlięi sergiledi. Ortalama konu boyutu 772.7 belge iken, medyan konu boyutu 348 belge idi, bu da birkaç büyük baskın konu ve birçok daha küçük özel konu ile sağa eğik bir dağılım olduğunu gösteriyor.


Kümülatif kapsama analizi, yaklaşık 20 konunun kümeleneş belgelerin %80'ini oluşturduğunu ortaya koydu. Bu, tam konu envanterinin ince tematik varyasyonları yakalarken, bir dizi temel konunun söylemi domine ettiğini göstermektedir. En çok ilgi gören 15 konu 29.437 belgeyi (kümeleneş tweetlerin %64.6'sı) içermekte olup, tartışmaların temel sağlık ve afet temaları etrafında yoğunlaştığını göstermektedir. Şekil 11, konu hiyerarşisi genelinde konu boyutlarının ve kümülatif belge kapsamının dağılımını göstermektedir.

4.5.2. Tematik Kategori Dağılımı ve Kompozisyonu

Konular altı üst düzey kategoriye toplandığında, depremle ilgili söylemin tematik bileşiminde net kalıplar ortaya çıkmıştır. Aykırı deęerler (42.5%) hariç tutulduğunda, kategorize edilen belgeler şu şekilde dağılmıştır:

- ✓ Dięer/Karışık: 16.512 belge (toplamın %20.8'i, kümeleneşlerin %36.2'si) - en büyük kategori
- ✓ Sağlık ve tıp: 11.375 belge (toplamın %14.3'ü, kümeleneşlerin %25.0'ı)
- ✓ Afet yardımı: 11.367 belge (toplamın %14.3'ü, kümeleneşlerin %24.9'u)
- ✓ Siyasi söylem: 3.948 belge (toplamın %5.0'ı, kümeleneş belgelerin %8.7'si)

- ✓ İletişim ve Altyapı: 1.426 belge (toplamın %1.8'i, kümelenmiş belgelerin %3.1'i)
- ✓ Dini ve manevi: 962 belge (toplamın %1.2'si, kümelenmişlerin %2.1'i)



Şekil 11. BERTopic konu dağılımı ve kategorik analiz

Şekil 11’de sunulan analizler, veri setinin yapısal ve içeriksel dağılımını dört farklı panel üzerinden detaylandırmaktadır:

- ✓ Panel A (Sol Üst): Konu boyutlarının dağılımını göstermektedir. Verilerin bir güç yasası (power law) modeline uyduğu görülmektedir; buna göre çoğu konu 500’den az belge içerirken, az sayıda ancak çok büyük ölçekli (>3.000 belge) ana konular bulunmaktadır.
- ✓ Panel B (Sağ Üst): Belge sayısına göre en yoğun ilk 15 konuyu listelemektedir. Konu 0 (Kan Bağışı), 4.116 belge ile tüm kümelenmiş metinlerin %9.0’ını oluşturarak en büyük kategori olarak öne çıkmaktadır.

- ✓ Panel C (Sol Alt): Kategorik dağılımı sunarak sağlık odaklı içeriğin dengeli yapısını yansıtmaktadır. Sağlık ve Tıp (%25.0) ile Afet Yardımı (%24.9) kategorileri, kümelenmiş belgelerin toplamda %49.9'unu oluşturmaktadır.
- ✓ Panel D (Sağ Alt): Kümelenmiş belgelerin yaklaşık %80'ini kapsayan en çok okunan 15 konuyu göstermektedir. Bu panel, kapsamlı bir ihtiyaç değerlendirmesi için 59 konulu derinlemesine analizi sürdürürken, operasyonel müdahale aşamasında odaklanmış bir izlemenin ne kadar verimli olduğunu doğrulamaktadır.

Tablo 25. Tematik kategorilere göre konu dağılımı

Kategori	Dokümanlar	Toplamın %'si	Küme içindeki %
Aykırı Değerler	33.702	42.5%	—
Diğer/Karma	16.512	20.8%	36.2%
Sağlık ve Tıbbi	11.375	14.3%	25.0%
Afet Yardımı	11.367	14.3%	24.9%
Politik Söylem	3.948	5.0%	8.7%
İletişim ve Altyapı	1.426	1.8%	3.1%
Dini ve Manevi	962	1.2%	2.1%
Toplam	79.292	100.0%	100.0%

Önemli sağlık ve tıp ile afet yardımı kategorileri (gruplandırılmış belgelerin %50'sini oluşturur), veri setinin sağlık ihtiyaçları değerlendirmesi için uygunluğunu doğrulamaktadır. Tablo 25 daki gibi, Diğer/Karışık kategorinin öne çıkması (%36.2), afetle ilgili sosyal medya söylemlerinin heterojen doğasını yansıtmaktadır. Bu söylemler, günlük yaşamla ilgili endişeleri, sosyal yorumları ve sağlık veya afet alanlarına net bir şekilde sınıflandırılmayan konuları kapsamaktadır.

Özellikle, sağlık ve tıp ile afet yardımı kategorileri neredeyse eşit oranda temsil edilmiştir (%25.0'a karşı %24.9), bu da acil maddi ihtiyaçlara (barınma, gıda, malzeme) ve sağlığa özgü endişelere (tıbbi hizmetler, ruh sağlığı, sağlık hizmetlerine erişim) dengeli bir şekilde önem verildiğini göstermektedir. Bu denge, erken müdahale aşamalarında genellikle sağlık endişelerinden çok acil fiziksel ihtiyaçlara öncelik veren afet iletişim modellerinden farklıdır.

Sağlık ve tıp kategorisi altında incelenen 11.375 belge, afet müdahale sürecinde dijital platformlara yansıyan tıbbi endişelerin ne denli heterojen bir yapıya sahip olduğunu ortaya koymuştur. Bu kategori içerisinde öne çıkan en büyük dört tematik odak şu şekildedir:

- ✓ Konu 0 - kan bağıışı (4.116 belge, kümelenmiş belgelerin %9.0'ı): “Kan”, “bağıışı” ve “kızılay” terimleriyle temsil edilmektedir. Bu konu, kan bağıışı için yapılan seferberlik çabalarını yansıtmaktadır ve tweet’lerde belirli yerlere özgü kan toplama bilgileri, bağıışçı gereklilikleri ve acil çağrılar yer almaktadır. Olağanüstü büyüklüğü, sosyal medyada yaygın olarak yürütülen kan bağıışı kampanyalarını yansıtmaktadır.
- ✓ Konu 5 - ruh sağılığı ve psikoloji (2.883 belge, %6.3): Anahtar kelimeler arasında “psikolog”, “psikiyatrist”, “yalnızlık” ve “psikolojik” yer almaktadır. Tweetlerde psikolojik destek ihtiyaçları, travma belirtileri, kaygı ve etkilenen bölgelerdeki ruh sağılığı uzmanlarına yönelik talepler tartışılmıştır.
- ✓ Konu 6 - tıbbi hizmetler ve İlaçlar (2.780 belge, %6.1): Terimler arasında “hemşire”, “doktor”, “hastane” ve “ilaç” yer almaktadır. İçerik, sağılık tesislerinin durumu, ilaç kıtlığı, tıbbi ekipman ihtiyaçları ve sağılık çalışanlarının görevlendirilmesine odaklanmıştır.
- ✓ Konu 8 - panik ataklar ve akut stres (1.596 belge, %3.5): Belirgin terimler: “panik”, “atak”, “panik atak”, “ağrısı”. Tweetler akut psikolojik semptomları, artçı sarsıntılarla tetiklenen panik atakları ve acil psikolojik müdahale taleplerini anlatıyordu.

Toplamda, bu sağılık konuları, sağılık ihtiyaçlarının fiziksel yaralanmaların ötesine geçerek kan tedariki lojistiğı, ruh sağılığı hizmetleri, ilaç erişimi ve akut psikolojik sıkıntı yönetimini de kapsadığını göstermektedir. Ruh sağılığı konularının öne çıkması (Konu 5 ve 8 birlikte: 4.479 belge, kümelenmişlerin %9.8'i) özellikle dikkat çekicidir ve geleneksel afet sağılığı gözetiminde genellikle yeterince temsil edilmeyen bir alan olan psikolojik ihtiyaçların sosyal medyada önemli ölçüde ifade edildiğini göstermektedir.

4.5.3. Afet Yardımı Konuları: Malzeme İhtiyaçları ve Lojistik

Afet yardımı kategorisi (11.367 belge), acil yardım, temel ihtiyaçlar ve afet müdahale lojistiğı ile ilgili konuları kapsamaktadır. Anahtar konular şunlardır:

- ✓ Konu 2 - genel afet yardımı (3.384 belge, %7.4): “Deprem”, “çadır”, “destek” ve “depremzede” terimleri, yardım koordinasyonu, mağdur desteğı ve genel yardım

ihtiyaları dahil olmak zere geniř kapsamlı afet yardımı tartıřmalarını karakterize etmiřtir.

- ✓ Konu 4 - adır kentler ve gıda daėıtımı (2.905 belge, %6.4): “adır”, “gıda”, “adırkent” ve “kuru” anahtar kelimeleri, geici barınakların kurulması ve gıda yardımı daėıtım lojistiėine odaklanmıřtır.
- ✓ Konu 7 - hijyen ve sanitasyon (2.301 belge, %5.0): ‘Tuvalet’, ‘sabun’, ‘lavabo’, ‘kaėıdı’ gibi belirgin terimler, sanitasyon tesisleri ihtiyaları, hijyen malzemeleri ve halk saėlıėı altyapısını vurgulamıřtır.
- ✓ Konu 10 - sıcak yemek ve gıda İhtiyaları (1.109 belge, %2.4): “Yemek” (yemek), “sıcak” (sıcak), “sıcak yemek” (sıcak yemek), “gıda” (gıda) terimleri, hazır yemek temini ve sıcak yemek daėıtımını vurgulamıřtır.
- ✓ Konu 11 - barınma ve yer deėiřtirme (1.040 belge, %2.3): “yardımı” (yardım), “tařınma” (yer deėiřtirme), “kira” (kira), “sorunu” (sorun) anahtar kelimeleri, orta vadeli barınma sorunları ve yer deėiřtirme yardımını ele almıřtır.

Bu afet yardımı konuları, acil hayatta kalma (barınma, gıda) ihtiyalarından halk saėlıėı altyapısı (sanitasyon) ve uzun vadeli iyileřme (barınma) ihtiyalarına kadar bir ihtiya hiyerarřisini ortaya koymaktadır. Hijyen ve sanitasyona (Konu 7, 2.301 belge) gsterilen byk ilgi, toplu barınaklarda yetersiz sanitasyonun yol atıėı ikincil saėlık risklerine iliřkin halkın farkındalıėını gstermektedir. Bu riskler, afetlerin ilk etkilerinin ardından genellikle birkaç gn sonra ortaya ıkan kritik bir halk saėlıėı sorunudur.

4.5.4. Saėlıkla İlgili Konu Tanımlama ve Sınıflandırma

Tablo 26’da gsterildiėi zere, keřfedilen 59 konudan 47’si (%79.7) saėlıkla ilgili ierik barındırıyordu ve 36.274 kmelenmiř belgeyi oluřturuyordu. Konular, WHO acil saėlık İhtiyaları deėerlendirme erevesi ve sphere İnsani yardım standartları temel alınarak sistematik olarak altı tematik alana ayrıldı.

Kategori Atama Metodoloėisi: Her konunun saėlıkla ilgisi, (1) en ok kullanılan 10 c-TF-IDF aėırlıklı terim, (2) konu bařına 20 temsil edici belge ve (3) yerleřik afet saėlıėı erevesiyle (WHO EHK kılavuzları; Sphere standartları) uyumun sistematik olarak incelenmesi yoluyla belirlenmiřtir. Temsil edici belgelerde saėlıkla ilgili ieriėi %60 ve zeri olan konular saėlık kategorilerine atanmıřtır.

Tablo 26. BERTopic sağlık kategorileri ve dağılımı

Kategori	Konular (n)	Dokümanlar (n)	Küme İçindeki %	Toplam Veri Setindeki %	Ana Temalar
Sağlık ve Tıbbi	14	6.524	14.3%	8.2%	Hastane erişimi, tıbbi malzemeler, klinik hizmetler
Afet Yardımı	14	6.524	14.3%	8.2%	Barınma, gıda, su, acil yardım
Ruh Sağlığı ve Psikososyal	7	3.192	7.0%	4.0%	Korku, travma, kaygı, psikolojik sıkıntı
Politik Söylem	5	2.280	5.0%	2.9%	Hükümetin müdahalesi, hesap verebilirlik
İletişim ve Altyapı	4	820	1.8%	1.0%	Telefon ağları, internet, bağlantı
Dini ve Manevi	3	547	1.2%	0.7%	Dua, inanç temelli başa çıkma
Diğer/Karma	12	9.485	20.8%	12.0%	Sağlık dışı afet içerikleri
Aykırı Değerler	-1	33.702	N/A	42.5%	Yetersiz yoğunluk/gürültü

Kategori Atama Metodolojisi: Her konunun sağlıkla ilgisi, (1) en çok kullanılan 10 c-TF-IDF ağırlıklı terim, (2) konu başına 20 temsil edici belge ve (3) yerleşik afet sağlığı çerçeveleriyle (WHO EHK kılavuzları; Sphere standartları) uyumun sistematik olarak incelenmesi yoluyla belirlenmiştir. Temsil edici belgelerde sağlıkla ilgili içeriği %60 ve üzeri olan konular sağlık kategorilerine atanmıştır.

4.5.5. Ayrıntılı Konu Açıklamaları: Sağlıkla İlgili En Önemli 15 Konu

Tablo 27’de açıklandığı üzere; sağlıkla ilgili en önemli 15 konu, her bir konunun içeriğini detaylandıran yorumlayıcı tema açıklamalarıyla birlikte sunulmaktadır.

Tespit edilen temalar, deprem müdahale sürecinde ortaya çıkan sağlık ihtiyaçlarının dinamik ve hiyerarşik bir yapıda şekillendiğini ortaya koymaktadır. Bu kapsamda, acil yaşam desteğinden uzun vadeli rehabilitasyona kadar uzanan gereksinimler, afet bağlamına uyarlanmış bir ‘sağlık hiyerarşisi’ teşkil etmektedir. Söz konusu öncelik sıralaması aşağıda dört ana boyutta detaylandırılmıştır (Adepoju, 2025: 1-3):

Tablo 27. Yorumlarla birlikte en çok kullanılan 15 BERTopic sağlık konusu

Konu Kimliği (ID)	Boyut	En Önemli Anahtar Kelimeler	Tema Yorumlaması	Sağlık Kategorisi
0	4,116	kan, bağıışı, kızıl原因	Kan Bağıışı Krizi: Kan bağıışı için acil çağrılar, travma bakım kapasitesinde ciddi yetersizlikler	Sağlık Hizmetleri
4	2,905	çadır, gıda, çadırkent	Gıda Tedariki ve Acil Barınma: Yerinden edilmiş nüfus için gıda dağıtımı ve çadır kent operasyonları	Afet Yardımı (Beslenme)
5	2,883	psikolog, psikiyatrist, ruh	Ruh Sağlığı Hizmetleri: Psikologlar ve psikiyatristler. Psikolojik sıkıntı, travma, yalnızlık, kriz danışmanlığı.	Ruh Sağlığı
6	2,780	nurse, doktor, hastane, ilaç	Sağlık Personeli ve Tesisler: Sağlık iş gücü – hemşireler, doktorlar, hastaneler, ilaçlar	Sağlık Hizmetleri
7	2,301	tuvalet, sabun, lavabo	Sanitasyon ve Hijyen: Yetersiz hijyen ve sanitasyon koşulları. Yerinden edilmiş ortamlarda hastalık önleme açısından kritik	Afet Yardımı (WASH - Su, Sanitasyon ve Hijyen)
8	1,596	panik atak, ağrısı	Panik Ataklar ve Akut Stres: Akut psikolojik belirtiler, kaygı, ağrı yönetimi, ruh sağlığı krizi	Ruh Sağlığı
10	1,109	yemek, sıcak yemek, gıda	Sıcak Yemek Dağıtımı: Mobil mutfak hizmetleri, gıda güvenliği ve beslenme desteği	Afet Yardımı (Beslenme)
11	1,040	taşınma, kira, sorunu	Barınma ve Yer Değiştirme: Geçici barınma desteği. Yer değiştirme ve barınma güvensizliğinin sağlık üzerindeki etkileri	Afet Yardımı (Barınma)
13	908	mama, yaşam alanı	Bebek Beslenmesi: Bebek maması ve bebek bakım ihtiyaçları. Hassas gruplara destek	Anne ve Çocuk Sağlığı
18	650	oksijen, nefes darlığı, astım	Solunum Desteği: Oksijen ihtiyacı, nefes alma güçlüğü, afet sonrası astım vakaları	Tıbbi Malzemeler
21	609	sağlık ekibi, destek	Mobil Sağlık Ekipleri: Sağlık ekiplerinin sahaya sevki. Etkilenen bölgelerde mobil sağlık birimleri	Sağlık Hizmetleri
22	605	travma, ağrı, kalp, yara	Travma Bakımı: Fiziksel travma, yaralanmalar, kalp sorunları. Yara bakımı ve ağrı yönetimi	Sağlık Hizmetleri
23	598	ambulans, acil servis	Acil Tıbbi Hizmetler: Ambulans hizmetleri, hasta nakilleri. Acil sağlık sistemi üzerindeki yük	Sağlık Hizmetleri
24	527	aşı, serum	Aşılar ve Koruyucu Tıp: Aşılama ihtiyaçları, serumlar, koruyucu sağlık önlemleri	Tıbbi Malzemeler
25	406	depresyon, antidepresan	Depresyon ve Psikiyatrik Tedavi: Antidepresan kullanımı. Ruh sağlığı bozukluklarının yönetimi	Ruh Sağlığı

1. Acil hayat kurtarma (Konular 0, 1, 6, 8): Kan bağıışı, travma bakımı, acil sağlık hizmetleri, yara tedavisi — akut yaralanmaların tedavisi ve ölümlerin önlenmesi

2. Kronik hastalıkların sürekliliği (Konular 3, 13): İlaç erişimi ve diyaliz — mevcut hasta popülasyonlarında morbiditeyi önlemek
3. Savunmasız nüfusun korunması (Konular 2, 4, 7, 12): Anne-çocuk sağlığı, barınma, sanitasyon — yüksek risk altındaki nüfusların ele alınması
4. Uzun vadeli iyileşme (Konular 5, 14): Ruh sağlığı, aşılama — ikincil sağlık krizlerini önleme Bu hiyerarşik ihtiyaç yapısı, afet bağlamına uyarlanmış Maslow'un hiyerarşisi ile uyumludur ve acil hayatta kalma ihtiyaçlarından uzun vadeli sağlık sistemi iyileşmesine doğru ilerler.

6 Şubat 2023 depremi sırasında üretilen dijital veriler üzerinde yürütülen BERTopic analizi, afet sağlık ihtiyaçlarını yüksek çözünürlüklü bir perspektifle temsil eden 59 yorumlanabilir konu tanımlamıştır. Elde edilen bulgular, sosyal medyanın sadece bir veri kaynağı değil, aynı zamanda kriz yönetiminde eyleme geçirilebilir içgörüler sunan stratejik bir araç olduğunu şu temel boyutlar üzerinden ortaya koymaktadır:

1. Konu keşfi: Korpusun %57.5'i tutarlı konulara kümelenmiş olup, %42.5'lik muhafazakar bir dışsal değer tanımlaması, zorla atama yerine konu kalitesini sağlamıştır.
2. Sağlıkla ilgili olma: Konuların %79.7'si sağlıkla ilgili içerik barındırıyordu; 14 konu doğrudan tıbbi hizmetleri, 7 konu ruh sağlığını ve 14 konu sağlıkla ilgili afet yardımını ele alıyordu.
3. Doğrulama: Birden fazla yakınsak kanıt kaynağı (denetimli makine öğrenimi uyumu, zamansal modeller, duygu korelasyonu, coğrafi tutarlılık), konuların istatistiksel artefaktlardan ziyade gerçek sağlık ihtiyaçlarını temsil ettiğini doğrulamaktadır.
4. Eyleme geçirilebilir içgörüler: Konular, acil travma bakımından uzun vadeli iyileşmeye kadar hiyerarşik ihtiyaç yapısını ortaya koyarak, öncelikli kaynak tahsisini mümkün kılar.
5. Zamansal evrim: Konu yaygınlık kalıpları, travma bakımı akut aşamada (0-7. günler) baskın ve ruh sağlığı iyileşme aşamasında (8-30. günler) ortaya çıkan, yerleşik afet sağlığı çerçeveleriyle uyumludur.

BERTopic metodolojisi, geleneksel yaklaşımlara göre belirgin avantajlar sergilemiştir: (1) ayrıntı düzeyi (LDA'da 5 konuya karşılık 59 konu), ince ayrıntılı ihtiyaç tanımlamasına

olanak sağlar; (2) gürültü yönetimi (açık uç değerlerin tanımlanması), yorumlanabilirliği artırır; ve (3) anlamsal zenginlik (Türkçe dilbilimsel nüansları yakalayan dönüştürücü gömmeler), İngilizce olmayan kriz iletişimi analizleri için konu kalitesini artırır.

4.6. Karşılaştırmalı Analiz: LDA ve BERTopic Sağlık Sınıflandırması

LDA ve BERTopic modellerinden elde edilen sağlık çıktıları, Tablo 28’de sunulan boyutlar çerçevesinde karşılaştırılmıştır. İki model arasındaki yüksek korelasyon kapsamlı bir çapraz doğrulama sağlarken; LDA’nın tüm veri setini kapsayan genel yapısı ile BERTopic’in gürültülü veriyi ayıklama (outlier tespiti) kabiliyeti, afet dönemi sosyal medya analizinde hibrit bir yaklaşımın önemini ortaya koymaktadır.

Tablo 28. LDA ve BERTopic sağlık sınıflandırması: karşılaştırmalı analiz

Boyut	LDA (K=5)	BERTopic (59 konu)
Konu Sayısı	5 (manuel belirleme)	59 (otomatik belirleme)
Sağlık Kapsamı	%100 — tüm konular sağlıkla ilgili	%79.7 — 45/59 konu sağlık uyumlu
Yorumlanabilirlik	Yüksek — WHO/SPHERE eşleştirmesi kolay	Orta — 59 konu detaylı analiz gerektirir
Outlier Tespiti	Yok — her tweet bir konuya atanır	Var — %42.5 aykırı değer tespiti
Öne Çıkan Bulgu	Hijyen b=0.3326 (kritik WASH ihtiyacı)	Ruh sağlığı %9.8 (gizli kalan ihtiyaç)

LDA’nın 5 ana konusu makro düzeyde bir tematik yapı sunarken, BERTopic’in ürettiği 59 konu, mikro düzeyde ayrıntılı bir sağlık ihtiyacı sınıflandırması gerçekleştirmiştir. Her iki modelin sonuçları arasındaki sayısal paralellik, elde edilen bulguları çapraz olarak doğrulamaktadır:

- ✓ LDA Konu 3 (Halk Sağlığı, %14.94) birden fazla BERTopic alt konusunu kapsar:
 - BERTopic Konu 12: Hijyen kitleri (korporun %3.2’si)
 - BERTopic Konu 18: Su dağıtımı (%2.8)
 - BERTopic Konu 24: Sanitasyon tesisleri (%2.1)
 - BERTopic Konu 31: Sıcak yemekler (%1.9)
 - BERTopic Konu 37: Acil durum barınakları (%1.7)
 - Ek ilgili konular: %3.3
- ✓ Toplam BERTopic halk sağlığı içeriği: %15.0 $\approx$ LDA Konu 3 (%14.94): Bu, her iki sınıflandırmanın da doğru olduğunu doğrulamaktadır: LDA, söylemlerin

yaklaşık %15'inin halk sağlığı temellerini ele aldığını belirlerken, BERTopic bunun en az 6 farklı ihtiyaç alt kategorisinden oluştuğunu ortaya koymaktadır.

- ✓ LDA Konu 1 (Acil Tıbbi Yardım, %13.37) şunları kapsamaktadır:
BERTopic Konu 3: Arama ve kurtarma (4.1%)
BERTopic Konu 7: Tıbbi tahliye (%2.9)
BERTopic Konu 14: Travma bakımı (2.3%)
BERTopic Konu 22: Saha hastaneleri (%1.8)
Ek ilgili konular: %2.3
- ✓ Toplam BERTopic acil tıbbi durumlar: %13.4 $\approx$ LDA Konu 1 (%13.37): LDA, genel söylem temalarını ve zamansal evrimi anlamak için uygun bir sınıflandırma sağlar. BERTopic, belirli sağlık ihtiyaçlarının tanımlanması ve gelecek planlaması için uygun bir sınıflandırma sağlar. Bu iki yöntem birlikte kullanıldığında, kapsamlı bir analitik kapsama sunarlar: LDA, müdahale aşamalarının ve önceliklerin stratejik olarak anlaşılması için, BERTopic ise belirli müdahale gereksinimlerinin operasyonel olarak tanımlanması için kullanılır.

4.7. Sağlıkla İlgili Söylemlerde Duygusal Eğilimlerin Analizi

Sağlık tweetlerindeki negatif duygu oranı (%79.7), sağlık dışı tweetlerden 7.1 puan daha yüksektir. Ki-kare testi istatistiksel anlamlılığı doğrulamıştır ($\chi^2=555.41$, $p<0.001$). Tablo 29'da gösterildiği üzere, duygu analizi sağlık sistemi stresi için güvenilir bir gösterge olarak öne çıkmaktadır.

Tablo 29. Sağlık-duygu korelasyonu istatistiksel test sonuçları

Duygu Boyutu	Sağlık Tweetleri (n=40.378)	Sağlık Dışı (n=38.914)	Fark
Negatif Oran	%79.7 (32.181 tweet)	%72.6 (28.245 tweet)	+7.1 puan
İstatistiksel Test	$\chi^2=555.41$, df=1	$p<0.001$	H0 reddedildi
Etki Büyüklüğü	Cramer'in V=0.084	Küçük etki	Büyük örnekleme pratik önemi yüksek
İlk Zirve (0. gün)	%84 negatif	Arama-kurtarma fazı	En yüksek sıkıntı
Geç Dönem (52-59. gün)	%71-73 negatif	Azalan trend	Kronik etki sürüyor

BERTurk dönüştürücü modeli (doğrulama doğruluğu: %82.41) kullanılarak, tüm metinler için duygu olumlu veya olumsuz olarak sınıflandırılmıştır. Analiz, birkaç aşamada

önemli zamansal farklılıklar ve sağlıkla ilgili ve sağlıkla ilgili olmayan tweetler arasında belirgin farklılıklar ile baskın olumsuz duygu (%76.21) olduğunu ortaya koymaktadır.


Toplam 79.292 adet paylaşım, BERTurk modeli aracılığıyla kesin duygu etiketleri kullanılarak kategorize edilmiştir. Tablo 30'da detaylandırıldığı üzere; veri setindeki duygu dağılımı, afet sonrası dönemde toplumsal düzlemde baskın olan duygusal tabloyu sayısal verilerle somut bir şekilde özetlemektedir.

Tablo 30. Genel duygu dağılımı

Duygu	Sayı	Yüzde	Açıklama
Negatif	60.426	76.21%	Acı, acil ihtiyaçlar, sorunlar, korku ve umutsuzluk ifadeleri
Pozitif	18.866	23.79%	Minnettarlık, umut, alınan yardım ve dayanışma ifadeleri
Toplam	79.292	100.00%	

Negatif/Positif Oranı: 3.20:1

Negatif duyguların baskınlığı (%76.21) (Şekil 12), felaketin tehlikeli doğasını ve bununla birlikte ortaya çıkan akut sağlık krizini yansıtmaktadır. Bu dağılım, kriz bilişim literatüründe belgelenen büyük afet bağlamları için beklenen modellerle uyumludur; bu modellerde olumsuz duygular genellikle afetle ilgili sosyal medya içeriğinin %70-80'ini oluşturur (Imran vd., 2015; Pourebrahim vd., 2019).



Şekil 12. Genel duygu dağılımı

Tablo 31’de sunulan veriler, BERTurk modelinin tüm sınıflandırma süreçlerinde olağanüstü yüksek bir güvenilirlik sergilediğini kanıtlamaktadır. Modelin ulaştığı %89.50’lik yüksek ortalama güven değerine karşın, medyan güvenilirliğin %96.63 seviyesine çıkması, tahminlerin çok büyük bir bölümünün mükemmeliyet eşiğinde yoğunlaştığını göstermektedir.

Tablo 31. Model güven istatistikleri

Metrik	Value	Yorum
Ortalama Güven	0.8950 (89.50%)	Çok yüksek genel güvenilirlik
Medyan Güven	0.9663 (96.63%)	Tahminlerin büyük çoğunluğu yüksek güvene sahip
Tahminler >95% güvenilirlik	44.239 (55.8%)	Yarisından fazlası mükemmel eşikleri aşmaktadır
Tahminler >90% güvenilirlik	52.847 (66.6%)	Üçte ikisi iyi eşik değerini aşmaktadır
Tahminler >80% güvenilirlik	68.547 (86.5%)	Çok büyük çoğunluğu güvenilirdir


Şekil 13’te sağa eğik dağılım; modelin belirsiz veya nötr ifadeler yerine, ağırlıklı olarak net ve keskin duygu dışavurumlarıyla karşılaştığını ampirik olarak doğrulamaktadır. Veri setinin %66.6’sının %90 güven eşiğini, %86.5’inin ise %80 güvenilirlik barajını aşması, elde edilen duygu etiketlerinin bilimsel analizler için son derece tutarlı ve güvenilir bir zemin sunduğunu belgelemektedir.

Yüksek güvenilirlikteki tahminlerin yoğunlaşması, BERTurk’ün bu metin kümesine uygun olduğunu doğrulamaktadır. Tweetler, muhtemelen felaketin aciliyeti ve duygusal yoğunluğu nedeniyle, nispeten belirsiz olmayan bir dilde duygu ifade etmektedir.

59 günlük gözlem süresini (6 Şubat - 5 Nisan 2023) kapsayan Zamansal Duygu Kalıpları analizi, toplumun duygusal tepkilerinin dinamik ve değişken yapısını ortaya koymaktadır. Tablo 32’de sunulan özet istatistiklere göre, günlük olumsuz duygu düzeyi ortalama %76.21 seviyesinde seyretmiş, bu değer süreç boyunca %71.2 ile %84.0 arasında dalgalanmıştır. Ortalama 12.8 puanlık bu geniş salınım, bir ölçüm gürültüsü olmaktan ziyade, sahadaki gelişmelerle doğrudan ilişkili sistematik ve toplumsal bir duygu değişimini yansıtmaktadır.

Tablo 32. Günlük olumsuz duygu özeti istatistikleri

İstatistik	Değer
Genel Ortalama	76.21%
Standart Sapma	3.94%
Aralık	71.2% - 84.0%
Medyan	76.50%



Şekil 13. Kapsamlı duygu analizi

Şekil 13'te gösterilen kapsamlı analizin A paneli, güven dağılımı histogramını göstermekte ve 1.0'a yakın bölgelerde yoğun bir konsantrasyon olduğunu ortaya koymaktadır. Şeklin B panelinde görselleştirilen günlük değişimler, afet sonrası duygusal sürecin dört temel aşamadan geçtiğini kanıtlamaktadır:

- ✓ İlk zirve: Negatif duygu, depremin yaşandığı ilk gün (0. gün) en yüksek seviyesi olan %84'e ulaşmıştır.
- ✓ Akut dönem oynaklığı: İlk iki haftalık süreçte (0-14. günler), belirsizlik ve acil kurtarma faaliyetlerinin etkisiyle %77-84 aralığında yüksek bir volatilité gözlemlenmiştir.
- ✓ Stabilizasyon eğilimi: 15. günden itibaren 30. güne kadar duygusal tabloda bir durulma yaşanmış ve oranlar %76-78 bandına doğru kademeli bir iniş sergilemiştir.
- ✓ Geç dönem azalması: Gözlem süresinin son haftasında (52-59. günler), negatiflik düzeyi en düşük seviyeleri olan %71-73 aralığına gerilemiştir.

Bu aşığı yönlü eğilim, acil kriz aşamasından uzun vadeli iyileşme ve rehabilitasyon dönemine geçişle birlikte toplumsal psikolojide kademeli bir toparlanma olduğunu göstermektedir. Ancak, olumsuz duygu oranının tüm süreç boyunca %70 eşikinin üzerinde kalması, psikolojik stresin kronikleştikini ve bölgedeki ihtiyaçların henüz tam anlamıyla karşılanamadığını gösteren kritik bir göstergedir.

Günlük tweet hacmi, şekil 14'te gösterildiğı üzere, krizin gelişimine paralel olarak zaman içinde belirgin bir değışkenlik sergilemiştir. Sağlıkla ilgili Twitter aktivitesinin homojen bir dağılım izlemediğı, aksine belirli kırılma noktaları ve önemli tarihler etrafında kümелendiğı gözlemlenmiştir. Analiz edilen süreçteki temel hacim modelleri şu şekildedir:


- ✓ Ani artış (0. Gün): 6 Şubat tarihinde, depremin hemen ardından günlük hacim yaklaşık 200 tweet seviyesinden 400 tweet'e ani bir sıçrama yapmıştır. Bu, kriz anındaki ilk dijital tepkiyi temsil etmektedir.
- ✓ En yoğun aktivite (28-32. Günler): Depremin üzerinden bir ay geçtikten sonra, 6 Mart tarihinde tek bir günde yaklaşık 13.000 tweet ile en büyük hacim artışı yaşanmıştır. Bu olağanüstü artış, afetin birinci ay dönümünde toplumsal hafızanın ve karşılanmamış ihtiyaçların dijital mecralarda zirve yaptığını kanıtlamaktadır.
- ✓ İkincil zirve (53-59. Günler): Nisan ayı başlarında hacim yeniden yükseliş geçerek yaklaşık 11.000 tweet seviyesine ulaşmıştır. Bu durum, sağlıkla ilgili tartışmaların akut evreden uzun vadeli rehabilitasyon evresine geçişte yeni gündem maddeleriyle (yeni yerleşim yerleri, kronik sağlık sorunları vb.) canlılığını koruduğunu göstermektedir.

Bu zamansal dağılım, afet sonrası dijital gözetim sistemlerinin sadece ilk günlere odaklanmaması gerektiğini, krizin birinci ayı gibi kritik eşiklerde artan veri hacmine karşı hazırlıklı olması gerektiğini ortaya koymaktadır.

Sağlık-duygu korelasyon analizi kapsamında elde edilen veriler, afet sonrası dijital iletişim ekosisteminde sağlığın ne denli belirleyici bir paya sahip olduğunu kanıtlamaktadır. 120 sağlık odaklı anahtar kelimedenden oluşan kapsamlı bir sözlük aracılığıyla gerçekleştirilen sınıflandırma sonucunda, toplam 79.292 paylaşım “sağlıkla ilgili” ve “sağlık dışı” olmak üzere iki ana kategoriye ayrılmıştır.

Tablo 33'te sunulan istatistikler, bu dağılımın sayısal dökümünü şu şekilde özetlemektedir:

- ✓ Sağlık odaklı tweetler: %50.9 (40.378 adet)
- ✓ Sağlık dışı tweetler: %49.1 (38.914 adet)



Şekil 14. Duygu kategorilerine göre günlük tweet sayılarını gösteren zamansal analiz

Veri setindeki bu neredeyse eşit dağılım, deprem sonrası gelişen sosyal medya söyleminin yarısından fazlasının doğrudan tıbbi gereksinimler, halk sağlığı endişeleri ve tıbbi lojistik meselelerine ayrıldığını ampirik olarak doğrulamaktadır. Bu bulgu, sağlık başlığının sadece teknik bir müdahale alanı olmadığını, aynı zamanda afet müdahale söyleminin tam merkezinde yer alan en temel toplumsal öncelik olduğunu açıkça vurgulamaktadır.


Duygu analizi sonuçları, sağlık odaklı içeriklerin genel afet söyleminden duygusal ton bakımından keskin bir şekilde ayrıştığını kanıtlamaktadır. Tablo 34’te sunulan veriler, sağlıkla ilgili ve sağlık dışı tweetler arasındaki bu belirgin farkı sayısal olarak ortaya koymaktadır.

Tablo 33. Sağlıkla ilgili tweet sınıflandırması

Kategori	Sayı	Toplamın Yüzdesi
Sağlıkla İlgili	40.378	50.9%
Sağlıkla İlgili Olmayan	38.914	49.1%
Toplam	79.292	100.0%

Tablo 34. Sağlıkla ilgili duygu durumu

Kategori	Toplam	Negatif	Negatif %	Positif	Positif %
Sağlıkla İlgili	40.378	32.181	79.7%	8.197	20.3%
Sağlık Dışı	38.914	28.245	72.6%	10.669	27.4%
Fark			+7.1 pp		-7.1 pp



Şekil 15. Sağlık duygu korelasyonu karşılaştırması

Şekil 15’da yer alan karşılaştırmalı çubuk grafikler, sağlıkla ilgili paylaşımlardaki negatif duygu yoğunluğunun çok daha baskın olduğunu görselleştirmektedir. Sağlık odaklı tweetlerin, diğer afet içeriklerine göre 7.1 puan daha yüksek negatiflik sergilemesi, toplam negatiflik yaygınlığında %9.8’lik bir artışa tekabül etmektedir.

Bu durum, afet sonrası süreçte sağlık meselelerinin (ilaç eksikliği, yaralanmalar, salgın riski ve psikolojik travma) toplumda en yüksek stres, endişe ve tatminsizlik yaratan alan olduğunu ampirik olarak doğrulamaktadır. Sağlık sistemindeki tıkanıklıklar veya

karşılanmayan tıbbi ihtiyaçlar, dijital mecralara doğrudan daha yüksek bir negatif duygu yüküyle yansımaktadır.

İstatistiksel Anlamlılık Testi kapsamında gerçekleştirilen analizler, sağlık odaklı paylaşımlar ile sergilenen duygusal tepkiler arasındaki ilişkinin tesadüfi olmadığını bilimsel verilerle ortaya koymaktadır. Bağımsızlık için yapılan Ki-kare (χ^2) testi, bu iki değişken arasındaki etkileşimi şu hipotezler çerçevesinde değerlendirmiştir:

- ✓ H_0 : Duygu dağılımı, içeriğin sağlıkla ilgili olup olmasından bağımsızdır.
- ✓ H_1 : Sağlık odaklı tweetler, diğer içeriklerden farklı bir duygu dağılımı sergiler.

Analiz Sonuçları ve Yorumlama:

- ✓ $\chi^2 (1) = 555.41$
- ✓ $p < 0.001$
- ✓ Cramér's V = 0.084 (küçük etki büyüklüğü)

1 serbestlik derecesiyle elde edilen 555.41 değerindeki Ki-kare istatistiği, $p < 0.001$ sonucuyla sıfır hipotezini (H_0) reddetmek için son derece güçlü bir kanıt sunmaktadır. Bu durum, tweetin sağlıkla ilgili olmasının, taşıdığı olduğu duygusal yük üzerinde istatistiksel olarak anlamlı bir etkisi olduğunu kesinleştirmiştir.

Pratik Önem ve Etki Büyüklüğü açısından değerlendirildiğinde; her ne kadar Cramér's V (0.084) değeri teorik olarak “küçük” bir etki büyüklüğüne işaret etse de, 79.292 adetlik devasa örneklem büyüklüğü ve afet bağlamı dikkate alındığında, bulgunun pratik değeri oldukça yüksektir. Aradaki 7.1 puanlık fark; eğer sağlık içerikleri sağlık dışı konularla aynı duygu dağılımına sahip olsaydı “olumlu” etiketlenecek olan yaklaşık 2.860 ek tweetin, sağlık kategorisinde olduğu için “olumsuz” (stres, endişe, tıbbi yetersizlik sinyali) olarak gerçekleştiği anlamına gelmektedir. Bu veri, afet sonrası yönetimde sağlık başlığının neden en yüksek “negatif sinyal” üreten alan olduğunu matematiksel olarak açıklamaktadır.

Sağlık-duygu İlişkisi yorumlaması kapsamında, sağlık odaklı konular ile olumsuz duygular arasındaki anlamlı pozitif korelasyon şu temel çıkarımları desteklemektedir:

- ✓ Fizyolojik Sıkıntının Olumsuz İfadeleri Tetiklemesi: Sağlık ihtiyaçları; doğası gereği ağrı, hastalık ve yaralanma gibi olumsuz duygusal durumlar yaratan fizyolojik acılardan beslenir. Sağlıkla ilgili acil durumlar hakkında paylaşım

yapan bireylerin doğrudan fiziksel acı çekiyor olmaları veya bu duruma tanıklık etmeleri, dijital söylemde doğal bir olumsuz duygu akışı oluşturmaktadır.

- ✓ Acil Durum Çerçevelemesinin Olumsuz Dil Gereksinimi: Tıbbi yardım talepleri, durumun ciddiyetini ve müdahale ivediliğini vurgulamak adına “sıkıntı” içeren bir dil yapısını zorunlu kılar. Kan bağıışı, ilaç veya sağlık personeli arayan iletiler, harekete geçirme motivasyonunu durumun vahametini ileterek sağlar. Bu bağlamda, etkili yardım arama stratejileri doğası gereği olumsuz duyguları bir araç olarak kullanır.
- ✓ Karşılanmayan İhtiyaçların Yarattığı Hayal Kırıklığı ve Umutsuzluk: Sağlık tweetlerindeki %79.7 gibi yüksek bir olumsuzluk oranı, büyük ölçüde karşılanmamış ihtiyaçların yansımasıdır. Yeterli bakım alan bireyler “minnettarlık” (pozitif duygu) ifade ederken; gecikme, eksiklik veya reddedilme yaşayanların öfke ve umutsuzluk (olumsuz duygu) sergilemesi, bu yüksek oranın sahadaki yetersizlikleri kanıtladığını göstermektedir.
- ✓ Sistem Arızalarının Olumsuz Duygu Üretimi: Sağlık içerikli negatif duygular sadece bireysel acıları değil, aynı zamanda sistemik başarısızlıkları da yansıtmaktadır. Aşırı yüklenmiş hastaneler, ilaç kıtlığı, personel yetersizliği ve koordinasyon bozuklukları hakkındaki iletiler, içeriğin sağlıkla ilgili olmasının yanı sıra doğal olarak ağır bir olumsuz duygu yükü taşımaktadır.

Pratik uygulamada, sağlık-duygu korelasyonu, duygu analizinin sağlık sistemindeki stres seviyesini ölçen gerçek zamanlı bir gösterge olarak kullanılmasına olanak tanır. Sağlık odaklı tweetlerde gözlemlenen yüksek olumsuz duygu yoğunluğu; acil kaynak tahsisi veya ivedi müdahale gerektiren kritik alanları ve konuları doğrudan işaret etmektedir.

Model doğrulama süreci, tüm duygu kategorilerini orantılı olarak temsil eden 199 tweetlik rastgele bir örneklem grubu üzerinden gerçekleştirilmiştir. Bu aşamada, her tweet BERTurk tahminlerinden bağımsız olarak manuel olarak “temel gerçek” (ground truth) şeklinde etiketlenmiş ve elde edilen sonuçlar model tahminleriyle karşılaştırılarak sınıflandırma başarısı değerlendirilmiştir. Tablo 35’de, bu doğrulama sürecine ait temel metrikleri sunmaktadır.


Tablo 35. BERTurk doğrulama metrikleri

Metrik	Değer	Yorum
Genel Doğruluk	82.41%	Güçlü uyum
Ağırlıklı Kesinlik	82.09%	Güvenilir tahminler
Ağırlıklı Duyarlılık	82.41%	Yüksek kapsama düzeyi
Ağırlıklı F1-Skoru	82.23%	Dengeli performans
Toplam Uyum	164/199	%82.41 uyum
Toplam Uyumsuzluk	35/199	%17.59 uyumsuzluk

*n=199

Genel doğrulama performansı incelendiğinde; elde edilen %82.41 oranındaki genel doğruluk değeri, BERTurk modelinin başarısını akademik standartlara göre (%80-90 eşiği) “İYİ” kategorisine yerleştirmektedir. Bu performans düzeyi, BERTurk’ün Türkçe sosyal medya verileri üzerindeki duygu analizi kapasitesine ilişkin literatürdeki güncel çalışmalarla (Yıldırım, 2024; Köksal ve Özgür, 2021) büyük ölçüde örtüşmektedir.

Şekil 16, bu doğrulama sonuçlarını bir karışıklık matrisi (sol panel) ve metrik çubuk grafiği (sağ panel) aracılığıyla görselleştirerek; modelin hangi duygu kategorilerinde daha keskin, hangilerinde ise daha esnek tahminler yaptığını somut bir şekilde ortaya koymaktadır.



Şekil 16. Doğrulama metriklerinin görselleştirilmesi

Sınıf başına performans verileri incelendiğinde, Tablo 36’da görüldüğü üzere modelin sergilediği başarı düzeyinin duygu kategorilerine göre belirli ölçüde değişiklik gösterdiği gözlemlenmektedir:

Tablo 36. Sınıf başına doğrulama sonuçları

Sınıf	Kesinlik	Duyarlılık	F1-Skoru	Destek (n)
Negatif	87.50%	89.26%	88.37%	149
Positif	65.96%	62.00%	63.92%	50

Olumsuz duygu (F1 = %88.37): BERTurk, olumsuz duygu sınıflandırmasında mükemmel bir performans sergiledi ve gerçek olumsuz tweetlerin %89.26’sını doğru bir şekilde tanımlarken (%87.50 doğruluk oranı ile çok az sayıda yanlış pozitif sonuç verdi).

Olumlu duygu (F1 = %63.92): Olumlu duygu konusunda performans belirgin şekilde daha zayıftı; yalnızca %62.00 hatırlama (olumlu tweetlerin %38’ini kaçırma) ve %65.96 doğruluk (bazı yanlış pozitifler) elde edildi. Bu asimetri, aşağıdaki durumlarda afet bağlamında beklenir:

1. Olumsuz ifadeler daha sık görülür ve daha fazla eğitim örneği sağlar
2. Olumsuz afet dili daha tutarlı ve stereotiptir
3. Olumlu ifadeler daha nadirdir ve dilbilimsel olarak daha çeşitlidir

Olumlu duygu performansının daha düşük olmasına rağmen, %82.41’lik genel doğruluk oranı, BERTurk’ün toplu duygu eğilimlerini analiz etmek ve koşullar (ör. sağlık ve sağlık dışı, zamansal aşamalar) arasındaki dağılımları karşılaştırmak için uygun olduğunu doğrulamaktadır.

BERTurk modelinin tahmin başarılarını ve hata paylarını özetleyen karmaşıklık matrisi, Tablo 37’de detaylandırılmıştır. Söz konusu matris, modelin negatif ve pozitif sınıflar arasındaki ayrımı hangi hassasiyetle gerçekleştirdiğini gösteren temel hata modellerini sunmaktadır.

Tablo 37. Manuel etiketlemeler ve berturk tahminlerine dayalı hata matrisi karşılaştırması

	Tahmin Edilen Negatif	Tahmin Edilen Pozitif	Tahmin Edilen Nötr
Gerçek Negatif	133	16	0
Gerçek Pozitif	19	31	0
Gerçek Nötr	0	0	0

Hata kalıpları:

1. Yanlış pozitifler (n=16): Aslında negatif olan 16 tweet pozitif olarak yanlış sınıflandırılmıştır (negatiflerin %10.7'si), Olası durumlar: Karışık duygular içeren veya ironik/alaycı pozitif dil kullanılan tweetler
2. Yanlış negatifler (n=19): Aslında pozitif olan 19 tweet negatif olarak yanlış sınıflandırılmıştır (pozitiflerin %38.0'ı), Olası durumlar: Önceki acıların anlatımına yerleştirilmiş şükran ifadeleri

Asimetrik hata oranı (10.7% yanlış pozitif ve 38.0% yanlış negatif) sınıf başına performans farkını açıklamaktadır. BERTurk, negatifleri pozitif olarak yanlış sınıflandırma eğilimi göstermezken, pozitifleri negatif olarak yanlış sınıflandırma eğilimi gösterir. Bu önyargı, genel negatif duygu tahminlerini sistematik olarak şişirmedeği veya düşürmediği için bu uygulama için kabul edilebilir.

Doğrulama şunları teyit etmektedir:

- ✓ %82.41 doğruluk, genel duygu dağılımlarını, zamansal eğilimleri ve kategoriler arası karşılaştırmaları raporlamak için yeterlidir
- ✓ Negatif duygu için %88.37 F1 puanı, yüksek negatif duygu yaygınlığı ile ilgili bulguları doğrulamaktadır.
- ✓ Daha düşük pozitif duygu F1 (63.92%) değeri, kesin pozitif duygu yüzdeleri (ör. “%23.79”) $\pm$ %3-5 belirsizlikle tahminler olarak yorumlanmalıdır.
- ✓ Doğrulama, sistematik önyargının kategorileri eşit şekilde etkileyeceği için, sağlık ve sağlık dışı kategoriler ile zamansal aşamalar arasında duygu karşılaştırmalarını desteklemektedir.

Bu çalışmada elde edilen bulgular, sağlıkla ilgili tweet içeriği ile duygusal durumlar arasındaki istatistiksel ilişkileri ortaya koymaktadır; ancak bu ilişkiler nedensel olarak yorumlanmamalıdır. Analiz sonuçları, sağlık ihtiyaçlarının olumsuz duygulara neden olduğunu veya olumsuz duyguların sağlık ihtiyaçlarının ifade edilmesine yol açtığını göstermez.

Çalışmada kullanılan yöntemler kesitsel niteliktedir ve bireylerin davranışlarındaki zaman içindeki değişiklikleri veya duygusal durumlarındaki dönüşümleri izlemeye izin vermez. Ayrıca, analizler bireysel düzeyde değil, toplu metin söylem düzeyinde

gerçekleştirilmiştir. Bu nedenle, sağlıkla ilgili söylem ile olumsuz duygu yoğunluğu arasında gözlemlenen ilişki, yalnızca eşzamanlı bir ilişki olarak değerlendirilmelidir.

Bu bağlamda, çalışma afet sonrası sosyal medya söylemlerinde sağlık ihtiyaçlarının görünürlüğü ile duygusal ton arasındaki ilişkileri tanımlamayı amaçlamaktadır; bir neden-sonuç ilişkisi kurmayı iddia etmemektedir.

4.8. Makine Öğrenimi Sınıflandırma Sonuçları

Lojistik regresyon, yapılan analizler sonucunda %89.07 doğruluk oranıyla en başarılı model olarak belirlenmiştir. Tablo 38’de detaylandırıldığı üzere; altı farklı sağlık kategorisindeki F1 skorları, Anne-çocuk sağlığı alanında 0.77 ile en düşük, İlaç ve Tıbbi Malzemeler alanında ise 0.93 ile en yüksek değerine ulaşarak kategoriler arasında değişkenlik göstermektedir.

Tablo 38. Lojistik regresyon modelinin kategori bazlı sınıflandırma performansı

Sağlık Kategorisi	Örnek Sayısı	F1-Skoru	Kesinlik	Geri Çağırma
İlaç ve Malzemeler -- En İyi	n=1.082	0.93	%94	%92
Barınma ve Temel İhtiyaçlar	n=2.518	0.91	%94	%90
Ruh Sağlığı	n=1.098	0.89	%88	%90
Altyapı	n=615	0.87	%86	%89
Sağlık Hizmetleri	n=594	0.82	%79	%84

Tablo 38 (Devam)

Anne ve Çocuk Sağlığı	n=381	0.77	%73	%83
-----------------------	-------	------	-----	-----

4.8.1. Genel Model Performansı Karşılaştırması

Sağlık tweetlerinin sınıflandırılması için beş makine öğrenimi algoritması değerlendirilmiştir. Lojistik regresyon ve doğrusal SVM, sırasıyla %89.07 ve %88.92 doğruluk oranlarıyla en yüksek performansı göstermiş ve neredeyse aynı sonuçları vermiştir. Sinir Ağı %86.66 doğruluk elde ederken, Çok terimli Naif Bayes %83.52’ye ulaştı, Rastgele Orman ise %79.48 ile düşük performans gösterdi ve eğitim verilerine aşırı uyum belirtileri gösterdi.

Dengeli doğruluk (sınıf dengesizliğini hesaba katan) incelendiğinde, Lojistik Regresyon %87.86 ile üstünlüğünü korurken, onu %87.55 ile doğrusal SVM izledi. Test setindeki 6.62:1 sınıf dengesizliği göz önüne alındığında, bu metrik özellikle önemlidir, çünkü modelin sadece çoğunluk sınıflarını tahmin ederek doğru görünmesini engeller.


Tablo 39 ve Şekil 17 ve 18’de detaylandırıldığı üzere; modellerin performans karşılaştırması ve değerlendirme süreçleri şu şekilde gerçekleşmiştir.

Hesaplama verimliliği açısından, Lineer SVM 3.03 saniye ile en hızlı eğitilen model olurken, onu 1.74 saniye ile Çok Terimli Naif Bayes takip etmiştir. Diğer modellerden Rastgele Orman 119.87 saniye, Lojistik Regresyon 159.63 saniye ve Sinir Ağı 199.20 saniye eğitim süresi kaydetmiştir.


Eğitim süresinin diğer hızlı modellere kıyasla daha uzun olmasına rağmen; Lojistik Regresyon, sergilediği üstün doğruluk oranı, sonuçlarının yorumlanabilirliği ve tüm değerlendirme metriklerindeki tutarlı performansı nedeniyle en iyi model olarak seçilmiştir.

Tablo 39. Makine öğrenimi model performans karşılaştırması

Model	Doğruluk	Dengeli Doğruluk	Kesinlik	Geri Çağırma	F1 Skoru	Eğitim Süresi
Lojistik Regresyon	0.890744275	0.878604011	0.893666334	0.890744275	0.891723281	159.632336
Doğrusal SVM	0.889153944	0.875467695	0.891001635	0.889153944	0.88979036	3.034553
Sinir Ağı	0.866571247	0.838282238	0.866689694	0.866571247	0.866546314	199.198409
Multinomial Naive Bayes	0.83524173	0.817080722	0.841940646	0.83524173	0.837344283	1.735013
Rastgele Orman	0.794847328	0.806580643	0.862483985	0.794847328	0.813343465	119.873487



Şekil 17. Modellerin karşılaştırılmasına genel bakış



Şekil 18. Ayrıntılı model karışıklık matrisleri

4.8.2. Kategori Başına Performans Analizi

En iyi performans gösteren LR modeli, Tablo 40’de gösterildiği gibi altı sağlık kategorisinde farklı performanslar sergilemiştir. İlaç ve Malzemeler, 0.93 ile en yüksek F1 skorunu elde etmiş (kesinlik: 0.94, geri çağırma: 0.92) ve bu kategori için mükemmel sınıflandırma doğruluğu sergilemiştir. Barınma ve Temel İhtiyaçlar, 2.518 test örneğiyle en büyük kategori olmasının avantajıyla 0.91 F1 puanı (kesinlik: 0.94, geri çağırma: 0.90) ile onu yakından takip etti.

Ruh sağlığı ise 0.89 F1 puanı (kesinlik: 0.88, geri çağırma: 0.90) ile güçlü bir performans gösterdi ve modelin psikolojik sıkıntı ifadeleriyle ilişkili ayırt edici dilbilimsel kalıpları etkili bir şekilde öğrendiğini gösterdi. Altyapı, veri setinin yalnızca %7.8’ini

temsil etmesine rağmen 0.87 F1 puanı (kesinlik: 0.86, geri çağırma: 0.89) ile iyi bir performans gösterdi.

Sağlık hizmetleri, 0.82 F1 puanı (kesinlik: 0.79, geri çağırma: 0.84) elde ederek orta düzeyde bir performans gösterdi; bu durum, diğer sağlık kategorileriyle anlamsal örtüşmeden kaynaklanıyor olabilir. En küçük kategori olan Anne ve Çocuk Sağlığı (veri setinin %4.8'i), 0.77 F1 puanı elde etti (kesinlik: 0.73, geri çağırma: 0.83). Geri çağırma oranı saygın bir seviyedeysen, düşük kesinlik (0.73) modelin zaman zaman diğer kategorilerdeki tweetleri anne sağlığı sorunları olarak yanlış sınıflandırdığını gösterdi.

Tablo 40. Lojistik regresyon modelinin kategori bazlı performans analizi

Kategori	Kesinlik	Geri Çağırma	F1-Skoru	Destek (n)
Sağlık Hizmetleri	0.794585987	0.84006734	0.816693944	594
Altyapı	0.862341772	0.886178862	0.874097835	615
Anne Çocuk Sağlığı	0.727482679	0.826771654	0.773955774	381
İlaç_Malzemeler	0.939565628	0.919593346	0.929472209	1082
Ruh Sağlığı	0.881777778	0.903460838	0.892487629	1098
Barınma Temel İhtiyaçlar	0.935296557	0.895552025	0.914992899	2518

4.8.3. Sınıflandırma Hata Kalıpları

Karışıklık matrisi analizi, Tablo 41'da gösterildiği gibi sistematik yanlış sınıflandırma kalıplarını ortaya çıkarmıştır. Sağlık hizmetleri tweetleri bazen İlaç ve malzemeler (14 vaka), altyapı (14 vaka) ve anne ve çocuk sağlığı (10 vaka) ile karıştırılmıştır, bu da tıbbi hizmet talepleri ile ilgili kategoriler arasındaki anlamsal örtüşmeyi yansıtmaktadır.

Altyapı, diğer kategorilerle minimum düzeyde karışıklık göstermiş olup, en yüksek yanlış sınıflandırma Barınma ve Temel İhtiyaçlar (22 vaka) kategorisinde görülmüştür, zira altyapı hasarı ile barınma ihtiyaçları arasında örtüşme bulunmaktadır. Ruh sağlığı tweetleri bazen barınma ve temel İhtiyaçlar (36 vaka) olarak yanlış sınıflandırılmış olup, bu durum barınma güvensizliği ile ilgili psikolojik sıkıntıyı ifade eden tweetlerin varlığını teyit etmektedir.

İlaç ve malzemeler kategorisi, 1.082 örnekten sadece 88'inde yanlış sınıflandırma ile (yüzde 91.9 doğruluk) güçlü bir ayırım sergilemiştir. En büyük karışıklık sağlık hizmetleri kategorisinde (36 vaka) meydana gelmiştir, ancak tıbbi malzemeler ile sağlık hizmeti sunumu arasındaki anlamsal ilişki göz önüne alındığında bu kabul edilebilir bir durumdur.

Tablo 41. Sınıflandırma hata kalıpları

	Sağlık Hizmetleri	Altyapı	Anne Çocuk Sağlığı	İlaç Malzemeler	Ruh Sağlığı	Barınma Temel İhtiyaçlar
Sağlık Hizmetleri	499	12	14	10	24	35
Altyapı	15	545	13	5	15	22
Anne Çocuk Sağlığı	12	6	315	11	10	27
İlaç Malzemeler	18	6	14	995	13	36
Ruh Sağlığı	28	9	18	15	992	36
Barınma Temel İhtiyaçlar	56	54	59	23	71	2255

4.8.4 Sağlıkla İlgili İçerik Sınıflandırması için Makine Öğrenimi Model Performansı

Aşağıdaki şekil 19’de görüldüğü gibi, beş modele de bir ROC Eğrisi Analizi yapılmıştır. Bu analiz, ikili sağlık içeriği sınıflandırması için beş makine öğrenimi algoritmasını karşılaştıran Alıcı Çalışma Karakteristiği (ROC) eğrilerini göstermektedir. ROC eğrisi, tüm olası sınıflandırma eşiklerinde duyarlılık (Gerçek pozitif oran) ve özgüllük (1 - Yanlış pozitif oran) arasındaki dengeyi görselleştirir.


Model performans sıralaması: Beş modelin tümü “Mükemmel” kategorisinde (AUC > 0.90) performans göstererek, Türkçe depremle ilgili tweetlerde otomatik sağlık içeriği algılamının uygulanabilirliğini kanıtlamıştır:

- ✓ Lojistik regresyon (AUC = 0.9512) - En iyi performans
- ✓ Doğrusal SVM (AUC = 0.9489) - İkinci en iyi
- ✓ Rastgele orman (AUC = 0.9234) - Üçüncü
- ✓ Sınır ağı (AUC = 0.9167) - Dördüncü
- ✓ Çok terimli Naive Bayes (AUC = 0.8912) - En düşük ancak yine de mükemmel

Diagonal kesikli çizgi ise rastgele sınıflandırıcıyı (AUC = 0.5000) temsil eder ve tüm modellerin rastgele tahminlerden önemli ölçüde daha iyi performans gösterdiğini gösterir. Sol üst bölgedeki (yeşil ile vurgulanmış) eğrilerin sıkı kümelenmesi, tüm algoritmalarda tutarlı ve mükemmel performans olduğunu ve ayırt edici yeteneklerinde sadece marjinal farklılıklar olduğunu gösterir.

Daha basit modellerin (Lojistik Regresyon, Doğrusal SVM) güçlü performansı, sağlıkla ilgili içeriğin karmaşık doğrusal olmayan modelleme gerektirmeyen dilbilimsel özellikler içerdiğini göstermektedir. Bu da, temel ihtiyaçlar sözcük dağarcığının tüm sağlık

kategorilerine yayıldığı anlamına gelir ve bu da gerçek dünyadaki kriz izleme sistemlerinde hesaplama verimliliği ve model yorumlanabilirliği açısından önemli sonuçlar doğurur.



Şekil 19. Modellerin roc eğrisi analizi ve karşılaştırılması

4.8.5. İkili Sınıflandırma Performansı (Lojistik Regresyon)


Şekil 20’de sunulan Karışıklık Matrisi verilerine göre; dengesiz bir test setinde Lojistik Regresyon (LR) modeli kullanılarak yapılan ikili (sağlık ve sağlık dışı) sınıflandırma analizinde (N=17.615), model oldukça güçlü performans metrikleri sergilemiştir:

- ✓ Genel Doğruluk: %89.34
- ✓ Kesinlik (Sağlık): %83.43 - Sağlık odaklı olduğu tahmin edilen her 100 tweetten yaklaşık 83’ü doğru sınıflandırılmıştır.
- ✓ Duyarlılık / Geri Çağırma (Sağlık): %87.52 - Model, veri setindeki gerçek sağlık tweetlerinin %87.52’sini başarıyla yakalamıştır.
- ✓ F1 Puanı: 0.854 - Kesinlik ve duyarlılık arasında dengeli ve yüksek bir performans elde edilmiştir.

Hata Analizi kapsamında, modelin sınıflandırma sürecinde ortaya çıkan sapmalar afet yönetimi perspektifinden şu şekilde değerlendirilmektedir:

Yanlış pozitifler (Tip I Hata): 1.093 Tweet (%9.6) Model, aslında sağlıkla ilgili olmayan 1.093 iletiyi yanlışlıkla “sağlık” kategorisinde işaretlemiştir. Afet durumlarında bu tür bir “aşırı tahmin”, kritik bir sağlık vakasını gözden kaçırma riskine (Yanlış Negatif) kıyasla daha kabul edilebilir bir hata türüdür; zira yanlış alarmlar, gerçek bir acil durumun ıskalanmasından daha az maliyetlidir.

Yanlış negatifler (Tip II Hata): 785 Tweet (%12.5) Model, gerçekte sağlıkla ilgili olan 785 iletiyi tespit edemeyerek gözden kaçırmıştır. Bu durum, fark edilemeyen tıbbi ihtiyaçların acil müdahaleyi geciktirme potansiyeli taşıması nedeniyle “daha kritik” bir hata türü olarak tanımlanmaktadır.



Şekil 20. İkili sağlık sınıflandırması için karışıklık matrisi

5. SONUÇLAR

Bu bölümde, temel araştırma sorularına verilen yanıtlar ve elde edilen bulgular bütünsel bir perspektifle özetlenmektedir. Yürütülen analizler, sosyal medya verilerinin afet sonrası sağlık ihtiyaçlarının değerlendirilmesinde güçlü ve gerçek zamanlıya yakın bir tamamlayıcı araç olduğunu ampirik olarak kanıtlamıştır; bu kapsamdaki araştırma çıktıları ve pratik çıkarımlar Tablo 42’de detaylandırılmıştır.

Tablo 42. Araştırma soruları, bulgular ve pratik çıkarımlar

Araştırma Sorusu	Temel Bulgu	Pratik Etki
AS-1: Hangi sağlık konuları tartışıldı?	5 LDA + 59 BERTopic; Hijyen $b=0.3326$	WASH altyapısı önceliklendirilmeli
AS-2: Duygu-sağlık ilişkisi nasıl?	%79.7 negatif; 7.1 puan fark ($p<0.001$)	Duygu analizi = erken uyarı sistemi
AS-3: İhtiyaçlar zamanla nasıl değişti?	3 aşama: Travma → WASH → Kronik bakım	Aşamalı müdahale stratejisi gerekli
AS-4: Sağlık tweetleri sınıflandırılabilir mi?	LR %89.07; 6 kategoride $F1=0.77-0.93$	Otomatik gerçek zamanlı izleme mümkün
Sınırlılıklar	Yalnızca Türkçe; 60 gün; Twitter’a özgü	Çok dilli genişleme önerilir

Bu çalışma, 6 Şubat 2023 Kahramanmaraş depremlerinin ardından deprem sonrası sağlık ihtiyaçlarını sistematik olarak belirlemek, sınıflandırmak ve analiz etmek için LDA, BERTopic ve duygu analizini Türkçe sosyal medya verileriyle birleştiren çok yöntemli bir hesaplama çerçevesinin yararını başarıyla göstermiştir. Ortaya konulan araştırma soruları kapsamlı bir şekilde ele alınmış ve üç temel sonuç ortaya çıkmıştır:

1. Analiz, uluslararası insani yardım standartlarıyla (WHO’nun EMT ve SPHERE) tutarlı bir şekilde uyumlu, net ve veriye dayalı bir sağlık ihtiyaçları sınıflandırması sağlamıştır. Tematik yapı, sosyal medya söylemlerinin neredeyse yarısının insani yardım koordinasyonuna odaklandığını, ancak en önemli acil sağlık ihtiyacının hijyen ($\beta=0.3326$) olduğunu ortaya koydu. Bu da, felaketin hemen ardından hasar gören su, sanitasyon ve hijyen (WASH) altyapısının oluşturduğu kritik halk sağlığı risklerini doğruladı (Balikuddembe vd., 2024: 945, Koçer vd., 2024: 1-14). Buna ek olarak, zamansal analiz, sağlık ihtiyaçlarının öngörülebilir aşamalardan geçerek, acil tıbbi hizmetlerden (0-3. günler) sürdürülebilir halk sağlığı ihtiyaçlarına (4-14.

günler) ve son olarak geçici barınma ve sosyal bakıma (15. gün ve sonrası) doğru ilerlediğini doğruladı (Laosunthara vd., 2025: 87-96).

2. Sağlıkla ilgili söylemler ile olumsuz duygular arasında istatistiksel olarak anlamlı bir korelasyon bulunmuştur. Sağlıkla ilgili tweetler, sağlıkla ilgili olmayan tweetlere (72.6%) kıyasla 7.1 puan (79.7%) daha yüksek olumsuz duygu içeriğine sahiptir ($p < 0.001$). Bu sonuç, duygu analizinin sağlık sistemi stresi ve karşılanmamış ihtiyaçların yaygınlığı için müdahaleci olmayan, gerçek zamanlı bir gösterge olarak kullanılmasının geçerliliğini doğrulamakta ve belirli sağlık konularına odaklanan yüksek olumsuz duyguların kaynak tahsisi için erken uyarı sinyali olarak hizmet edebileceğini göstermektedir (Hossain vd., 2025: 79–94).
3. Çalışma, sağlık ihtiyaçlarını otomatik olarak sınıflandırmak için makine öğreniminin kullanılmasının uygulanabilirliğini doğrulamıştır. Ancak, hesaplamalı yöntemler sağlıkla ilgili içeriği filtrelemede oldukça etkili olsa da, doğru ihtiyaç değerlendirmesi için metodolojinin daha da geliştirilmesi gerekmektedir.

Sonuç olarak, bu çalışma, sağlık ihtiyaçlarını neredeyse gerçek zamanlı olarak değerlendirmek için dile özgü, doğrulanmış bir çerçeve sağlayarak kriz bilişimine katkıda bulunmakta ve sosyal medya analizinin, uyarlanabilir ve duyarlı afet yönetimi stratejilerine rehberlik etmek için daha yavaş geleneksel değerlendirme yöntemlerini etkili bir şekilde tamamlayabileceğini göstermektedir.

5.1. Çalışmanın Epistemolojik Kapsamı ve Metodolojik Sınırları

Bu çalışma, afet sonrası sağlık ihtiyaçlarını nesnel gerçekliğin doğrudan bir temsili olarak değil, sosyal medyada görünen söylemler aracılığıyla algılanan ve ifade edilen ihtiyaçlar bağlamında ele almaktadır. Bu bakımdan, araştırma, sağlık ihtiyaçlarının kapsamı veya yaygınlığı konusunda kesin nicel tahminler üretmeyi değil, afet sonrası dönemde hangi sağlık temalarının hangi bağlamlarda ve ne yoğunlukta ifade edildiğini ortaya koymayı amaçlamaktadır.

Kullanılan sosyal medya verileri, afet bölgesindeki tüm bireyleri kapsayan temsili bir örneklem sağlamamaktadır. Twitter verileri dijital erişimi olan kullanıcıların söylemlerini yansıttığı için, bu çalışmanın bulguları nüfus düzeyinde genelleştirilebilir olduğunu iddia etmemektedir. Bu nedenle, elde edilen sonuçlar resmi istatistikleri veya saha temelli ihtiyaç

analizlerini ikame etmekten ziyade, erken uyarı niteliğinde bilgi üreten tamamlayıcı unsurlar olarak değerlendirilmelidir.

Metodolojik olarak, çalışmada kullanılan LDA ve BERTopic modelleri, keşifsel bir şekilde tematik yapıları ortaya çıkarır ve önceden tanımlanmış kategorileri doğrulamayı amaçlamaz. Bu modeller tarafından üretilen temalar istatistiksel olarak “gerçek” kategoriler değildir; metin verileri içindeki anlamsal kalıpların olasılıksal temsilleridir. Benzer şekilde, duygu analizi sonuçları, bireylerin gerçek psikolojik durumlarını ölçmek için değil, afet sonrası söylemin genel duygusal tonunu tanımlamak için kullanılmıştır.

Denetimli makine öğrenimi modelleri, sağlıkla ilgili içeriğin otomatik olarak sınıflandırılabilirliğini test etmeyi amaçlayan operasyonel bir değerlendirme sağlar ve bireysel kullanıcı davranışlarını veya ihtiyaçlarını tahmin etmeyi amaçlamaz. Bu bağlamda, çalışma tahminsel bir çerçeve yerine tanımlayıcı ve destekleyici bir analitik çerçeveye sahiptir.

Sonuç olarak, bu çalışma afet sonrası sağlık ihtiyaçları açısından “ne olduğu” yerine “nasıl ifade edildiği ve hangi temaların görünürlük kazandığı” sorusuna cevap aramaktadır. Çalışmanın epistemolojik sınırlamaları, bulguların yorumlanmasında bilinçli olarak dikkate alınmıştır; aşırı genelleme, nedensel çıkarım ve bireysel düzeyde yorumlardan özellikle kaçınılmıştır.

5.2. Sağlık İhtiyaçları Sınıflandırmasının Yorumlanması

LDA ve BERTopic modellemesinin uygulanması, Twitter’da tartışılan sağlıkla ilgili konuları belirleyip kategorize ederek ilk araştırma sorusunu başarıyla ele almıştır. 0.4267’lik bir tepe tutarlılık puanı ile doğrulanmış LDA modelinin beş konulu yapısı, afet sonrası söylemin net bir hiyerarşisini ortaya koymuştur.

Yardım Standartlarıyla Uyum kapsamında belirlenen konuların tematik yapısı; Tablo 43’te gösterildiği üzere, DSÖ (WHO) Acil Tıp Ekibi (EMT) sınıflandırmaları ve SPHERE Standartları gibi yerleşik uluslararası insani yardım çerçeveleriyle güçlü bir uyum sergilemektedir.

Bu uyum, modelin sadece teknik bir başarı sergilemekle kalmadığını, aynı zamanda üretilen verilerin küresel yardım protokollerine doğrudan entegre edilebileceğini ve operasyonel bir karşılığının olduğunu kanıtlamaktadır.

Table 43. İnsani yardım standartlarıyla uyumlu LDA konuları

Konu	Tema Etiketleri	Corpus Oranı (%)	Uyumlu İnsani Yardım Standardı	Temel Bulgu
Konu 1	Acil Tıbbi Hizmetler ve Arama Kurtarma	13.37%	WHO ACT Tip 1 Mobil	Acil hayat kurtarma müdahalelerine ve travma bakımına odaklanma.
Konu 3	Halk Sağlığı Temelleri	14.94%	SPHERE WASH ve Gıda Güvenliği	Hijyen teriminin istisnai β ağırlığı ($\beta=0.3326$).
Konu 4	Geçici Barınma ve Sosyal Refah	12.99%	SPHERE Barınma ve Beslenme	Kalıcı barınma çözümlerine ve sağlığın sosyal belirleyicilerine odaklanma.
Konu 0	İnsani Yardım Koordinasyonu	46.64%	Koordinasyon Altyapısı	Organizasyonel süreçlerin doğrudan ihtiyaçların önüne geçmesi.

Konu modellemesinden elde edilen en önemli bulgu, tüm modelde en yüksek β ağırlığına sahip olan Konu 3'te hijyenin olağanüstü önemi. Bu bulgu, afet sonrası sağlık öncelikleri ile ilgili literatürü güçlü bir şekilde doğrulamaktadır. Bu literatür, yerinden edilme durumlarında sağlığın kritik belirleyicisi olarak Su, Sanitasyon ve Hijyen (WASH) konularını tutarlı bir şekilde vurgulamaktadır (Balikuddembe vd., 2024: 945, Koçer vd., 2024: 1-14). Hijyenle ilgili söylemlerin yüksek prevalansı, su ve sanitasyon sistemlerinin tahrip olmasının hastalık bulaşma riskini artırdığı etkilenen bölgelerde altyapı hasarı ve halk sağlığı riskinin kritik kesişimini yansıtmaktadır. Bu bulgu, Balikuddembe ve ark. (2024: 945) tarafından yapılan kapsamlı incelemeyle tutarlıdır. Bu inceleme, insani sağlık yardımı ve tıbbi bakımı deprem sonrası en öncelikli sağlık hizmetleri olarak belirlemiştir.

Buna göre, metinlerin neredeyse yarısını (46.64%) oluşturan Konu 0'ın (İnsani Yardım Koordinasyonu) baskınlığı, kriz durumlarında sosyal medyanın ikili işlevini vurgulamaktadır: sosyal medya, sadece doğrudan ihtiyaçların iletilmesi için bir kanal olarak değil, aynı zamanda otomatik ihtiyaç tespit sistemleri oluşturarak örgütsel koordinasyon için bir platform olarak da işlev görmektedir.

5.3. Duygu ve Sağlık İhtiyaçları Arasındaki Korelasyon

BERTurk modelini kullanan duygu analizi, ikinci araştırma sorusuna net bir cevap vermiş ve sağlıkla ilgili konular ile olumsuz duygular arasında önemli bir korelasyon olduğunu ortaya koymuştur. Sağlıkla ilgili tweetler, sağlıkla ilgili olmayan tweetlere kıyasla %7.1 puan daha yüksek olumsuz duygu (79.7%) sergilemiştir. Bu bulgu, sağlık ihtiyaçlarının ifade edilmesinin çeşitli nedenlerle olumsuz duygularla doğal olarak

bağlantılı olduğunu öne süren, yerleşik afet psikolojisi ve iletişim literatürü ile uyumludur. Bu nedenler şunlardır:

- ✓ Fizyolojik Sıkıntı: Sağlık ihtiyaçları genellikle fiziksel acıdan (ağrı, yaralanma, hastalık) kaynaklanır ve bu da doğal olarak olumsuz duygusal durumlar yaratır (Akçay vd., 2024: 519–530).
- ✓ Acil durum çerçevesi: Acil tıbbi yardım talepleri, ciddiyeti iletmek ve acil müdahaleyi teşvik etmek için olumsuz bir dil kullanmalıdır. Kriz bağlamında etkili yardım arama dilbilgisi yapısı, doğası gereği sıkıntı sinyallerini kullanır (Hossain vd., 2025: 79–94).
- ✓ Karşılanmamış İhtiyaçlar: Sağlıkla ilgili söylemlerdeki sürekli yüksek olumsuz duygu (79.7%), muhtemelen yaygın olarak karşılanmamış sağlık ihtiyaçlarını ve sağlık müdahalesindeki eksiklikler, gecikmeler veya sistemik başarısızlıklardan kaynaklanan hayal kırıklığını yansıtmaktadır. Bu, 2023 depremlerinin ardından belgelenen yaygın bir sorundur (Froeschl vd., 2025: 1-10).

Bu korelasyon, sağlık sistemindeki stresi gösteren değerli bir gerçek zamanlı gösterge olarak işlev görebilir. Belirli sağlık konularında yoğunlaşan yüksek olumsuz duygu, acil kaynak tahsisi veya müdahale gerektiren alanları işaret ederek geleneksel ihtiyaç değerlendirme yöntemlerini tamamlar.

5.4. ML Sınıflandırmasının Uygulanabilirliği

ML sonuçları, Türkçü tweetlerden sağlık ihtiyaçlarını sınıflandırmanın fizibilitesini doğruladı ve aynı zamanda kriz bağlamında doğru sınıflandırmanın doğasında var olan zorlukları da vurguladı.

İkili sınıflandırmada elde edilen yüksek doğruluk oranı (%89.34), ML modellerinin sağlıkla ilgili içeriği genel afet söyleminden güvenilir bir şekilde ayırt edebildiğini göstermektedir. Ancak, çok sınıflı kategorizasyon yüksek genel doğruluk (%89.07) elde etmesine rağmen, kategori bazında analiz özellikle Anne ve Çocuk Sağlığı ($F1=0.77$) gibi özel sağlık ihtiyaçlarını ayırt etmede zorluklar olduğunu ortaya koymuştur. Karışıklık matrisi analizine gelince; bu analiz, özellikle Anne ve Çocuk Sağlığı gibi özel ihtiyaçlar için “Barınma ve Temel İhtiyaçlar” kategorisine yönelik sistematik bir yanlış sınıflandırma olduğunu ortaya koydu. Bu da, akut acil durumlarda temel fizyolojik ihtiyaçların (barınma,

gıda, hijyen) özel ihtiyaçların önüne geçtiği Maslow’un ihtiyaçlar hiyerarşisi teorisiyle de uyumludur (Maslow, 1943: 370–396). Temel ihtiyaçlar ile özel sağlık ihtiyaçları arasındaki dilbilimsel örtüşme (örneğin, “bebek maması” talebinin “Anne ve Çocuk Sağlığı” yerine “gıda/temel ihtiyaç” olarak sınıflandırılması), gelecekteki çalışmalarda, ihtiyaçları genellikle hayatta kalma konusundaki baskın söylem tarafından gizlenen savunmasız nüfus gruplarının tespitini iyileştirmek için daha spesifik öğrenme yaklaşımlarının kullanılması gerektiğini göstermektedir.

5.5. İhtiyaçların Zamansal Evrimi

Konu yaygınlığının zamansal analizi, afet aşamaları boyunca ihtiyaçların beklenen gelişimini izlemek için bir araç olarak çalışma metodolojisini güçlü bir şekilde doğruladı. Baskın konuların sistematik değişimi - ilk 72 saatte zirveye ulaşan Acil Tıp (Konu 1) konusundan, 7. gün civarında zirveye ulaşan Halk Sağlığı (Konu 3) konusuna ve son olarak 21. gün civarında zirveye ulaşan Geçici Barınma (Konu 4) konusuna - afet durumlarında sağlık önceliklerinin ilerleyişini ideal bir şekilde yansıtmaktadır (WHO, 2013). Hayat kurtarmadan hastalık önlemeye ve ardından uzun vadeli iyileşme/barınmaya geçiş, Laosunthara vd. (2025: 87-96) tarafından önerilen afet yönetimi döngüsüyle tutarlı olan temel bulgulardan biridir.

Bu zamansal model, sosyal medya izleme sistemlerinin, afet başlangıcından bu yana geçen süreye göre anahtar kelime önceliklerini ve sınıflandırmayı ayarlayarak ve halk sağlığı ihtiyaçlarındaki değişiklikleri öngörerek daha doğru ve operasyonel olarak daha uygun hale getirilebileceğini göstermektedir.

5.6. Öneriler

Bu çalışma kapsamında elde edilen bulgular, afet yönetimi süreçlerinin dijital verilerle desteklenmesi ve gelecekteki akademik çalışmaların metodolojik derinlik kazanması için bir dizi stratejik öneri sunmaktadır.

5.6.1. Afet Yönetimi için Pratik Öneriler

Afet anında ve sonrasında karar vericilerin daha veri odaklı ve etkin müdahalelerde bulunabilmesi adına aşağıdaki adımların atılması önerilmektedir:

- ✓ Sağlık sistemi üzerindeki baskının bir göstergesi olarak duyguları dahil edin: Afet yönetimi yetkilileri, duygu analizini sosyal medya panellerine dahil etmelidir. Özellikle sağlıkla ilgili konularda (örneğin, “ilaç kıtlığı” ve “hastane kapasitesi”) olumsuz duyguların ani bir artış olması, etkilenen bölgedeki kaynak tahsisi ve tedarik zinciri lojistiğinin derhal gözden geçirilmesini tetiklemelidir.
- ✓ Sanitasyon, hijyen ve temel iletişim ihtiyaçlarına öncelik verin: Hijyen mesajlarının kritik önemi göz önüne alındığında, sosyal medyadaki halk sağlığı kampanyaları, ikincil hastalık salgınları riskini azaltmak için geçici yerleşim yerlerinde güvenli su, sanitasyon ve hijyen uygulamaları hakkında doğru bilgileri proaktif olarak yaymalıdır.
- ✓ Aşamalı bir izleme yaklaşımı benimseyin: Sosyal medya izleme sistemleri, afetten bu yana geçen süreye göre dinamik olarak ayarlanmalıdır. Sistem, ilk 72 saatte acil tıbbi ihtiyaçlarla ilgili anahtar kelimeleri ve sınıflandırma modellerini önceliklendirmeli, ardından ilk iki hafta içinde halk sağlığı/su, sanitasyon ve hijyene odaklanmalı ve daha sonra iyileşme aşamasında barınma, ruh sağlığı ve kronik hastalık yönetimine geçmelidir.
- ✓ Savunmasız gruplar için hedefli izleme geliştirmek: Savunmasız grupların ihtiyaçlarının (örneğin anne ve çocuk sağlığı) dilsel kamuflejini aşmak için özel sınıflandırma modelleri geliştirilmelidir. Bu, düşük hacimli, kritik ihtiyaçların gözden kaçmaması için özel, açıklamalı Türkçe dil setleri gerektirir.

5.6.2. Gelecekteki Araştırmalar için Akademik Öneriler

Afet bilişimi (disaster informatics) alanındaki literatürü geliştirmek ve teknik kapasiteyi artırmak amacıyla gelecek çalışmalarda şu hususlara odaklanılması faydalı olacaktır:

- ✓ Hiyerarşik modeller kullanarak çoklu kategori sınıflandırmasını iyileştirme: Gelecekteki araştırmalar, önce sağlıkla ilgili içeriği (ikili) filtreleyen ve ardından alt kategoriler için özel ve doğru bir sınıflandırıcı uygulayan hiyerarşik sınıflandırma modellerini araştırmalıdır. Maliyet duyarlı öğrenme yaklaşımları, düşük hacimli kritik kategoriler için yanlış negatif sonuçları yanlış pozitif sonuçlardan daha ağır şekilde cezalandırmak için kullanılmalıdır.

- ✓ Çapraz platform ve çapraz dil analizi: Tek platform ve tek dil analizinde var olan önyargıyı azaltmak için çerçevenin kapsamı diğer sosyal medya platformlarını (ör. Telegram ve Facebook) ve diğer bölgeyle ilgili dilleri (ör. Arapça ve Kürtçe) içerecek şekilde genişletilmelidir.
- ✓ Uzun vadeli ruh sağlığı ihtiyaçlarının değerlendirilmesi: Gelecekteki çalışmalar, gözlem süresini akut aşamanın ötesine uzatarak, ilk olaydan aylar sonra zirveye ulaştığı bilinen ruh sağlığı ihtiyaçlarının gelişimini sistematik olarak izlemelidir. Bu, travma sonrası stres bozukluğu (PTSD), anksiyete ve depresyonun ince belirtilerini tespit etmek için özel ölçekler ve modellerin kullanılmasını içerebilir.
- ✓ Konu modelleme yaklaşımlarının karşılaştırmalı çalışması: Belirli bir araştırma veya operasyonel hedefe dayalı olarak uygun konu modelleme tekniğini seçmek için en iyi uygulamaları belirlemek amacıyla, afet bağlamında LDA (genel konular) ve BERTopic (ayrıntılı konular) tekniklerinin operasyonel sonuçlarını karşılaştırmak için özel bir çalışma yapılması gerekmektedir.

5.7. Sınırlamalar

Bu çalışma kapsamlı ve sağlam bulgular sunmakla birlikte, sonuçların değerlendirilmesinde dikkate alınması gereken bazı sınırlamalara sahiptir:

- ✓ Halka açık Twitter verilerine dayanmak, internet erişimi olmayan veya platformu kullanmayan nüfusun sesini dışladığı için potansiyel bir önyargı taşır.
- ✓ İki aylık zaman aralığı akut ve stabilizasyon aşamalarını kapsasa da, aylar veya yıllar sonra ortaya çıkan uzun vadeli iyileşme ve ruh sağlığı ihtiyaçlarını tam olarak temsil etmemektedir.
- ✓ Ayrıca, Türk para biriminin karmaşıklığı ve sosyal medya verilerindeki doğal gürültü (spam ve yanlış bilgi), doğal dil işleme modelleri için sürekli zorluklar oluşturmaktadır.
- ✓ Bu çalışmada bildirilen duygu analizi bulguları, sağlıkla ilgili söylemler ile duygusal durum arasındaki ilişkileri tanımlamakta olup, nedensel çıkarımlara izin vermemektedir.

KAYNAKÇA

- Adepoju, O. E. (2025). Not “woke” agendas, basic human rights: Reimagining disaster preparedness through Maslow’s lens. *Frontiers in Public Health*, 13, 1-3. <https://doi.org/10.3389/fpubh.2025.1533117>.
- Ağralı, Ö., Sökün, H. ve Karaarslan, E. (2022). Twitter Data Analysis: Izmir Earthquake Case. *Journal of Emerging Computer Technologies*, 2(2), 36–41. <https://dergipark.org.tr/en/pub/ject/issue/72547/1158830>
- Akçay, S., Beydili Gürbüz, E. ve Koca, E. (2024). Trauma levels after the 2023 Kahramanmaraş earthquakes in Türkiye. *Journal of Social Service Research*, 50(4), 519–530. <https://doi.org/10.1080/01488376.2024.2339967>
- Akın, A. A., ve Akın, M. D. (2007). Zemberek: An open source NLP framework for Turkic languages, 1-8.
- Aktuna, G. ve Bahar-Özvarış, Ş. (2023). Investigating the aftermath of the Türkiye 2023 earthquake: Exploring post-disaster uncertainty among Syrian migrants using social network analysis with public health approach. *Frontiers in Public Health*, 11, 1204589, 1-13. <https://doi.org/10.3389/fpubh.2023.1204589>
- Aldamen, Y. ve Hacimi, E. (2023). Positive determinism of Twitter usage development in crisis communication: Rescue and relief efforts after the 6 February 2023 earthquake in Türkiye as a case study. *Social Sciences*, 12(8), 436, 1-37. <https://doi.org/10.3390/socsci12080436>
- Allahyari, M., Pouriyeh, S., Assefi, M., Safaei, S., Trippe, E. D., Gutierrez, J. B. ve Kochut, K. (2017). A brief survey of text mining: Classification, clustering and extraction techniques. In *Proceedings of the 2017 ACM International Conference on Knowledge Discovery and Data Mining (KDD 2017)*, 1–13. <https://doi.org/10.48550/arXiv.1707.02919>
- Anthony, P. ve Zhou, J. (2025). Leveraging transformer with self-attention for multi-label emotion classification in crisis tweets. *Informatics*, 12(114), 1-18. <https://doi.org/10.3390/informatics12040114>

- Antonakaki, D., Fragopoulou, P. ve Ioannidis, S. (2021). A survey of Twitter research: Data model, graph structure, sentiment analysis and attacks. *Expert Systems with Applications*, 164, 114006, 1-2. <https://doi.org/10.1016/j.eswa.2020.114006>
- Arvandi, A., Rokne, J. ve Alhajj, R. (2024). Twitter analysis in emergency management: recent research and trends. *Social Network Analysis and Mining*, 14, 154, 1-19. <https://doi.org/10.1007/s13278-024-01308-8>
- Aslan, S. ve Yildirim, M. (2025). A novel attention-based deep learning model for improving sentiment classification after the case of the 2023 Kahramanmaraş/Turkey earthquake on Twitter. *PeerJ Computer Science*, 11, 1-18. <https://doi.org/10.7717/peerj-cs.2881>
- Ataş, M., Yeşilnacar, M. İ. ve Demir Yetiş, A. (2022). Novel machine learning techniques based hybrid models (LR-KNN-ANN and SVM) in prediction of dental fluorosis in groundwater. *Environmental Geochemistry and Health*, 44, 3891–3905. <https://doi.org/10.1007/s10653-021-01148-x>
- Auxier, B. ve Anderson, M. (2021, April 7). *Social media use in 2021*. Pew Research Center. <https://www.pewresearch.org/internet/2021/04/07/social-media-use-in-2021/>
- Babayigit, B. ve Sattuf, H. (2025). BERT-based keyword extraction model for the Turkish language. *Neural Computing and Applications*, 37, 9807–9819. <https://doi.org/10.1007/s00521-025-11103-x>
- Bai, H. ve Yu, G. (2016). A Weibo-based approach to disaster informatics: Incidents monitor in post-disaster situation via Weibo text negative sentiment analysis. *Natural Hazards*, 83(2), 1177–1196. <https://doi.org/10.1007/s11069-016-2370-5>
- Balikuddembe, J. K., Reinhardt, J. D., Vahid, G. ve Di, B. (2024). A scoping review of post-earthquake healthcare for vulnerable groups of the 2023 Turkey-Syria earthquakes. *BMC Public Health*, 24, 945, 1-15. <https://doi.org/10.1186/s12889-024-18395-z>
- Beauchesne, Ann M. (2001). A governor's guide to emergency management. Volume one, Natural disasters.
- Behl, S., Rao, A., Aggarwal, S., Chadha, S. ve Pannu, H. S. (2021). Twitter for disaster relief through sentiment analysis for COVID-19 and natural hazard crises.

- International Journal of Disaster Risk Reduction*, 55, 102101, 1-13.
<https://doi.org/10.1016/j.ijdr.2021.102101>
- Bosmans, M. W. G., Baliatsas, C., Yzermans, C. J. ve Dückers, M. L. A. (2022). A systematic review of rapid needs assessments and their usefulness for disaster decision making: Methods, strengths and weaknesses and value for disaster relief policy. *International Journal of Disaster Risk Reduction*, 71, 1-16.
<https://doi.org/10.1016/j.ijdr.2022.102807>
- Boztepe, E. B., Karakaya, B., Karasulu, B. ve Ünlü, İ. (2022). An approach for audio-visual content understanding of video using multimodal deep learning methodology. *Sakarya University Journal of Computer and Information Sciences*, 5(2), 181-207.
<https://doi.org/10.35377/saucis.05.02.1139765>
- Bruns, A. ve Burgess, J. (2012). Local and global responses to disaster: #eqnz and the Christchurch earthquake. Proc. of the 2012 Australian and New Zealand Disaster and Emergency Management Conference. AST Management Pty Ltd, ss. 86-103.
- Budur, E., Özçelik, R., Güngör, T. ve Potts, C. (2020). Data and representation for Turkish natural language inference. Proc. of the 2020 Conference on Empirical Methods in Natural Language Processing. Association for Computational Linguistics, ss. 8253-8267.
- Caillaut, G., Auclair, S., Gracianne, C., Abadie, N. ve Touya, G. (2024). Entity linking for real-time geolocation of natural disasters from social network posts. *PLOS ONE*, 19(10), 1-29. <https://doi.org/10.1371/journal.pone.0307254>
- Cao, J., Xia, T., Li, J., Zhang, Y. ve Tang, S. (2009). A density-based method for adaptive LDA model selection. *Neurocomputing*, 72(7-9), 1775-1781.
<https://doi.org/10.1016/j.neucom.2008.06.011>
- Caragea, C., McNeese, N., Jaiswal, A., Traylor, G., Kim, H.-W., Mitra, P., Wu, D., Tapia, A. H., Giles, L., Jansen, B. J. ve Yen, J. (2011). Classifying text messages for the Haiti earthquake. Proc. of the 8th International ISCRAM Conference. ISCRAM, ss. 1-10.
- Caragea, C., McNeese, N., Jaiswal, A., Traylor, G., Kim, H.-W., Mitra, P., Wu, D., Tapia, A. H., Giles, L., Jansen, B. J. ve Yen, J. (2011). Classifying text messages for the

- Haiti earthquake. Proc. of the 8th International ISCRAM Conference. ISCRAM, ss. 1-10.
- Çelikten, A. ve Bulut, H. (2021). Turkish medical text classification using BERT. In *2021 29th Signal Processing and Communications Applications Conference (SIU)*. <https://doi.org/10.1109/SIU53274.2021.9477847>
- Çetin, K. O., Ilgac, M., Can, G. ve Çakir, E. (Eds.). (2023). Preliminary reconnaissance report on February 6, 2023, Pazarcık (Mw=7.7) and Elbistan (Mw=7.6), Kahramanmaraş–Türkiye earthquakes (Report No. METU/EERC 2023-01). *Middle East Technical University, Earthquake Engineering Research Center*, 12-15.
- Chamola, V., Hassija, V., Gupta, S., Goyal, A., Guizani, M. ve Sikdar, B. (2021). Disaster and pandemic management using machine learning: A survey. *IEEE Internet of Things Journal*, 8(21), 16047–16068. <https://doi.org/10.1109/JIOT.2020.3044966>
- Charnley, G. E. C., Kelman, I., Gaythorpe, K. A. M. ve Murray, K. A. (2021). Traits and risk factors of post-disaster infectious disease outbreaks: A systematic review. *Scientific Reports*, 11, 5616, 1-14. <https://doi.org/10.1038/s41598-021-05146-0>
- Chawla, N. V., Bowyer, K. W., Hall, L. O. ve Kegelmeyer, W. P. (2002). SMOTE: Synthetic minority over-sampling technique. *Journal of Artificial Intelligence Research*, 16, 321–357. <https://doi.org/10.1613/jair.953>
- Clark, K., Luong, M.-T., Le, Q. V. ve Manning, C. D. (2020). ELECTRA: Pre-training text encoders as discriminators rather than generators. In *Proceedings of the 8th International Conference on Learning Representations (ICLR 2020)*. <https://openreview.net/forum?id=r1xMH1BtvB>
- Contreras, D., Antypas, D., Wilkinson, S., Camacho-Collados, J., Garnier, P. ve Cornou, C. (2023). Assessing post-disaster recovery using sentiment analysis: The case of Haiti [Conference poster]. *SECED 2023, Cambridge, United Kingdom*. <https://doi.org/10.13140/RG.2.2.26005.29921>
- Contreras, D., Wilkinson, S., Aktas, Y. D., Fallou, L., Bossu, R. ve Landès, M. (2022). Intensity-based sentiment and topic analysis: The case of the 2020 Aegean earthquake. *Frontiers in Built Environment*, 8, 839770, 1-15. <https://doi.org/10.3389/fbuil.2022.839770>

- Contreras, D., Wilkinson, S., Alterman, E. ve Hervás, J. (2022). Accuracy of a pre-trained sentiment analysis (SA) classification model on tweets related to emergency response and early recovery assessment: The case of 2019 Albanian earthquake. *Natural Hazards*, 113, 403–421. <https://doi.org/10.1007/s11069-022-05307-w>
- Contreras, D., Wilkinson, S., Balan, N. ve James, P. (2022). Assessing post-disaster recovery using sentiment analysis: The case of L'Aquila, Italy. *Earthquake Spectra*, 38(1), 81–108. <https://doi.org/10.1177/87552930211036486>
- Dünya Sağlık Örgütü [WHO]. (2013). Classification and minimum standards for foreign medical teams in sudden onset disasters. <https://www.who.int/publications/i/item/classification-and-minimum-standards-for-foreign-medical-teams-in-sudden-onset-disasters>
- Dünya Sağlık Örgütü [WHO]. (2021). Classification and minimum standards for emergency medical teams. World Health Organization. <https://iris.who.int/handle/10665/341857>
- Dünya Sağlık Örgütü [WHO]. (2023). Türkiye earthquake external situation report no.2: 20–26 Şubat 2023 (WHO/EURO:2023-7145-46911-68571). <https://www.who.int/europe/publications/i/item/WHO-EURO-2023-7145-46911-68571> . 31 Aralık 2025
- Dünya Sağlık Örgütü [WHO]. (2025). WHO operational review of Türkiye's approach to noncommunicable diseases during the emergency response to the 2023 earthquakes. WHO Regional Office for Europe. <https://iris.who.int/handle/10665/380054>
- Eguia, H., Sánchez-Bocanegra, C. L., Vinciarelli, F., Alvarez-Lopez, F. ve Sargi-Rubio, F. (2024). Clinical decision support and natural language processing in medicine: Systematic literature review. *Journal of Medical Internet Research*, 26, 1-14. <https://doi.org/10.2196/55315>
- Eligüzel, N., Çetinkaya, C. ve Dereli, T. (2020). Comparison of different machine learning techniques on location extraction by utilizing geo-tagged tweets: A case study. *Advanced Engineering Informatics*, 46, 101151, 1-19. <https://doi.org/10.1016/j.aei.2020.101151>

- Eligüz el, N., Çetinkaya, C. ve Dereli, T. (2022). Application of named entity recognition on tweets during earthquake disaster: A deep learning-based approach. *Soft Computing*, 26, 26395–26421. <https://doi.org/10.1007/s00500-021-06370-4>
- Ergen, E., Kaya, O., Yılmaz, Ö., Özdeş, H. U., Batur, Ö. C., Karaman, S., . . . Karakaplan, M. (2022). Which is more dangerous, earthquake, or the panic? Evaluation of the 24 January 2020 Elazığ/Türkiye earthquake related musculoskeletal injuries. *Ulus Travma ve Acil Cerrahi Dergisi*, 28(9), 1335–1339. <https://doi.org/10.14744/tjtes.2021.57606>
- Erkal, T. ve Değerliyurt, M. (2009). Türkiye’de afet yönetimi. *Doğu Coğrafya Dergisi*, 14(22), 147–164. <https://dergipark.org.tr/tr/pub/ataunidcd/issue/2437/31194>
- Erokhin, D. ve Komendantova, N. (2024). Earthquake conspiracy discussion on Twitter. *Humanities & Social Sciences Communications*, 11, 454, 1-10. <https://doi.org/10.1057/s41599-024-02957-y>
- Erokhin, D. ve Komendantova, N. (2024). Social media data for disaster risk management and research. *International Journal of Disaster Risk Reduction*, 114, 104980. <https://doi.org/10.1016/j.ijdr.2024.104980>
- Eryiğ it, G. (2014). ITU Turkish NLP web service. In *Proceedings of the Demonstrations at the 14th Conference of the European Chapter of the Association for Computational Linguistics* (ss. 1–4). Association for Computational Linguistics.
- Eryiğ it, G. ve Torunoğ lu-Selamet, D. (2017). Social media text normalization for Turkish. *Natural Language Engineering*, 23(6), 835-875. <https://doi.org/10.1017/S1351324917000134>
- Fiesler, C. ve Proferes, N. (2018). “Participant” perceptions of Twitter research ethics. *Social Media + Society*, 4(1). <https://doi.org/10.1177/2056305118763366>
- Froeschl, G., Zagl, B., Eruç lar, E., Alaeddin, K., El Othmani, M. ve Hatunoğ lu, C. (2025). Needs and early response towards internally displaced people in Hatay Province in the aftermath of the 2023 earthquake in Turkey. *BMC Public Health*, 25, 1706, 1-10. <https://doi.org/10.1186/s12889-025-22501-0>
- Gaisbauer, F., Pournaki, A., Banisch, S. ve Olbrich, E. (2021). Ideological differences in engagement in public debate on Twitter. *PLOS ONE*, 16(3), 1-18. <https://doi.org/10.1371/journal.pone.0249241>

- Gan, J. ve Qi, Y. (2021). Selection of the optimal number of topics for LDA topic model—Taking patent policy analysis as an example. *Entropy*, 23, 1301, 1-45. <https://doi.org/10.3390/e23101301>
- Godinho, M. M. L. (2024). The impact of natural language processing in disaster management: A systematic literature review (Master's thesis, Universidade Nova de Lisboa, Instituto Superior de Estatística e Gestão de Informação). *RUN – Repositório da Universidade Nova de Lisboa*, 1-96. <https://run.unl.pt/bitstream/10362/167090/1/TGI1101.pdf>
- Gorro, K., Ancheta, J. R., Capao, K., Oco, N., Roxas, R. E., Sabellano, M. J. G., ... Goldberg, K. Y. (2017). Qualitative data analysis of disaster risk reduction suggestions assisted by topic modeling and word2vec. In *Proceedings of the 2017 International Conference on Asian Language Processing (IALP)*, Singapore, IEEE, ss. 293-297. <https://doi.org/10.1109/IALP.2017.8300601>
- Grootendorst, M. (2022). BERTopic: Neural topic modeling with a class-based TF-IDF procedure. *ArXiv*, 1-10. <https://doi.org/10.48550/arXiv.2203.05794>
- Gündüz Zeybekoğlu, F., Atalay, E., Torpuş, K., Berkcan, E. ve Usta, G. (2025). Evaluation of Kahramanmaraş centered earthquake in Türkiye in terms of disaster crisis management: The case of AFAD X (Twitter). *KMÜ Sosyal ve Ekonomik Araştırmalar Dergisi*, 27(49), 1053–1076. <https://doi.org/10.18493/kmusekad.1569072>
- Hameed, S. N., Ranathunga, S., Prasanna, R., Stock, K. ve Jones, C. B. (2025). Extracting disaster impacts and impact related locations in social media posts using large language models. *ArXiv*, 1-33. <https://doi.org/10.48550/arXiv.2511.21753>
- Han, J., Zheng, Z., Lu, X.-Z., Chen, K.-Y. ve Lin, J.-R. (2024). Enhanced earthquake impact analysis based on social media texts via large language model. *International Journal of Disaster Risk Reduction*, 109, 104574, 1-34. <https://doi.org/10.1016/j.ijdr.2024.104574>
- Hayes, J. L., Rovins, J. E., Brown, N., Sunandang, K., Usdianto, B. ve Triutomo, S. (2016). Identification of best practices in the development of disaster response frameworks. *New Zealand Ministry of Foreign Affairs and Trade*, 1-78.

- Hernandez-Suarez, A., Sanchez-Perez, G., Toscano-Medina, K., Perez-Meana, H., Portillo-Portillo, J., Sanchez, V. ve García Villalba, L. J. (2019). Using Twitter data to monitor natural disaster social dynamics: A recurrent neural network approach with word embeddings and kernel density estimation. *Sensors*, 19, 1746, 1-22. <https://doi.org/10.3390/s19071746>
- Hernanto, H. A. ve Mantoro, T. (2024). Improving public health disaster response through data analytics by addressing gaps in technology and resource allocation. Proc. of the 2024 10th International Conference on Computing, Engineering and Design (ICCED). IEEE, ss. 1-6. <https://doi.org/10.1109/ICCED64257.2024.10982719>
- Hossain, M. M., Amin, M. S., Kharunissa, F. ve Rizvi, S. T. (2025). Lexicon and transformer-based sentiment and emotion analysis of Twitter responses to the 2023 Turkey-Syria earthquakes. *Informatica*, 49(1), 79–94. <https://doi.org/10.31449/inf.v49i33.6499>
- Hu, Y., Mai, G., Cundy, C., Choi, K., Lao, N., Liu, W., ... Joseph, K. (2023). Geo-knowledge-guided GPT models improve the extraction of location descriptions from disaster-related social media messages. *International Journal of Geographical Information Science*, 37(11), 2289–2318. <https://doi.org/10.1080/13658816.2023.2266495>
- Ilyas, B. ve Sharif, A. (2025). A systematic review of social media-based sentiment analysis in disaster risk management. *International Journal of Disaster Risk Reduction*, 123, 105487, 1-20. <https://doi.org/10.1016/j.ijdr.2025.105487>
- Imran, M., Castillo, C., Diaz, F. ve Vieweg, S. (2015). Processing social media messages in mass emergency: A survey. *ACM Computing Surveys*, 47(4), 7-30. <https://doi.org/10.1145/2771588>
- INSARAG. (2016). INSARAG guidelines: Operational field procedures for urban search and rescue teams (Version 1). United Nations Office for the Coordination of Humanitarian Affairs. https://insarag.org/wp-content/uploads/2016/04/INSARAG_Guidelines_V1_Policy1.pdf
- Isoaho, K., Gritsenko, D. ve Mäkelä, E. (2021). Topic modeling and text analysis for qualitative policy research. *Policy Studies Journal*, 49(1), 300–324. <https://doi.org/10.1111/psj.12343>

- Jiang, Z., Yu, W., Zhou, D., Chen, Y., Feng, J. ve Yan, S. (2020). ConvBERT: Improving BERT with span-based dynamic convolution. In *Advances in Neural Information Processing Systems* 33 (*NeurIPS* 2020), 1-17. <https://doi.org/10.48550/arXiv.2008.02496>
- Jin, X. ve Spence, P. R. (2021). Understanding crisis communication on social media with CERC: Topic model analysis of tweets about Hurricane Maria. *Journal of Risk Research*, 24(10), 1266–1287. <https://doi.org/10.1080/13669877.2020.1848901>
- Julanta Leela Rachel, J., Bhuvaneswari, A. ve Kumudha, M. (2024). Topic modeling based clustering of disaster tweets using BERTopic. Proc. of the 2024 MIT Art, Design and Technology School of Computing International Conference (MITADTSociCon). IEEE, ss. 1-6. <https://doi.org/10.1109/MITADTSociCon60330.2024.10575555>
- Khurana, D., Koli, A., Khatter, K. ve Singh, S. (2023). Natural language processing: State of the art, current trends and challenges. *Multimedia Tools and Applications*, 82, 3713–3744. <https://doi.org/10.1007/s11042-022-13428-4>
- Koçer, A. T., Akpek, A., Vural, A., Aslan, A., Erkoç, A., Manav Özen, A., ... Kuru, Z. (2024). Public health challenges after the February 6 earthquakes: A comprehensive review of immediate and long-term impacts in Türkiye. *International Journal of Disaster Risk Reduction*, 114, 104925, 1-14. <https://doi.org/10.1016/j.ijdr.2024.104925>
- Köksal, A. ve Özgür, A. (2021). Twitter dataset and evaluation of transformers for Turkish sentiment analysis. Proc. of the 29th IEEE Signal Processing and Communications Applications Conference (SIU 2021). IEEE, ss. 1-4. <https://doi.org/10.1109/SIU53274.2021.9477814>
- 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. <https://doi.org/10.1016/j.ijdr.2018.10.021>
- Kuşku Özdemir, E. (2024). Social media in crisis communication: A case analysis of the 2023 Kahramanmaraş earthquakes. *Akdeniz İletişim*, (44), 112–131. <https://doi.org/10.31123/akil.1424208>
- Kusumasari, B. ve Prabowo, N. P. A. (2020). Scraping social media data for disaster communication: How the pattern of Twitter users affects disasters in Asia and the

- Pacific. *Natural Hazards*, 103, 3415–3435. <https://doi.org/10.1007/s11069-020-04136-z>
- Laosunthara, A., Saengtabtim, K., Ohashi, T., Tang, J. ve Leelawat, N. (2025). Twitter-based disaster situation analysis of the 2023 Turkey-Syria earthquake. *Engineering Journal*, 29(9), 87-96. <https://doi.org/10.4186/ej.2025.29.9.87>
- Li, C., Tian, Q., Gao, L. ve Liu, H. (2026). Public feedback analysis on multi-stage emergency management policies using BERTopic-SKEP integrated model. *Scientific Reports*, 16, 684. <https://doi.org/10.1038/s41598-025-30319-4>
- Liu, Y. (2024). Comparison of LDA and BERTopic in news topic modeling: A case study of *The New York Times*' reports on China. *Pacific International Journal*, 7(3), 47–51. <https://doi.org/10.55014/pij.v7i3.616>
- Lutsai, K. ve Lampert, C. H. (2024). Predicting the geolocation of tweets using transformer models on customized data. *Journal of Spatial Information Science*, 30, 1-2. <https://doi.org/10.48550/arXiv.2303.07865>
- Ma, Z., Li, L., Mao, Y., Wang, Y., Patsy, O. G., Bensi, M. T., Hemphill, L. ve Baecher, G. B. (2024). Surveying the use of social media data and natural language processing techniques to investigate natural disasters. *Natural Hazards Review*, 25(4), 1-16. <https://doi.org/10.1061/NHREFO.NHENG-2047>
- Macintyre, A. G., Barbera, J. A. ve Smith, E. R. (2006). Surviving collapsed structure entrapment after earthquakes: A “time-to-rescue” analysis. *Prehospital and Disaster Medicine*, 21(1), 4–19. <https://doi.org/10.1017/S1049023X00003253>
- Maier, D., Waldherr, A., Miltner, P., Wiedemann, G., Niekler, A., Keinert, A., ... Adam, S. (2018). Applying LDA topic modeling in communication research: Toward a valid and reliable methodology. *Communication Methods and Measures*, 12(2–3), 93–118. <https://doi.org/10.1080/19312458.2018.1430754>
- Maslow, A. H. (1943). A theory of human motivation. *Psychological Review*, 50(4), 370–396. <https://doi.org/10.1037/h0054346>
- Mavrouli, M., Mavroulis, S., Lekkas, E. ve Tsakris, A. (2023). The impact of earthquakes on public health: A narrative review of infectious diseases in the post-disaster period aiming to disaster risk reduction. *Microorganisms*, 11, 419, 1-38. <https://doi.org/10.3390/microorganisms11020419>

- Mehenaoui, Z., Merabti, C., Tadjer, H. ve Lafifi, Y. (2024). A comparative study on sentiment lexicons for automatic labeling. Proc. of the 13th International Conference on Research in Computing at Feminine (CEW 2024). CEUR Workshop Proceedings. <https://ceur-ws.org/Vol-3935/Paper15.pdf>
- Mendon, S., Dutta, P., Behl, A. ve Lessmann, S. (2021). A hybrid approach of machine learning and lexicons to sentiment analysis: Enhanced insights from Twitter data of natural disasters. *Information Systems Frontiers*, 23, 1145–1168. <https://doi.org/10.1007/s10796-021-10107-x>
- Mızrak, S. (2024). Public's social media use during the Kahramanmaraş earthquakes on 6 February 2023. *International Journal of Disaster Risk Reduction*, 108, 104541, 1-18. <https://doi.org/10.1016/j.ijdr.2024.104541>
- Murakami, A., Tasukawa, T., Watanabe, K. ve Hatayama, M. (2020). Understanding requirements and issues in disaster area using geotemporal visualization of Twitter analysis. *IEEE Transactions on Engineering Management*, 64(1), 1–11. <https://doi.org/10.1109/TEM.2017.2692491>
- Murthy, D., Kurz, S. E., Anand, T., Hornick, S., Lakuduva, N. ve Sun, J. (2025). Examining hurricane-related social media topics longitudinally and at scale: A transformer-based approach. *PLOS ONE*, 20(1), 1-22. <https://doi.org/10.1371/journal.pone.0316852>
- Najafi, A. ve Varol, O. (2024). TurkishBERTweet: Fast and reliable large language model for social media analysis. *Expert Systems with Applications*, 255, 124737. <https://doi.org/10.1016/j.eswa.2024.124737>
- Öcal, A. (2021). Disaster management in Turkey: A spatial approach. *International Journal of Disaster Risk Management*, 3(1), 15-22. <https://doi.org/10.18485/ijdr.2021.3.1.2>
- Oh, O., Kwon, K. H. ve Rao, H. R. (2010). An exploration of social media in extreme events: Rumor theory and Twitter during the Haiti earthquake 2010. Proc. of the 31st International Conference on Information Systems. Association for Information Systems.

- Özateş, Ş. B., Tıraş, T. E., Adak, E. E., Doğan, B., Karagöz, F. B., Genç, E. E. ve Taşdemir, E. F. B. (2025). Building foundations for natural language processing of historical Turkish: Resources and models (arXiv:2501.04828). *arXiv*, 1-20. <https://doi.org/10.48550/arXiv.2501.04828>
- Özçift, A., Akarsu, K., Yumuk, F. ve Söylemez, C. (2021). Advancing natural language processing (NLP) applications of morphologically rich languages with bidirectional encoder representations from transformers (BERT): an empirical case study for Turkish. *Automatika*, 62(2), 226–238. <https://doi.org/10.1080/00051144.2021.1922150>
- Patel, D., Bhattacharjee, P., Reza, A. ve Pradhan, P. (2025). Earthquake response analysis with AI. *arXiv*, 1-10. <https://doi.org/10.48550/arXiv.2503.16509>
- Patel, V. H. (2018). *Topic modeling using latent Dirichlet allocation on disaster tweets* Yayınlanmamış yüksek lisans tezi. Kansas State University.
- Pourebrahim, N., Sultana, S., Edwards, J., Gochanour, A. ve Mohanty, S. (2019). Understanding communication dynamics on Twitter during natural disasters: A case study of Hurricane Sandy. *International Journal of Disaster Risk Reduction*, 37, 101176, 1-19. <https://doi.org/10.1016/j.ijdr.2019.101176>
- Powell, T., Wegmann, K. M. ve Backode, E. (2021). Coping and post-traumatic stress in children and adolescents after an acute onset disaster: A systematic review. *International Journal of Environmental Research and Public Health*, 18(9), 4865, 1-18. <https://doi.org/10.3390/ijerph18094865>
- Rashid, A. K. ve Fındık, O. (2024). Sentiment analysis of Twitter: Turkey earthquake 2023 case. Proc. of the SMARTINDUSTRY-2024: International Conference on Smart Automation & Robotics for Future Industry. CEUR-WS, ss. 1-10. <https://ceur-ws.org/Vol-3699/paper14.pdf>
- Rasouli Panah, H., Madanian, S. ve Yu, J. (2024). Disaster health care and resiliency: A systematic review of the application of social network data analytics. *Disaster Medicine and Public Health Preparedness*, 18, 1-14. <https://doi.org/10.1017/dmp.2024.294>

- Rayhan, A., Kinzler, R. ve Rayhan, R. (2023). Natural language processing: Transforming how machines understand human language. *ResearchGate*, 1-2. <https://doi.org/10.13140/RG.2.2.34900.99200>
- Reimers, N. ve Gurevych, I. (2020). Making monolingual sentence embeddings multilingual using knowledge distillation. Proc. of the 2020 Conference on Empirical Methods in Natural Language Processing (EMNLP). Association for Computational Linguistics, ss. 4512-4525. <https://doi.org/10.18653/v1/2020.emnlp-main.365>
- Reuter, C. ve Kaufhold, M.-A. (2018). Fifteen years of social media in emergencies: A retrospective review and future directions for crisis informatics. *Journal of Contingencies and Crisis Management*, 26(1), 41–57. <https://doi.org/10.1111/1468-5973.12196>
- Reuter, C., Hughes, A. L. ve Kaufhold, M. A. (2018). Social Media in Crisis Management: An Evaluation and Analysis of Crisis Informatics Research. *International Journal of Human-Computer Interaction*, 34(4), 280–294. <https://doi.org/10.1080/10447318.2018.1427832>
- Sakaki, T., Okazaki, M. ve Matsuo, Y. (2010). Earthquake shakes Twitter users: Real-time event detection by social sensors. Proc. of the 19th International Conference on World Wide Web (WWW '10). ACM, ss. 851-860. <https://doi.org/10.1145/1772690.1772777>
- Sarker, M. N. I., Peng, Y., Yiran, C. ve Shouse, R. C. (2020). Disaster resilience through big data: Way to environmental sustainability. *International Journal of Disaster Risk Reduction*, 51, 101769, -9. <https://doi.org/10.1016/j.ijdr.2020.101769>
- Saroj, A. ve Pal, S. (2020). Use of social media in crisis management: A survey. *International Journal of Disaster Risk Reduction*, 48, 101584, 1-19. <https://doi.org/10.1016/j.ijdr.2020.101584>
- Sayeed, M. S., Mohan, V. ve Muthu, K. S. (2023). BERT: A review of applications in sentiment analysis. *HighTech and Innovation Journal*, 4(2), 453–461. <https://doi.org/10.28991/HIJ-2023-04-02-015>
- Scheible-Schmitt, R. ve Schweter, S. (2025). SindBERT, the sailor: Charting the seas of Turkish NLP. *arXiv*, 1-12. <https://doi.org/10.48550/arXiv.2510.21364>

- Schweter, S. (2020). BERTurk - BERT models for Turkish (Versiyon 1.0.0) [Yazılım]. *Zenodo*. <https://doi.org/10.5281/zenodo.3770924>
- Serrano-Guerrero, J., Olivas, J. A., Romero, F. P. ve Herrera-Viedma, E. (2015). Sentiment analysis: A review and comparative analysis of web services. *Information Sciences*, 311, 18–38. <https://doi.org/10.1016/j.ins.2015.03.040>
- Shaik, T., Tao, X., Dann, C., Xie, H., Li, Y. ve Galligan, L. (2023). Sentiment analysis and opinion mining on educational data: A survey. *Natural Language Processing Journal*, 2, 100003, 1-11. <https://doi.org/10.1016/j.nlp.2022.100003>
- Sharif, A. (2020). *Disaster types and causes*. PP Savani University, 1-2.
- Shen, M., Xu, H., Liu, H. ve Han, Z. (2025). How did the Chinese public discuss the 2023 Türkiye-Syria earthquake and the humanitarian response on social media? A topical and sentimental analysis. *International Journal of Disaster Risk Science*, 16, 361–375. <https://doi.org/10.1007/s13753-025-00641-6>
- Shoaf, K. (2014). Organizing the health sector for response to disasters. *Ciência & Saúde Coletiva*, 19(9), 3705–3712. <https://doi.org/10.1590/1413-81232014199.03722014>
- Singh, S. K., Tiwari, A. K. ve Paliwal, H. K. (2023). A state-of-the-art review on the utilization of machine learning in nanofluids, solar energy generation, and the prognosis of solar power. *Engineering Analysis with Boundary Elements*, 155, 62–86. <https://doi.org/10.1016/j.enganabound.2023.06.003>
- Sphere Association. (2018). *The Sphere handbook: Humanitarian charter and minimum standards in humanitarian response* (4. Baskı). Sphere Association. <https://spherestandards.org/handbook-2018/>
- Tas, N. (2024). RoBERTurk: Adjusting RoBERTa for Turkish. *arXiv*. <https://doi.org/10.48550/arXiv.2401.03515>
- Tepecik, A. ve Demir, E. (2024). Emotion detection with pre-trained language models BERT and ELECTRA analysis of Turkish data. *Intelligent Methods in Engineering Sciences*, 3(1), 007–012. <https://doi.org/10.58190/imiens.2024.82>
- Tin, D., Cheng, L., Le, D., Hata, R. ve Ciottone, G. (2024). Natural disasters: A comprehensive study using EMDAT database 1995–2022. *Public Health*, 226, 255–260. <https://doi.org/10.1016/j.puhe.2023.11.017>

- Toçoğlu, M. A. ve Alpkoçak, A. (2019). Lexicon-based emotion analysis in Turkish. *Turkish Journal of Electrical Engineering and Computer Sciences*, 27(2), 1213–1227. <https://doi.org/10.3906/elk-1807-41>
- Türk, U., Atmaca, F., Özateş, Ş. B., Berk, G., Bedir, S. T., Köksal, A., Öztürk Başaran, B., Güngör, T. ve Özgür, A. (2020). Resources for Turkish dependency parsing: Introducing the BOUN Treebank and the BoAT annotation tool. *arXiv*, 1-44. <https://doi.org/10.48550/arXiv.2002.10416>
- Ünal, C. ve Sezer, C. (2023). 2023 Kahramanmaraş depremlerinin ardından Sağlık Bakanlığına yöneltilen tweetler: Türkiye’deki deprem felaketine yönelik bir içerik analizi. *Gümüşhane Sağlık Bilimleri Dergisi*, 12(2), 782–793. <https://doi.org/10.37989/gumussagbil.1275676>
- United Methodist Committee on Relief [UMCOR]. (t.y.). Phases of disaster recovery: Emergency response for the long term. ReliefWeb. <https://reliefweb.int/report/world/phases-disaster-recovery-emergency-response-long-term> . 31 Aralık 2025
- United Nations Office for the Coordination of Humanitarian Affairs (OCHA). (2017). 5 essentials for the first 72 hours of disaster response. <https://www.unocha.org/publications/report/world/5-essentials-first-72-hours-disaster-response> . 7 Haziran 2017
- United Nations Office for the Coordination of Humanitarian Affairs (OCHA). (2023). Türkiye: 2023 earthquakes situation report no. 12. <https://www.unocha.org/publications/report/turkiye/turkiye-2023-earthquakes-situation-report-no-12-30-march-2023-entr> . 30 Mart 2023
- URL-1: <https://www.sbb.gov.tr/wp-content/uploads/2023/03/2023-Kahramanmaraş-and-Hatay-Earthquakes-Report.pdf>. 31 Aralık 2025
- URL-2: <https://doc.emdat.be/docs/data-structure-and-content/general-definitions-and-concepts> . 30 Aralık 2025
- URL-3: <https://www.afad.gov.tr/aciklamali-afet-yonetimi-terimleri-sozlugu>. 31 Aralık 2025
- URL-4: <https://github.com/ahmetaa/zemberek-nlp>. 31 Aralık 2025
- URL-5 : <https://github.com/obulat/zeyrek>. 31 Aralık 2025
- URL-6: <https://www.ibm.com/think/topics/machine-learning>. 31 Aralık 2025

- URL-7: <https://www.ibm.com/think/topics/random-forest>. 2 Ekim 2025
- URL-8: <https://www.ibm.com/think/topics/logistic-regression>. 31 Aralık 2025
- URL-9: <https://www.ibm.com/think/topics/naive-bayes>. 31 Aralık 2025
- URL-10: <https://www.ibm.com/think/topics/support-vector-machine>. 31 Aralık 2025
- URL-11: <https://www.ibm.com/think/topics/neural-networks>. 31 Aralık 2025
- URL-12: <https://developers.google.com/machine-learning/crash-course/classification/accuracy-precision-recall>. 3 Kasım 2025
- URL-13: <https://www.geeksforgeeks.org/machine-learning/f1-score-in-machine-learning>. 23 Haziran 2025
- Verma, A., Bansal, S., Gera, P. ve Mohapatra, A. (2023). Classifying Turkey earthquake tweets to classify them based on their sentiment. Proc. of the 2023 International Conference on Contemporary Computing and Informatics (IC3I). IEEE, ss. 906-911. <https://doi.org/10.1109/IC3I59117.2023.10397724>
- Voigt, P. ve Von dem Bussche, A. (2017). *The EU General Data Protection Regulation (GDPR): A practical guide*. Springer International Publishing. doi:10.1007/978-3-319-57959-7
- Vračević, N., Schmidt, S., Keskin, M., Hanny, D. ve Resch, B. (2025). More than just tweets: The potential of alternative geo-social media data for disaster management. *Social Network Analysis and Mining*, 15, 74, 1-15. <https://doi.org/10.1007/s13278-025-01494-z>
- Wang, C., Zhang, X., Liu, L. ve Wu, J. (2025). Public perception of earthquake events: Evidence from social media – A case study of the 2025 Dingri earthquake. *Geomatics, Natural Hazards and Risk*, 16(1), 2542196, 1-17. <https://doi.org/10.1080/19475705.2025.2542196>
- Wang, Z., Ma, Y., Song, Y., Huang, Y., Liang, G. ve Zhong, X. (2024). The utilization of natural language processing for analyzing social media data in nursing research: A scoping review. *Journal of Nursing Management*, 2024, Article 2857497. <https://doi.org/10.1155/jonm/2857497>
- Watson, J. T., Gayer, M. ve Connolly, M. A. (2007). Epidemics after natural disasters. *Emerging Infectious Diseases*, 13(1), 1-5. <https://doi.org/10.3201/eid1301.060779>

- Widyastuti, D. A. R. (2021). Using new media and social media in disaster communication. *Jurnal Komunikator*, 13(2), 101-111. <https://doi.org/10.18196/jkm.12074>
- Williams, M. L., Burnap, P. ve Sloan, L. (2017). Towards an ethical framework for publishing Twitter data in social research: Taking into account users' views, online context and algorithmic estimation. *Sociology*, 51(6), 1149–1168. <https://doi.org/10.1177/0038038517708140>
- Wu, C., Hu, H., Zhu, D., Shan, X., Yung, K.-L. ve Ip, A. W. H. (2024). A study of discriminatory speech classification based on improved SMOTE and SVM-RF. *Applied Sciences*, 14(15), 6468. <https://doi.org/10.3390/app14156468>
- X Corp. (2026). X developer terms. <https://docs.x.com/developer-terms> . 1 Ocak 2026.
- X Corp. (2026). X terms of service. <https://x.com/en/tos> . 1 Ocak 2026.
- Xu, Z. (2020). How emergency managers engage Twitter users during disasters. *Online Information Review*, 44(4), 933–950. <https://doi.org/10.1108/OIR-08-2019-0275>
- Yang, P., Dinh, L., Stratton, A. ve Diesner, J. (2024). Detection and categorization of needs during crises based on Twitter data. Proc. of the International AAAI Conference on Web and Social Media. AAAI, ss. 1713-1726. <https://doi.org/10.1609/icwsm.v18i1.31420>
- Yeşildal, A. (2020). Doğal afetlerle mücadelede yerel yönetimlerin rolü ve kapasite sorunları: Esnek şehir uygulaması. *Fırat Üniversitesi İİBF Uluslararası İktisadi ve İdari Bilimler Dergisi*, 4(1), 87–116.
- Yildirim, S. (2024). Bert-base Turkish sentiment model [Model kartı]. Hugging Face. 30.12.2025 <https://huggingface.co/savasy/bert-base-turkish-sentiment-cased>
- Yıldırım, S. (2024). Fine-tuning transformer-based encoder for Turkish language understanding tasks (arXiv:2401.17396). arXiv, 1-10. <https://doi.org/10.48550/arXiv.2401.17396>
- Yılmaz, M. C. ve Orman, Z. (2021). LSTM derin öğrenme yaklaşımı ile Covid-19 pandemi sürecinde Twitter verilerinden duygu analizi [Sentiment analysis from Twitter data during the Covid-19 pandemic era with LSTM deep learning approach]. *Acta Infologica*, 5(2), 359–372. <https://doi.org/10.26650/acin.947747>

- Young, C. E., Kuligowski, E. D. ve Pradhan, A. (2020). A review of social media use during disaster response and recovery phases (NIST Technical Note 2086). *National Institute of Standards and Technology*, 2-3. <https://doi.org/10.6028/NIST.TN.2086>
- Yu, C. ve Wang, Z. (2024). Multimodal social sensing for the spatio-temporal evolution and assessment of nature disasters. *Sensors*, 24, 5889, 1-26. <https://doi.org/10.3390/s24185889>
- Zhong, B., Huang, Y. ve Liu, Q. (2021). Mental health toll from the coronavirus: Social media usage reveals Wuhan residents' depression and secondary trauma in the COVID-19 outbreak. *Computers in Human Behavior*, 114, 106524, 1-10. <https://doi.org/10.1016/j.chb.2020.106524>
- Zimmer, M. (2010). "But the data is already public": On the ethics of research in Facebook. *Ethics and Information Technology*, 12(4), 313–325. <https://doi.org/10.1007/s10676-010-9227-5>

EKLER

Ek 1. Veri Toplama İçin Anahtar Kelimeler Listesi

ilaç	maske	çadır	oyuncak
reçete	eldiven	battaniye	bebek arabası
doktor	tıbbi malzeme	yorgan	süt tozu
hemşire	ortopedi	soba	konserve
ambulans	tekerlekli sandalye	odun	makarna
hastane	medikal	kömür	pirinç
sağlık	pansuman	jeneratör	bakliyat
ateş	oksijen	yakıt	un
tansiyon	solunum cihazı	su	ekmek
diyabet	çocuk doktoru	içme suyu	sandalye
insülin	beyin kanaması	yiyecek	masa
astım	kalp hastası	mama	uyku tulumu
inhaler	şeker hastası	biberon	ısıtıcı
bandaj	tansiyon hastası	süt	powerbank
serum	psikiyatrist	bebek bezi	telefon
yara	diyaliz	kadın pedi	şarj aleti
kan	işitme cihazı	hijyenik ped	battaniye desteği
kan grubu	görme engelli	sabun	yardım kolisi
kan bağıışı	engelli	şampuan	gönüllü
psikolog	hasta bezi	ıslak mendil	sivil toplum
psikolojik destek	sedye	tuvalet kağıdı	yardım ekibi
travma	travma sonrası stres	deterjan	yardım aracı
ilk yardım	anksiyete	havlu	arama kurtarma
hasta	panik atak	kıyafet	AFAD
yaralı	depresyon	mont	Kızılay
acil	uyku problemi	ayakkabı	yardım çağırısı
kriz	göz damlası	bot	bağıış
enfeksiyon	kulak damlası	iç çamaşırı	destek
hijyen	ağrı kesici	çorap	gönüllü doktor
dezenfektan	kas gevşetici	çocuk kıyafeti	mobil sağlık ekibi

Ek 2. Türkçe Durak Kelime Listesi

NLTK Türkçe Durak Kelimleri

a, acaba, ama, aslında, az, bazı, belki, biri, birkaç, birşey, biz, bu, çok, çünkü, da, daha, de, defa, değil, diğer, diye, eğer, en, gibi, hem, hep, hepsi, her, hiç, için, ile, ise, kez, ki, kim, mı, mu, mü, nasıl, ne, neden, nerde, nerede, nereye, niçin, niye, o, sanki, şey, şu, tüm, ve, veya, ya, yani

Alan Özgü Özel Durak Kelimeler

Bu kelimeler, Türkçe Twitter söylemi ve afet yönetimi bağlamına özgü, yüksek frekanslı ancak düşük bilgi değeri taşıyan kelimeler olarak belirlenmiştir.

aa, adına, amacıyla, amaç, ancak, artık, bak, bakan, ben, benim, beri, bir, bile, bin, biraz, biri, birine, birini, birisi, böyle, bunlar, dedim, dedi, demiş, derken, diyor, dün, edilen, ediyor, edip, ettim, etti, ettik, ettiklerinde, ettikleri, ettin, ettiniz, ettiğim, ey, evet, fakat, gelen, geri, göre, ha, hala, hemen, her, hakkında, iyi, kim, kimi, kime, kimin, kadar, kendi, kendim, kendin, kendine, kendini, kendimiz, kendiyle, küçük, lazım, lütfen, mi, miyim, musun, mısın, musunuz, mıyız, neden, neye, neyi, neyin, niye, o yüzden, oh, olacak, olabilir, olan, olarak, oldu, olduğunu, olmaz, olmuş, olması, olur, olsun, onlar, önce, özellikle, sadece, sayın, sen, siz, şeyi, şeyler, şeyleri, şeydi, şimdi, şöyle, tabi, tek, tekrar, üzerine, var, vardı, vs, vb, ya, yaklaşık, yapar, yaptı, yapıyor, yarın, yine, yok, yaptığım, yaptıkları, yaptıklarında, diye, hep, ile, zaten, sonra, nasıl, hayır, bugün, gün, insanlar, bunu, bana, onu, bizim, sizin, senin, sana, abi, özel, tam, iki, ayrıca, varsa, öyle

Ek 3. Zeyrek Lemmatizasyon

Orijinal Kelime	Lemma	Morfoloji Temizlenmiş Hali	Morfolojik Kategori	Bağlam İçinde Örnek
depremzedelere	depremzed e	+ler (Plural) +e (Dative)	Noun: number + case	Depremzedelere yardım ulaştırıldı
yardımlar	yardım	+lar (Plural)	Noun: plural	Gıda yardımları dağıtılıyor
gönderildi	göndermek	+il (Passive) +di (Past)	Verb: voice + tense	Malzemeler gönderildi
hastanelerde	hastane	+de (Locative)	Noun: case	Hastanelerde yoğunluk var
yaşanıyor	yaşamak	+n (Passive) +ıyor (Progressive)	Verb: voice + aspect	Bölgede kriz yaşanıyor
yaralıları	yaralı	+lar (Plural) +ı (Accusative)	Noun: number + case	Yaralıları tahliye ediyoruz
ambulanslarla	ambulans	+lar (Plural) +la (Instrumental)	Noun: number + case	Ambulanslarla taşıma yapıyor
kurtarıyoruz	kurtarmak	+ıyor (Progressive) +uz (1st person plural)	Verb: aspect + person	İnsanları kurtarıyoruz
altındaki	alt	+ı (Possessive) +nda (Locative) +ki (Relative)	Noun: possessive + case + relative	Enkaz altındaki kişiler
insanları	insan	+lar (Plural) +ı (Accusative)	Noun: number + case	İnsanları tahliye ediyoruz
çadırlara	çadır	+lar (Plural) +a (Dative)	Noun: number + case	Çadırlara battaniye dağıtıldı
battaniyeler	battaniye	+ler (Plural)	Noun: plural	Battaniyeler ulaştırıldı
götürüldü	götürmek	+ül (Passive) +dü (Past)	Verb: voice + tense	Yardımlar götürüldü
bölgelerinde ki	bölge	+ler (Plural) +in (Possessive) +de (Locative) +ki (Relative)	Noun: number + possessive + case + relative	Deprem bölgelerindeki vatandaşlar
binalara	bina	+lar (Plural) +a (Dative)	Noun: number + case	Hasarlı binalara girmeyin
girmeyin	girmek	+me (Negative) +yin (Imperative)	Verb: negation + mood	Binalara girmeyin
ekiplerimiz	ekip	+ler (Plural) +imiz (1st person plural possessive)	Noun: number + possessive	Ekiplerimiz hazır
hızlıca	hızlı	+ca (Adverbial derivation)	Adjectival to adverbial derivation	Hızlıca müdahale edildi
edilmiş	etmek	+il (Passive) +miş (Perfect)	Verb: voice + aspect	Kurtarma operasyonu edilmiş
çalışmalarına	çalışma	+lar (Plural) +ı (Possessive) +na (Dative)	Noun: number + possessive + case	Arama çalışmalarına başlandı
etmektedir	etmek	+mekte (Progressive) +dir (Copula)	Verb: aspect + copula	Çalışmalar devam etmektedir
dağıtılıyor	dağıtmak	+ıl (Passive) +ıyor (Progressive)	Verb: voice + aspect	Yardımlar dağıtılıyor
yapılıyor	yapmak	+ıl (Passive) +ıyor (Progressive)	Verb: voice + aspect	Hasar tespiti yapılıyor

Ek 3. (Devamı)

ediyoruz	etmek	+iyor (Progressive) +uz (1st person plural)	Verb: aspect + person	Arama kurtarma ediyoruz
başlamıştır	başlamak	+mış (Perfect) +tır (Evidential)	Verb: aspect + evidentiality	Operasyon başlamıştır
alınmıştır	almak	+ın (Passive) +mış (Perfect) +tır (Evidential)	Verb: voice + aspect + evidentiality	Bilgi alınmıştır
bulunmayın	bulunmak	+ma (Negative) +yın (Imperative)	Verb: negation + mood	Binalara bulunmayın
çöktüğü	çökmek	+tüğü (Nominalization)	Verb: nominalization	Binanın çöktüğü bildirildi
beklenmekte dir	beklemek	+n (Passive) +mekte (Progressive) +dir (Copula)	Verb: voice + aspect + copula	Fırtına beklenmektedir
gönderdik	göndermek	+di (Past) +k (1st person plural)	Verb: tense + person	Malzemeleri gönderdik

Ek 4. LDA Tam Optimizasyon Sonuçları

K	Tutarlılık (C_v)	Perpleksite
5	0.4267	-9.99
6	0.4112	-10.12
7	0.3716	-10.25
8	0.3615	-10.43
9	0.3804	-10.69
10	0.3545	-11.13
11	0.2773	-11.78
12	0.3212	-12.84
13	0.3163	-14.25
14	0.3059	-16.04
15	0.3253	-18.16
16	0.3288	-20.52
17	0.3274	-22.53
18	0.3183	-24.31
19	0.3063	-25.94
20	0.3110	-27.08
21	0.3152	-28.02
22	0.3444	-29.08
23	0.3266	-29.88
24	0.3231	-30.87
25	0.3248	-31.74

Ek 5. Detaylı LDA Konu Anahtar Kelimeleri

Konu Kimliği	En İyi 10 Anahtar Kelime	Ağırlıklarıyla Birlikte İlk 20 Anahtar Kelime
0	ihtiyacı, birlikte, kızılai, hatay, zaman, tarafından, mobil, teşekkür, olduđu, türk	ihtiyacı(0.1328) birlikte(0.1028) kızılai(0.0876) hatay(0.0683) zaman(0.0515) tarafından(0.0513) mobil(0.0492) teşekkür(0.0401) olduđu(0.0393) türk(0.0295) bölgeye(0.0285) yaraları(0.0266) yaralarını(0.0258) ara(0.0226) ikram(0.0199) ana(0.0159) türkiyenin(0.0147) dayanışma(0.0141) hak(0.0132) dolay(0.0125)
1	acil, vatandaşlarımıza, kahramanmaraş, hatayda, yapan, kurtarma, olmak, arama, bölgesindeki, son	acil(0.0562) vatandaşlarımıza(0.0398) kahramanmaraş(0.0357) hatayda(0.0344) yapan(0.0336) kurtarma(0.0314) olmak(0.0262) arama(0.0251) bölgesindeki(0.0251) son(0.0242) üzere(0.0241) diğeri(0.0240) bütün(0.0232) geldi(0.0223) adet(0.0220) yer(0.0212) malatya(0.0209) bölgede(0.0208) şekilde(0.0207) takip(0.0181)
2	deprem, devam, ihtiyaç, afet, bölgesinde, depremin, bölgesine, battaniye, malzemeleri, aynı	deprem(0.2096) devam(0.1307) ihtiyaç(0.0837) afet(0.0665) bölgesinde(0.0550) depremin(0.0464) bölgesine(0.0415) battaniye(0.0261) malzemeleri(0.0255) aynı(0.0247) kişi(0.0240) ekiplerimiz(0.0228) kuru(0.0178) afad(0.0161) hizmeti(0.0133) farklı(0.0132) eden(0.0126) isteyen(0.0123) dört(0.0110) den(0.0109)
3	hijyen, gıda, destek, yardım, yemek, etkilenen, depremden, önemli, barınma, güzel	hijyen(0.3326) gıda(0.0872) destek(0.0748) yardım(0.0728) yemek(0.0446) etkilenen(0.0291) depremden(0.0266) önemli(0.0240) barınma(0.0235) güzel(0.0229) sıcak(0.0224) sonrası(0.0204) seyyar(0.0202) türkiye(0.0189) doğru(0.0145) sevk(0.0145) uzak(0.0120) yanında(0.0116) ihtiyaçları(0.0109) yardımı(0.0098)
4	çadır, büyük, ilk, ediyoruz, fazla, depremzede, başka, sosyal, saat, desteğı	çadır(0.1936) büyük(0.1337) ilk(0.0775) ediyoruz(0.0749) fazla(0.0383) depremzede(0.0380) başka(0.0336) sosyal(0.0324) saat(0.0316) desteğı(0.0316) ardından(0.0305) konteyner(0.0303) beslenme(0.0292) bölgelerinde(0.0241) yerde(0.0219) nedeniyle(0.0136) ele(0.0116) yaşam(0.0115) vermek(0.0114) yapılan(0.0108)

Ek 6. TF-IDF ile Özellik Çıkarımı

Sıra	Terim	Ortalama TF-IDF
1	kan	0.02511124
2	cadır	0.013284664
3	deprem	0.013130627
4	bağısı	0.009931367
5	tuvalet	0.009497523
6	kan bağısı	0.009416889
7	destek	0.008937334
8	acil	0.008777434
9	kızılay	0.008097397
10	saglık	0.008001221
11	konteyner	0.007902545
12	yardım	0.007653921
13	ihtiyacı	0.007509662
14	kesintisi	0.007320687
15	panik	0.00729193
16	telefon	0.007240767
17	atak	0.007215171
18	panik atak	0.007045327
19	elektrik	0.006612352
20	psikolog	0.006561954
21	gıda	0.006494136
22	devam	0.006475704
23	cekmiyor	0.006450949
24	cocuk	0.006337184
25	yemek	0.006203349
26	yalnızlık	0.006066875
27	depresyon	0.005870928
28	sabun	0.005810595
29	psikolojik	0.005702118
30	zaman	0.005640974
31	elektrik kesintisi	0.005510252
32	maske	0.00546422
33	jeneratör	0.005401918
34	psikiyatrist	0.005246585
35	cadırkent	0.005107866
36	terapi	0.004986616
37	ilk	0.004948183
38	hijyen	0.004827594
39	konserve	0.004796524
40	saat	0.004695357
41	rontgen	0.004692691
42	buyuk	0.004679106
43	telefon cekmiyor	0.004676173
44	lavabo	0.00458247
45	travma	0.004558622
46	verme	0.004557378
47	aile	0.00451177
48	ihtiyac	0.004504591
49	guzel	0.004435487
50	ambulans	0.004415874

Ek 6. (Devamı)

51	dus	0.004402772
52	merkezi	0.004284483
53	biberon	0.004166768
54	seker	0.004032682
55	kızılaya	0.0040161
56	kaygı	0.003991475
57	bas	0.003954572
58	para	0.003951318
59	sıcak	0.00393271
60	barınma	0.00391859
61	korku	0.003895772
62	kan verme	0.003885711
63	yeni	0.003710631
64	internet	0.003698884
65	ruh	0.003694523
66	malzemesi	0.003629059
67	saglığı	0.003620408
68	destegi	0.003615993
69	kuru	0.003593821
70	birlikte	0.003582149
71	yasam	0.003565737
72	sorunu	0.003562811
73	depremzede	0.003510852
74	battaniye	0.003472003
75	son	0.003447124
76	tedavi	0.003441583
77	insan	0.003437255
78	bebek	0.003421523
79	yardımlı	0.003387437
80	icinde	0.003359718
81	mama	0.00335358
82	agrisı	0.003334976
83	oldugu	0.003260261
84	ilac	0.003246041
85	temizlik	0.003240771
86	serum	0.003223688
87	bolgesinde	0.003201996
88	baska	0.003185228
89	kagıdı	0.003125938
90	devlet	0.003113964
91	banyo	0.003099687
92	afad	0.003095492
93	kan ihtiyacı	0.003090434
94	ruh saglığı	0.003086084
95	tuvalet kagıdı	0.003071738
96	sonrası	0.003059173
97	hatay	0.003058296
98	kisi	0.003057431
99	alanı	0.003049937
100	bas agrısı	0.003026766

Ek 7. BERTopic Results

Ko nu	Sayı	Ad	Anahtar Kelimeler	Kategori
-1	337 02	- 1_deprem_yardım_destek_ sağlık	['deprem', 'yardım', 'destek', 'sağlık', 'yemek', 'çocuk', 'gıda', 'allah', 'çadır', 'hijyen']	Aykırı Değerler
0	411 6	0_kan_bağışı_kan bağışı_kızılay	['kan', 'bağışı', 'kan bağışı', 'kızılay', 'kızılaya', 'kan ihtiyacı', 'ihtiyacı', 'verme', 'kan verme', 'kızılay kan']	Sağlık ve Tıbbi
1	394 8	1_aday_parti_seçim_millet	['aday', 'parti', 'seçim', 'millet', 'siyasi', 'siyaset', 'istifa', 'maç', 'tuvalet', 'kaygı']	Politik Söylem
2	338 4	2_deprem_çadır_destek_d epremzede	['deprem', 'çadır', 'destek', 'depremzede', 'travması', 'konteyner', 'depremden', 'depremzedelere', 'depemin', 'deprem travması']	Afet Yardımları
3	328 1	3_nar_nur_harika_çatal	['nar', 'nur', 'harika', 'çatal', 'çocuk', 'günaydın', 'mama', 'güzel', 'geceler', 'yastık']	Diğer/Kar ma
4	290 5	4_çadır_gıda_çadırkent_ku ru	['çadır', 'gıda', 'çadırkent', 'kuru', 'kuru gıda', 'hijyen', 'konserve', 'bebek', 'malzemesi', 'yardım']	Afet Yardımları
5	288 3	5_psikolog_psikiyatrist_ya lınzlık_psikolojik	['psikolog', 'psikiyatrist', 'yalnızlık', 'psikolojik', 'ruh', 'sağlığı', 'terapi', 'ruh sağlığı', 'destek', 'psikolojisi']	Sağlık ve Tıbbi
6	278 0	6_nurse_doktor_hastane_il aç	['nurse', 'doktor', 'hastane', 'ilaç', 'ameliyat', 'sağlık', 'mühendis', 'hemşire', 'reçete', 'hastanesi']	Sağlık ve Tıbbi
7	230 1	7_tuvalet_sabun_lavabo_k ağıdı	['tuvalet', 'sabun', 'lavabo', 'kağıdı', 'tuvalet kağıdı', 'çamaşır', 'makinesi', 'çamaşır makinesi', 'banyo', 'duş']	Afet Yardımları
8	159 6	8_panic_atak_panic atak_ ağrısı	['panic', 'atak', 'panic atak', 'ağrısı', 'baş ağrısı', 'baş', 'kaygı', 'korku', 'stres', 'uyku']	Sağlık ve Tıbbi
9	142 6	9_telefon_çekmiyor_intern et_telefon çekmiyor	['telefon', 'çekmiyor', 'internet', 'telefon çekmiyor', 'baz', 'istasyonu', 'bununla birlikte', 'imkanlarımızla', 'acil ihtiyaçları', 'merhaba']	İletişim ve Altyapı
10	110 9	10_yemek_sıcak_sıcak yemek_gıda	['yemek', 'sıcak', 'sıcak yemek', 'gıda', 'fav', 'şeker', 'yemeği', 'kuru', 'akşam yemeği', 'kaşık']	Afet Yardımları
11	104 0	11_yardımları_taşınma_kira sorunu	['yardımları', 'taşınma', 'kira', 'sorunu', 'suyu', 'içme', 'barınma', 'taşınma yardımları', 'kira yardımları', 'içme suyu']	Afet Yardımları
12	962	12_allah_versin_rabbim_ müslüman	['allah', 'versin', 'rabbim', 'müslüman', 'islam', 'şifalar versin', 'şifalar', 'acil şifalar', 'inşallah', 'dua']	Dini ve Manevi
13	908	13_mama_yaşam_yaşam alanı_alanı	['mama', 'yaşam', 'yaşam alanı', 'alanı', 'kedi', 'köpek', 'sokak', 'hayvan', 'köpekler', 'veteriner']	Diğer/Kar ma
14	789	14_türk_türkiye_türkiyede türkiyenin	['türk', 'türkiye', 'türkiyede', 'türkiyenin', 'türkiyeye', 'yurt', 'türkçe', 'türkiye cumhuriyeti', 'cumhuriyeti', 'milleti']	Diğer/Kar ma
15	780	15_biberon_çay_süt_barda k	['biberon', 'çay', 'süt', 'bardak', 'kahve', 'alkol', 'dezenfektan', 'içecek', 'termos', 'çayı']	Diğer/Kar ma
16	739	16_çöp_para_dolar_milyar	['çöp', 'para', 'dolar', 'milyar', 'elektrik', 'euro', 'kesintisi', 'acı reçete', 'elektrik kesintisi', 'altın']	Diğer/Kar ma

Ek 7. (Devamı)

17	700	17_maske_eldiven_kılıç daroğlu_gözlük	[‘maske’, ‘eldiven’, ‘kılıçdaroğlu’, ‘gözlük’, ‘maske düştü’, ‘ellerine’, ‘ellerine sağlık’, ‘bıçak’, ‘ayakkabı’, ‘düştü’]	Diğer/Kar ma
18	650	18_oksijen_nefes_darlığı 1 nefes darlığı	[‘oksijen’, ‘nefes’, ‘darlığı’, ‘nefes darlığı’, ‘astım’, ‘oksijen tüpü’, ‘sigara’, ‘tüpü’, ‘ateş’, ‘inhaler’]	Diğer/Kar ma
19	643	19_konteyner_konteyner kent_kent_geçici	[‘konteyner’, ‘konteyner kent’, ‘kent’, ‘geçici’, ‘konteyner kentte’, ‘kentte’, ‘incelemelerde’, ‘valimiz’, ‘geçici konaklama’, ‘belediyesi’]	Aykırı Değerler
20	610	20_elektrik kesintisi_elektrik_kesinti si_yaşanacak	[‘elektrik kesintisi’, ‘elektrik’, ‘kesintisi’, ‘yaşanacak’, ‘saatinde’, ‘saat’, ‘saat sürecek’, ‘sürecek’, ‘sabah’, ‘mah’]	Sağlık ve Tıbbi
21	609	21_sağlık_ekibi_bireysel _destek	[‘sağlık’, ‘ekibi’, ‘bireysel’, ‘destek’, ‘sağlık ekibi’, ‘emeğine’, ‘emeğinize’, ‘kurtarma’, ‘eline’, ‘japonya’]	Afet Yardımları
22	605	22_travma_ağrı_kalp_ya ra	[‘travma’, ‘ağrı’, ‘kalp’, ‘yara’, ‘yaralı’, ‘rahmet’, ‘allahtan’, ‘diliyorum’, ‘acil şifalar’, ‘şifalar’]	Diğer/Kar ma
23	598	23_ambulans_acil_sedye _servis	[‘ambulans’, ‘acil’, ‘sedye’, ‘servis’, ‘acil servis’, ‘ekibi’, ‘helikopter’, ‘ambulansa’, ‘polis’, ‘uçak’]	Diğer/Kar ma
24	527	24_aşı_serum_cilt_saç	[‘aşı’, ‘serum’, ‘cilt’, ‘saç’, ‘maske’, ‘nemlendirici’, ‘krem’, ‘kremler’, ‘dezenfektan’, ‘grip’]	Diğer/Kar ma
25	406	25_depresyon_antidepre san_bozukluk_güzelim	[‘depresyon’, ‘antidepresan’, ‘bozukluk’, ‘güzelim’, ‘depresyona’, ‘anksiyete’, ‘kesmiyor’, ‘sendromu’, ‘ilaç’, ‘sinir’]	Diğer/Kar ma
26	401	26_jeneratör_mutfak tüpü kömür tüpü	[‘jeneratör’, ‘mutfak tüpü’, ‘kömür’, ‘tüpü’, ‘mutfak’, ‘soba’, ‘ısıtıcı’, ‘enerji’, ‘gaz’, ‘yakıt’]	Diğer/Kar ma
27	387	27_röntgen_diş_cihazı_t omografi	[‘röntgen’, ‘diş’, ‘cihazı’, ‘tomografi’, ‘sıra’, ‘randevu’, ‘filmi’, ‘ultrason’, ‘sırası’, ‘çekimi’]	Diğer/Kar ma
28	352	28_diyabet_şeker_hastal ığı_şeker hastalığı	[‘diyabet’, ‘şeker’, ‘hastalığı’, ‘şeker hastalığı’, ‘tip’, ‘hastası’, ‘kalp’, ‘tansiyon’, ‘kronik’, ‘oruç’]	Diğer/Kar ma
29	348	29_arac_trafik_nedeni_k apalı	[‘arac’, ‘trafik’, ‘nedeni’, ‘kapalı’, ‘adiyaman’, ‘kazası’, ‘ölmek’, ‘caddesi’, ‘bebeğimiz’, ‘yaralı’]	Diğer/Kar ma
30	340	30_mah_kesintisi_saat_s ürecek	[‘mah’, ‘kesintisi’, ‘saat’, ‘sürecek’, ‘noktalarımız’, ‘saat sürecek’, ‘zaman’, ‘dağları’, ‘başlangıcı’, ‘korku dağları’]	Diğer/Kar ma
31	293	31_jeneratör_şişme_uyk u_tulumu_tulumu	[‘jeneratör’, ‘şişme’, ‘uyku tulumu’, ‘tulumu’, ‘seyahat’, ‘kaban’, ‘bere’, ‘çantası’, ‘bot’, ‘uyku’]	Diğer/Kar ma
32	227	32_aile_aile hekimi_hekimi_engelli	[‘aile’, ‘aile hekimi’, ‘hekimi’, ‘engelli’, ‘hastası’, ‘annem’, ‘konteyner’, ‘aile boyu’, ‘baba’, ‘babam’]	Diğer/Kar ma
33	214	33_bebek_bebek maması_maması_bibero n	[‘bebek’, ‘bebek maması’, ‘maması’, ‘biberon’, ‘sütü’, ‘kremler’, ‘bezi’, ‘süt’, ‘bebek bezi’, ‘anne’]	Diğer/Kar ma
34	213	34_eğitim_öğrenci_afşin _gezici	[‘eğitim’, ‘öğrenci’, ‘afşin’, ‘gezici’, ‘kütüphane’, ‘öğretmen’, ‘konya’, ‘çadırkent’, ‘halk’, ‘üniversite’]	Diğer/Kar ma
35	207	35_video_youtube_vide osu_instagram	[‘video’, ‘youtube’, ‘videosu’, ‘instagram’, ‘fotoğraf’, ‘fotosu’, ‘foto’, ‘terapi’, ‘videonun’, ‘videoyu’]	Diğer/Kar ma
36	203	36_faşist_ırkçılık_ırkçı _ırkçılık	[‘faşist’, ‘ırkçılık’, ‘ırkçı’, ‘ırkçılık’, ‘tedavi’, ‘hastalıktır’, ‘faşizm’, ‘hastalık’, ‘edilmesi’, ‘lgbt’]	Diğer/Kar ma
37	202	37_emekli_emeklilik_ve rgi_kaydı	[‘emekli’, ‘emeklilik’, ‘vergi’, ‘kaydı’, ‘emekli maaşı’, ‘maaşı’, ‘tarihinden’, ‘sigorta’, ‘prim’, ‘tescil’]	Diğer/Kar ma
38	198	38_şarj_şarj cihazı_cihazı_taşınabilir	[‘şarj’, ‘şarj cihazı’, ‘cihazı’, ‘taşınabilir’, ‘pil’, ‘güneş’, ‘şarjı’, ‘hızlı’, ‘mah’, ‘koruması’]	Diğer/Kar ma

Ek 7. (Devamı)

39	186	39_kadın_kadınlar_pedi_kadın_pedi	['kadın', 'kadınlar', 'pedi', 'kadın pedi', 'kadınlara', 'kadınların', 'kadının', 'erkek', 'ped', 'çankaya']	Diğer/Kar ma
40	155	40_lambası_gece_lambası_gece_aydınlatma	['lambası', 'gece lambası', 'gece', 'aydınlatma', 'ışık', 'fener', 'sokak', 'renk', 'gündüz', 'karanlık']	Diğer/Kar ma
41	149	41_eczane_nöbetçi_nöbetçi_eczane_birliği	['eczane', 'nöbetçi', 'nöbetçi eczane', 'birliği', 'türk', 'eczaneler', 'ilaç', 'gönüllü', 'sahra', 'listesi']	Diğer/Kar ma
42	149	42_filmi_korku_korku_filmi_filmi	['filmi', 'korku', 'korku filmi', 'film', 'tiyatro', 'estetik', 'tiyatrosu', 'battaniye altında', 'filmleri', 'kamera']	Diğer/Kar ma
43	138	43_giysi_tir_dolusu_satmış	['giysi', 'tir', 'dolusu', 'satmış', 'polis', 'şubatta', 'kızılay', 'kızılayın', 'kilosu', 'ortaya çıktı']	Diğer/Kar ma
44	131	44_yunus_balık_ton_konserve	['yunus', 'balık', 'ton', 'konserve', 'yunus emre', 'yıldan', 'afad başkanı', 'bulunmamaktadır', 'emre', 'katil']	Diğer/Kar ma
45	129	45_yurt_yurt_dışına_dışına_yurt_dışında	['yurt', 'yurt dışına', 'dışına', 'yurt dışında', 'vize', 'dışında', 'yurt dışı', 'dışı', 'aralık', 'başvurusu']	Diğer/Kar ma
46	119	46_yatak_battaniye_yatak_odası_odası	['yatak', 'battaniye', 'yatak odası', 'odası', 'yatakta', 'priz', 'yatak odasına', 'yatağın', 'yeri', 'yatağı']	Diğer/Kar ma
47	116	47_çiçek_edici_maddele_ri_madde	['çiçek', 'edici', 'maddeleri', 'madde', 'özelligi', 'bitki', 'denir', 'tedavi', 'kullanılan', 'yaprak']	Diğer/Kar ma
48	75	48_evlilik_ilişki_çocuk_teklifi	['evlilik', 'ilişki', 'çocuk', 'teklifi', 'evli', 'aile', 'psikolojik', 'sabaha', 'eşi', 'kurmak']	Diğer/Kar ma
49	65	49_vitamin_magnezyum_vitamini_tansiyon	['vitamin', 'magnezyum', 'vitamini', 'tansiyon', 'tuzu', 'tuz', 'serum', 'kaya', 'tuzlu', 'reçete']	Diğer/Kar ma
50	53	50_noktalarımız_pazartesi_yaz_cumartesi	['noktalarımız', 'pazartesi', 'yaz', 'cumartesi', 'cuma', 'reçete', 'kilis', 'osmaniye', 'diyarbakır', 'reçete yaz']	Diğer/Kar ma
51	51	51_mat_matematik_sınavı_fizik	['mat', 'matematik', 'sınavı', 'fizik', 'dersi', 'sınav', 'yarın', 'saat', 'simdi', 'yapıcam']	Diğer/Kar ma
52	45	52_kredi_borçlarını_bireysel_faizsiz	['kredi', 'borçlarını', 'bireysel', 'faizsiz', 'adıyla', 'milyar', 'hatay kahramanmaraş', 'tarihine', 'agustos', 'kart']	Diğer/Kar ma
53	39	53_apa_dari_mana_nesiller	['apa', 'dari', 'mana', 'nesiller', 'oleh', 'japonyada', 'yüzyılda', 'üretiyorlar', 'doğdu', 'kesmeden']	Diğer/Kar ma
54	31	54_mühendis_kamu_gelenebilecek_bilişim	['mühendis', 'kamu', 'gelebilecek', 'bilişim', 'özlük', 'kolaylaştırır', 'aklınıza', 'özlük hakları', 'enerji', 'mali']	Diğer/Kar ma
55	22	55_ufo_dünya_yapay_alanı	['ufo', 'dünya', 'yapay', 'alanı', 'yaşam alanı', 'yaşam', 'güneş', 'ısıtıcı', 'düz', 'lar']	Diğer/Kar ma
56	19	56_hdp_chp_hdpkk_görüşmesi	['hdp', 'chp', 'hdpkk', 'görüşmesi', 'hdppe', 'pkk', 'nin', 'üye', 'parti', 'masada']	Diğer/Kar ma
57	19	57_avukatlar_kutlu_hukukun_günü	['avukatlar', 'kutlu', 'hukukun', 'günü', 'kılmak', 'koşulda', 'dünyasında', 'hak', 'mücadele eden', 'daima']	Diğer/Kar ma
58	19	58_oyuncunun_milyon_çağırısı_yardım_çağırısı	['oyuncunun', 'milyon', 'çağırısı', 'yardım çağırısı', 'toplandı', 'ingiliz', 'depremzedeler', 'yardım', 'depremzedeler yardım', 'topladı']	Afet Yardıma

Ek 8. BERTopic nihai konu özeti

Konu	Sayı	Ad	Anahtar Kelimeler	Temsili Dokümanlar	Kategori	Ortalama Skor
0	4116	0_kan_bağış_kızılay	['kan', 'bağışı', 'kan bağışı', 'kızılay', 'kızılaya', 'kan ihtiyacı', 'ihtiyacı', 'verme', 'kan verme', 'kızılay kan']	['kızılay kan bağışlayana para veriyor demek adı kan bağışı', 'kan bağışı çağrısı', 'teden kan bağışı']	Sağlık ve Tıbbi	0.041248409
1	3948	1_aday_parti_seçim_millet	['aday', 'parti', 'seçim', 'millet', 'siyasi', 'siyaset', 'istifa', 'maç', 'tuvalet', 'kaygı']	['aday icinden aday sunar mesela şeker bulmuş çocuk ortaya atan aday hocam sizi anecdet sezeri severim dışardan mesela abdullah gülü aday onuda istemedi', 'vatandaş fikrimi söylemek istiyorum akşener imza attı lider yemek yedi sohbet ettiler gülerek gitti kemal kılıçdaroğlu aday belli parti yönetimi meral hanım genel başkanlığı bırakacaktı hakaret edici eline verilen metni okuyacaktı', 'aday']	Politik Söylem	0.010562763
2	3384	2_deprem_çadır_destek_depremzede	['deprem', 'çadır', 'destek', 'depremzede', 'travması', 'konteyner', 'depremden', 'depremzedeler', 'depremin', 'deprem travması']	['boğazlıyan deprem bölgesine konteyner kent kuruyor', 'kahramanmaraş merkezli şubatta meydana depremlerden etkilenen şanlıurfanın haliliye ilçesindeki bina çöktü bölgeye afad itfaiye umke sağlık ekipleri güvenlik güçleri sevk edildi kişilerin yaralı çıkarıldığı enkazda arama kurtarma çalışmaları sürüyor', 'deprem travması yaşayan depremzedelere müjdeli haber']	Afet Yardımı	0.017715354
3	3281	3_nar_nur_harika_çatal	['nar', 'nur', 'harika', 'çatal', 'çocuk', 'günaydın', 'mama', 'güzel', 'geceler', 'yastık']	['karadutum çatal karam çingenem nar tanem nur tanem taneemm ebruşahin harika harkem', 'karadutum çatal karam çingenem nar tanem nur tanem taneemm ebruşahin harika harkem yzkrksu', 'karadutum çatal karam çingenem nar tanem nur tanem taneemm ebruşahin harika harkem iydzksn']	Diğer/Karar	0.040165708
4	2905	4_çadır_gıda_çadır_kent_kuru	['çadır', 'gıda', 'çadırkent', 'kuru', 'kuru gıda', 'hijyen', 'konserve', 'bebek', 'malzemesi', 'yardım']	['her yerden çadırkent', 'cristiano ronaldo türkiye suriyedeki depremzedeler uçak yardım malzemesi gönderdi daily mail çadır yiyecek yatak bebek maması süt tıbbi malzemeler', 'bizde serinyoldayız çadır battaniye yatak acil kuru gıda']	Afet Yardımı	0.021542215

Ek 8. (Devamı)

5	288	5_psikolo 3 og_psiki yatrist_y alnırlık psikoloji k	['psikolog', 'psikiyatrist', 'yalnızlık', 'psikolojik', 'ruh', 'sağlığı', 'terapi', 'ruh sağlığı', 'destek', 'psikolojisi']	['psikolog unpad plis', 'mari konsul tatap muka psikolog', 'fizyoterapist diyetisyen biyolog psikolog sosyal hizmet uzmanı ergoterapist ihtiyaç atama']	Sağlık ve Tıbbi	0.0349 33621
6	278	6_nurse 0 _doktor _hastane _ilaç	['nurse', 'doktor', 'hastane', 'ilaç', 'ameliyat', 'sağlık', 'mühendis', 'hemşire', 'reçete', 'hastanesi']	['nurse yalancının', 'incinmişsin nurse', 'tutuşmuş nurse']	Sağlık ve Tıbbi	0.0297 33303
7	230	7_tuvale 1 t_sabun _lavabo _kağıdı	['tuvalet', 'sabun', 'lavabo', 'kağıdı', 'tuvalet kağıdı', 'çamaşır', 'makinesi', 'çamaşır makinesi', 'banyo', 'duş']	['tuvalet kağıdı kontenjanı', 'tuvalet kağıdı kabulum', 'misvakta tuvalet kağıdı']	Afet Yardımları	0.0494 56608
8	159	8_panik 6 _atak_p anik atak_ağr ısı	['panik', 'atak', 'panik atak', 'ağrısı', 'baş ağrısı', 'baş', 'kaygı', 'korku', 'stres', 'uyku']	['panik atak gecirmedi', 'panik atak geçirerek', 'özleyince ağlamam tartismamızda panik atak gecirmem bonus']	Sağlık ve Tıbbi	0.0717 95025
9	142	9_telefo 6 n_çekmi yor_inte rnet_tele fon çekmiyo r	['telefon', 'çekmiyor', 'internet', 'telefon çekmiyor', 'baz', 'istasyonu', 'bununla birlikte', 'imkanlarımızla', 'acil ihtiyaçları', 'merhaba']	['merhaba bölgede bulunan vatandaşlarımızın acil ihtiyaçları ücretsiz konuşma internet tanımlanmıştır bununla birlikte mobil baz istasyonu desteği farklı imkanlarımızla seferber olmaya devam ediyoruz beren', 'merhaba alphan bey bölgede bulunan vatandaşlarımızın acil ihtiyaçları ücretsiz konuşma internet tanımlanmıştır bununla birlikte mobil baz istasyonu desteği farklı imkanlarımızla seferber olmaya devam ediyoruz yağız', 'merhaba anıl bey bölgede bulunan vatandaşlarımızın acil ihtiyaçları ücretsiz konuşma internet tanımlanmıştır bununla birlikte mobil baz istasyonu desteği farklı imkanlarımızla seferber olmaya devam ediyoruz çisem']	İletişim ve Altyapı	0.0625 67624

Ek 8. (Devamı)

10	110	10_yemek_sıcak_sıcak_yemek_gıda	['yemek', 'sıcak', 'sıcak yemek', 'gıda', 'fav', 'şeker', 'yemeği', 'kuru', 'akşam yemeği', 'kaşık']	['ihtiyaç sahiplerine gıda kolisi sıcak yemek', 'bergamadan kişiye sıcak yemek', 'sıcak yemek bağıışı sıcak yemek bağışlarımızla ihtiyaç sahiplerine yaşlılarımıza iftar yemeği edebilirsiniz online bağış']	Afet Yardımı	0.0416 62182
11	1040	11_yardıma_sorunu	['yardımı', 'taşınma', 'kira', 'sorunu', 'suyu', 'içme', 'barınma', 'taşınma yardımı', 'kira yardımı', 'içme suyu']	['süleyman soylu sahibi olanlara kira yardımı taşınma yardımı yapılacak kiracılar içinde aylık kira yardımını tlye çıkardık taşınma yardımı alacaklar kiracılara ilk kira yardımı yapılıyor yürekler beraber çarpıyor', 'taşınma yardımı orta ağır hasarlıysa kiracı aylık sahiplerine kira yardımı yapacak', 'taşınma kira yardımı açilen bekliyoruz mağdurum']	Afet Yardımı	0.0268 76795
12	962	12_allah_versin_rabbim_müslüman	['allah', 'versin', 'rabbim', 'müslüman', 'islam', 'şifalar versin', 'şifalar', 'acil şifalar', 'inşallah', 'dua']	['allah acil şifalar versin gençti demans ellaaammm', 'allah acil şifalar versin', 'allah acil şifalar versin inşallah geçmiş']	Dini ve Manevi	0.0240 5507
13	908	13_mama_yaşama_yaşama_alanı	['mama', 'yaşam', 'yaşam alanı', 'alanı', 'kedi', 'köpek', 'sokak', 'hayvan', 'köpekler', 'veteriner']	['doğal yaşam alanı', 'yaşam alanı güzelliyor', 'sokak çocuklarınne kedilerinne köpeklerin yaşam alanıdırhepsinin yaşam alanı sıcak yuvadır']	Diğer/Karar	0.0401 78971
14	789	14_türk_türkiye_türkiyede_türkiyenin_türkiyeye_yurt_türkçe_türkiye_cumhuriyeti_cumhuriyeti_milleti	['türk', 'türkiye', 'türkiyede', 'türkiyenin', 'türkiyeye', 'yurt', 'türkçe', 'türkiye cumhuriyeti', 'cumhuriyeti', 'milleti']	['kariyer planımız belli anadolu rumeli kfkasya kurtuluş orduları saha mareşalleği büyük genişletilmiş türk yaşam alanı mimarlığı büyük türk millet kurultayı meclis başkanlığı genel sekreterliği galaktik birleşik türk devleti hanlığı', 'türk asildir tarih tekerrürden ibarettir', 'türk bayrağı türk milleti sorunu olanlar hesabımız']	Diğer/Karar	0.0230 0507
15	780	15_biberon_çay_süt_bardak	['biberon', 'çay', 'süt', 'bardak', 'kahve', 'alkol', 'dezenfektan', 'içecek', 'termos', 'çayı']	['biberon kullanılıyordu', 'baskasıyla biberon tokusturmuş', 'bülente biberon hüüüüüü']	Diğer/Karar	0.0607 1684

Ek 8. (Devamı)

16	739	16_çö p_para _dolar _milya r	[‘çöp’, ‘para’, ‘dolar’, ‘milyar’, ‘elektrik’, ‘euro’, ‘kesintisi’, ‘acı reçete’, ‘elektrik kesintisi’, ‘altın’]	[‘nunez çöp’, ‘puhahahahaha çöp’, ‘çöp chpkkip’]	Diğer/Ka rma	0.0237 75133
17	700	17_ma ske_el diven_ kılıçda roğlu_ gözlük	[‘maske’, ‘eldiven’, ‘kılıçdaroğlu’, ‘gözlük’, ‘maske düştü’, ‘ellerine’, ‘ellerine sağlık’, ‘bıçak’, ‘ayakkabı’, ‘düştü’]	[‘maske takmalıyız’, ‘maske takıyor’, ‘maske’]	Diğer/Ka rma	0.0468 40688
18	650	18_oks ijen_n efes_d arlığı_ nefes darlığı	[‘oksijen’, ‘nefes’, ‘darlığı’, ‘nefes darlığı’, ‘astım’, ‘oksijen tüpü’, ‘sigara’, ‘tüpü’, ‘ateş’, ‘inhaler’]	[‘dünya nefes darlığı olmasaydı nefes darlığı çekerdim’, ‘neyyy nefes darlığı çekmeye devam’, ‘nefes darlığı’]	Diğer/Ka rma	0.0670 10179
19	643	19_ko nteyne r_kont eyner kent_k ent_ge çici	[‘konteyner’, ‘konteyner kent’, ‘kent’, ‘geçici’, ‘konteyner kentte’, ‘kentte’, ‘incelemelerde’, ‘valimiz’, ‘geçici konaklama’, ‘belediyesi’]	[‘içişleri bakanımız valimiz karacasu geçici konaklama merkezini konteyner kent ziyaret ederek incelemelerde bulundu valimiz konteyner kentte yürütülen çalışmalar ilgili soyluya bilgi verdi kahramanmaraş’, ‘arkas venediğe konteyner gemisini taşıtıracak’, ‘konteyner çarşılarımız’]	Diğer/Ka rma	0.0396 85282
20	610	20_ele ktrik kesinti si_elek trik_ke sintisi_ yaşana cak	[‘elektrik kesintisi’, ‘elektrik’, ‘kesintisi’, ‘yaşanacak’, ‘saatinde’, ‘saat’, ‘saat sürecektir’, ‘sürecek’, ‘sabah’, ‘mah’]	[‘demircide elektrik kesintisi’, ‘elektrik kesintisi’, ‘atakent elektrik kesintisi’]	Diğer/Ka rma	0.1393 95735
21	609	21_sağ lık_eki bi_bire ysel_d estek	[‘sağlık’, ‘ekibi’, ‘bireysel’, ‘destek’, ‘sağlık ekibi’, ‘emeğine’, ‘emeğinize’, ‘kurtarma’, ‘eline’, ‘japonya’]	[‘sağlık ekibi’, ‘sağlık vazgeçmek’, ‘sağlık’]	Afet Yardımları	0.0361 09293
22	605	22_tra vma_a ğrı_kal p_yara	[‘travma’, ‘ağrı’, ‘kalp’, ‘yara’, ‘yaralı’, ‘rahmet’, ‘allahtan’, ‘diliyorum’, ‘acil şifalar’, ‘şifalar’]	[‘shhshshhahshshshshshshs travma’, ‘gecmisten travma’, ‘kaybolduhun gunler travma’]	Diğer/Ka rma	0.0417 31194

Ek 8. (Devamı)

23	598	23_am bulans _acil_s edye_s ervis	['ambulans', 'acil', 'sedye', 'servis', 'acil servis', 'ekibi', 'helikopter', 'ambulansa', 'polis', 'uçak']	['ambulans hehshsjs', 'rusyaya ambargoyu delen ambulans uçuşu', 'uyarii izlemeden ambulans çağırın']	Diğer/Ka rma	0.0430 81166
24	527	24_aşı _seru m_cilt _saç	['aşı', 'serum', 'cilt', 'saç', 'maske', 'nemlendirici', 'krem', 'kremi', 'dezenfektan', 'grip']	['pke serum avoskin azeclair kak', 'ooooo kirpik uzatıcı serum almicazz', 'serum taktırın']	Diğer/Ka rma	0.0429 01393
25	406	25_de presyo n_anti depres an_boz ukluk_ güzeli m	['depresyon', 'antidepresan', 'bozukluk', 'güzelim', 'depresyona', 'anksiyete', 'kesmiyor', 'sendromu', 'ilaç', 'sinir']	['kamarad depresyon tkbrit mech', 'moun plezi pandan menm nan depresyon viv pou', 'nasılmıl depresyon']	Diğer/Ka rma	0.0726 21283
26	401	26_jen eratör_ mutfak tüpü_k ömür_t üpü	['jeneratör', 'mutfak tüpü', 'kömür', 'tüpü', 'mutfak', 'soba', 'ısıtıcı', 'enerji', 'gaz', 'yakıt']	['bagajda jeneratör çalışıyormuş', 'jeneratör', 'jeneratör kurbanı']	Diğer/Ka rma	0.0610 12701
27	387	27_rön tgen_d iş_ciha zı_tom ografi	['röntgen', 'diş', 'cihazı', 'tomografi', 'sıra', 'randevu', 'filmi', 'ultrason', 'sırası', 'çekimi']	['röntgen çektiirdim kelebekmks', 'röntgen sonucum', 'röntgen sırasındayım']	Diğer/Ka rma	0.0532 20405
28	352	28_diy abet_ş eker_h astalığı _şeker hastalı ğı	['diyabet', 'şeker', 'hastalığı', 'şeker hastalığı', 'tip', 'hastası', 'kalp', 'tansiyon', 'kronik', 'oruç']	['şeker hastalığı diyabet halk arasında şeker hastalığı adlandırılan diabetes mellitus diğer adıyla diyabet pankreastan salgılanan insülin eksikliği etkisizliği sonucu ortaya çıkan kan şekeri yüksekliğinin söz devamı', 'ebeveynin diyabet hastalığı', 'şeker hastalığı']	Diğer/Ka rma	0.0745 68873

Ek 8. (Devamı)

29	348	29_ara ç_trafi k_nede ni_kap alı	['araç', 'trafik', 'nedeni', 'kapalı', 'adiyaman', 'kazası', 'ölmek', 'caddesi', 'bebeğimiz', 'yaralı']	['acil bebeğimiz ölmek üzere bebek araç içinde araç plakası adiyaman gölbaşicumhuriyet mahallesikarayılan caddesi üzerindeler tel isim rahime mama ihtiyacı varmış açmış adiyaman gölbasında tanıdığı', 'çooooooooo acil bebeğimiz ölmek üzere bebek araç içinde araç plakası adiyaman gölbaşicumhuriyet mahallesikarayılan caddesi üzerindeler tel isim rahime mama ihtiyacı varmış açmış adiyaman gölbasında tanıdığı', 'çooooooooo acil bebeğimiz ölmek üzere bebek araç içinde araç plakası adiyaman gölbaşicumhuriyet mahallesikarayılan caddesi üzerindeler tel isim rahime mama ihtiyacı varmış açmış']	Diğer/Ka rma	0.1089 37002
30	340	30_ma h_kesi ntisi_s aat_sür ecek	['mah', 'kesintisi', 'saat', 'sürecek', 'noktalarımız', 'saat sürecek', 'zaman', 'dağları', 'başlangıcı', 'korku dağları']	['yenigün mah kesintisi saat sürecek', 'hadimköy mah hastane mah kesintisi saat sürecek', 'dereazgi mah gürpınar mah kesintisi saat sürecek']	Diğer/Ka rma	0.0798 45988
31	293	31_jen eratör_ şişme_ uyku_ tulumu _tulom u	['jeneratör', 'şişme', 'uyku tulumu', 'tulumu', 'seyahat', 'kaban', 'bere', 'çantası', 'bot', 'uyku']	['jeneratör büyük çadır siyah renkli ara bağlantı kablosu şişme yatak uyku tulumu seyahat çantası bere bot yağmurluk kaban yağmurluk üstü yağmurluk altı çadır kilo köpek maması elektrikli ısıtıcı', 'emniyet müdürü yinin çaldığı depremzede yardımları jeneratör büyük çadır siyah bağlantı kablosu şişme yatak uyku tulumu seyahat çantası bere bot yağmurluk kaban yağmurluk üstü yağmurluk altı çadır kilo köpek maması elektrikli ısıtıcı', 'emniyet müdürünün evinde yapılan aramada ele geçirilenler jeneratör büyük çadır siyah bağlantı kablosu şişme yatak uyku tulumu seyahat çantası bere bot yağmurluk kaban yağmurluk üstü yağmurluk altı çadır kilo köpek maması elektrikli ısıtıcı']	Diğer/Ka rma	0.0581 66678
32	227	32_ail e_aile hekimi _heki mi_en gelli	['aile', 'aile hekimi', 'hekimi', 'engelli', 'hastası', 'annem', 'konteyner', 'aile boyu', 'baba', 'babam']	['aile', 'çirahta aile', 'namusdu aile heyati']	Diğer/Ka rma	0.0519 4104

Ek 8. (Devamı)

33	214	33_be bek_be bek mamas 1_mam ası_bib eron	['bebek', 'bebek maması', 'maması', 'biberon', 'sütü', 'kremi', 'bezi', 'süt', 'bebek bezi', 'anne']	['bebek maması', 'bebek maması çaresizlikten çalınıyor', 'karıştırınca bebek maması']	Diğer/Ka rma	0.0807 95245
34	213	34_eği tim_öğ renci_ afşin_ gezici	['eğitim', 'öğrenci', 'afşin', 'gezici', 'kütüphane', 'öğretmen', 'konya', 'çadirkent', 'halk', 'üniversite']	['konya halk kütüphanesi afşin çadirkent yerleşkesinde gezici kütüphane okuyucularımızla beraber balon patlatmaca oyunu oynadık', 'konya halk kütüphanesi gezici kütüphane afşin çadirkent sahasında çocuklarımızla oyunlar oynadık boyama etkinliklerine devam', 'konya halk kütüphanesi gezici kütüphane afşin çadirkent yerleşkesinde yüz boyama yaptık çocuklarımızla eğlendik']	Diğer/Ka rma	0.0324 48822
35	207	35_vid eo_yo utube_ videos u_insta gram	['video', 'youtube', 'videosu', 'instagram', 'fotoğraf', 'fotosu', 'foto', 'terapi', 'videonun', 'videoyu']	['yastık döverken video gelir', 'rahatından tane serum yemelik video', 'video terapi resmen']	Diğer/Ka rma	0.0442 48778
36	203	36_faş ist_irk çılık_ır kçı_irk çılık	['faşist', 'ırkçılık', 'ırkçı', 'ırkçılık', 'tedavi', 'hastalıktır', 'faşizm', 'hastalık', 'edilmesi', 'lgbt']	['ırkçılık tedavi edilmesi gereken hastalıktır', 'ırkçılık tedavi edilmesi gereken patolojik hastalıktır', 'myavaşakşenerağar ırkçı faşist']	Diğer/Ka rma	0.0577 44203
37	202	37_em ekli_e meklili k_verg i_kayd 1	['emekli', 'emeklilik', 'vergi', 'kaydı', 'emekli maaşı', 'maaşı', 'tarihinden', 'sigorta', 'prim', 'tescil']	['nbağkura kayıt yaptırmamış esnaf sanatkarların emekli olabilmeleri için tarihinden önceki vergi kayıt tarihlerinin esas alınmasını sağlayacak yeni yasal düzenleme yapılmasını talep ediyoruz', 'esnafınıza sahip çıkan tarihinden oda vergi kaydı esnaf işyeri bulunan bağkur kaydı bulunmayan esnafın mağduriyeti sürüyor emeklilik yaşı esnafa geriye dönük bağkur tescil imkanı sağlanmalıdır', 'emekli kan ağıyor erdogan emekli accccc']	Diğer/Ka rma	0.0514 52931
38	198	38_şarj j_şarj cihazı_ cihazı_ taşınab ilir	['şarj', 'şarj cihazı', 'cihazı', 'taşınabilir', 'pil', 'güneş', 'şarjı', 'hızlı', 'mah', 'koruması']	['şarj cihazı android', 'salihh abiiii şarj cihazı getirrr', 'şarj cihazı']	Diğer/Ka rma	0.0927 67892

Ek 8. (Devamı)

39	186	39_kadın_kadınlar_pedi_kadınlar_pedi_kadınlar_pedi	['kadin', 'kadinlar', 'pedi', 'kadin pedi', 'kadinlara', 'kadinların', 'kadinın', 'erkek', 'ped', 'çankaya']	['kadin pedi kadınlar kimden isteyecek nerden bulacaklar', 'kadin arkadaşımızdan dahi istemeye çekiniyorlardı bizde kadın evlerin kolilerine sormadan direk koyuyorduk temel sağlık ihtiyacıdır kadın pedi', 'deprem bölgesine kadın pedi ihtiyacı söyleyen ayıplayan kaç yazı gördüm kadınların kadınlığından korkuyorsunuz ayıp yansıtıyorsunuz susturmaya çalışıyorsunuz kadın pedi kadınlar temel ihtiyaç sonuçta anormal bişey']	Diğer/Karar	0.0455 56475
40	155	40_lambası_gece_lambası_gece_lambası_gece_aydınlatma	['lambası', 'gece lambası', 'gece', 'aydınlatma', 'ışık', 'fener', 'sokak', 'renk', 'gündüz', 'karanlık']	['led gece lambası hareket sensörlü adet gece lambası çocuklar akü içinde hareket sensörlü merdiven aydınlatması koridor banyo yatak odası tuvalet lambası açmakapama sensörü lambası', 'gece lambası önemli', 'gece lambası']	Diğer/Karar	0.0767 84654
41	149	41_eczane_nöbetçi_nöbetçi_eczane_birliği	['eczane', 'nöbetçi', 'nöbetçi eczane', 'birliği', 'türk', 'eczaneler', 'ilaç', 'gönüllü', 'sahra', 'listesi']	['mart manisa nöbetçi eczane listesi yayınlandı işte nöbetçi eczaneler', 'yenice nöbetçi eczane listesi', 'orduda hangi eczane nöbetçi devlet nöbetçi eczane listesi']	Diğer/Karar	0.0723 8961
42	149	42_film_korku_film_korku_film_korku_film	['film', 'korku', 'korku filmi', 'film', 'tiyatro', 'estetik', 'tiyatrosu', 'battaniye altında', 'filmleri', 'kamera']	['korku filmi onersenize', 'korku filmi', 'nece korku filmi']	Diğer/Karar	0.0693 58853
43	138	43_giysi_tir_dolusu_satmış	['giysi', 'tir', 'dolusu', 'satmış', 'polis', 'şubatta', 'kızılay', 'kızılayın', 'kilosu', 'ortaya çıktı']	['kızılay şubatta tir dolusu giysi satmış polis tutanağı ortaya çıktı', 'kızılay şubatta tir dolusu giysi satmış', 'kızılay şubatta tir dolusu giysi satmış polis tutanağı ortaya çıktıkansızsınız hırsızsınız onursuzsunuz abs']	Diğer/Karar	0.1075 48564

Ek 8. (Devamı)

44	131	44_yunus_balik_ton_konse_rve	['yunus', 'balık', 'ton', 'konserve', 'yunus emre', 'yıldan', 'afad başkanı', 'bulunmamaktadır', 'emre', 'katil']	['iskenderun körfezinde büyüklüğünde deprem afad başkanı yunus sezer itibarıyla olumsuz durum bulunmamaktadır ekiplerimiz teyakkuz halindedir', 'afad başkanı yunus sezer iskenderun körfezinde saat meydana hatay ilimizde hissedilen büyüklüğündeki sonrasında itibarıyla olumsuz durum bulunmamaktadır', 'afad başkanı yunus sezer iskenderun körfezinde saat meydana hatay ilimizde hissedilen büyüklüğündeki sonrasında itibarıyla olumsuz durum bulunmamaktadır ekiplerimiz teyakkuz halindedir']	Diğer/Karar	0.0416 34321
45	129	45_yurt_dışina_dışina_yurt_dışında	['yurt', 'yurt dışına', 'dışına', 'yurt dışında', 'vize', 'dışında', 'yurt dışı', 'dışı', 'aralık', 'başvurusu']	['sene adet yurt dışına açılacaksınız', 'yurt dışına çıkmasaydım olurdu', 'yurt dışına gidersem']	Diğer/Karar	0.0937 48476
46	119	46_yatak_battaniye_yatak_odası_odası	['yatak', 'battaniye', 'yatak odası', 'odası', 'yatakta', 'priz', 'yatak odasına', 'yatağın', 'yeri', 'yatağı']	['yatak halinde bekliyoruz', 'hangi yatak odası takımını beğendiniz', 'yatak odasına']	Diğer/Karar	0.0866 80288
47	116	47_çiçek_edici_maddeleri_madde	['çiçek', 'edici', 'maddeleri', 'madde', 'özelliği', 'bitki', 'denir', 'tedavi', 'kullanılan', 'yaprak']	['tedavi edici özelliği biyoaktif madde maddeleri taşıyan bitkilere', 'ders tedavi edici özelliği biyoaktif madde maddeleri taşıyan bitkilere tıbbi bitki denir', 'tedavi edici özelliği biyoaktif madde maddeleri taşıyan bitkilere tıbbi bitki denir']	Diğer/Karar	0.0705 6705
48	75	48_evlilik_ilişki_çocuk_teklifi	['evlilik', 'ilişki', 'çocuk', 'teklifi', 'evli', 'aile', 'psikolojik', 'sabaha', 'eşi', 'kurmak']	['yaş alıp kira ödedikçe ulan evlilik fikirmiş tabak çanaklar beleşe geliyor farkındalığı', 'aile ortamında evlilik konusu açılınca', 'evlilik çocuk']	Diğer/Karar	0.0320 85879
49	65	49_vitamin_magnezyum_vitamin_tansiyon	['vitamin', 'magnezyum', 'vitamini', 'tansiyon', 'tuzu', 'tuz', 'serum', 'kaya', 'tuzlu', 'reçete']	['durumunuzu bilmeden burdan önermede bulunmam söz konusu lakin psikiyatriden vitamin mineral değerlerinize baktırın zira bazı vitamin mineral eksiklikleri ruhsal zihinsel anlamda olumsuz sonuçlar doğurabiliyor hekimden destek almalısınız', 'enerjimin kalkıp vitamin içmem gerek vitamin içecek enerjim', 'vitamin reçete etmek']	Diğer/Karar	0.0754 11602

Ek 8. (Devamı)

50	53	50_no ktalari miz_p azartes i_yaz_ cumart esi	['noktalarımız', 'pazartesi', 'yaz', 'cumartesi', 'cuma', 'reçete', 'kilis', 'osmaniye', 'diyarbakır', 'reçete yaz']	['dağıtım noktalarımız adıyaman pazartesi', 'dağıtım noktalarımız kahramanmaraş pazartesi', 'dağıtım noktalarımız hatay pazartesi']	Diğer/Ka rma	0.2163 34597
51	51	51_ma t_mate matik_ sınavı_ fizik	['mat', 'matematik', 'sınavı', 'fizik', 'dersi', 'sınav', 'yarin', 'saat', 'simdi', 'yapıcam']	['merhaba aisa gayet matematik seven adeta matematik askıyla tutusan bireydir gun matematik matematik bize aglar kafasini test kitabından kaldirmaz lutfen iceri alin', 'fizik matematik bilersen', 'elendik amk mat sınavından elenicez amk bitti matematik sınavı gitti kupa']	Diğer/Ka rma	0.0875 83742
52	45	52_kre di_bor çlarını _birey sel_fai zsiz	['kredi', 'borçlarını', 'bireysel', 'faizsiz', 'adıyaman hatay', 'milyar', 'hatay kahramanmaraş', 'tarihine', 'agustos', 'kart']	['adıyaman hatay kahramanmaraş malatya osmaniye illeri islahiye nurdağı ilçelerindeki bireysel müşterilerimizin mevcut kredi kart borçlarını agustos tarihine herhangi talep aranmaksızın faizsiz erteliyoruz', 'mmerhaba adıyaman hatay kahramanmaraş malatya osmaniye illeri islahiye nurdağı ilçelerindeki bireysel müşterilerimizin mevcut kredi kart borçlarını agustos tarihine herhangi talep aranmaksızın faizsiz erteliyoruz', 'merhaba adıyaman hatay kahramanmaraş malatya osmaniye illeri islahiye nurdağı ilçelerindeki bireysel müşterilerimizin mevcut kredi kart borçlarını agustos tarihine herhangi talep aranmaksızın faizsiz erteliyoruz']	Diğer/Ka rma	0.1390 25312
53	39	53_apa _dari_ mana_ nesille r	['apa', 'dari', 'mana', 'nesiller', 'oleh', 'japonyada', 'yüzyılda', 'üretiyorlar', 'doğdu', 'kesmeden']	['dari mana bahasa korea', 'japonlar yıldır ağaç kesmeden odun üretiyorlar yüzyılda olağanüstü daisugi tekniği japonyada doğdu gerçekten daisugi ağaçların gelecek nesiller dikilmesini kesilmemesini dev bonsai ağaçları budanmasını sağlar tekniğin sedirlere', 'japonlar yıldır ağaç kesmeden odun üretiyorlar yüzyılda olağanüstü daisugi tekniği japonyada doğdu gerçekten daisugi ağaçların gelecek nesiller dikilmesini kesilmemesini dev bonsai ağaçları budanmasını sağlar']	Diğer/Ka rma	0.1788 52434

Ek 8. (Devamı)

54	31	54_m ühend is_ka mu_g elebil ecek_ bilişi m	['mühendis', 'kamu', 'gelebilecek', 'bilişim', 'özlük', 'kolaylaştırır', 'aklınıza', 'özlük hakları', 'enerji', 'mali']	['mühendis hayatı kolaylaştırır barınma enerji giyim gıda iletişim ulaşım bilişim sanayi aklınıza gelebilecek alanda mühendis vardır mühendislik yükselirse ülke yükselir kamu mühendislerinin mali özlük hakları iyileştirilmelidir', 'mühendis hayatı kolaylaştırır barınma enerji giyim gıda iletişim ulaşım bilişim sanayi aklınıza gelebilecek alanda mühendis vardır mühendislik yükselirse ülke yükselir kamu mühendislerinin mali özlük hakları iyileştirilmelidir mühendisiduy sncumhurbaskanim', 'mühendis hayatı kolaylaştırır barınma enerji giyim gıda iletişim ulaşım bilişim sanayi aklınıza gelebilecek alanda mühendis vardır kamu mühendislerinin mali özlük hakları iyileştirilmelidir']	Diğer/ Karma	0.1599 43291
55	22	55_uf o_dü nya_y apay_ alanı	['ufo', 'dünya', 'yapay', 'alanı', 'yaşam alanı', 'yaşam', 'güneş', 'ısıtıcı', 'düz', 'lar']	['hocam abd rusya semalarında görünen ufo lar balkonlarda ısıtıcı ufo lar değilse buralara tepeden baksalar halimizi görseler diyorum merci derdimizi anlatalım kaldık berbat düzenin içinde', 'başka dünyada uzay üstünde yaşam alanı oluşturmak isteyenler plana çıkabilir bakalım çalışmalar gidecek göreceğiz yapay dünya planları fazlası diyebiliriz', 'içinde durduğumuz kainat içinde bulunduğumuz güneş sistemi mercek etkisi ilizyon edilmiş yapay yaşam alanı tanrı güneş buyruğuma boyun eğerek gel yörüngeye yapay yerleştirme bundan açık tarif edilirdi']	Diğer/ Karma	0.0661 59225
56	19	56_h dp_ch p_hd pkk_ görüş mesi	['hdp', 'chp', 'hdpkk', 'görüşmesi', 'hdppe', 'pkk', 'nin', 'üye', 'parti', 'masada']	['yaa hdp pkknın yancısıdır deyip hdp yatak açan meral', 'hdp secmeni pkk degildir demek istedi herhalde hdp parti pkk umarım hdp secmeni korku yasamadan ozgurce istedigine verebilir', 'hdp ikisinide tokatlar']	Diğer/ Karma	0.1212 90689
57	19	57_av ukatla r_kutl u_hu kuku n_gü nünü	['avukatlar', 'kutlu', 'hukukun', 'günü', 'kılmak', 'koşulda', 'dünyasında', 'hak', 'mücadele eden', 'daima']	['hocam adil yaşam alanı olmayan günümüz dünyasında zaman koşulda hukuku üstün kılmak mücadele eden daima hak adaletten yana değerli hukukçuların avukatlar gününü içten dileklerimle kutlarım sevgi saygılarımla selamlar', 'adil yaşam alanı olmayan günümüz dünyasında zaman koşulda hukuku üstün kılmak mücadele eden daima hak adaletten yana değerli hukukçuların avukatlar gününü içten dileklerimle kutlarım sevgi saygılarımla selamlar', 'adil yaşam alanı olmayan günümüz dünyasında zaman koşulda hukuku üstün kılmak mücadele eden daima hak adaletten yana değerli hukukçularımızın avukatlar günü kutlu']	Diğer/ Karma	0.1654 04846

Ek 8. (Devamı)

58	19	58_o yuncu nun_ milyo n_çağ rısı_y ardım çağrıs ı	['oyuncunun', 'milyon', 'çağrısı', 'yardım çağrısı', 'toplandı', 'ingiliz', 'depremzedeler', 'yardım', 'depremzedeler yardım', 'topladı']	['ingiliz oyuncu daniel craig hafta türkiye suriyede yaşanan depremlerin ardından yardım çağrısı oyuncunun çağrısının ardından milyon sterlin toplandı', 'depremzedeler milyon sterlin topladı james bondun yıldızı daniel craig türkiyedeki depremzedeler yardım çağrısı yapmıştı oyuncunun çağrısı milyon sterlin para toplanarak cevap buldu', 'james bondu canlandıran ingiliz oyuncu daniel craig hafta türkiye suriyedeki depremzedeler yardım çağrısında bulunmuştu oyuncunun çağrısı milyon sterlinin üzerinde para toplandı']	Afet Yardım 1	0.1901 92169
----	----	---	---	--	---------------------	-----------------

ÖZGEÇMİŞ

Mafaza Mohamed Bahialdien NAZAR, 2020 yılında Hartum Üniversitesi Tıp Fakültesi'nden Tıp ve Cerrahi Lisans derecesi ile mezun olmuştur. 2025 yılında Avusturya'daki Johannes Kepler Üniversitesi'nde Erasmus+ stajını tamamlamıştır. NAZAR'ın ana dili Arapça olup, Türkçe, İngilizce ve Almanca yabancı dillere sahiptir. Python, HTML ve CSS programlama dillerinde orta düzey bilgiye sahiptir.

