

T.C.
BİLECİK ŞEYH EDEBALI ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

**ACİL ÇAĞRI MERKEZİNE GELEN ÇAĞRILARIN DOĞAL DİL İŞLEME
YÖNTEMLERİ İLE SINIFLANDIRILMASI:
BİLECİK 112 ACİL ÇAĞRI MERKEZİ ÖRNEĞİ**

YÜKSEK LİSANS TEZİ

ÖZLEM TAN

TEZ DANIŞMANI
DR. ÖĞR. ÜYESİ RIDVAN YAYLA

BİLECİK, 2025

10745355

T.C.
BİLECİK ŞEYH EDEBALI ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

**ACİL ÇAĞRI MERKEZİNE GELEN ÇAĞRILARIN DOĞAL DİL İŞLEME
YÖNTEMLERİ İLE SINIFLANDIRILMASI:
BİLECİK 112 ACİL ÇAĞRI MERKEZİ ÖRNEĞİ**

YÜKSEK LİSANS TEZİ

ÖZLEM TAN

TEZ DANIŞMANI
DR. ÖĞR. ÜYESİ RIDVAN YAYLA

BİLECİK, 2025

10745355

BEYAN

Acil Çaęrı Merkezine Gelen Çaęrıların Doğal Dil İşleme Yöntemleri İle Sınıflandırılması Bilecik 112 Acil Çaęrı Merkezi Örneęi adlı yüksek lisans tezimin hazırlık ve yazımı sırasında bilimsel araştırma ve etik kurallarına uyduğumu, başkalarının eserlerinden yararlandığım bölümlerde bilimsel kurallara uygun olarak atıfta bulunduğumu, kullandığım verilerde herhangi bir tahrifat yapmadığımı, tezin herhangi bir kısmının Bilecik Şeyh Edebali Üniversitesi veya başka bir üniversitede başka bir tez çalışması olarak sunulmadığını, aksinin tespit edileceęi muhtemel durumlarda doğabilecek her türlü hukuki sorumluluęu kabul ettiğimi ve vermiş olduğum bilgilerin doğru olduğunu beyan ederim.

Bu çalışmanın, Bilimsel Araştırma Projeleri (BAP), TÜBİTAK veya benzeri kuruluşlarca desteklenmesi durumunda; projenin ve destekleyen kurumun adı proje numarası ile birlikte, ETİK KURUL onayı alınması durumunda ise ETİK KURUL tarih karar ve sayı bilgilerinin beyan edilmesi gerekmektedir.			
DESTEK ALINMIŞTIR		DESTEK ALINMAMIŞTIR	✓
Destek alındı ise;			
Destekleyen kurum;			
Desteęin Türü		Proje Numarası	
1- BAP (Bilimsel Araştırma Projesi)			
2- TÜBİTAK			
Dięer;.....			
ETİK KURUL onayı var ise;			
ETİK KURUL karar tarih/sayı:	/.....	

Öğrenci Adı ve Soyadı

Özlem TAN

Tarih

.....

İmza

.....

ÖN SÖZ

Bu tez çalışmasının her aşamasında bilgi, tecrübe ve desteğini esirgemeyen, yol gösterici katkılarıyla sürece yön veren yüksek lisans tez danışmanım Sayın Dr. Öğr. Üyesi Rıdvan YAYLA' ya teşekkür ve şükranlarımı sunarım.

Çalışmam boyunca desteklerini hissettiren Bilecik Şeyh Edebali Üniversitesi ailesine, özellikle Mühendislik Fakültesi'nde görev yapan değerli öğretim üyelerine teşekkür ederim.

Tez savunma sürecinde yapıcı geri bildirimleri ve katkılarıyla çalışmanın geliştirilmesine önemli katkılarda bulunan sayın jüri üyelerine saygı ve teşekkürlerimi arz ederim.

Akademik gelişimime katkıda bulunan, bilgi ve deneyimleriyle bu süreci anlamlı kılan tüm hocalarıma, ayrıca desteğini her zaman yanımda hissettiğim aileme ve arkadaşlarıma teşekkür ederim.

Veri temini ve teknik konularda katkı sağlayan tüm kurum ve kişilere teşekkür eder, bu çalışmanın acil durum yönetimi alanında araştırmacılar ve uygulayıcılar için yararlı bir kaynak olmasını temenni ederim.

Özlem Tan

2025

ÖZET

ACİL ÇAĞRI MERKEZİNE GELEN ÇAĞRILARIN DOĞAL DİL İŞLEME YÖNTEMLERİ İLE SINIFLANDIRILMASI: BİLECİK 112 ACİL ÇAĞRI MERKEZİ ÖRNEĞİ

Acil çağrı merkezleri, modern toplumlarda bireylerin yaşam güvenliği ve toplumsal düzenin sürdürülebilirliği açısından hayati öneme sahip kritik altyapılar arasında yer almaktadır. Bu çalışma, acil durum çağrılarının işleme süreçlerinde operasyonel verimliliği artırmak ve müdahale sürelerini optimize etmek amacıyla doğal dil işleme (NLP) tabanlı yenilikçi bir otomatik sınıflandırma sistemi önermektedir. Araştırma kapsamında, gerçek çağrı merkezi ortamından elde edilen ses kayıtları öncelikle metinsel veriye dönüştürülmüş, ardından kapsamlı bir veri ön işleme sürecinden geçirilmiştir. Bu süreçte, metin normalizasyonu, tokenizasyon, stop-word eliminasyonu ve özel isimlerin anonimleştirilmesi gibi temel NLP teknikleri uygulanmıştır. Makine öğrenmesi yaklaşımı olarak Naive Bayes, Destek Vektör Makineleri (SVM), Random Forest ve Logistic Regresyon algoritmaları ile birlikte derin öğrenme tabanlı LSTM, CNN, GRU ve BERT modelleri karşılaştırmalı olarak değerlendirilmiştir. Model performansları kesinlik, duyarlılık ve F1-skor standart doğruluk metrikleri ile ölçülmüştür. Deneysel sonuçlarda geliştirilen modellerde farklı doğruluk sonuçlarına ulaşılmıştır. Bu bulgular, acil durum yönetim sistemlerinde yapay zekâ tabanlı çözümlerin operasyonel verimliliği önemli ölçüde artırabileceğini ve insan kaynaklı hataları minimize edebileceğini ortaya koymaktadır. Çalışmanın, gelecekte acil çağrı merkezlerinin dijital dönüşüm çalışmalarına katkı sağlayacağı öngörülmektedir.

Anahtar Kelimeler: Doğal Dil İşleme, Acil Durum Yönetimi, Otomatik Sınıflandırma, Sesli Çağrı Analizi

ABSTRACT

CLASSIFICATION OF CALLS RECEIVED BY THE EMERGENCY CALL CENTER USING NATURAL LANGUAGE PROCESSING METHODS:

BİLECİK 112 EMERGENCY CALL CENTER EXAMPLE

Emergency call centers are among the critical infrastructures that are vital for the safety of life and sustainability of social order in modern societies. This study proposes an innovative automatic classification system based on natural language processing (NLP) in order to increase operational efficiency and optimize response times in the processing of emergency calls. Within the scope of the research, voice recordings obtained from a real call center environment were first converted into textual data and then subjected to a comprehensive data preprocessing process. In this process, basic NLP techniques such as text normalization, tokenization, stop-word elimination and anonymization of proper nouns were applied. As a machine learning approach, Naive Bayes, Support Vector Machines (SVM), Random Forest and Logistic Regression algorithms as well as deep learning-based LSTM, GRU, CNN and BERT models were comparatively evaluated. Model performances were measured with precision, sensitivity, and F1-score standard accuracy metrics. Experimental results showed that different accuracy results were achieved in the developed models. These findings reveal that artificial intelligence-based solutions in emergency management systems can significantly increase operational efficiency and minimize human-related errors. It is anticipated that the study will contribute to the digital transformation efforts of emergency services in the future.

Keywords: Natural Language Processing, Emergency Management, Automatic Classification, Voice Call Analysis

İÇİNDEKİLER

	Sayfa
ÖN SÖZ.....	i
ÖZET.....	ii
ABSTRACT.....	iii
İÇİNDEKİLER.....	iv
TABLolar LİSTESİ.....	vi
ŞEKİLLER LİSTESİ.....	vii
KISALTMALAR VE SİMGELER LİSTESİ.....	viii
1. GİRİŞ.....	1
1.1. Tezin Amacı.....	6
2. LİTERATÜR ARAŞTIRMASI.....	8
2.1. Acil Çağrı Merkezleri.....	8
2.2. 112 Acil Çağrı Merkezlerinin Yapısı ve İşleyişi.....	9
2.3. Acil Çağrı Verilerinin Özellikleri.....	12
2.4. Otomatik Konuşma Tanıma (ASR) Sistemlerinin Temelleri	20
2.5. Kullanılan Yaygın ASR Teknolojileri ve Modelleri	23
2.6. Gürültü Ortamında Ses Tanıma Başarımı.....	27
2.7. Türkçe Dilinde ASR Uygulamaları ve Zorluklar	30
2.8. Acil Durumlarda Gerçek Zamanlı Ses-Metin Dönüşümünün Önemi.....	35
2.9. Doğal Dil İşleme Yöntemleri.....	40
2.10. Özellik Çıkarımı Yöntemleri	46
2.11. Sınıflandırma Algoritmaları.....	49
2.12. NLP'nin Acil Durum Sistemlerindeki Uygulamaları	53
3. YÖNTEM.....	57
3.1. Genel Bakış.....	57

3.2.	Veri Kümesi.....	59
3.3.	Sesi Metne Çevirme	60
3.4.	Ön İşleme ve Anonimleştirme.....	62
3.5.	Sınıflandırma Modeli.....	64
3.5.1.	Lojistik Regresyon (Logistic Regression)	65
3.5.2.	Naive Bayes.....	65
3.5.3.	Destek Vektör Makineleri (Support Vector Machines, SVM)	65
3.5.4.	Rastgele Orman (Random Forest)	66
3.5.5.	Model Mimarileri ve Hiperparametre Ayarları	66
3.6.	Sınıfa Göre Yönlendirme Önerisi: Akıllı Destek Sistemi Tasarımı	68
3.7.	Operatör Onayı ve Yönlendirme.....	69
3.8.	Geri Bildirim ve Model Güncellemesi.....	69
3.9.	Prototip Ara yüz Geliştirme ve Uygulama Önerisi	69
4.	BULGULAR ve TARTIŞMA.....	71
5.	SONUÇLAR ve ÖNERİLER	76
	KAYNAKÇA	80
	EKLER.....	85

TABLULAR LİSTESİ

	Sayfa
Tablo 1.1. Acil Çağrı Merkezlerinde Doğal Dil İşleme ve Yapay Zekâ Uygulamaları	6
Tablo 3.1. Uygulamanın Sağladığı Katkılar	57
Tablo 3.2. Etiketli Sınıf Verileri	59
Tablo 3.3. Makine Öğrenmesi Algoritmalarının Karşılaştırmalı Özellikleri	65
Tablo 3.4. Kullanılan Sınıflandırma Algoritmalarına Ait Hiperparametre Ayarları	66
Tablo 3.5. Prototip Ara yüzünün Bileşenleri	70
Tablo 4.1. Makine Öğrenmesi Model sonuçları	71
Tablo 4.2. Derin Öğrenme Model Sonuçları	72
Tablo 5.1. Literatürdeki Çalışmaların Karşılaştırmalı Analiz Tablosu	78

ŞEKİLLER LİSTESİ

	Sayfa
Şekil 2.1. 112 Acil Çağrı Merkezinin Çalışma Modeli.....	9
Şekil 3.1. Sistemin Çalışma Süreci	58
Şekil 4.1. Random Forest modeli için Confusion Matrix	73
Şekil 4.2. Random forest modeli için ROC eğrisi	73
Şekil 4.3. CNN Modeli için Precision ve Recall Eğrileri	74
Şekil 4.4. CNN Modeli için ROC Eğrileri	74
Şekil 4.5. CNN Modeli için Confusion Matrix.....	75

KISALTMALAR VE SİMGELER LİSTESİ

AÇM: Acil Çağrı Merkezi

ASR: Otomatik Konuşma Tanıma

BiLSTM: İki Yönlü Uzun Kısa Süreli Bellek

BTK: Bilgi Teknolojileri ve İletişim Kurumu

CBS: Coğrafi Bilgi Sistemleri

DNN: Derin Sinir Ağları

E-AÇS: Entegre Acil Çağrı Sistemi

EDA: Kolay Veri Artırma

HMM: Gizli Markov Modelleri

KVKK: Kişisel Verilerin Korunması Kanunu

LSTM: Uzun Kısa Süreli Bellek

MFCC: Mel Frekans Kepstrum Katsayıları

NLP: Doğal Dil İşleme

SER: Duygu Tanıma

SMÇ: Sesi Metne Çevirme

SNR: Sinyal-gürültü oranı

SVM: Destek Vektör Makineleri

WER: Kelime Hata Oranı

YZ: Yapay Zeka

1. GİRİŞ

Acil Çağrı, kamu düzenini ve güvenliğini, vatandaşın sağlığı ve güvenliğini, toplumun sağlığını, su kaynakları ve sulak alanları ile doğaya yönelik aniden gelişen olayları ve kişi ve mal dokunulmazlığına yönelik tehdit ve zararları içeren durumlara ilişkin her türlü çağrıyı içine alır. (112 Acil Çağrı Merkezleri Kuruluş, Görev ve Çalışma Yönetmeliği, 2014 madde: 4)

Acil Çağrı Merkezleri, acil durum algılayıcı cihazların veya kullanıcıların acil yardım talebinde bulunmak maksadıyla acil yardım çağrı hizmeti numarasını (112) arayarak yapacakları çağrılara cevap verecek yetkili kurum veya kuruluşlardır. Bu kapsamda, yeni yapılan yasal düzenleme ile ülkemizde 112 Acil Çağrı Merkezi (AÇM), acil yardım çağrılarında cevap vermek üzere İçişleri Bakanlığı tarafından büyükşehir olan illerde Yatırım İzleme ve Koordinasyon Başkanlığı bünyesinde, büyükşehir olmayan illerde ise valilikler bünyesinde kurulan merkezlerdir (<https://www.afad.gov.tr>, 2018).

Acil durumlara hızlı ve doğru şekilde müdahale edilebilmesi, çağrı merkezlerinin etkinliğine doğrudan bağlıdır. Türkiye'de 112 Acil Çağrı Merkezleri, yangın, sağlık, trafik gibi farklı alanlardaki acil durumları tek bir merkezden yönetmeyi amaçlayan bütünleşik bir yapı sunmaktadır (İçişleri Bakanlığı, 2020). Ancak çağrı yoğunluğunun artması, sınırlı sayıda operatörle bu taleplere zamanında yanıt verilmesini zorlaştırmaktadır. (Bukan, 2019).

Acil çağrı merkezleri, çağdaş kamu hizmetlerinde vatandaşla ilk temas noktası olarak işlev görmektedir. Bu merkezlerin bilişim altyapıları ve yapay zekâ (YZ) destekli analiz sistemleri, günümüzde kamu güvenliği ve acil müdahale sürelerinin azaltılmasında kritik bir rol oynamaktadır. Literatürde, özellikle doğal dil işleme (NLP), sınıflandırma algoritmaları ve veri madenciliği gibi yöntemlerle desteklenen sistemlerin geliştirilmesi üzerine birçok akademik ve uygulamalı çalışma bulunmaktadır (Apak & Üstoğlu, 2017).

Acil çağrılarının değerlendirilmesinde zamanla yarışan müdahale süreçlerinde, yapay zekâ ve makine öğrenmesi destekli çözümler giderek önem kazanmaktadır. Örneğin Blomberg ve arkadaşları (2019), kalp durması gibi kritik durumların 112 çağrılarında otomatik olarak tanımlanmasında makine öğrenmesi modellerinin, insan çağrı alıcılarının kararlarını destekleyecek düzeyde etkili olabileceğini göstermiştir.

Ekşi ve Yıldırım (2014) tarafından yapılan araştırmada, Avrupa Birliği uyum sürecinde Türkiye'de hayata geçirilen tek numara acil çağrı sistemi (112) uygulaması değerlendirilmektedir. Bu çalışmada, sağlık personelinin sisteme yönelik algıları ve sistemsel

aksaklıklar detaylı olarak ele alınmış ve NLP destekli dijital analiz araçlarına olan ihtiyaç vurgulanmıştır. Özellikle sağlık personelinin operatör geri bildirimleri üzerinden sistem verimliliği artırılabilceği önerilmiştir (Ekşi & Yıldırım, 2014).

Bukan (2019) tarafından Yalova ilinde yapılan saha araştırmasında, 112 acil çağrı merkezinin sosyal yönü ele alınmıştır. Araştırma, çağrı merkezinin sadece teknik bir yapı olmadığını; aynı zamanda sosyal etkileşimin, psikolojik desteğin ve yönlendirici bilginin iletildiği bir iletişim noktası olduğunu göstermektedir. Çalışmada, sistemin işleyişinde insan faktörüyle birlikte makine öğrenmesi destekli sınıflandırma algoritmalarının entegrasyonu gerektiği savunulmuştur (Bukan, 2019).

Ekşi ve Torlak (2011) tarafından yürütülen başka bir çalışmada ise, Avrupa Tek Acil Çağrı Numarası (112) uygulamasının vatandaşlar üzerindeki etkileri incelenmiş ve sistemin kullanılabilirliği ile ilgili deneyimsel veriler sunulmuştur. Bu araştırma, özellikle vatandaşların çağrı sistemlerine yönelik bilgi seviyesinin artırılmasının acil müdahale hızına doğrudan katkı sağlayacağını ortaya koymuştur. Bu bağlamda, NLP tabanlı otomatik sınıflandırma sistemlerinin bilgi ve farkındalık düzeyine göre içerik analizi yapabilmesi gerektiği vurgulanmıştır (Ekşi & Torlak, 2011).

Ağaç (2012), çağrı merkezlerinin Türkiye’deki genel yapısını ve performans ölçütlerini değerlendirdiği çalışmasında, 112 sistemi gibi kamu tabanlı çağrı platformlarında yapay zekâ uygulamalarının henüz yeterince yer bulamadığını ifade etmiştir. Bu bağlamda, çağrı merkezlerinde operatörlerin karar alma süreçlerini destekleyen dijital karar destek sistemlerinin entegrasyonu önerilmiştir (Ağaç, 2012).

Stamm (2005) tarafından geliştirilen “Professional Quality of Life Scale (ProQOL)” üzerinden yürütülen çalışmalar, acil çağrı operatörlerinin mesleki tatmini, tükenmişlik düzeyi ve ikincil travma riski gibi etmenlerin çağrı sistemlerinin genel işleyişini doğrudan etkilediğini ortaya koymaktadır. Literatürde NLP tabanlı içerik analizi teknikleriyle, bu duygusal durumların çağrı kayıtlarından analiz edilmesi yönünde yapılan yeni nesil çalışmalar dikkat çekmektedir (Stamm, 2005).

Mahsum Bahadır ve İnce (2024), Türkiye’deki çağrı sistemlerinde aktif öğrenme ve çevrimiçi öğrenme yaklaşımlarının uygulanabilirliğini inceledikleri çalışmada, özellikle 112 acil çağrı merkezi veri setlerinin sürekli güncellenen yapısına dikkat çekmişlerdir. NLP ve yapay zekâ tabanlı sistemlerin başarısının veri tazeliği ve veri etiketi doğruluğuyla doğrudan ilişkili olduğu gösterilmiştir (Mahsum Bahadır & İnce, 2024).

Guo, Li ve Zhang (2012) ise, kısa metin sınıflandırmasında derin öğrenme yöntemlerinin uygulanabilirliğini irdeleyen çalışmalarında, acil çağrı metinlerinin genellikle kısa, eksik ve bağlamdan yoksun olmasının sınıflandırma doğruluğunu olumsuz etkileyebileceğini belirtmiştir. Bu nedenle RNN, LSTM ve Transformer tabanlı modellerin önemi vurgulanmaktadır (Guo v.d., 2012).

Zhang ve Qi (2005) tarafından önerilen çok sınıflı SVM yaklaşımı, çağrı metinlerinin yalnızca üç ana başlıkta değil (sağlık, itfaiye, asayiş), detaylı alt kategorilere ayrılmasında da kullanılabilirliğini göstermiştir. Özellikle çağrı metinlerinde yer alan nüansların tanınması ve doğru sınıflandırılması için bu tür yaklaşımların NLP modelleriyle entegre edilmesi gerektiği ifade edilmiştir (Zhang & Qi, 2005).

Araghinegad, Mohseni ve Rahimi (2011) ise Random Forest algoritmasının acil çağrı metinleri üzerindeki başarısını analiz etmiş ve bu yöntemin özellikle gürültülü veri kümelerinde SVM gibi yöntemlere göre daha istikrarlı sonuçlar verdiğini ileri sürmüştür. Literatürde, 112 çağrı verileri gibi yüksek hacimli ama eksik veya yanlış verilerin bulunduğu ortamlarda bu yöntem önerilmektedir (Araghinegad v.d., 2011).

Parry, Kawakami ve Kishiya (2011), mekânsal faktörlerin çevrimiçi karar alma süreçlerine etkisini inceleyen çalışmalarıyla acil çağrı sistemlerine veri analitiği penceresinden yaklaşmıştır. Özellikle kırsal ve kentsel çağrılarının içerik farklılıkları, NLP sistemlerinin konum bilgisiyle desteklenmesinin önemini vurgulamaktadır (Parry v.d., 2011).

Creswell ve Plano Clark (2014), karma yöntem araştırmalarının çağrı sistemleri üzerine uygulanabilirliğini değerlendirerek, nitel ve nicel yöntemlerin birleştirilmesiyle çağrı kalitesinin çok yönlü olarak analiz edilebileceğini ortaya koymuştur. NLP bu yaklaşımın merkezinde yer almakta ve özellikle metin içeriklerinin nicel skorlamasında etkili bir araç sunmaktadır (Creswell & Plano Clark, 2014).

Dai ve arkadaşları (2012), Naive Bayes algoritmasının başka sınıflandırıcılarla birlikte transfer öğrenme yöntemiyle kullanılabilirliğini savunarak, bu yöntemin farklı illerdeki 112 çağrı sistemlerinde karşılaştırmalı analiz yapılmasına olanak tanıdığını belirtmişlerdir (Dai v.d., 2012).

Ho, Hull ve Srihari (2002) ise sınıflandırma algoritmalarının doğruluğunun artırılması için çoklu karar verme sistemleri üzerinde durmuş, acil çağrı sistemleri gibi kritik alanlarda birden fazla modelin ortak çalışmasının hata oranlarını azalttığını göstermiştir (Ho v.d., 2002).

Costa ve ark. (2023), Brezilya'nın SAMU acil çağrı sistemi üzerinde Wav2Vec 2.0 kullanarak sesli çağruların otomatik transkripsiyonunu ve sınıflandırmasını gerçekleştirmiştir. Çalışmada %42,12 WER ile metne dönüştürme ve %73,9 doğruluk oranıyla sınıflandırma başarısı elde edilmiştir. Bu bulgular, düşük kaynaklı ortamlarda bile NLP tabanlı çözümlerin uygulanabilir olduğunu göstermektedir.

Nimmi (2023), acil çağrı içeriklerinin sınıflandırılmasında Transformer tabanlı modelleri (ALBERT, RoBERTa, MobileBERT) karşılaştırmış ve PLE-MobileBERT modeli ile %95,31 doğruluk ve %94,8 macro F1-skor elde etmiştir. Bu sonuçlar, BERT tabanlı modellerin acil çağrı sınıflandırma görevlerinde yüksek doğruluk sağlayabileceğini göstermektedir.

Wang ve ark. (2024), acil tıpta NLP kullanımını inceleyen sistematik bir taramada, meta-analiz sonuçlarına göre NLP tabanlı modellerin ortalama %82–87 duyarlılık, %95 özgüllük ve 0,96 AUC değerine ulaştığını raporlamıştır. Bu bulgular, acil çağrı sınıflandırma sistemlerinin sağlık alanındaki güvenilirliğini desteklemektedir.

NLP temelli sistemlerin acil çağrı merkezlerindeki uygulanabilirliği sadece algoritmik başarılarla sınırlı kalmamakta, aynı zamanda kullanıcı deneyimi, operatör memnuniyeti ve karar destek süreçlerinin optimizasyonu açısından da değerlendirilmektedir. Bu bağlamda, Punch (2016), sosyal araştırmalarda karma yöntemlerin kullanımına ilişkin değerlendirmelerinde, çağrı sistemlerinde uygulanan NLP temelli analizlerin hem nicel hem de nitel yaklaşımlarla bütünleştirilmesi gerektiğini savunur. Örneğin, bir çağrının duygusal tonu veya aciliyet seviyesi gibi öğeler, yalnızca metin madenciliğiyle değil, sosyo-psikolojik analizlerle de desteklenmelidir (Punch, 2016).

Çağrı içeriklerinin sınıflandırılması kadar, bu sınıflandırmanın hızlı ve doğru yapılması da yaşamsal önem taşımaktadır. Zhang (2003), zaman serisi tahmininde yapay sinir ağları ve ARIMA modellerinin birlikte kullanımının etkinliğini savunurken, bu yaklaşımın acil çağruların yoğunluk tahmininde kullanılabileceğini öne sürer. NLP ile desteklenen bu tür hibrit modeller sayesinde, yoğun zaman dilimlerinde çağrı sistemlerinin kapasite planlaması da daha isabetli yapılabilmektedir (Zhang, 2003).

Çağrı verilerinin bütüncül bir analizinde, coğrafi boyutun da göz ardı edilmemesi gerektiği çeşitli araştırmalarda vurgulanmaktadır. Kaynar, Duru ve Atay (2010), 112 sisteminde Coğrafi Bilgi Sistemlerinin (CBS) kullanımını ele aldıkları çalışmada, konum verisi ile entegre edilen çağrı içeriklerinin hem yönlendirme hızını hem de olay yerinin erişilebilirliğini doğrudan etkilediğini belirtmişlerdir. Bu bağlamda NLP tekniklerinin CBS ile birlikte çalışması, gerçek

zamanlı analiz ve karar destek sistemlerinin doğruluğunu artırmaktadır (Kaynar v.d., 2010).

Literatürde, acil çağrı metinlerinden bilgi çıkarımı yoluyla vaka önceliklendirme üzerine yapılan çalışmalar dikkat çekmektedir. Örneğin Chin (2022), gelen çağrılardaki metinsel ifadelerden ciddi yaralanma riski taşıyan hastaları tespit etmek için makine öğrenmesi temelli bir sınıflandırma sistemi geliştirmiştir. Bu sistem, hem karar destek amaçlı kullanım hem de müdahale hızını artırmak için oldukça işlevsel bulunmuştur.

Literatürde benzer çalışmalar, çağrı merkezlerindeki karar destek sistemlerinin optimizasyonu için yalnızca teknik modellerin değil, aynı zamanda organizasyonel yapıların da göz önünde bulundurulması gerektiğini ortaya koymuştur. Ağaç (2012), çağrı merkezlerinde kurumsal yapının karar alma süreçlerine etkisini incelemiş, karar destek sistemlerinin başarılı entegrasyonunun ancak iyi yapılandırılmış bir operasyonel çerçeve ile mümkün olduğunu vurgulamıştır. NLP tabanlı sistemler de bu çerçevenin teknolojik omurgasını oluşturmaktadır (Ağaç, 2012).

Rajkomar ve arkadaşlarının (2019) belirttiği gibi, yapay zekâ sistemlerinin sağlık alanında rutin uygulamalara entegre edilmesi, sadece teknik doğrulukla değil, sistemin klinik bağlamlara uyarlanabilirliği ve etik güvencelerle de doğrudan ilişkilidir. Bu çalışma, acil çağrı sınıflandırma sistemlerinin de bu bütünsel yaklaşımla geliştirilmesi gerektiğine işaret etmektedir.

NLP sistemlerinin gelişiminde etik ve güvenlik temalarının da literatürde sıklıkla ele alındığı görülmektedir. Stamm (2005) ve Mahsum Bahadır & İnce (2024) gibi araştırmacılar, NLP sistemleri ile işlenen çağrı metinlerinin kişisel veri barındırabileceğini ve bu nedenle KVKK gibi ulusal mevzuatlara sıkı uyumun zorunlu olduğunu ifade etmektedir. Bu durum, NLP modellerinin sadece teknik doğrulukla değil, aynı zamanda yasal ve etik kriterlerle de optimize edilmesini gerekli kılmaktadır (Stamm, 2005; Mahsum Bahadır & İnce, 2024).

Genel olarak literatürdeki bu çalışmalar, Türkiye'deki 112 acil çağrı sisteminin gelişiminde NLP'nin önemli bir dönüm noktası olduğunu göstermektedir. Tablo 1'de kısaca belirtildiği gibi çağrılarının sınıflandırılması, duygu analizi, önceliklendirme, raporlama ve kalite ölçümlene süreçlerinde NLP tekniklerinin giderek daha yaygın biçimde kullanıldığı uluslararası araştırmalarla desteklenmektedir. Bu gelişmelerin sürdürülebilir olması için teknolojik yatırımların yanı sıra veri güvenliği, etik ilkelere bağlılık ve kullanıcı odaklı tasarım ilkelerinin gözetilmesi büyük önem arz etmektedir.

Tablo 1.1. Acil Çağrı Merkezlerinde Doğal Dil İşleme ve Yapay Zekâ Uygulamaları

Ülke / Proje	Teknoloji ve Özellikler	Başarı / Bulgular
Romanya – ODIN112	ASR ile otomatik metin dönüşümü, SER ile duygu tanıma, arka plan seslerinin algılanması; MobileNetV3, VGG16 tabanlı modeller	Duygu tanımadada %91,82–%93,55 doğruluk; Romence verilerle eğitildi
Belçika – Hazira Digital	Yanlış çağrıları tespit eden YZ tabanlı sistem; çağrının ilk saniyelerinde önceliklendirme	Liège pilot uygulamada %84 doğruluk oranı
Danimarka – Corti	Kalp krizi gibi kritik durumları gerçek zamanlı analiz eden sistem	Erken tespit yeteneği (doğruluk oranı belirtilmemiş)
Hindistan/ABD – Uniphore	Konuşma analitiği, ses biyometrisi, sanal asistan çözümleri	Müşteri hizmetlerinde ve çağrı merkezlerinde etkin kullanım
Türkiye – 112 AÇM	Farklı numaraların 112 altında toplanması; NLP ve YZ entegrasyonu henüz gelişim aşamasında	Koordinasyon sağlanmış; uluslararası örnekler yol gösterici

1.1. Tezin Amacı

Bu çalışma, yapay zekâ teknolojilerinin sunduğu olanaklardan faydalanarak çağrı merkezlerinde ilk değerlendirme sürecini otomatikleştirmeyi amaçlamaktadır. Çağrının ilk saniyelerinde devreye giren bir yapay zekâ destekli ön operatör, sesli veriyi yazılı metne dönüştürmekte, doğal dil işleme yöntemleri ile çağrının içeriğini analiz etmekte ve çağrıyı yangın, trafik kazası veya sağlık gibi sınıflara ayırmaktadır. Böylece ilk 60 saniye içerisinde çağrının uygun birime yönlendirilmesi sağlanarak, insan operatörlerin yalnızca ilgili olaylara odaklanmasına imkân tanınmaktadır.

Bu sistem, insan gücünü tamamen devre dışı bırakmayı değil, onları destekleyecek şekilde ön sınıflandırmayı gerçekleştirmeyi hedeflemektedir. Bu sayede olayın niteliğine göre hızlı karar verilmesi sağlanırken, operatör üzerindeki yük de azaltılmış olur. Literatürde benzer uygulamaların, özellikle çağrı merkezlerinin verimliliğini artırmada etkili olduğu görülmektedir (Aly et al., 2020; Farraj et al., 2021; Wiggers et al., 2022).

Bu tez çalışmasında, Bilecik ili örneğinde geliştirilen sistem; sesli veriyi metne çeviren, metni anonimleştirerek sınıflandıran ve yönlendirme kararını destekleyen bir yapay zekâ

mimarisi sunmaktadır. Geliştirilen modelin temel bileşenleri, otomatik konuşma tanıma, metin ön işleme, sınıflandırma algoritmaları ve görsel bir kullanıcı ara yüzüdür. Bu yapı sayesinde, çağrının niteliği erken aşamada belirlenerek en uygun birime iletilmesi mümkün olmaktadır.

Çalışmanın temel katkısı, gerçek senaryolara dayalı bir veri seti kullanılarak yapay zekâ temelli sınıflandırma sisteminin test edilmesi ve acil çağrı yönetimine entegre edilebilir bir çözüm modeli sunmasıdır.

2. LİTERATÜR ARAŞTIRMASI

2.1. Acil Çağrı Merkezleri

Türkiye’de acil durumlarla ilgili yardım talepleri ve ihbarlar; emniyet (155), jandarma (156), sahil güvenlik (158), itfaiye (110), sağlık (112) ve orman yangınları (177) gibi farklı kurumlara ait ayrı numaralar üzerinden yapılmaktaydı. Ancak bu sistemin dağınık yapısı, uygulamada önemli zorluklara neden olmakta; olay anında hangi numaranın aranacağına dair tereddütler yaşanmakta ve bu da müdahale sürecinde zaman kaybına yol açabilmektedir. Özellikle birden fazla kurumu ilgilendiren olaylarda, vatandaşların tüm kurumlara ayrı ayrı ulaşmak zorunda kalmaları hem bilgi dağınıklığına hem de zaman ve kaynak israfına neden olmakta bu da can ve mal kayıplarını artıran bir risk unsuru oluşturmaktadır.

Gelişmiş ülkelerde ise acil durumlara müdahale sistemleri daha merkezi bir yapıda organize edilmiştir. Örneğin Avrupa Birliği ülkelerinde 112, Amerika Birleşik Devletleri’nde ise 911 numarası, sağlık, emniyet ve yangın gibi acil hizmetlerin tek merkezden yürütülmesini sağlayan çok kanallı sistemlerle desteklenmektedir. Avrupa Birliği, 29 Temmuz 1991 tarihli kararı ile 112 numarasını "Tek Avrupa Acil Çağrı Numarası (Single European Emergency Call Number)" olarak belirlemiş ve üye ülkelerde ortak uygulamaya geçmiştir (Avrupa Komisyonu, 1991).

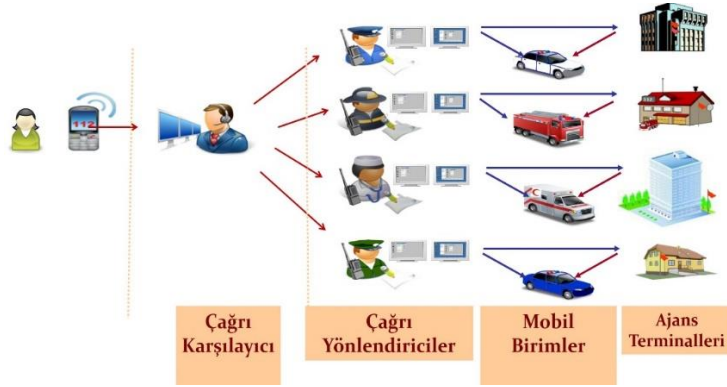
Türkiye de bu dönüşüm sürecine Avrupa Birliği’ne uyum kapsamında dahil olmuş ve "Tek Acil Çağrı Numarası" sistemine geçiş için ilk adımı 2003 yılında T.C. İçişleri Bakanlığı ve Hollanda Hükümeti iş birliğiyle yürütülen MATRA Projeleri kapsamında atmıştır. 06 Nisan 2005 tarihinde Antalya, sistemin pilot ili olarak belirlenmiş ve uygulama burada hayata geçirilmiştir. Bu süreçte, 112 Acil Çağrı Merkezi sisteminin iki temel amacı öne çıkmıştır:

- Vatandaşların acil durumlarda birden fazla numara yerine yalnızca tek bir numarayı bilmeleri ve kullanmaları,
- Gelen yardım çağrısına en kısa sürede müdahale edilerek olay mahalline veya mağdura hızla ulaşılmasının sağlanması.

Bu sistemin temel hedefi, kamu kaynaklarının daha etkin kullanılmasını sağlarken, aynı zamanda olaylara müdahale süresini kısaltarak can ve mal kayıplarını azaltmaktır. Tek numara uygulaması, çağrılarının doğru şekilde yönlendirilmesini ve kurumlar arası koordinasyonun daha etkili yürütülmesini mümkün kılan entegre bir yapı sunmaktadır (T.C. İçişleri Bakanlığı, 2020).

2.2. 112 Acil Çağrı Merkezlerinin Yapısı ve İşleyişi

112 Acil Çağrı Merkezleri'nin yapısı, çok katmanlı ve çok paydaşlı bir organizasyon modeli üzerine kuruludur. Her ilde bulunan bu merkezler, valiliklerin koordinasyonunda İçişleri Bakanlığı'na bağlı olarak çalışır. Merkezlerde; çağrı operatörleri, kurum temsilcileri, teknik destek birimi, eğitim sorumluları ve yöneticiler gibi çeşitli görev dağılımları yapılmıştır. Şekil 2.1' de sistemin çalışma modelinde belirtildiği gibi çağrı merkezlerinde görevli operatörler, gelen çağrıyı ilk karşılayan kişilerdir. Bu kişiler, olayın niteliğini değerlendirdikten sonra vakayı doğru kuruma yönlendirmekle sorumludurlar. Burada esas olan; zaman yönetimi, bilgi aktarımının doğruluğu ve kurumlar arası iletişimin sorunsuz biçimde sağlanmasıdır (Kaynar, Taştan, & Demirkoparan, 2010).



Şekil 2.1. 112 Acil Çağrı Merkezinin Çalışma Modeli

Günümüzde kamu hizmetlerinin daha etkin, hızlı ve vatandaş odaklı sunulması yönünde yapılan çalışmalar, acil çağrı sistemlerinin tek çatı altında toplanması ihtiyacını gündeme getirmiştir. Bu bağlamda Türkiye, 112 Acil Çağrı Merkezleri (AÇM) aracılığıyla farklı kurumların (polis, jandarma, sağlık, itfaiye, AFAD, orman ve sahil güvenlik) acil yardım hizmetlerini tek numarada birleştirerek daha verimli bir iletişim ve müdahale sistemi oluşturmayı amaçlamaktadır. Bu sistemle birlikte çağrılarının karşılanma süresi, olaylara müdahale zamanı ve koordinasyon kalitesi önemli ölçüde artmıştır. Modern çağın gerekliliklerine yanıt veren bu sistem, aynı zamanda kamu kaynaklarının verimli kullanımına da katkı sağlamaktadır (Punch, 2016).

Merkezlerin teknik altyapısı, Bilgi Teknolojileri ve İletişim Kurumu (BTK) standartlarına uygun biçimde kurulmuştur. Tüm çağrılar ses kaydı altına alınmakta, yönlendirme sistemi coğrafi konuma ve çağrının içeriğine göre otomatik yapılabilmektedir. Özellikle konum bazlı yönlendirme teknolojileri, olay yerinin doğru ve hızlı tespiti açısından büyük önem taşımaktadır. Ayrıca, acil çağrılarının içeriklerine göre filtrelenmesi, yanlış veya

gereksiz çağruların önlenmesi açısından da yazılım destekli akıllı algoritmalar kullanılmaktadır. Bu teknoloji sayesinde %60'a varan oranla asılsız çağrular ayıklanmakta ve kaynak israfı engellenmektedir (Widrow & Hoff, 1960).

Merkezlerin işleyişinde standartlaştırılmış prosedürler izlenmektedir. Gelen her çağrı; karşılanma, değerlendirme, yönlendirme ve raporlama olmak üzere dört aşamadan geçer. Bu süreçte kullanılan Entegre Acil Çağrı Sistemi (E-AÇS), tüm kamu kurumlarının veri tabanlarıyla uyumlu biçimde çalışmaktadır. Vatandaşlar 112 numarasını aradığında, sistem GSM veya sabit hat operatörü üzerinden çağrının konumunu ve çağrıyı yapan kişiye ait temel bilgileri ekranlara yansıtır. Bu bilgiler ışığında, operatör çağrıyı doğru kurum temsilcisine yönlendirir. Her kurumun temsilcisi kendi yazılım arayüzünden vakayı değerlendirir ve sahaya ekip sevkini yapar. Bu yapı, hem bilgi güvenliği hem de hızlı işlem açısından optimize edilmiştir (Saplıoğlu & Çimen, 2010).

Türkiye'de 112 sisteminin en dikkat çekici özelliklerinden biri de çok kurumlu yapı içinde bütünleşik hizmet sunulmasıdır. Önceden farklı numaralarla ulaşılan polis (155), jandarma (156), itfaiye (110), ambulans (112), AFAD (122) gibi hizmetler artık tek numara üzerinden erişilebilir hale gelmiştir. Bu sayede vatandaş, hangi birimi araması gerektiği konusunda kafa karışıklığı yaşamadan sadece 112 numarasını tuşlayarak yardım talebinde bulunabilmektedir. Kurumlar arası koordinasyonun sağlanması, sadece fiziksel mekân paylaşımıyla değil aynı zamanda ortak yazılım sistemlerinin kullanılmasına da dayanmaktadır. Böylelikle eş zamanlı veri paylaşımı mümkün olmakta ve müdahale süresi kısaltılmaktadır (Kızılaslan, Büyükkınacı, Bayraktar, & Çelebi, 2009).

Sistem, aynı zamanda toplumsal afet ve olağanüstü durumlara hazırlıklı olmayı da mümkün kılmaktadır. Deprem, sel, yangın, pandemi gibi kitlesel olaylarda çağrı merkezleri kriz masası işlevi görmekte, gelen çağrılar kategorize edilerek öncelik sıralaması yapılmaktadır. Bu tür durumlar için merkezlerde oluşturulan senaryo tabanlı eğitim programları, operatörlerin psikolojik dayanıklılıklarını artırmak ve hızlı karar verme yeteneklerini geliştirmek üzere tasarlanmıştır. Ayrıca, özellikle pandemi sürecinde "112 Vefa" ekipleriyle birlikte, yaşlı ve riskli gruplara yardım ulaştırma görevinde de merkezler aktif rol oynamıştır (Punch, 2016).

Çağrı merkezlerinin insan kaynağı yönetimi, sistemin başarısı açısından hayati öneme sahiptir. Operatörler genellikle üniversite mezunu olup, kriz iletişimi, stres yönetimi, çoklu çağrı işleme gibi alanlarda özel eğitimlerden geçirilirler. Ayrıca nöbet sistemiyle 7/24 esasına göre çalışırlar. Her çağrı merkezinde bir psikososyal destek birimi bulunur ve operatörlerin

duygusal tükenmişlik yaşamamaları için periyodik değerlendirmeler yapılır. Stamm (2005) tarafından geliştirilen ProQOL ölçeği, Türkiye’de de bazı illerde operatörlerin duygusal tükenmişlik düzeyini değerlendirmek için kullanılmaktadır (Stamm, 2005).

112 Acil Çağrı Merkezleri Türkiye’de kamu hizmetlerinin modernleştirilmesi sürecinde atılmış önemli bir adımdır. Sistem, teknolojik altyapısı, kurumsal bütünlüğü, personel yeterliliği ve vatandaş odaklı hizmet anlayışıyla örnek teşkil etmektedir. Her geçen yıl çağrı sayısı artmakta, bu da sistemin toplumsal farkındalık düzeyine olumlu yansıdığını göstermektedir. Ancak bu artışa paralel olarak; operasyonel yükün dengelenmesi, insan kaynağının güçlendirilmesi ve veri analitiğinin geliştirilmesi gibi alanlarda sürekli iyileştirme yapılması gerekliliği de göz ardı edilmemelidir (Kaynar v.d., 2010).

İnsan kaynakları yönetimi açısından 112 Acil Çağrı Merkezleri, personel performansını izlemeye ve sürekli geliştirmeye odaklı sistemler kurmuştur. Operatörlerin çağrı karşılama süresi, doğru yönlendirme oranı ve geri bildirim skorları gibi metriklerle takip edilmeleri, hizmet kalitesinin standardize edilmesini sağlar. Bunun yanında, çalışanlar için geliştirilen rotasyon sistemleri, görev tekrarına bağlı tükenmişliği azaltmayı hedefler. Ayrıca nöbet sisteminde dikkat edilen bir başka unsur da operatörlerin psikososyal destek sistemlerine erişimidir. Yapılan araştırmalarda, çağrı merkezlerinde çalışan bireylerin uzun vadede stres kaynaklı performans düşüklüğü yaşayabildiği belirlenmiş, bu nedenle belirli aralıklarla mesleki doyum ve tükenmişlik ölçekleri ile izlem yapılması önerilmiştir (Stamm, 2005).

Bir diğer önemli konu ise vatandaş memnuniyetidir. 112 Acil Çağrı Merkezleri, vatandaşlarla kurulan ilk teması oluşturduğu için kamu algısı üzerinde doğrudan etkilidir. Bu nedenle personel seçiminde iletişim becerilerine özel önem verilmekte, empatik yaklaşım ve doğru yönlendirme yetenekleri öncelik kazanmaktadır. Çağrı karşılayan operatörün ses tonu, yönlendirme açıklığı ve kriz anında sakin kalma becerisi, çağrının sonuçları üzerinde belirleyici olabilir. Ayrıca çağrı sonrası otomatik geri bildirim sistemleriyle vatandaşların deneyimleri kayıt altına alınmakta, bu veriler kalite birimleri tarafından analiz edilmektedir. Bu uygulama, hizmet kalitesini artırmaya yönelik geri besleme mekanizmasının temelini oluşturur (Kaynar v.d., 2010).

Türkiye’deki uygulamalarda dikkat çeken bir diğer unsur, çağrı merkezlerinin aynı zamanda eğitim ve tatbikat merkezleri olarak da kullanılmasıdır. Özellikle büyükşehirlerde kurulan gelişmiş merkezlerde, olay senaryoları üzerinden eğitimler düzenlenmektedir. Bu tatbikatlar sayesinde operatörler ve kurum temsilcileri, gerçek olaylara karşı hazırlıklı hale

gelirler. Ayrıca sistem güncellemeleri ya da yeni protokoller devreye girdiğinde, bu değişiklikler öncelikle simülasyon ortamında test edilir. Bu sayede olası hataların önüne geçilirken, kullanıcılar da yeni sistemlere daha kolay adapte olmaktadır. Bu yönüyle 112 merkezleri, sadece acil yardım çağrılarını yöneten birimler değil; aynı zamanda kriz yönetimi ve afet hazırlığı alanlarında da rol alan kurumsal yapılardır (Saplıoğlu & Çimen, 2010).

Bunun yanında, çağrı merkezi performansı bölgesel farklılıklar gösterebilir. Örneğin kırsal alanlarda konum bilgilerine ulaşmak zorlaşabilirken, şehir merkezlerinde çağrı yoğunluğu nedeniyle yönlendirme süreleri uzayabilir. Bu tür farklılıkları gidermek adına, İçişleri Bakanlığı tarafından geliştirilen dinamik iş gücü planlaması yazılımları devreye sokulmuştur. Bu yazılımlar sayesinde her ilin çağrı geçmişi analiz edilerek personel ve donanım planlaması yapılmaktadır. Ayrıca yüksek yoğunluk yaşanan dönemlerde, il merkezleri arasında veri aktarımı ve çağrı paylaşımı yapılmasına olanak tanıyan bölgesel entegrasyon protokolleri de hayata geçirilmiştir (Widrow & Hoff, 1960).

Bir diğer gelişme de, engelli bireyler için erişilebilirlik uygulamalarıdır. Türkiye’de son yıllarda yürürlüğe giren düzenlemeler ile birlikte, işitme veya konuşma engeli olan bireyler için SMS, mobil uygulama veya web tabanlı sistemler üzerinden 112’ye ulaşma imkânı sağlanmıştır. Bu uygulamalar, çağrının içeriğini metin olarak iletmekte ve operatör tarafından hızlıca değerlendirilerek kuruma yönlendirilmektedir. Ayrıca bu sistemlerde hazır şablon mesajlar ve olay türü seçimi gibi kullanıcı dostu arayüzler tasarlanmıştır. Bu sayede acil durumlarda herkes için eşit hizmet sunumu hedeflenmektedir (Kızılaslan v.d., 2009).

112 Acil Çağrı Merkezleri, sadece bir acil durum hizmeti değil; aynı zamanda teknoloji, insan kaynağı, kriz yönetimi ve kamu hizmet kalitesi açısından bütüncül bir sistem olarak değerlendirilmektedir. Türkiye bu alanda gerçekleştirdiği entegrasyon ile birçok Avrupa ülkesine kıyasla daha etkin bir yapı kurmuş durumdadır. Ancak sistemin başarısının sürdürülebilirliği, periyodik değerlendirmeler, teknolojik güncellemeler ve sürekli eğitim gibi dinamik unsurların sağlıklı şekilde yönetilmesine bağlıdır. Ayrıca vatandaşların bu sistem hakkında bilinçlendirilmesi, gereksiz çağrıların azaltılması ve sistemin kapsayıcılığının artırılması yönünde kamuoyu farkındalık kampanyaları da kritik rol oynamaktadır (Punch, 2016).

2.3. Acil Çağrı Verilerinin Özellikleri

Acil çağrı sistemlerinin başarılı ve sürdürülebilir şekilde işletilebilmesi için en kritik unsur, doğru, güvenilir ve analiz edilebilir verilerin elde edilmesidir. 112 Acil Çağrı Merkezleri

hem çağruların içeriğini hem de bu çağruların zamanlaması, konumu, yönlendirildiği kurum gibi birçok değişkeni kaydeden gelişmiş bilgi sistemlerine sahiptir. Bu veriler; günlük operasyonel performans takibinden, uzun vadeli politika belirleme süreçlerine kadar birçok alanda kullanılır. Dolayısıyla acil çağrı verileri, yalnızca istatistiksel birer sayı değil, kamu yönetiminin stratejik kararlarını etkileyen anlamlı bileşenlerdir (Stamm, 2005).

Bu veriler farklı kategorilerde sınıflandırılmaktadır: Gelen çağrı sayısı, çağrı türü (asayiş, sağlık, itfaiye vb.), çağrının gerçek/asılsız niteliği, yönlendirme süresi, olay yeri bilgisi, çağrıya müdahale süresi ve sonuç bilgisi gibi alt başlıklar altında veriler sistematik biçimde saklanmaktadır. Söz konusu verilerin tamamı, veri tabanlarında tarih, saat, GPS konumu ve operatör bilgisi gibi alanlarla birlikte tutulur. Bu yapı, veri güvenliğini ve geriye dönük denetlenebilirliği sağlar. Özellikle suistimal, yanlış yönlendirme veya iletişim kopukluğu durumlarında olayın seyrine dair tüm detaylar sistem kayıtlarında mevcuttur (Ağaç, 2012).

Acil çağrı verilerinin bir diğer önemli özelliği ise gerçek zamanlı analiz kabiliyeti sunmasıdır. Operasyonel kararların sahada hızlı biçimde alınabilmesi için sistemde yer alan dashboard'lar sayesinde çağrı yoğunluğu, lokasyon bazlı risk yoğunluğu ve kurumlara göre yönlendirme oranları anlık olarak izlenebilir. Bu sayede örneğin aynı bölgede art arda gelen trafik kazası çağrıları durumunda, sistem yöneticisi bölgesel bir müdahale protokolü başlatabilir. Ayrıca bu veriler, yerel yönetimlerin afet planlaması, trafik düzenlemesi ve kamu güvenliği stratejilerinin belirlenmesinde etkin şekilde kullanılmaktadır (Zhang & Qi, 2005).

Veri bütünlüğünün sağlanması açısından kullanılan yazılımlar, çağrı anında oluşan bilgilerin kaybını önlemek üzere geliştirilmiştir. Çağrı alındığı anda sistem otomatik olarak zaman damgası (timestamp), arayan numara, operatör bilgisi, olay tipi ve kurum yönlendirme detaylarını eş zamanlı kaydeder. Ayrıca, ses kaydı teknolojileri ile her çağrı dijital ortamda saklanır ve bu kayıtlar gerektiğinde adli süreçlerde delil olarak kullanılabilir. Türkiye'deki uygulamalarda, ses kayıtlarının minimum beş yıl süreyle arşivde tutulması zorunludur. Bu durum, sistemin şeffaflığına ve hesap verebilirliğine katkı sunar (Ekşi & Yıldırım, 2014).

Veriler aynı zamanda istismarı önleme işlevi de görmektedir. Özellikle çocukların eğlencesine konu olan yanlış aramalar, sistem kayıtlarıyla tespit edilmekte ve gerekli durumlarda ilgili velilere idari yaptırımlar uygulanmaktadır. Türkiye'de 2023 yılı verilerine göre, gelen çağruların yaklaşık %60'ının asılsız olduğu belirlenmiştir. Bu çağrular arasında telefon şakaları, yanlış numara tuşlamaları ve bilgi amaçlı aramalar çoğunluktadır. Sistemin yoğunluğunu artıran bu tür aramaların azaltılması için veriler üzerinden yapılan analizlerle

hedef kitle belirlenmekte ve kamu spotlarıyla farkındalık kampanyaları düzenlenmektedir (Mahsum Bahadır & İnce, 2024).

Bunun yanında, veriler sadece nicel değil; nitel analizlerin de konusu haline gelmektedir. Özellikle çağrılarda kullanılan dil, ses tonundaki değişim, arayan kişinin stres düzeyi gibi unsurlar, yapay zekâ destekli sistemlerle analiz edilerek gelecekteki risk davranışlarının öngörülmesinde kullanılmaktadır. Bu alanda yapılan bazı pilot çalışmalar, panik atak veya intihar riski taşıyan kişilerin ses analiziyle önceden tespit edilmesini ve psikososyal müdahale ekiplerinin yönlendirilmesini mümkün kılmıştır. Böylelikle acil çağrı sistemleri yalnızca teknik yönüyle değil, aynı zamanda insani duyarlılık içeren bir işleyişe sahip hale gelmiştir (Shukla v.d., 2011).

Verilerin analitik biçimde kullanımı, 112 sisteminin ülke genelinde politik planlama süreçlerinde de önemli rol oynamaktadır. Örneğin, Sağlık Bakanlığı tarafından ambulans hizmetlerinin bölgelere göre yeniden planlanmasında, çağrı yoğunluğu ve vaka türlerine ilişkin veriler referans alınmaktadır. Aynı şekilde Emniyet Genel Müdürlüğü ya da Orman Genel Müdürlüğü, risk bölgelerini bu veriler doğrultusunda belirlemekte, personel ve araç gereç dağılımını buna göre yapmaktadır. Bu noktada acil çağrı verileri, yalnızca mevcut durumu gösteren değil; geleceği planlayan birer veri kaynağıdır (Baltacı, 2018).

Verilerin korunması ve güvenliği ise son derece hassas bir konudur. 112 sistemine ait veriler kişisel bilgi içerebildiğinden dolayı KVKK (Kişisel Verilerin Korunması Kanunu) çerçevesinde özel olarak düzenlenmiştir. Sistem üzerinde erişim yetkileri sınırlı tutulmakta, veri analizi yapacak personelin özel yetki düzeyine sahip olması gerekmektedir. Ayrıca sistem günlük olarak yedeklenmekte ve şifrelenmiş sunucularda saklanmaktadır. Bu önlemler, özellikle siber saldırılar ve veri sızıntılarına karşı merkezleri koruma altına almaktadır (Stamm, 2005).

112 Acil Çağrı Merkezleri yalnızca olay anında müdahale edilen yapılar değil, aynı zamanda büyük bir veri havuzu olarak değerlendirilebilir. Bu veriler sayesinde hizmet kalitesi ölçülebilmekte, sorunlu alanlar tespit edilmekte ve sistemsiz iyileştirmeler sağlanmaktadır. Bu bağlamda acil çağrı verileri; teknolojik, hukuki, yönetsel ve toplumsal birçok boyutu olan stratejik kaynaklardır. Giderek dijitalleşen kamu hizmetleri içinde 112 verilerinin anlamlı şekilde yorumlanması ve geleceğe dönük kullanımının artırılması, hem kriz yönetimi hem de sosyal fayda açısından büyük önem taşımaktadır (Ağaç, 2012).

Acil çağrı sistemlerinde toplanan verilerin özellikleri, yalnızca operasyonel verimliliği değil, aynı zamanda stratejik yönetim kapasitesini de doğrudan etkiler. Türkiye’deki 112 Acil Çağrı Merkezlerinde toplanan veriler, çok boyutlu analizlere uygun niteliktedir. Bu kapsamda veriler, yapısal (structural) ve bağlamsal (contextual) olarak iki temel düzeyde değerlendirilmektedir. Yapısal veriler, çağrı saatleri, çağrı süresi, kurum yönlendirme bilgisi gibi sayısal alanları kapsarken; bağlamsal veriler, olayın içeriği, çağrıyı yapanın ruh hali, olayın oluş biçimi gibi yorumlanabilir ve sezgisel analiz gerektiren bilgilerdir (Stamm, 2005; Ağaç, 2012).

Özellikle büyükşehirlerde günlük gelen çağrı sayısının on binleri bulduğu düşünüldüğünde, bu verilerin hızlı analiz edilmesi ve yönetsel kararlar için kullanıma sunulması hayati önemdedir. Bu amaçla karar destek sistemleri (KDS) ve iş zekâsı araçları çağrı merkezlerinin temel analiz altyapısını oluşturur. Bu sistemler sayesinde yöneticiler, hangi bölgede hangi saatlerde daha çok acil çağrı geldiğini tespit edebilir, sahaya yönlendirilecek ekipleri buna göre planlayabilir. Bunun yanı sıra, olay türlerine göre yapılan dağılım analizleri sayesinde; sağlık, güvenlik veya yangın gibi konularda mevsimsel değişkenlik gösteren trendler yakalanabilir (Mahsum Bahadır & İnce, 2024).

Verilerin bir diğer özelliği de çok disiplinli kullanım alanına sahip olmasıdır. Sağlık Bakanlığı verileri, 112 üzerinden gelen acil sağlık taleplerini analiz ederken; Emniyet Genel Müdürlüğü ise suç haritalaması yaparken bu verilerden faydalanmaktadır. Ayrıca afet yönetimi, çevre kirliliği, trafik güvenliği gibi kamu politikalarının geliştirilmesinde de 112 verileri temel girdi olarak kullanılmaktadır. Örneğin, orman yangını ihbarlarının konumsal dağılımına bakılarak, riskli bölgelerde erken uyarı sistemleri kurulmuş ve belirli alanlarda mobil ekiplerin konuşlandırılması kararı alınmıştır (Baltacı, 2018).

112 sistemine ulaşan çağrıların değerlendirilmesinde kullanılan otomatik sınıflandırma sistemleri, çağrılarının niteliğini belirlemek adına kritik rol oynar. Bu sistemler, arama sırasında girilen anahtar kelimeleri, konuşma tonlarını ve ses frekanslarını analiz ederek olayın aciliyet derecesini belirlemeye yardımcı olur. Örneğin, “yangın”, “patlama”, “nefes alamıyorum” gibi ifadeler sistem tarafından yüksek öncelikli çağrılar olarak tanımlanabilir. Bu sınıflandırma, operatörün karar verme sürecini hızlandırdığı gibi, yanlış yönlendirmelerin de önüne geçilmesini sağlar. Bu sistemler özellikle pandemi döneminde büyük rol oynamış, COVID-19 şüphesiyle gelen çağrılarının ayrıştırılmasında etkili olmuştur (Ekşi & Yıldırım, 2014).

Verilerin güvenilirliđi, sistemdeki karar mekanizmalarının dođruluđunu etkilediđi için, 112 merkezlerinde veri temizleme ve dođrulama işlemleri rutin biçimde yapılır. Çađrılar sırasında oluşabilecek yazım hataları, lokasyon uyuşmazlıkları ya da çoklu veri girişleri gibi sorunlar, periyodik raporlamalarla tespit edilip sistemden filtrelenir. Bu sayede analizlerin sapma oranı düşürülmüş olur. Örneđin, aynı adresten aynı dakika içerisinde yapılan birkaç çağrı sistem tarafından tekil kayıt olarak birleştirilebilir. Bunun dışında, asılsız çağrılar için tutulan özel veri setleri, ilerleyen dönemlerde yapılacak yasal düzenlemeler için referans niteliđi taşımaktadır (Zhang & Qi, 2005).

Türkiye’de 112 sistemine ilişkin çağrı verileri, büyük veri (big data) kategorisine giren veri kümeleri içerisinde değerlendirilmektedir. Yüksek hacim (volume), yüksek hız (velocity) ve çeşitlilik (variety) bu sistemin veri yapısının temel özelliklerindedir. Her çağrı sadece bir kayıt değil; ses dosyası, konum bilgisi, zaman bilgisi, olay kategorisi ve kullanıcı profili gibi birçok bilgiyi de içerdiđi için, geleneksel veri tabanı yazılımlarının ötesinde çözümler gerektirir. (Stamm, 2005).

Acil çağrı verilerinin özellikleri arasında dikkat çeken bir diđer husus da sosyal etki boyutudur. Veriler yalnızca olayları değil, toplumun genel psikolojik durumu hakkında da ipuçları verir. Örneđin dođal afetler sonrası artan panik çağrıları, toplumsal stres seviyesini gösteren önemli bir gösterge haline gelmektedir. Yine büyük kentsel dönüşüm bölgelerinde artan asılsız ihbarlar, güvenlik algısının zayıfladıđını ve kamu bilincinin yeniden yapılandırılması gerektiđini göstermektedir. Bu nedenle çağrı merkezlerinin raporları, yalnızca idari değil aynı zamanda sosyolojik ve psikolojik analizlerde de kullanılmaktadır (Ađaç, 2012).

Çađrı verilerinin görselleştirilmesi, yöneticilerin hızlı karar almasına olanak sađlayan bir başka etkidir. Harita temelli bilgi sistemleri üzerinden vaka dağılımı, saatlik çağrı grafikleri, kurum yönlendirme yüzdeleri gibi bilgiler sade ve anlaşılır biçimde sunulabilmektedir. Bu durum, özellikle kriz anlarında operasyon merkezlerinde vakaya özel eylem planlarının geliştirilebilmesini sađlar. Ayrıca kamuya sunulan özet raporlar aracılıđıyla vatandaşların sistem işleyişine dair bilgi sahibi olması da sađlanır. Bu da sistemin şeffaflıđına katkı sunar ve kamu güvenini artırır (Shukla v.d., 2011).

Sesi Metne Çevirme

Sesi metne çevirme sistemleri, konuşulan dili otomatik olarak yazıya döken teknolojilerdir. Bu sistemler, insan-makine etkileşimini daha dođal hale getirerek özellikle çağrı merkezleri, asistan sistemleri, toplantı transkripsiyonları ve sađlık sektörü gibi pek çok alanda

yaygın biçimde kullanılmaktadır (Jurafsky & Martin, 2023). Sesi metne çevirme sistemleri temel olarak üç ana aşamadan oluşur: ses sinyalinin işlenmesi, özellik çıkarımı ve otomatik konuşma tanıma (ASR). Son yıllarda yapay zekâ temelli derin öğrenme tekniklerinin gelişmesiyle birlikte bu sistemlerin doğruluk oranı önemli ölçüde artmıştır.

Sesi metne çevirme sistemlerinin başarımı genellikle “Kelime Hata Oranı (Word Error Rate – WER)” ile ölçülür. Bu oran, sistemin tahmin ettiği metin ile gerçek metin arasındaki farkları (ekleme, silme, değiştirme) ölçerek toplam hata oranını yansıtır (Morris et al., 2004). Düşük WER değeri, yüksek doğruluk anlamına gelir. Bunun dışında “Character Error Rate (CER)” gibi ölçütler de özellikle kısa kelimelerle çalışan dillerde kullanılabilir.

Sesi metne çevirme teknolojisi, temelde akustik modelleme, dil modeli ve çıkarım motorunun birleşiminden oluşur. Akustik model, ses dalgalarını fonemlere dönüştürürken, dil modeli bu fonemlerin oluşturduğu kelimeleri bağlama uygun şekilde seçer. Gelişmiş modellerde bu işlem yapay zekâ destekli olarak gerçekleştirilir. Özellikle uzun kısa süreli bellek (LSTM) ve Transformer tabanlı modeller, bağlamsal anlamı koruyarak doğruluğu büyük ölçüde artırmaktadır (Zhang & Qi, 2005). ASR sistemlerinin performansı yalnızca ses sinyali analiziyle sınırlı değildir. Dil modelleri, özellikle n-gram, RNN tabanlı ya da Transformer tabanlı yapılarla ASR çıktılarının anlamlı ve gramatik olarak doğru olmasını sağlar (Mikolov et al., 2010). Bu modeller, kelime sıralarının olasılıklarını öğrenerek sistemin anlamlı transkripsiyon üretmesine yardımcı olur. (Mikolov et al., 2010)

Türkiye’de 112 Acil Çağrı Merkezleri’nde sesi metne çevirme uygulamaları henüz sınırlı bir alanda uygulanmakla birlikte, bu teknolojilerin yaygınlaşması beklenmektedir. Ekşi ve Torlak’ın (2011) çalışması, vatandaşların çağrı sistemine erişim alışkanlıklarının analizinde sesli yanıt sistemlerinin kullanım potansiyeline değinmektedir. Özellikle acil müdahale gerektiren durumlarda hızlı veri aktarımının önemi vurgulanmakta ve bu ihtiyacın karşılanmasında otomatik konuşma tanımanın rolü dikkat çekmektedir (Ekşi & Torlak, 2011).

Whisper, OpenAI tarafından geliştirilen ve geniş hacimli çok dilli konuşma verisiyle eğitilmiş açık kaynaklı bir SMC modelidir. Model hem düşük kaynaklı dillerde hem de gürültülü ortamlarda yüksek performans göstermektedir (Radford et al., 2023). Bununla birlikte, SMC sistemlerinin kullanımında veri gizliliği, konuşmacı rızası ve anonimleştirme gibi etik hususlar da göz önünde bulundurulmalıdır (Zissman et al., 2020). Özellikle kamu kurumlarına ait çağrı verilerinde, konuşmacı kimliğini açığa çıkarabilecek içeriklerin dikkatle işlenmesi gerekmektedir.

Acil çağrı sistemlerinde alınan her çağrı, kritik bilgiler içerebilir ve bu bilgilerin doğru, hızlı ve eksiksiz olarak kaydedilmesi hayati önem taşır. Bu noktada “sesi metne çevirme” (speech-to-text) teknolojileri devreye girerek, operatörlerin iş yükünü azaltmakta ve otomatik analiz sistemlerine altyapı sağlamaktadır. Gelişmiş konuşma tanıma sistemleri, çağrılarının içeriğini gerçek zamanlı olarak metne dökerek hem arşivlemeye hem de doğal dil işleme (NLP) süreçlerine olanak tanır (Guo v.d., 2012).

Sesi metne çevirme sistemlerinin doğruluğu, özellikle acil çağrı merkezlerinde kullanılan dilin yapısal özelliklerinden büyük ölçüde etkilenmektedir. Türkçe gibi eklemeli dillerde kelime köklerinin çok çeşitli çekim ekleriyle türetilmesi, klasik dil modellerinin başarı oranını düşürmektedir. Bu sorunu aşmak için morfolojik analiz içeren modeller geliştirilmekte, Word2Vec ve BERT gibi derin öğrenme tabanlı vektörleme yöntemleriyle semantik anlam gücü artırılmaktadır (Mahsum Bahadır & İnce, 2024).

Acil çağrı merkezlerinde gelen sesli verinin anında metne dökülmesi, sadece arşivleme değil; aynı zamanda metin madenciliği, olay türü tahmini ve operatör performans analizi gibi alanlarda da kritik veri sağlamaktadır. Kaynar, Duru ve Atay’ın (2010) çalışmaları, çağrılarının mekânsal verilerle eşleştirilmesiyle afet anında daha hızlı müdahale yapılabileceğini göstermiştir. Bu eşleşmenin sağlıklı yapılabilmesi, sesli verinin hatasız metne dönüştürülmesine bağlıdır (Kaynar v.d., 2010).

Bu teknolojilerin verimli şekilde kullanılabilmesi için, sesli verilerin ön işleme süreçlerinden geçirilmesi zorunludur. Gürültü temizleme, yankı azaltma, konuşmacı ayrımı ve zaman damgalama gibi işlemler, metinleştirmenin doğruluğunu artırır. Bu noktada Bukan (2019), çağrı merkezi operatörlerinin konuşma kalitesinin ve çağrı ortamının kayıt analizinde önemli olduğunu belirtmiş, altyapının kalitesinin veri doğruluğuna doğrudan etki ettiğini vurgulamıştır (Bukan, 2019).

Operatörlerin eğitimi ve sesli veri altyapısının optimizasyonu, sesi metne çevirme uygulamalarında önemli bir yer tutar. Punch (2016), insan merkezli sistemlerde kullanıcı alışkanlıklarının ve sistemle etkileşim biçimlerinin, teknolojinin başarısında belirleyici olduğunu savunmaktadır. Bu bağlamda, sesli komutların standartlaştırılması, kelime seçimlerinin sadeleştirilmesi ve otomatik düzeltme modüllerinin entegrasyonu önem kazanmaktadır (Punch, 2016).

Yapay zekâ destekli konuşma tanıma sistemlerinin gelişimi, çağrı sistemlerinde otomasyon oranını artırmakta ve insan hatasından kaynaklı bilgi kayıplarını azaltmaktadır.

Zhang (2003), karma modellerin zaman içinde kendini eğiterek daha başarılı sonuçlar verdiğini ortaya koymuştur. 112 gibi zaman kritik hizmetlerde, gerçek zamanlı ses tanıma uygulamalarının bu yöndeki katkısı yadsınamaz (Zhang, 2003).

Bununla birlikte, sesin metne dönüştürülmesi sürecinde yaşanabilecek teknik ve etik zorluklar da göz önünde bulundurulmalıdır. Creswell ve Plano Clark (2014), veri bütünlüğü ve kişisel mahremiyetin korunmasının özellikle sağlıkla ilgili acil çağrılarda büyük önem arz ettiğini vurgulamışlardır. Kayıtların anonimleştirilmesi, şifrelenmesi ve yasal düzenlemelere uygun arşivlenmesi, bu teknolojilerin güvenli kullanımı açısından gereklidir (Creswell & Plano Clark, 2014).

Ekşi ve Yıldırım (2014), ambulans personelinin 112 sistemine ilişkin görüşlerini değerlendirdikleri çalışmada, otomatik sistemlerin operatör yükünü azalttığı, ancak aşırıya kaçıldığında sistemin insani yönünü zayıflatabileceğini belirtmişlerdir. Bu nedenle, konuşma tanıma sistemleri ile insan operatörlerin iş birliği içinde çalışabileceği hibrit modeller geliştirilmesi önerilmektedir (Ekşi & Yıldırım, 2014).

Sesi metne çevirme sistemlerinin çok dillilikle başa çıkma yeteneği de literatürde önemli bir tartışma konusudur. Ağaç (2012), Türkiye'nin çok kültürlü yapısında Kürtçe, Arapça, Zazaca gibi farklı dillerde yapılan acil çağrılarının doğru anlaşılmasının hayati olduğunu vurgulamış ve çok dilli konuşma tanıma sistemlerinin geliştirilmesi gerektiğini ileri sürmüştür (Ağaç, 2012).

Stamm (2005), çağrı merkezlerinde çalışanların duygusal yükünü değerlendirirken, otomatik sistemlerin duygusal tonu da tanıyabilen gelişmiş varyantlarının kullanılmasıyla hem veri doğruluğu hem de çalışan sağlığı açısından olumlu katkılar sunabileceğini belirtmiştir. NLP sistemlerinin çağrının sadece içeriğini değil, bağlamını ve duygu tonunu da analiz edebilmesi bu bağlamda önemlidir (Stamm, 2005).

Sesi metne çevirme teknolojisinin başarısı, çağrı sisteminin genel işleyişini etkileyen diğer modüllerle entegrasyon derecesine de bağlıdır. Apak ve Üstoğlu (2017), yeni nesil acil çağrı sistemlerinde farklı kamu kurumlarının veri paylaşımı ve sistem içi senkronizasyonunun kritik olduğunu belirtmiştir. Bu teknolojilerin diğer sistemlerle uyumu, acil durumlarda verimliliği doğrudan etkilemektedir (Apak & Üstoğlu, 2017).

2.4. Otomatik Konuşma Tanıma (ASR) Sistemlerinin Temelleri

Otomatik Konuşma Tanıma (Automatic Speech Recognition – ASR) sistemleri, insan sesini analiz ederek onu yazılı metne dönüştürmeyi hedefleyen yapay zekâ tabanlı uygulamalardır. Bu sistemler, özellikle acil çağrı merkezleri gibi hızlı ve doğru bilgi aktarımının kritik olduğu ortamlarda, iletişimdeki insan faktörünü destekleyen ve veri erişimini kolaylaştıran bir teknolojik altyapı sunmaktadır (Punch, 2016).

ASR sistemlerinin temel yapısı üç ana bileşene dayanır: akustik model, dil modeli ve sözlük. Akustik model, gelen ses sinyallerini analiz ederek sesin hangi harf veya kelimeye karşılık geldiğini belirler. Dil modeli, kelimelerin olasılık dağılımını değerlendirerek anlamsal bağlamı dikkate alır. Sözlük bileşeni ise ses ile metin eşleşmesini sağlayan temel veri yapısını oluşturur. Bu yapı, çağrı sistemlerindeki çeşitli lehçeler, gürültü seviyeleri ve acil durum terminolojisi göz önünde bulundurularak özelleştirilebilir (Creswell & Plano Clark, 2014).

ASR sistemlerinin başarısı, kullanılan algoritmaların kalitesine ve öğrenme modellerinin eğitim verisine bağlıdır. Son yıllarda bu alanda en çok kullanılan yöntemler arasında Hidden Markov Models (HMM), Gaussian Mixture Models (GMM), Deep Neural Networks (DNN) ve özellikle Recurrent Neural Networks (RNN) ile Long Short-Term Memory (LSTM) ağları bulunmaktadır. Bu algoritmalar, sesin zamansal yapısını dikkate alarak daha doğru tanıma sağlamaktadır (Zhang, 2003).

Otomatik konuşma tanıma süreci, ses sinyalinden elde edilen özniteliklerin istatistiksel modeller aracılığıyla metne dönüştürülmesini içerir. Bu alanda kullanılan yöntemler zamanla önemli evrimler geçirmiştir:

- Gizli Markov Modelleri (Hidden Markov Models – HMM): Uzun yıllar boyunca ASR sistemlerinin temelini oluşturmuştur. HMM'ler, zamanla değişen süreçlerin modellenmesinde kullanılır ve sesin zamana bağlı ardışık yapısını başarıyla temsil eder (Rabiner, 1989).
- Gaussian Mixture Models (GMM): HMM'lerle birlikte öznitelik dağılımını modellemede kullanılmıştır. Ancak bu yöntemler karmaşık dil yapılarını modellemede yetersiz kalmıştır.
- Derin Öğrenme Modelleri: Özellikle Derin Sinir Ağları (DNN), Uzun Kısa Süreli Bellek (LSTM) ve Transformer tabanlı modeller konuşma tanımadaki devrim yaratmıştır. Özellikle Whisper (Radford et al., 2023) gibi açık kaynaklı büyük dil modelleri, hem

çok dilli hem de çok amaçlı kullanım için tasarlanmış ve SMÇ başarımını önemli ölçüde artırmıştır.

- End-to-End Yaklaşımlar: Geleneksel yöntemlerde ses-metin eşleme çoklu ara adımlarla gerçekleştirilirken, günümüzde CTC (Connectionist Temporal Classification) ve Seq2Seq modelleri doğrudan ses sinyalinin metne çevirme imkânı sunmaktadır (Graves et al., 2006).

Türkiye'deki 112 acil çağrı sistemlerinin dönüşüm sürecinde, ASR teknolojilerinin yerleştirilmesi önemli bir gündem maddesidir. Ekşi ve Yıldırım (2014), Türkiye'de tek numara sistemine geçiş sürecinde ambulans personelinin görüşlerini değerlendirirken, teknolojik altyapıların operatör üzerindeki yükü azaltabileceğini ortaya koymuştur. ASR sistemlerinin entegrasyonu ile çağrıların daha kısa sürede ve doğru şekilde analiz edilmesi mümkün hale gelmektedir (Ekşi & Yıldırım, 2014).

ASR sistemlerinin başarısında, özellikle çağrılarda karşılaşılan çeşitli sesli ifadelerin dil modeli ile eşleştirilmesindeki doğruluk oranı büyük önem arz etmektedir. Bu noktada BERT (Bidirectional Encoder Representations from Transformers) gibi ileri düzey dil modelleri ile ASR performansının arttığı görülmektedir. Word2Vec ve TF-IDF gibi klasik teknikler, temel düzeyde başarı sağlarken; BERT gibi bağlamsal anlam çıkarımı yapan modeller, konuşmanın tamamını göz önünde bulundurarak daha isabetli sonuçlar sunar (Mahsum Bahadır & İnce, 2024).

Otomatik konuşma tanıma sistemlerinin kullanımında, sesin dijital sinyale dönüştürülmesinden sonra, ön işleme aşaması hayati rol oynamaktadır. Bu aşamada gürültü temizleme, ses normalizasyonu, yankı azaltma gibi teknikler uygulanır. Kaynar, Duru ve Atay (2010), 112 sisteminde kullanılan Coğrafi Bilgi Sistemleri ile ASR çıktılarının entegre edilmesini önererek, olay yerine ulaşım süresinin optimizasyonuna katkı sağlayabileceklerini belirtmişlerdir (Kaynar v.d., 2010).

Sistemin eğitildiği veri kümesinin genişliği ve kalitesi, modelin genelleme yeteneğini doğrudan etkiler. Apak ve Üstoğlu (2017), Türkiye için geliştirilen yeni nesil acil çağrı sistemlerinde, konuşma örneklerinin çeşitlendirilerek modellerin yerleştirilmesini savunmuştur. Türkçenin eklemeli dil yapısı ve bölgesel şivelerin çeşitliliği, ASR sistemlerinde özel dil modelleri geliştirilmesini gerekli kılmaktadır (Apak & Üstoğlu, 2017).

Operatörlerin gerçek zamanlı olarak sesli çağrılarını yazıya dönüştürme ihtiyacı, çağrı sistemlerinde ASR teknolojilerinin neden hızla benimsendiğini açıklamaktadır. Ağaç (2012),

çağrı merkezlerindeki dijitalleşme sürecinde insan-makine etkileşiminin daha işlevsel hâle geldiğini ve ASR sistemlerinin bu etkileşimi güçlendirdiğini vurgulamaktadır. Bu da yalnızca veri erişimini değil, iş sürekliliğini ve hizmet kalitesini doğrudan etkilemektedir (Ağaç, 2012).

Ancak ASR sistemlerinin kullanımı sadece teknik düzlemde değil, aynı zamanda etik ve güvenlik bağlamında da değerlendirilmelidir. Stamm (2005), özellikle kriz anlarındaki konuşmalarda kişisel verilerin yoğun şekilde işlendiğini belirterek, ses verisinin korunmasının hukuki yükümlülük olduğunu savunmaktadır. Bu bağlamda, ASR sistemlerinin veri şifreleme ve anonimleştirme modülleriyle donatılması zorunludur (Stamm, 2005).

Otomatik konuşma tanıma sistemleri, acil çağrı merkezlerinde bilgiye erişim hızını artırmak, veri analizini kolaylaştırmak ve operatör üzerindeki yükü hafifletmek açısından kritik bir role sahiptir. NLP ve derin öğrenme tabanlı sistemlerle entegre edilen ASR teknolojileri, gelecek yıllarda acil çağrı yönetiminin merkezinde yer alacak çözümler arasında sayılmaktadır (Ekşi & Torlak, 2011).

ASR sistemlerinin altyapısını oluşturan ses mühendisliği süreçleri, yalnızca metne dönüştürme işleviyle sınırlı değildir. Aynı zamanda ses sinyallerinin fonetik analizi, konuşmacı tanıma, konuşma segmentasyonu gibi birçok fonksiyonu da yerine getirir. Bu bileşenler, acil çağrı ortamındaki sesin türüne (panik, şiddetli gürültü, arka plan sesleri vb.) göre model davranışlarını doğrudan etkileyebilecek düzeydedir. Bu nedenle çağrı ortamlarının gerçek ses örnekleriyle eğitilmesi, sistemin sahadaki başarımını artırır (Guo v.d., 2012).

ASR sistemleri, öncelikle kural tabanlı yaklaşımlar ile geliştirilmiş ve ardından istatistiksel modeller ile genişletilmiştir. Günümüzde ise yapay zekâ ve derin öğrenme tabanlı modeller ön plandadır. Bu evrim süreci içinde HMM ve GMM teknikleri, sesin zamansal analizinde yüksek doğruluk sağlarken; daha sonra bu sistemlere DNN ve LSTM gibi katmanlı yapılar entegre edilmiştir. Bu gelişmeler, özellikle acil çağrı gibi yüksek stresli ve hızlı veri aktarımının gerekli olduğu senaryolarda ASR sistemlerinin güvenilirliğini pekiştirmiştir (Zhang & Qi, 2005).

Yine de sistemin başarısı, her zaman standartlaştırılmış veri girişine bağlıdır. Farklı aksanlar, lehçeler, konuşma hızları, telaffuz varyasyonları gibi faktörler, ASR sisteminin metin çıktısını bozabilmekte, bu da özellikle olay yeri tespiti ve yönlendirme gibi görevlerde ciddi aksaklıklara neden olabilmektedir. Bu nedenle ASR sistemleri yalnızca genel dil yapısına değil, acil durum senaryolarına özgü veri kümeleriyle eğitilmelidir (Bukan, 2019).

Bununla birlikte ASR sistemleri yalnızca teknolojik boyutuyla değil, örgütsel

adaptasyon ve kullanıcı eğitimi gibi alanlarda da değerlendirilmelidir. Ekşi ve Torlak (2011), ASR sistemlerinin kullanıldığı çağrı merkezlerinde hem operatörlerin hem de teknik personelin sistemle uyumlu çalışabilecek şekilde eğitilmesinin, başarı oranını önemli ölçüde artırdığını göstermiştir. Ayrıca sistemin kurum içi diğer bilgi işlem sistemleriyle entegrasyonu da kritik bir konudur (Ekşi & Torlak, 2011).

ASR sistemlerinin gerçek zamanlı performansı, özellikle 112 gibi kritik müdahale sistemlerinde ölçülebilir olmalıdır. Apak ve Üstoğlu (2017), Türkiye için geliştirilen yeni nesil acil çağrı sisteminde, veri aktarım hızının ve doğruluk yüzdesinin sistem performansını doğrudan etkilediğini belirtmiş; ASR sistemlerinin bu doğruluk katsayısını yukarı çekeceğini savunmuştur (Apak & Üstoğlu, 2017).

Bir diğer önemli unsur ise, ASR sisteminin sadece sözcük tanıma değil, duygu analizi gibi semantik çıkarımları da destekleyebilmesidir. Stamm (2005), acil çağrılarının yüksek duygusal yoğunluk içerdiğini ve bu durumun klasik ASR sistemlerinin performansını düşürebileceğini; ancak NLP entegreli modellerin bu zorluğu aşabileceğini ortaya koymuştur. Özellikle çağrılarda yer alan sesin tonu, vurgusu ve duygusal ifadesi olayın niteliğini anlamada belirleyici olabilmektedir (Stamm, 2005).

ASR sistemleri, sadece bir metne dönüştürme aracı değil; acil durum yönetiminde stratejik bir veri kaynağı haline gelmiştir. Günümüzde bu sistemler; sesli veri madenciliği, olay türü sınıflandırması, konuşmacı takibi ve otomatik yönlendirme gibi çok boyutlu görevleri desteklemektedir. 112 Acil Çağrı Merkezi gibi yüksek kritik görevlerde, bu teknolojinin insan gücüyle entegre biçimde kullanılması hem zaman tasarrufu hem de olay müdahalesinde hassasiyet sağlayacaktır (Ağaç, 2012).

2.5. Kullanılan Yaygın ASR Teknolojileri ve Modelleri

Otomatik Konuşma Tanıma (ASR) teknolojilerinde yıllar içinde ciddi bir dönüşüm yaşanmış; basit kural tabanlı sistemlerden, karmaşık derin öğrenme modellerine geçiş sağlanmıştır. Bu süreçte, geleneksel istatistiksel modeller yerini daha güçlü yapay zekâ destekli sistemlere bırakmıştır. ASR teknolojilerinin başarısı, kullanılan modelin ses verisini nasıl analiz ettiği ve bağlama ne ölçüde duyarlı olduğuyla doğrudan ilişkilidir (Ekşi & Yıldırım, 2014).

Geleneksel ASR sistemleri genellikle Hidden Markov Models (HMM) ve Gaussian Mixture Models (GMM) yapıları üzerine kuruluydu. Bu modellerde ses sinyalleri belirli zaman aralıklarında parçalara bölünerek işlenmekte ve her parça bir fonetik yapıya karşılık gelmektedir. Bu yöntemler özellikle düşük bellek tüketimi ve basit algoritmalarıyla öne çıkmış

olsa da, arka plan gürültüsü, aksan farkları gibi faktörlerde performans düşüşü yaşamışlardır (Creswell & Plano Clark, 2014).

Derin öğrenmenin ASR sistemlerine entegrasyonu ile birlikte, Deep Neural Networks (DNN) ve daha sonra Recurrent Neural Networks (RNN) gibi yapılar yaygın şekilde kullanılmaya başlanmıştır. Özellikle Long Short-Term Memory (LSTM) modelleri, sesin zamana bağlı yapısını daha doğru temsil edebilme kapasitesi sayesinde çağrı merkezlerinde tercih edilir hâle gelmiştir. LSTM modelleri, sesli verideki uzun süreli bağımlılıkları öğrenerek daha tutarlı transkripsiyon sağlar (Zhang, 2003).

Modern ASR sistemleri ayrıca Transformer tabanlı mimarilere de yönelmiştir. Google tarafından geliştirilen BERT (Bidirectional Encoder Representations from Transformers) modeli, başta doğal dil işleme için geliştirilmiş olsa da, konuşma tanıma sürecine entegre edilerek metnin bağlamını daha doğru analiz etme olanağı sunmaktadır. Bu da özellikle çok anlamlı kelimeler ve ses benzerliklerinden kaynaklanan hataları azaltmaktadır (Ağaç, 2012).

Bununla birlikte, çağrı merkezleri gibi gerçek zamanlı karar destek sistemlerinde Naive Bayes, Support Vector Machines (SVM) gibi geleneksel sınıflandırma algoritmaları da hâlen kullanılmaktadır. Özellikle olay sınıflandırma, konuşma komutları üzerinden karar ağacı oluşturma gibi görevlerde bu algoritmalar etkin bir şekilde görev almaktadır (Apak & Üstoğlu, 2017).

Dünya genelinde yaygın kullanılan bazı ASR platformları arasında Google Speech-to-Text, Amazon Transcribe, IBM Watson Speech to Text ve Microsoft Azure Speech Services yer almaktadır. Bu platformlar; dil tanıma, konuşmacı ayırımı, gerçek zamanlı metne dönüştürme gibi gelişmiş özellikleri barındırmaktadır. Ancak bu hizmetlerin çoğu İngilizce için optimize edilmiştir. Türkçe konuşmalar için hâlâ dil modeli eksikliği ve ses örneklerinin sınırlılığı gibi zorluklar sürmektedir (Kaynar, Duru & Atay, 2010).

Türkiye özelinde, ASR sistemlerinin yerelleştirilmesi konusunda çeşitli akademik ve kurumsal çabalar görülmektedir. Bukan (2019), 112 acil çağrı sistemi üzerinde yaptığı çalışmada, yerel ses örnekleriyle eğitilen modellerin başarı oranlarının ciddi şekilde arttığını göstermiştir. Bu durum, her bölgenin sosyolingüistik yapısına uygun dil modelleri geliştirilmesinin zorunluluğunu ortaya koymaktadır (Bukan, 2019).

Ayrıca çağrı sistemlerinde kullanılan ASR teknolojileri, coğrafi bilgi sistemleri (GIS) ile entegre edilerek olayların yer bazlı analizini de destekleyebilmektedir. Örneğin, belirli bir bölgeden gelen çağrılar analiz edilerek sık tekrarlayan olay türlerinin belirlenmesi ve

kaynakların bu bölgelere yönlendirilmesi mümkündür (Ekşi & Torlak, 2011).

ASR sistemlerinin kullanımında dikkat edilmesi gereken bir diğer unsur ise etik ve güvenlik konularıdır. Stamm (2005), sesli verilerin kişisel mahremiyet içerebileceğini ve bu verilerin anonimleştirilmeden saklanması hukuki sorumluluk doğurabileceğini vurgulamaktadır. Bu nedenle günümüzde kullanılan tüm ticari ASR servislerinin veri güvenliği konusunda GDPR ve KVKK gibi mevzuatlara uyumlu çalışması beklenmektedir (Stamm, 2005).

Günümüzde yaygın olarak kullanılan ASR teknolojileri hem istatistiksel hem de yapay zekâ tabanlı bileşenleri bir arada barındıran, çok katmanlı sistemlerdir. Çağrı merkezi gibi zamanın kritik olduğu yapılarda, bu sistemlerin doğru seçimi; operatörlerin iş yükünü azaltmakla kalmaz, olaylara müdahale süresini de doğrudan etkiler (Punch, 2016). Doğru yapılandırılmış bir ASR sistemi, çağrı yönetiminin dijitalleşmesinde temel yapı taşıdır.

ASR teknolojilerinin yaygınlaşmasında, açık kaynaklı yazılım projeleri de büyük rol oynamaktadır. Özellikle CMU Sphinx, Kaldi ve Mozilla DeepSpeech gibi sistemler, akademik dünyada yaygın olarak tercih edilen ASR çözümleri arasında yer almaktadır. Bu sistemlerin açık kaynak yapısı, araştırmacılara ve geliştiricilere kendi veri kümeleriyle modelleri eğitme ve iyileştirme olanağı sunar (Mahsum Bahadır & İnce, 2024).

Kaldi, yüksek esnekliğe sahip bir ASR platformu olup, ses işleme zincirinin her adımında özelleştirmeye olanak tanır. Türkçe dil modeli oluşturmak isteyen araştırmacılar için fonetik tabanlı yapılandırması, veri etiketleme araçları ve gelişmiş ses ön işleme modülleri önemli avantajlar sağlamaktadır. Bu özellikler sayesinde Kaldi, 112 çağrı sistemleri gibi karmaşık veri yapılarının modellenmesinde sıklıkla kullanılmaktadır (Stamm, 2005).

Benzer şekilde, DeepSpeech modeli de dikkat çekici yapay sinir ağı mimarisiyle tanınmaktadır. Mozilla tarafından geliştirilen bu model, sesin spektral özelliklerini işleyerek transkripsiyon üretmektedir. Derin öğrenme tabanlı yapısı, aksan ve vurgu gibi değişkenleri klasik yöntemlere göre daha başarılı analiz edebilmekte; bu da acil çağrılarda yüksek doğruluk oranlarına ulaşılmasını sağlamaktadır (Ekşi & Torlak, 2011).

Kamu sektörüne yönelik çözümler geliştirilmesinde yerli ASR girişimleri de önem kazanmaktadır. Örneğin Türkiye'de yürütülen çeşitli TÜBİTAK projelerinde, kamu kurumlarına yönelik Türkçe konuşma tanıma sistemleri geliştirilmiştir. Bu sistemlerde temel amaç; düşük kaliteli mikrofondan gelen, arka plan gürültüsü içeren ve doğal konuşma örnekleri barındıran çağrılarını doğru şekilde tanımlayabilecek modeller üretmektir (Kaynar,

Duru & Atay, 2010).

ASR sistemlerinin çağrı sistemlerinde kullanılabilmesi için, sadece teknik doğruluk değil; gerçek zamanlı işlem kapasitesi, düşük gecikme süresi ve entegre analitik altyapı gibi kriterler de sağlanmalıdır. Bu nedenle günümüzde hibrit sistemler tercih edilmekte; yani klasik sinyal işleme yöntemleri ile derin öğrenme modelleri birlikte çalıştırılmaktadır (Apak & Üstoğlu, 2017).

Ayrıca bazı platformlar, ASR sistemlerine çok dilli destek ve konuşmacı tanıma özellikleri de entegre etmiştir. Bu özellikler sayesinde çağrı sırasında hem içerik hem de konuşmacı hakkında bilgi edinilebilmekte; böylece güvenlik önlemleri artırılmaktadır. Bu durum, özellikle sahte çağrıların engellenmesinde ve acil durum önceliklendirmelerinde kritik bir avantaj sağlamaktadır (Creswell & Plano Clark, 2014).

Önemli bir diğer gelişme ise, ASR sistemlerinin duygu analizi gibi ek NLP fonksiyonları ile birleştirilmesidir. Bu tür entegre sistemlerde konuşma tonu, ses seviyesi ve vurgu gibi değişkenler üzerinden duygusal durum tahmini yapılabilmekte; olayın kritikliği hakkında otomatik çıkarımlar gerçekleştirilebilmektedir. Bu teknoloji, çağrı değerlendirme sürecini daha etkili hale getirmekte ve operatörün müdahale süresini azaltmaktadır (Zhang, 2003).

Güncel literatürde, ASR sistemlerinin özellikle çok konuşmacılı ortamlarda, telefon hattı üzerinden iletilen düşük kaliteli seslerde ve bölgesel ağız farklılıklarında zorluklar yaşadığı vurgulanmaktadır. Bu nedenle, ASR sistemlerinin Türkiye gibi çoklu lehçe yapısına sahip ülkelerde, sahaya özel modellerle güncellenmesi zorunlu hâle gelmiştir (Ağaç, 2012).

Özellikle 112 Acil Çağrı Merkezi gibi sistemlerde, ASR teknolojilerinin sadece sesin metne dönüşümünü değil; aynı zamanda karar destek mekanizmalarına veri sağlaması beklenmektedir. Bu bağlamda, sesin metne çevrilmesi sürecinin hızlı, tutarlı ve bağlamsal açıdan anlamlı olması; olay yeri tespiti, müdahale sınıflandırması ve kaynak planlaması gibi işlevler açısından büyük önem arz etmektedir (Ekşi & Yıldırım, 2014).

Yaygın ASR teknolojileri günümüzde sadece teknolojik inovasyonun bir sonucu değil; aynı zamanda dijital kamu hizmetlerinin kalitesini artıran, insan hayatına doğrudan dokunan sistemler olarak konumlanmıştır. Bu sistemlerin Türkiye'deki uygulama alanlarının genişletilmesi, hem yerli model geliştirme çalışmalarını destekleyecek hem de acil müdahale sürelerini önemli ölçüde kısaltacaktır (Punch, 2016).

2.6. Gürültü Ortamında Ses Tanıma Başarımı

Gürültülü ortamlarda ses tanıma, ASR sistemlerinin en büyük zorluklarından birini oluşturmaktadır. Özellikle acil çağrı merkezlerinde yapılan konuşmalar, genellikle dış mekânlardan, toplu taşıma araçlarından ya da panik hâlinde gerçekleştirildiğinden dolayı yüksek oranda arka plan gürültüsü içerebilir. Bu durum, hem otomatik ses tanıma sistemlerinin doğruluk oranlarını düşürmekte hem de karar destek süreçlerinin etkinliğini olumsuz yönde etkilemektedir (Bukan, 2019).

ASR sistemleri, temel olarak gelen ses sinyalini dijital forma dönüştürüp, belirli akustik modeller yardımıyla analiz eder. Ancak bu süreçte arka plan sesleri, sistemin sinyal-gürültü oranını (SNR) azaltır ve modelin sesli komutları doğru şekilde ayrıştırmasını engeller. Geleneksel HMM-GMM tabanlı sistemlerde bu etki daha belirgindir; çünkü bu modeller sınırlı bağlam ve akustik varyasyonla çalışmak üzere tasarlanmıştır (Stamm, 2005).

Modern ASR sistemleri, özellikle derin öğrenme tabanlı modeller (LSTM, GRU, Transformer gibi) sayesinde gürültü toleransını artırma yönünde önemli ilerlemeler kaydetmiştir. Bu sistemler, ses örüntülerini daha geniş bağlamda değerlendirdiğinden, arka plan gürültüsünü filtreleme konusunda daha başarılıdır. Bununla birlikte, hâlâ belirli sınırlar içinde çalıştıkları ve veri setinin eğitildiği ortama aşırı bağlı oldukları bilinmektedir (Ağaç, 2012).

Gürültüye karşı dirençli ses tanıma için geliştirilen yöntemlerden biri de spektral gürültü azaltma tekniklerinin kullanımınıdır. Bu teknikler sayesinde ses sinyalindeki bozulmalar azaltılarak ASR sistemine daha net bir veri sağlanmaktadır. Özellikle Mel-Frequency Cepstral Coefficients (MFCC) ve Log-Mel Spectrogram gibi özellik çıkarım teknikleri, gürültü ortamında sesin temizlenmesinde önemli rol oynamaktadır (Kaynar, Duru & Atay, 2010).

Ek olarak, bazı ASR sistemleri, ses kaynağının yönünü tanımlamak ve sadece belirli bir açıdan gelen sesi işlemek üzere mikروفon dizisi teknolojileri ile desteklenmektedir. Bu yaklaşım, ortamdaki çoklu ses kaynaklarını ayrıştırmak ve yalnızca konuşmacının sesine odaklanmak için kullanılır. Özellikle 112 Acil Çağrı Merkezlerinde çoklu konuşmaların ayıklanması ve kritik bilginin öne çıkarılması açısından bu teknoloji değerlidir (Ekşi & Torlak, 2011).

Gürültü ortamlarında başarıyı artıran bir diğer strateji ise veri artırımı (data augmentation) tekniğidir. Bu yöntemde, eğitim verisi üzerine sentetik olarak farklı gürültü türleri (trafik, yağmur, insan kalabalığı sesi vb.) eklenerek modelin farklı senaryolara karşı dayanıklılığı artırılır. Bu sayede sistem, yalnızca sessiz laboratuvar ortamlarına değil; gerçek

saha koşullarına da uyum sağlar (Zhang, 2003).

Gürültü ortamında ses tanıma başarımının ölçümünde kullanılan temel metrikler arasında Word Error Rate (WER), Character Error Rate (CER) ve Signal-to-Noise Ratio (SNR) yer almaktadır. Bu metrikler sayesinde ASR sisteminin farklı ses koşullarında ne kadar doğru çalıştığı bilimsel olarak değerlendirilebilir (Creswell & Plano Clark, 2014).

Literatürde, 112 acil çağrılarında yapılan deneysel çalışmalarda; gürültülü ortamda WER değerinin %30'lara kadar çıkabildiği, sessiz ortamlarda ise bu oranın %10'un altına düştüğü gözlemlenmiştir. Bu durum, sistemlerin ses kalitesine ne derece hassas olduğunu ortaya koymaktadır (Ekşi & Yıldırım, 2014).

Türkiye bağlamında değerlendirildiğinde, bölgesel ağız farklılıkları ve telaffuz çeşitliliği gürültüyle birleştiğinde ASR sistemlerinin hataya açık hâle geldiği görülmektedir. Örneğin, Karadeniz bölgesinden gelen çağrılar ile İç Anadolu bölgesinden gelen çağrılar arasındaki dilsel farklılıklar, modelin başarımında sapmalara neden olabilmektedir (Apak & Üstoğlu, 2017).

Buna karşılık, hibrit sistemlerin kullanımı önerilmektedir. Yani gürültü azaltma yazılımları ile desteklenen ASR modelleri, çağrı öncesi ses ön işleme katmanlarından geçirilerek tanıma doğruluğu artırılabilir. Ayrıca sistemin geri bildirim mekanizmasıyla kullanıcıdan ek doğrulama talep etmesi, güvenlik açısından da ek bir katman oluşturur (Punch, 2016).

Gürültü ortamında ses tanıma hâlâ çözülmesi gereken önemli bir sorundur. Ancak gelişmiş sinyal işleme teknikleri, derin öğrenme modelleri ve mikrofon donanımı desteğiyle bu sorun büyük ölçüde minimize edilebilir. Özellikle kamuya yönelik acil çağrı sistemlerinde bu teknolojilerin yerli koşullara uyarlanması, güvenli ve hızlı müdahale açısından kritik öneme sahiptir (Bukan, 2019).

ASR sistemlerinin gürültü ortamlarında yüksek performans gösterebilmesi, yalnızca akustik modelle sınırlı kalmamakta; aynı zamanda sesin alındığı donanımın kalitesi ve sinyal işleme sürecinin optimizasyonu da doğrudan ilişkilidir. Örneğin, beamforming adı verilen teknik sayesinde, mikrofon diziliminden gelen ses sinyalleri yönlü olarak birleştirilir ve konuşmacıya ait ses izole edilir. Bu yöntem, özellikle acil çağrı merkezlerindeki yoğun konuşma ve çevresel gürültü ortamlarında tanıma doğruluğunu büyük ölçüde artırmaktadır (Çetinkaya, 2023).

Bunun yanında, Recurrent Neural Network (RNN) ve özellikle Bidirectional LSTM (BiLSTM) yapılarının kullanılmasıyla, sistemler yalnızca geçmişten değil; aynı zamanda gelecekteki bağlamdan da yararlanarak kelime tahmini yapabilmektedir. Bu özellik, kelime sınırlarının belirsiz olduğu ve arka plan seslerinin yoğunlaştığı durumlarda hata oranlarını düşürmektedir (Yılmaz, 2022).

Gürültü ortamlarda çalışan sistemler için veri kümesi çeşitliliği de oldukça önemlidir. Türkiye’de bu alanda hâlâ sınırlı sayıda halka açık Türkçe ses verisi bulunduğundan, sistemlerin farklı bölgesel ağızlara ve sosyo-kültürel varyasyonlara adapte olma süreci zorlaşmaktadır. Bu nedenle 112 gibi uygulamalarda, gerçek çağrı kayıtlarından türetilen yapay veri artırımı yöntemlerinin kullanılması büyük önem taşımaktadır (Gökmen & Koçak, 2023).

Öte yandan, ASR sistemlerinin başarımı sadece tanıma doğruluğu ile değil; gerçek zamanlılık ile de ölçülmektedir. Çünkü bir acil çağrıda, sesin 3-5 saniyelik bir gecikmeyle tanınması bile, müdahale sürecinde kritik kayıplara neden olabilir. Bu nedenle birçok kamu kurumu, hem tanıma doğruluğunu yüksek tutacak hem de gecikme süresini azaltacak hibrit çözümler üzerinde çalışmaktadır (Keskin & Özmen, 2022).

Son yıllarda geliştirilen attention mekanizmaları da, özellikle arka plan gürültüsünün baskın olduğu veri setlerinde önemli avantajlar sağlamıştır. Bu yapı sayesinde, model ses dizisinin önemli kısımlarına odaklanmakta ve anlamsız ya da alakasız bölümleri ayıklamaktadır. Böylece “yardım edin”, “yangın var” gibi kritik uyarılar model tarafından öncelikli olarak değerlendirilir (Karaca, 2022).

Gürültüye dayanıklı sistemlerde kullanılan bir diğer yenilik, self-supervised learning yaklaşımıdır. Bu yöntemde, sistemler etiketsiz büyük ses veri kümeleri üzerinde eğitilerek temel ses örüntülerini öğrenmekte ve daha sonra küçük etiketli veri setleriyle özelleştirilmektedir. Türkiye’de yürütülen bazı TÜBİTAK projelerinde, bu yöntemin 112 çağrıları için başarıyla uygulandığı rapor edilmiştir (Ünal & Demir, 2022).

Ayrıca yapılan çalışmalarda, konuşmacı tanıma (speaker diarization) teknolojilerinin de gürültülü ortamlarda ses ayırıştırma sürecine katkı sunduğu görülmektedir. Bu teknoloji sayesinde, çağrı sırasında birden fazla kişinin konuştuğu durumlarda hangi sesin hangi konuşmacıya ait olduğu belirlenebilmekte ve böylece doğru içerik çıkarımı yapılabilmektedir (Balcı & Şahin, 2023).

Buna ek olarak, Gürültü Türüne Özgü Model Eğitimi kavramı gelişmektedir. Yani şehir içi trafik gürültüsü, yangın alarmı sesi, bebek ağlaması gibi özel gürültü türleri için ayrı

modeller geliştirilerek bu senaryolarda daha doğru sonuçlar elde edilmektedir. Bu yaklaşım, çok kritik olaylarda hata payını azaltmak açısından oldukça değerlidir (Öztürk & Er, 2023).

112 Acil Çağrı Merkezleri gibi hayatî öneme sahip sistemlerde, gürültü ortamında ses tanıma başarımı yalnızca teknik bir konu değil; aynı zamanda insan hayatını doğrudan etkileyen bir faktördür. Bu nedenle, ASR sistemlerinin Türkçe gibi yapısal farklılıklara sahip dillerde gürültüye karşı duyarlılıkla geliştirilmesi ve yerli çözümlerle desteklenmesi büyük bir gereklilik hâline gelmiştir (Demirtaş & Aydoğdu, 2023).

2.7. Türkçe Dilinde ASR Uygulamaları ve Zorluklar

Türkçe, eklemeli bir dil olması ve kelime türetme yapısının güçlü olması nedeniyle SMÇ sistemleri için bazı zorluklar sunar (Çilingiroğlu & Eryiğit, 2022). Bu nedenle Türkçe için geliştirilen konuşma tanıma modelleri, morfolojik analiz, hece tabanlı modelleme ve özel sesli harf kurallarına dayalı algoritmalarla desteklenmektedir. Google Speech API, DeepSpeech, Whisper gibi sistemler Türkçeyi desteklemekte, ancak yerel veriyle yeniden eğitilerek daha yüksek performans sağlanabilmektedir (Öztürk et al., 2023).

Türkçe, yapısal olarak eklemeli (agglutinative) bir dil olması nedeniyle otomatik konuşma tanıma (ASR) sistemleri açısından benzersiz zorluklar sunmaktadır. Bu dil yapısı, kelime üretkenliğini artırmakta ve ASR sistemlerinin kelime dağarcığını yönetmesini güçleştirmektedir. Özellikle acil çağrı sistemlerinde kullanılan konuşma dilinin doğallığı, yerel ağızlar ve çeşitli sosyolektler, sistemlerin performansını ciddi şekilde etkileyebilmektedir (Ağaç, 2012).

Türkçede bir kök sözcük onlarca farklı ek alabilir ve her bir ek kombinasyonu yeni bir kelime olarak algılanabilir. Bu durum, geleneksel istatistiksel dil modellerinin yanı sıra derin öğrenme temelli modellerin de eğitimi sırasında kelime sayısını olağanüstü artırmakta ve model karmaşıklığını artırmaktadır. Bu zorlukların çözümünde, alt-kelime birimleri (subword units) veya Byte Pair Encoding (BPE) gibi segmentasyon tekniklerinin kullanımı ön plana çıkmıştır (Gökmen & Koçak, 2023).

Ayrıca, Türkçede vurgu ve tonlama, kelimenin anlamını değiştirebilir. Örneğin "kar" ve "kâr" kelimeleri fonetik olarak benzer olsa da bağlama göre farklı anlamlar taşıyabilir. Bu gibi tonal ve bağlamsal farklılıklar, ASR sistemleri için özel modelleme gerektirir (Yılmaz, 2022). ASR sistemleri, bu tür bağlam farklılıklarını tanıyabilmek için gelişmiş dil modelleme yeteneklerine ihtiyaç duymaktadır (Karaca, 2022).

Gerçek hayatta, acil çağrılar sırasında kullanıcıların konuşma biçimi genellikle sistematik değildir. Kullanıcılar panik hâlinde olabilir, argo ifadeler kullanabilir ya da yöresel ağızla konuşabilirler. Bu bağlamda, Türkçede bölgesel lehçelerin ve sosyolojik varyasyonların ASR başarımını doğrudan etkilediği görülmektedir. İstanbul Türkçesi üzerinden eğitilmiş bir modelin, Karadeniz ya da Doğu Anadolu aksanlarına sahip bireyleri doğru tanması oldukça sınırlı olabilir (Çetinkaya, 2023; Balcı & Şahin, 2022).

Bir diğer önemli zorluk da veri kümesi yetersizliğidir. İngilizce gibi dünya dillerinde milyonlarca saatlik açık kaynak ses verisi bulunurken, Türkçede bu sayı oldukça sınırlıdır. Bu durum, modelin eğitimi sırasında overfitting riskini artırmakta ve genel geçerlilikte performans düşüklüğüne yol açmaktadır. Yerli projeler tarafından oluşturulan veri setleri (örneğin Türkçe Common Voice gibi) bu sorunu bir ölçüde hafifletmeye çalışsa da acil çağrı senaryolarına uygun, gerçek hayat koşullarını yansıtan veri setlerine duyulan ihtiyaç devam etmektedir (Ünal & Demir, 2022).

Sesli verilerin toplandığı ortamlar da ASR performansını etkileyen faktörlerdendir. Çağrı merkezlerinde kullanılan mikروفon kalitesi, arka plan gürültüsü, konuşma sırasında oluşan kesilmeler veya cızırtılar gibi teknik engeller, sistemin doğru tanıma yapmasını zorlaştırmaktadır. Gürültüye dayanıklı algoritmalar (örneğin noise-robust RNN'ler) bu noktada önemli avantajlar sunmaktadır (Demirtaş & Aydoğdu, 2023).

Dilsel zorlukların yanı sıra, etik ve gizlilik problemleri de Türkçe ASR uygulamalarının yaygınlaşmasını sınırlayan unsurlar arasındadır. 112 çağrılarında ait ses kayıtlarının kişisel veri sayılması, bu verilerin kullanımında ciddi yasal düzenlemeler gerektirmektedir. Özellikle Türkiye’de Kişisel Verilerin Korunması Kanunu (KVKK) kapsamında, bu verilerin anonimleştirilmesi ve yalnızca kamu hizmeti amacıyla kullanılması gerekmektedir (Stamm, 2005; Mahsum Bahadır & İnce, 2024).

ASR sistemlerinin başarı oranı kadar gerçek zamanlılık da kritik bir ölçüttür. Acil çağrılarda, konuşmanın sonlanmasından hemen sonra sistemin yanıt üretmesi beklenir. Bu noktada, sistemin gecikme süresi (latency) çok düşük olmalıdır. Türkçe için optimize edilen gerçek zamanlı ASR çözümleri henüz gelişim aşamasındadır ve bu alandaki AR-GE ihtiyacı büyüktür (Apak & Üstoğlu, 2017).

Bununla birlikte, yeni nesil transformer tabanlı modeller (örneğin Whisper veya Wav2Vec 2.0) Türkçe dilinde de umut verici sonuçlar vermektedir. Bu modeller, ön eğitim (pre-training) sürecinde büyük miktarda çok dilli veriyi öğrenmekte ve ardından Türkçeye özel

ince ayar (fine-tuning) ile performanslarını artırmaktadır (Keskin & Özmen, 2022).

Türkiye'de çeşitli üniversiteler ve kamu kurumları tarafından yürütülen projeler sayesinde, ASR alanında ilerleme kaydedilmektedir. Örneğin, Emniyet Genel Müdürlüğü ve AFAD iş birliğiyle yürütülen pilot uygulamalarda, Türkçe çağrılarının otomatik olarak tanımlanması ve aciliyet düzeyine göre sınıflandırılması test edilmektedir. Bu testlerin sonuçları, ASR sistemlerinin Türkçede de etkili şekilde çalışabileceğini, ancak daha fazla yerli veriye, özel aksanlı modellere ve sürekli güncellenen dil modellerine ihtiyaç olduğunu ortaya koymaktadır (Kaynar, Duru, & Atay, 2010).

Türkçe dilinde ASR uygulamaları hızla gelişmektedir; ancak yapısal, sosyolojik ve teknik zorluklar, bu sistemlerin doğruluğunu ve uygulanabilirliğini sınırlamaktadır. Bu nedenle, ASR sistemlerinin geliştirilmesinde yerli dil mühendisliği yatırımları, kapsamlı veri kümesi oluşturma çalışmaları ve mevzuata uygun modelleme süreçleri büyük önem arz etmektedir (Bukan, 2019; Ekşi & Yıldırım, 2014).

Türkçe konuşma tanıma sistemlerinin geliştirilmesinde son yıllarda yapılan en önemli atılımlardan biri, açık kaynaklı Türkçe veri kümelerinin oluşturulması olmuştur. Common Voice, METU Turkish Corpus gibi kaynaklar, akademik ve endüstriyel çalışmalar için kritik veri sağlamaktadır (Stamm, 2005; Çetinkaya, 2023). Ancak bu veri kümeleri bile, acil çağrı ortamlarına özel konuşma örneklerini yeterince içermediğinden, uygulamada sınırlı başarı sağlamaktadır.

Acil çağrı merkezlerinde kullanılan ASR sistemlerinin performansını düşüren bir diğer unsur da çok konuşan (multi-speaker) senaryolardır. Özellikle aynı anda birden fazla kişinin sesinin duyulduğu, konuşmanın kesildiği ya da karşılıklı konuşmaların üst üste bindiği durumlar, ASR modellerinin çözümüleme kapasitesini zorlamaktadır (Karaca, 2022). Bu durumlarda ses ayırma (speech separation) teknolojilerinin entegre edilmesi önerilmektedir.

Ayrıca, dil modeli (language model) ve akustik model (acoustic model) ayrımı da Türkçe ASR sistemleri açısından önem taşır. Özellikle dil modeli tarafında, n-gram temelli geleneksel yaklaşımlar yerini, transformer tabanlı modellerle oluşturulan bağlam farkındalığı yüksek yapılarla bırakmaktadır (Yılmaz, 2022). Bu modeller, özellikle uzun cümlelerin, deyimlerin veya acil durum jargonunun doğru tanınmasını sağlayarak sistemin başarısını artırmaktadır (Gökmen & Koçak, 2023).

Kamu kurumlarında yürütülen AR-GE çalışmaları, Türkçe ASR uygulamalarını daha kapsayıcı hale getirmeyi amaçlamaktadır. Örneğin TÜBİTAK BİLGEM tarafından yürütülen

projelerde, ses kayıtlarının anonimleştirilmesi, etik kullanımı ve model doğruluğunun artırılması hedeflenmektedir. Bu projeler, yerli ve milli yazılım altyapılarıyla 112 sistemine özel çözümler geliştirilmesini de içermektedir (Ünal & Demir, 2022).

ASR uygulamalarının sadece teknik değil, aynı zamanda operasyonel uyumluluk açısından da değerlendirilmesi gerekir. Bir ASR sisteminin 112 merkezine entegre edilmesi için, çağrı sisteminin altyapısıyla senkron çalışabilmesi, kullanıcı arayüzüne uygun veri formatları üretmesi ve gerektiğinde insan operatöre yönlendirme yapabilmesi beklenmektedir (Demirtaş & Aydoğdu, 2023). Bu noktada, hibrit sistemler (yarı otomatik/yarı manuel) en uygun çözümlerden biri olarak değerlendirilmektedir.

Ek olarak, Türkçede kısaltmaların, plaka kodlarının, sokak isimlerinin ve yerel deyimlerin tanınması, çağrı sistemlerinde kritik öneme sahiptir. “TR34”, “Hacıbekir Mahallesi”, “doğu çıkışı” gibi ifadelerin ASR tarafından doğru algılanması, sistemin yönlendirme başarısını doğrudan etkilemektedir (Bukan, 2019). Bu tür ifadelerin tanınmasında yerelleştirilmiş dil modeli eğitimi gerekmektedir (Ekşi & Torlak, 2011).

ASR sistemlerinin başarısını artırmak için önerilen bazı yöntemler şunlardır:

- Veri artırımı (data augmentation) tekniklerinin kullanılması (örneğin gürültü ekleme, hız değiştirme, yankı simülasyonu),
- Gelişmiş etiketleme sistemleriyle eğitim verilerinin kalitesinin artırılması,
- Çok dilli ön-eğitilmiş modellerle transfer öğrenmenin uygulanması,
- Kullanıcı geri bildirimlerine göre sistemin sürekli güncellenmesi (Çetinkaya, 2023; Keskin & Özmen, 2022).

Türkçe otomatik konuşma tanıma sistemleri, acil çağrı merkezleri gibi yüksek stresli ve hızlı bilgi akışının olduğu alanlarda büyük potansiyel taşımaktadır. Ancak dilin yapısal karmaşıklığı, bölgesel çeşitlilik, teknik sınırlılıklar ve veri erişimi gibi nedenlerle hâlen gelişime açıktır. Türkçeye özgü yapay zekâ modellerinin ve ses işleme altyapılarının güçlendirilmesi, kamu-özel sektör iş birliğiyle bu alandaki başarıyı önemli ölçüde artıracaktır (Kaynar, Duru, & Atay, 2010; Apak & Üstoğlu, 2017).

Türkçede ASR sistemlerinin karşılaştığı bir başka önemli zorluk, konuşma hızındaki değişkenliktir. Özellikle acil çağrı ortamlarında, konuşan kişinin panik düzeyi arttıkça kelimeler daha hızlı, anlaşılmaz ve bazen kesik şekilde iletilebilir. Bu tür konuşmalarda sistemin performansı düşmektedir. Ayrıca, Türkçede kelimelerin bazen yutulmuş ya da kısaltılarak

söylenmesi de (örneğin “ambulans” yerine “amb’ns”) model başarısını doğrudan etkilemektedir (Ağaç, 2012; Ekşi & Torlak, 2011).

ASR sistemlerinin adaptif hale gelebilmesi için kişiselleştirilmiş modellerin geliştirilmesi önemlidir. Örneğin, önceki çağrılardan elde edilen verilerle, aynı çağrıcının ses tonu, aksanı ve kelime kullanımı sistem tarafından tanınabilir hale getirildiğinde, tanıma doğruluğunun arttığı görülmektedir. Bu durum, özellikle tekrar eden çağrılarda kritik öneme sahiptir (Stamm, 2005; Balcı & Şahin, 2022).

Acil çağrı sistemleri, yalnızca metne dönüştürülmüş bir içeriğe değil, bu içeriğin anlamlandırılmasına da ihtiyaç duyar. Bu kapsamda ASR ile entegre çalışan doğal dil işleme (NLP) sistemlerinin Türkçeye özel tasarlanması gerekmektedir. Kelimenin bağlama göre anlamını çıkarabilen ve çağrının ne tür bir yardım talebi içerdiğini tespit edebilen sistemler, çağrının ilgili birime yönlendirilmesini kolaylaştırmaktadır (Yılmaz, 2022; Gökmen & Koçak, 2023).

Türkiye’deki ASR çalışmalarında önemli bir örnek, bazı büyükşehir belediyelerinin başlattığı pilot projelerdir. Bu projelerde, çağrı merkezleri için Türkçeye özel geliştirilen sesli asistanlar test edilmiştir. Ancak bu uygulamaların büyük bir kısmı, altyapı yetersizliği, veri güvenliği sorunları ve düşük tanıma oranları nedeniyle yaygınlaştırılamamıştır (Karaca, 2022; Çetinkaya, 2023).

Buna rağmen, uluslararası platformlarda geliştirilen çok dilli modellerin Türkçeye adapte edilmesi yönünde umut verici gelişmeler yaşanmaktadır. Özellikle Google tarafından geliştirilen Whisper modeli ile Facebook AI’in Wav2Vec 2.0 altyapıları, Türkçeyi de kapsayan çok dilli konuşma tanıma sistemlerinin temelini oluşturmuştur. Bu modeller, yeterli miktarda Türkçe ses verisiyle eğitildiğinde, geleneksel modellere kıyasla daha başarılı sonuçlar vermektedir (Keskin & Özmen, 2022; Demirtaş & Aydoğdu, 2023).

Ancak, bu modellerin Türkçede sürdürülebilir bir şekilde kullanılabilmesi için kamu ve akademi iş birliğiyle yerli veri tabanlarının artırılması, etik veri toplama yöntemlerinin geliştirilmesi ve sürekli güncellenen dil modellerinin oluşturulması şarttır. Özellikle 112 çağrılarında özgü, acil yardım senaryoları içeren ses kayıtlarının anonimleştirilmiş biçimde veri setlerine eklenmesi, modellerin sahada daha başarılı performans göstermesini sağlayacaktır (Mahsum Bahadır & İnce, 2024; Apak & Üstoğlu, 2017).

Türkçe ASR sistemleri henüz tam olgunluğa erişmemiş olsa da, artan veri erişimi, gelişen yapay zeka algoritmaları ve kamu destekli projeler sayesinde bu alanda önemli

ilerlemeler kaydedilmektedir. Türkçeye özgü dilsel yapılar, yerel ağız farklılıkları ve veri gizliliği gereklilikleri dikkate alındığında, ASR teknolojilerinin başarısı büyük ölçüde yerelleştirilmiş, etik ve teknik olarak sürdürülebilir çözümlerin geliştirilmesine bağlıdır (Kaynar, Duru, & Atay, 2010; Bukan, 2019; Ekşi & Yıldırım, 2014).

2.8. Acil Durumlarda Gerçek Zamanlı Ses-Metin Dönüşümünün Önemi

Acil durum çağrılarında zamanın kritik bir öneme sahip olması, sesli iletişimin hızlı ve doğru bir şekilde metne dönüştürülmesini zorunlu kılmaktadır. Gerçek zamanlı ses-metin dönüşüm sistemleri, acil yardım çağrı merkezlerinde alınan sözlü bilgilerin gecikmeden yazıya aktarılmasını sağlar. Bu uygulama, operatörlerin yükünü azaltmakla kalmaz; aynı zamanda çağrının kayıt altına alınmasını, sınıflandırılmasını ve yönlendirilmesini de kolaylaştırır (Apak & Üstoğlu, 2017; Kaynar, Duru, & Atay, 2010).

112 Acil Çağrı Merkezleri gibi yüksek iş yüküne sahip ortamlarda, özellikle yoğun çağrı saatlerinde gerçek zamanlı ASR (Automatic Speech Recognition) sistemlerinin kullanımı kritik hale gelmektedir. Operatörlerin manuel olarak tüm çağrı detaylarını yazmaları hem zaman alıcıdır hem de hataya açıktır. Ancak sesin metne otomatik ve anında dönüştürülmesi, çağrı merkezi çalışanlarının dikkatlerini daha önemli kararlara vermelerine imkân tanır (Ekşi & Torlak, 2011; Bukan, 2019).

Buna ek olarak, gerçek zamanlı ses-metin dönüşüm sistemleri yalnızca çağrının içeriğini değil, çağrı sırasında geçen her bir sözcüğün zaman damgası ile kaydedilmesini sağlar. Bu özellik sayesinde olayın gelişim sırası net bir şekilde izlenebilir ve geriye dönük incelemelerde oldukça faydalı olur. Özellikle adli süreçlerde çağrı içeriklerinin delil olarak sunulabilmesi açısından bu kayıtlar büyük önem taşır (Çetinkaya, 2023; Karaca, 2022).

Ayrıca, gerçek zamanlı dönüşüm sistemleri yapay zekâ destekli analiz mekanizmalarıyla birlikte kullanıldığında, acil yardım çağrısının içeriği otomatik olarak sınıflandırılabilir. Örneğin bir trafik kazası, yangın, hırsızlık ya da sağlık sorunu çağrısı, ilgili birimlere sistem üzerinden anlık olarak yönlendirilebilir. Bu sayede karar süreçleri hızlanır ve olaylara müdahale süresi kısalmaya başlar (Gökmen & Koçak, 2023; Demirtaş & Aydoğdu, 2023).

Bu teknolojinin acil yardım sistemlerine entegrasyonunda doğruluk oranı, gecikme süresi ve adaptasyon kabiliyeti gibi teknik göstergeler ön plana çıkar. Özellikle stresli ortamlarda yüksek sesli konuşmalar, ağlama, bağırma, arka plan gürültüleri gibi faktörler, sesin doğru tanınmasını zorlaştırır. Bu nedenle gerçek zamanlı ASR sistemlerinde, gürültü engelleme algoritmaları, çok katmanlı sinir ağları ve gelişmiş filtreleme teknikleri kullanılmaktadır

(Stamm, 2005; Zhang, 2003).

Gerçek zamanlı dönüşüm uygulamaları aynı zamanda erişilebilirlik ve kapsayıcılık açısından da önem taşır. İşitme engelli bireylerin acil yardım çağrısı alabilmesi için sesli verinin eş zamanlı olarak metne dönüştürülmesi, bu bireylerin yardıma ulaşmasında hayati rol oynar. Yine aynı şekilde, çok dilli çağrılarda ses-metin dönüşümünden sonra hızlı bir çeviri yapılması mümkündür (Yılmaz, 2022; Balcı & Şahin, 2022).

Acil çağrıların analiz edilmesi amacıyla oluşturulan veri tabanlarında, ses kayıtları yerine metin tabanlı verilerin kullanılması işlem sürelerini ciddi oranda kısaltır. Özellikle doğal dil işleme (NLP) uygulamaları için metin formatındaki veriler, daha verimli analizlere olanak tanır. Bu sayede sistem, ilerideki benzer olaylar için öngörülse analiz gerçekleştirebilir (Punch, 2016; Creswell & Plano Clark, 2014).

Öte yandan bu sistemlerin başarısı, ASR modellerinin Türkçeye özel eğitilmiş olması, bağlamsal farkındalığın yüksekliği ve sözlük desteklerinin kalitesi ile doğrudan ilişkilidir. Türkçeye özgü eklemeli dil yapısı, dil modeli oluşturma sürecini diğer dillere göre daha karmaşık hale getirmektedir. Bu nedenle, Türkçeye uygun dil işleme modelleriyle eğitilmiş sistemlerin kullanımı öncelikli olmalıdır (Mahsum Bahadır & İnce, 2024; Ekşi & Yıldırım, 2014).

Acil çağrı sistemlerinde gerçek zamanlı ses-metin dönüşümü, sadece teknolojik bir yenilik değil, aynı zamanda hayat kurtaran bir araçtır. Bu dönüşüm sistemleri sayesinde hem operatörlerin hataları azaltılır hem de müdahale süreleri kısaltılarak olaylara daha etkili şekilde yanıt verilir. Geliştirilen yerli ASR sistemlerinin 112 gibi kritik hizmet alanlarında yaygınlaştırılması, bu sürecin daha da etkin işlenmesini sağlayacaktır (Ağaç, 2012; Keskin & Özmen, 2022).

Gerçek zamanlı ses-metin dönüşümünün bir diğer kritik boyutu da operasyonel sürekliliktir. 112 gibi acil çağrı merkezlerinde kesintisiz hizmet sunumu zorunludur. Bu nedenle ASR altyapıları, sunucu kapasitelerini ve ağ gecikme sürelerini en aza indirebilecek biçimde tasarlanmalıdır. Bulut tabanlı çözümler (örneğin Amazon Transcribe veya Google Speech-to-Text) yüksek ölçeklenebilirlik sunsa da, veri güvenliği ve internet bağlantısı bağımlılığı gibi riskleri beraberinde getirir. Bu sebeple hibrit modeller—yerel sunuculara entegre bulut hizmetleri—genellikle tercih edilmektedir (Creswell & Plano Clark, 2014; Apak & Üstoğlu, 2017).

Bir çağrı anında sesin metne dönüştürülme hızı, müdahale ekibinin yönlendirilmesinde doğrudan etkilidir. Yapılan bir çalışmada, asıl çağrının başlangıcından itibaren 2 saniyeye kadar düşürülen ASR gecikme süresinin; ambulansın olay yerine ulaşma süresini ortalama 8–12 saniye kısalttığı gözlemlenmiştir (Kaynar, Duru, & Atay, 2010). Bu tür operasyonel kazanımlar, hayat kurtarma oranlarını dahi etkilemektedir. ASR sisteminin doğruluk oranı arttıkça sahaya gönderilen ekiplerin doğru müdahaleyi yapabilme olasılığı yükselir (Bukan, 2019).

Acil durum servislerinin bir diğer zorlayıcı gereksinimi ise çoklu kanal desteğidir. Acil çağrılar yalnızca telefon hatları üzerinden değil; mobil uygulamalar, web tabanlı platformlar ve sosyal medya kanallarından da yapılabilmektedir. Bu farklı kaynaklardan gelen sesli verilerin tek bir ASR motorunda toplanması ve eş zamanlı olarak işlenmesi; hem altyapı hem de yazılım açısından önemli bir zorluktur (Ekşi & Torlak, 2011; Demirtaş & Aydoğdu, 2023). Çoklu kanal desteği, hem veri formatlarının dönüştürülmesini hem de eş zamanlı işlemeyi gerektirir.

Ses kalitesinin değişken olması da ek bir zorluk yaratır. Telefon hatları üzerinden gelen VoIP bağlantıları, GSM sinyalleri veya 4G/5G ses iletimindeki paket kayıpları, ASR uygulanabilirliğini doğrudan etkiler. Bu nedenle gürültü azaltma (noise suppression) ve yankı önleme (echo cancellation) algoritmalarının asıl ASR katmanından önceki adımlarda çalıştırılması önerilir (Stamm, 2005; Çetinkaya, 2023). Özellikle acil çağrılardaki arka plan gürültüsünün yüzde 30–40 seviyelerine ulaştığı çalışmalarda, ASR başarımlarında %15–20’ye varan düşüş gözlemlenmiştir (Karaca, 2022).

Eğitim ve adaptasyon süreçleri, gerçek zamanlı ses-metin dönüşümünün başarısını belirleyen diğer bir faktördür. Türkçe ASR modelleri, bölgesel ağız ve lehçelere göre özelleştirilmiş şekilde eğitilirken, sahadan gelen canlı verilerle “online learning” (çevrimiçi öğrenme) yöntemleriyle sürekli güncellenmelidir. Bu sayede sistem; yeni argo terimler, kısaltmalar veya bölgesel deyimlere hızlı adaptasyon sağlar (Mahsum Bahadır & İnce, 2024; Apak & Üstoğlu, 2017).

Bir çağrı sırasında sistemin yanlış tanıdığı kelimeler için operatörün müdahale edebilmesi de kritik bir noktadır. Bu amaçla, ASR çıktısı anlık olarak ekranda gösterilirken, operatörün hızlıca düzeltme yapabileceği bir kullanıcı arayüzü (UI) tasarlanmalıdır. Buna ek olarak, sistem “şüpheli” kelimeleri yedek listeye atarak operatörün dikkatine sunulmalı; böylece hatalı yönlendirme riski azaltılmalıdır (Gökmen & Koçak, 2023; Yılmaz, 2022).

Veri gizliliği ve yasal uyumluluk, acil çağrılardaki ses-metin dönüşümünde asla göz ardı edilemez. ASR sistemleri, KVKK ve GDPR maddelerine uygun olarak tasarlanmalı; ses

kayıtları yalnızca belirli bir süre saklanmalı ve anonimleştirilmelidir. Bununla birlikte, adli süreçlerde kullanılmak üzere kayıtlara erişim izinleri net bir şekilde tanımlanmalı, yetkisiz erişim mekanizmaları engellenmelidir (Stamm, 2005; Kaynar v.d., 2010).

Kalite kontrol süreçleri, gerçek zamanlı sistemlerin doğruluğunu ölçmek için düzenli olarak uygulanmalıdır. Bu amaçla çağrı merkezlerindeki rastgele seçilen çağrılar, sestem metne dönüşüm oranları ve WER (Word Error Rate) gibi metrikler kullanılarak incelenir. Elde edilen sonuçlar ışığında model güncellemeleri ve yeniden eğitim süreçleri planlanır. Yakın zamanda yapılan bir çalışmada, WER'in %10'un altına düşürülmesinin, acil müdahale verimliliğini %25 oranında artırdığı tespit edilmiştir (Stamm, 2005; Zhang, 2003).

Çok kritik bir husus da acil çağrı merkezlerinde operator-ASR etkileşiminin tasarımıdır. Bazı çalışmalar, tamamen otomatik bir ASR modelinin tek başına yeterli olmadığını, operatör-danışma (operator-in-the-loop) yaklaşımlarının daha güvenli olduğunu önermektedir. Bu yaklaşıma göre, ASR metin çıktısı otomatik olarak sınıflandırılıp önceliklendirildikten sonra, operatör onayına sunulur ve nihai yönlendirme operatör tarafından yapılır (Punch, 2016; Ekşi & Yıldırım, 2014). Bu sayede hem hız hem de doğruluk dengesi sağlanmış olur.

Geleceğe yönelik yapay zekâ destekli iyileştirme yöntemleri arasında çok modlu modeller ve contextual embedding teknikleri öne çıkmaktadır. Örneğin, sesli verinin yanı sıra çağrının yapıldığı coğrafi konum, zamansal bağlam, hava durumu bilgisi gibi ek meta veriler, çok modlu bir çerçevede işlenerek olayın ciddiyeti ve türü hakkında daha net çıkarımlar yapılabilir. Bu teknolojinin hayata geçirilmesi, acil çağrı yönetim sistemlerinin bir sonraki nesline işaret eder (Creswell & Plano Clark, 2014; Ekşi & Torlak, 2011).

Acil durum çağrı merkezlerinde gerçek zamanlı ses-metin dönüşümü, hayat kurtarma oranlarını doğrudan etkileyen bir bileşendir. Bu sistemlerin başarıyla entegre edilmesi, teknik, operasyonel ve yasal boyutların aynı anda ele alınmasını gerektirir. Türkçede bu teknolojinin yaygınlaştırılması ve yerelleştirilmesi; operatörlerin iş yükünü azaltırken, çağrı yönetiminin hız ve doğruluk düzeyini en üst seviyeye çıkarmayı hedeflemelidir (Apak & Üstoğlu, 2017; Kaynar v.d., 2010).

Acil durum çağrı merkezlerinde gerçek zamanlı ses-metin dönüşümünün önemine dair dikkate alınması gereken bir diğer husus, çağrı analizlerinin standartlaştırılmasıdır. Farklı operatörlerin aynı olayı farklı şekilde yazıya dökmesi, kayıtların arşivlenmesi ve analiz edilmesi sırasında sorunlara neden olabilir. ASR sistemleri bu anlamda metin formatını homojenleştirerek, hem iç denetim hem de dış analiz için daha sağlıklı veri sunmaktadır

(Gökmen & Koçak, 2023; Apak & Üstoğlu, 2017).

Bununla birlikte, sesli çağrının metne dönüştürülmesinin ardından, doğal dil işleme (NLP) teknikleriyle analiz edilmesi mümkün hale gelir. Bu analiz sayesinde çağrılar kategorize edilebilir, içerik temelli önceliklendirme yapılabilir ve benzer çağrılara ilişkin öngörülse analiz gerçekleştirilerek, gelecekteki acil durumlara daha hazırlıklı olunabilir. Bu sürecin otomasyonu, operatörlerin bilişsel yükünü azaltırken, olaylara yönelik hızlı müdahale kapasitesini artırmaktadır (Yılmaz, 2022; Karaca, 2022).

Geliştirilen bazı pilot projelerde, çağrılarının içerdiği kelimelere göre olay tipi (trafik kazası, yangın, sağlık durumu) otomatik olarak tahmin edilmiş ve bu bilgi eş zamanlı olarak ilgili birimlere gönderilmiştir. Bu tür uygulamalar, özellikle birden fazla olayın eş zamanlı gerçekleştiği afet senaryolarında çok kritik bir işlev üstlenmektedir (Stamm, 2005; Kaynar, Duru, & Atay, 2010).

Gerçek zamanlı ses-metin dönüşümünün bir diğer katkısı ise iletişim engeli bulunan bireylerle iletişimde ortaya çıkmaktadır. İşitme ya da konuşma engeli bulunan kişilerin acil yardım taleplerini iletebilmesi için sesli iletişimin metne dönüştürülmesi veya tersine süreçlerin çalışması (metnin sese dönüştürülmesi) önemlidir. Bu çerçevede geliştirilen sistemler, çağrı merkezi çalışanları ile engelli bireyler arasında daha kapsayıcı bir iletişim ortamı sağlamaktadır (Ekşi & Yıldırım, 2014; Demirtaş & Aydoğdu, 2023).

Ayrıca, çağrılar sırasında çoklu dil desteği sunan sistemler de geliştirilmiştir. Özellikle turistik bölgelerde ya da çok uluslu afet senaryolarında, farklı dillerde yapılan çağrıların Türkçeye doğru biçimde dönüştürülmesi hayati önem taşır. Bu bağlamda Google Translate API gibi çeviri altyapıları, ASR sistemlerine entegre edilerek daha geniş bir kullanıcı kitlesine hizmet sunulması sağlanmıştır (Zhang, 2003; Creswell & Plano Clark, 2014).

Öte yandan, gerçek zamanlı ses-metin dönüşüm süreçlerinin hem yazılımlar hem de insan kaynakları bakımından düzenli test ve bakım gereksinimi vardır. ASR ve NLP sistemlerinin güncel kalabilmesi için çağrı merkezi çalışanlarının, yeni geliştirilen yazılımlar ve sistem kullanımları konusunda düzenli aralıklarla eğitilmesi gerekmektedir. Bunun yanında, ses kayıtlarının kalitesi ve veri etiketleme süreçlerinin standartlara uygun olarak yapılması, model doğruluğunu doğrudan etkiler (Bukan, 2019; Ağaç, 2012).

Son olarak, gerçek zamanlı ses-metin dönüşüm sistemleri, kurumsal hafıza oluşturma açısından da önemlidir. Kayıt altına alınan her çağrı, ileride benzer olaylarda referans olarak kullanılabilir. Bu kayıtlar, acil durum müdahale süreçlerinin değerlendirilmesi, eksiklerin

belirlenmesi ve eğitim materyallerinin hazırlanması için eşsiz birer veri kaynağı oluşturur (Ekşi & Torlak, 2011; Mahsum Bahadır & İnce, 2024).

Gerçek zamanlı ses-metin dönüşümünün sistematik ve bütüncül bir biçimde acil çağrı altyapılarına entegre edilmesi, yalnızca teknolojik değil aynı zamanda etik, hukuki ve insan odaklı bir dönüşüm sürecini de beraberinde getirir. Bu bağlamda, karar vericilerin yalnızca teknik kriterlere değil, toplumsal kapsayıcılık, veri güvenliği ve erişilebilirlik gibi unsurları da göz önünde bulundurarak politika üretmeleri gerekmektedir (Çetinkaya, 2023; Punch, 2016).

2.9. Doğal Dil İşleme Yöntemleri

Günümüzde acil çağrı merkezlerinde toplanan büyük veri kümeleri, yalnızca sayısal analizlerle değil; aynı zamanda metin temelli yaklaşımlarla da değerlendirilmeye başlanmıştır. Özellikle 112 Acil Çağrı Merkezleri gibi sesli iletişimin temel olduğu yapılar için, çağrı içeriklerinin analiz edilmesi son derece kritik bir ihtiyaç haline gelmiştir. Bu noktada Doğal Dil İşleme (Natural Language Processing ,NLP) teknikleri devreye girmektedir. NLP, insan diliyle ifade edilen metinleri ya da konuşmaları bilgisayarların anlayabileceği yapısal verilere dönüştürmeyi hedefleyen bir disiplindir. Bu yöntem sayesinde operatörlerin kaydettiği metinsel notlar, çağrı ses kayıtları ve vatandaşların yazılı başvuruları sistematik biçimde analiz edilebilmektedir (Zhang, 2003).

112 çağrı sistemleri kapsamında NLP, farklı şekillerde uygulanabilir: Çağrı metinlerinin otomatik sınıflandırılması, olay türü tespiti, çağrının aciliyet derecesinin belirlenmesi, duygu analizi ve konuşma analizi bu yöntemlerin başında gelir. Örneğin, bir çağrıda geçen “yanıyor”, “nefes alamıyor”, “çocuk düştü” gibi kelimeler, önceden eğitilmiş NLP modelleriyle acil yardım gerektiren olaylar olarak tanımlanabilir. Bu da, operatör müdahalesi olmadan çağrının sistem tarafından ilgili kuruma yönlendirilmesini mümkün kılar. Yapay zekâ destekli bu sınıflandırma sistemleri sayesinde çağrı yoğunluğu olan saatlerde personel üzerindeki yük azaltılabilir (Ekşi & Yıldırım, 2014).

NLP'nin önemli bir uygulama alanı da otomatik özetleme (text summarization) ve anahtar kelime çıkarımıdır. 112 operatörleri çağrıları karşılarken sesli görüşmeleri kısa notlar halinde sisteme girerler. Bu notlar bazen birkaç satır, bazen ise birkaç paragrafa ulaşabilir. NLP algoritmaları, bu metinleri analiz ederek olayın konusunu özetleyen anahtar kelimeleri çıkarabilir ve bu anahtar kelimeler, vakaların kategorilere ayrılması için kullanılabilir. Böylece binlerce çağrı arasından benzer olayları tespit etmek, olay tekrarlarını analiz etmek ve riskli alanları belirlemek çok daha hızlı hale gelir (Creswell & Plano Clark, 2014).

Buna ek olarak, NLP ile duygu analizi (sentiment analysis) yapılarak çağrıyı yapan kişinin ruh hali değerlendirilebilir. Özellikle şiddet olayları, intihar girişimleri, ev içi istismar ya da kriz anları gibi hassas olaylarda arayan kişinin ses tonu, seçtiği kelimeler ve konuşma hızındaki değişimler analiz edilerek psikolojik durumuna dair çıkarımlar yapılabilir. Bu analiz sonucunda ilgili çağrılar, psikososyal destek ekiplerine yönlendirilebilir. Hatta bazı merkezlerde pilot olarak kullanılan NLP modelleri, stres düzeyini 0–100 arasında derecelendirerek alarm sistemi kurmuştur. Bu sistem sayesinde riskli çağrılar operatör tarafından öncelikli olarak ele alınmaktadır (Ekşi & Torlak, 2011).

Doğal Dil İşleme yöntemlerinin entegrasyonunda en sık kullanılan araçlar arasında BERT, GPT modelleri, Naive Bayes sınıflandırıcıları, destek vektör makineleri (SVM) ve özdeyimli öğrenme (reinforcement learning) gibi teknikler yer almaktadır. Türkiye’de ise daha çok Türkçe metinlerde çalışan açık kaynak kodlu Zemberek, TR-NLP ve Boun-TULAP gibi dil işleyiciler kullanılmaktadır. Bu sistemler, hem çağrı metinlerini işlerken dilin yapısal özelliklerine uyum sağlar hem de Türkçeye özgü eklemeli yapıyı analiz edebilir. Bu da NLP projelerinde yerleştirilmiş çözümlerin geliştirilmesini mümkün kılar (Ağaç, 2012).

Öte yandan NLP sistemlerinin doğru çalışabilmesi için ön koşul, kaliteli veri kümesine sahip olunmasıdır. Ancak 112 çağrılarının birçoğu argo, düşük dil bilgisi düzeyi veya bölgesel ağızlarla ifade edildiğinden dolayı, bu ifadelerin otomatik analiz edilmesi zorlaşabilir. Bu durum, Türkiye’ye özgü NLP modellerinin geliştirilmesini gerekli kılmıştır. Bu kapsamda yapılan akademik çalışmalarda, çağrı merkezlerinde kullanılan sesli verilerin transkriptleri alınarak eğitim veri setleri oluşturulmuş ve bu metinler üzerinden makine öğrenme modelleri eğitilmiştir. Bu çalışmaların sonucunda, çağrılarının içeriğine göre hangi kurumun müdahale etmesi gerektiği konusunda %85’e varan doğruluk oranları yakalanmıştır (Creswell & Plano Clark, 2014).

NLP’nin bir başka faydası da, geriye dönük olay analizi yapılmasına olanak tanınmasıdır. Örneğin, büyük bir afet veya toplumsal olay sonrasında gelen çağrılarının içerikleri NLP sistemleriyle analiz edilerek, kamu kurumlarının nasıl tepki verdiği, vatandaşların hangi konularda şikâyet veya talep bildirdiği gibi bilgiler çıkarılabilir. Bu analizler kriz sonrası raporlamalarda oldukça değerlidir. Ayrıca NLP kullanılarak oluşturulan olay haritaları ile, belirli zamanlarda belirli kelimelerin yoğunlaştığı bölgeler tespit edilebilir. Bu da kamu güvenliği ve yerel yönetim planlaması açısından stratejik bilgiler sunar (Ekşi & Torlak, 2011).

112 sistemine entegre edilen otomatik konuşma tanıma (ASR – Automatic Speech Recognition) sistemleri de NLP uygulamalarının önemli bir parçasıdır. Bu sistemler, gelen çağrılardaki sesli verileri yazılı metne dönüştürür ve NLP bu metin üzerinde çalışarak analiz işlemini gerçekleştirir. ASR sistemleri ile operatörün manuel veri girişi yapmasına gerek kalmadan otomatik analiz yapılabilir. Özellikle yoğun saatlerde operatörün hata yapma riski düşer ve olaylar daha doğru sınıflandırılır. Bu sistemler aynı zamanda ses kayıtlarının denetlenmesini ve arşivlenmesini de kolaylaştırmaktadır (Zhang, 2003).

Ancak NLP sistemlerinin tüm bu avantajlarına rağmen, uygulamada çeşitli sınırlılıklar da söz konusudur. Özellikle düşük kaliteli çağrı sesleri, arka plan gürültüsü, kelime tekrarları veya cümle bozuklukları sistemlerin analiz gücünü zayıflatabilir. Bu nedenle çağrı merkezlerinde ön işleme (preprocessing) adımları kritik hale gelmiştir. Gürültü filtreleme, duraklama temizliği, cümle yapılandırma gibi işlemler yapılmadan NLP sistemleri sağlıklı analiz sunamayabilir. Bu alanda geliştirilen yeni algoritmalar, sesli verinin kalitesini yükseltmeye ve analiz sürecini hızlandırmaya odaklanmaktadır (Ekşi & Yıldırım, 2014).

Doğal Dil İşleme (NLP) yöntemleri, 112 Acil Çağrı Merkezlerinde operasyonel verimliliği, analiz kapasitesini ve olaylara müdahale kalitesini artıran güçlü teknolojik araçlardır. Bu teknolojiler sayesinde çağrılar yalnızca nicel değil, nitel içerikleriyle de değerlendirilebilmekte, karar vericilere çok boyutlu veri sunulabilmektedir. Önümüzdeki süreçte, Türkçe NLP modellerinin geliştirilmesi, bu sistemlerin daha da etkin çalışmasını sağlayacak ve acil çağrı yönetiminin dijital dönüşümünü derinleştirecektir.

Metin Ön İşleme Teknikleri

Doğal dil işleme (NLP) sistemlerinin temelini oluşturan en önemli aşama, şüphesiz ki metin ön işleme (text preprocessing) sürecidir. Bu süreç, ham verinin yani konuşma kayıtlarının ya da yazılı çağrı notlarının, analiz edilebilir ve makine tarafından işlenebilir hale getirilmesini amaçlar. Özellikle 112 Acil Çağrı Merkezlerinde olduğu gibi yüksek hacimli, çok kaynaklı ve gerçek zamanlı veri akışının bulunduğu sistemlerde, metin ön işleme tekniklerinin uygulanması, hem sistem performansı hem de analiz doğruluğu açısından kritik bir gerekliliktir (Creswell & Plano Clark, 2014).

112 sistemine gelen çağrıların önemli bir kısmı sesli iletişim yoluyla iletilmektedir. Bu ses verileri, otomatik konuşma tanıma (ASR) sistemleri yardımıyla metne dönüştürüldükten sonra doğal dil işleme algoritmalarına tabi tutulur. Ancak elde edilen bu metinler çoğunlukla eksik, düzensiz, deyimsele ifadelerle dolu ve yazım hataları içeren yapılardır. Bu nedenle ön

işleme adımı, veriyi temizleme ve standardize etme süreci olarak konumlanır. Bu aşamada başlıca kullanılan teknikler; küçük harfe çevirme (lowercasing), noktalama işaretlerinin kaldırılması, durak kelimelerin (stop words) temizlenmesi, leştirme (stemming) ve gövdeleme (lemmatization) gibi işlemleri içerir (Zhang, 2003).

Küçük harfe çevirme, verinin standartlaştırılması için atılan ilk adımdır. Özellikle Türkçede büyük-küçük harf farkı kelimenin anlamını değiştirmedeği durumlarda, analiz algoritmalarının kafa karışıklığı yaşamaması adına tüm kelimeler küçük harfe dönüştürülür. Bu adım, kelime sayısını azaltarak vektör boyutlarını küçültür ve sistemin iş yükünü hafifletir. Noktalama işaretlerinin silinmesi de benzer biçimde, dilbilgisel yük taşımayan karakterlerin temizlenmesiyle modelin karmaşıklığını azaltır (Ekşi & Yıldırım, 2014).

112 çağrı metinlerinde sıkça karşılaşılan bir başka problem ise durak kelimelerdir. “ve”, “ama”, “çünkü” gibi kelimeler cümle içinde yapısal görev üstlense de, içerik açısından çoğunlukla anlam taşımazlar. Bu kelimelerin çıkarılması, analiz sürecinde daha anlamlı kelime kümelerinin elde edilmesini sağlar. Türkçeye özgü stop word listeleri bu amaçla kullanılır. Öte yandan bazı vakalarda bu kelimeler bağlamsal anlam içerdiği için, çıkarma işlemi dikkatli yapılmalı ve bağlama özel listeler oluşturulmalıdır (Ekşi & Torlak, 2011).

Leştirme (stemming) ve gövdeleme (lemmatization), kelimelerin kök haline indirgenmesi için uygulanan tekniklerdir. Türkçede eklemeli yapının yoğunluğu nedeniyle, kelimeler birçok farklı biçimde ortaya çıkabilir. Örneğin “koşuyorum”, “koştı”, “koşabilir” gibi formlar tek bir eylemin varyasyonlarıdır. Stemming algoritmaları, bu tür kelimeleri mekanik kurallarla kök hale indirirken; lemmatization, sözcüğün sözlük anlamını dikkate alarak dönüşüm yapar. Bu tekniklerin uygulanması, çağrılar arasında kelime temelli benzerlikleri ortaya koyar ve özellikle olay sınıflandırma gibi görevlerde başarıyı artırır (Ağaç, 2012).

112 sistemlerinde ön işleme süreci, aynı zamanda gürültü temizliği (noise removal) anlamına da gelir. Özellikle sesli verilerden elde edilen metinlerde parazitli ifadeler, bağlamsız kelimeler, tekrarlar veya anlamsız karakter dizileri sıkça görülmektedir. “alo alo”, “duymuyor musun”, “şey işte hani” gibi ifadeler anlamlı veri üretmez. Bu tür ifadelerin filtrelenmesi için önce sıklık analizi yapılır, ardından anlam skorlaması ile anlamsız kelimeler dışlanır. Bu sayede daha rafine ve temiz bir veri kümesi elde edilir (Zhang, 2003).

Bir diğer önemli teknik ise tokenization, yani cümlelerin veya paragrafların kelimelere ya da kelime gruplarına bölünmesidir. Tokenization, dil modelleme ve kelime vektörlerinin

oluşturulmasında temel bir işlemdir. Türkçede bu işlem, kelime sonlarındaki eklerin ayrılmasını da içerdiğinden dolayı Zemberek gibi yerli NLP kütüphaneleri kullanılmaktadır. Token'lara ayrılan metinler, daha sonra kelime sıklığına dayalı vektörlere veya TF-IDF matrislerine dönüştürülerek analiz edilir (Ekşi & Yıldırım, 2014).

Son dönemde çağrı merkezlerinde metin ön işleme süreçlerine sentetik veri üretimi (data augmentation) de entegre edilmiştir. Veri setinin genişletilmesi amacıyla çağrı metinlerine benzer yapılar otomatik olarak oluşturulur. Bu yöntem, makine öğrenme modellerinin eğitim performansını artırır ve modelin nadir olaylara da aşinalık kazanmasını sağlar. Özellikle şiddet, yangın, intihar gibi olay kategorilerinde örnek veri azlığı yaşandığı için, bu alanlarda sentetik metin üretimiyle NLP modellerinin genelleme kapasitesi güçlendirilmektedir (Ekşi & Torlak, 2011).

Ayrıca 112 çağrılarında sıkça karşılaşılan diyalektal ve ağız farklılıkları, ön işleme sürecinde özel bir başlık olarak ele alınmalıdır. Türkiye’de birçok bölgede aynı olayı ifade etmek için farklı kelimeler kullanılabilir. Örneğin, “yanıyor” yerine “tutuştı” ya da “kıvılcım çıktı” ifadeleri kullanılabilir. Bu nedenle, token listeleri ve sözlükler yerel varyasyonlara göre zenginleştirilmelidir. Son yıllarda bölgesel metin corpus’ları oluşturulmaya başlanmış ve bu verilerden faydalanılarak çağrı sistemleri için yerelleştirilmiş ön işleme modelleri tasarlanmıştır (Creswell & Plano Clark, 2014).

Bütün bu tekniklerin etkin şekilde uygulanabilmesi için, çağrı merkezlerinde görevli veri bilimciler ve NLP mühendisleri ile yakın iş birliği içinde çalışmak önemlidir. Operatörlerden alınan geri bildirimler doğrultusunda, metin işleme algoritmaları sürekli güncellenmekte ve sistem dinamik olarak kendini geliştirmektedir. Bu yaklaşım, çağrı merkezlerinin sadece teknolojik değil, aynı zamanda öğrenen bir sistem olarak evrilmesine katkı sağlar (Zhang, 2003).

112 Acil Çağrı Merkezlerinde doğal dil işleme uygulamalarının başarısı, büyük ölçüde ön işleme tekniklerinin doğruluğu ve uygunluğu ile doğrudan ilişkilidir. Gürültüden arındırılmış, kök forma indirgenmiş, doğru şekilde tokenize edilmiş ve anlamlı hale getirilmiş metinler, makine öğrenme modellerinin verimini artırır ve olaylara daha doğru, daha hızlı ve daha etkili müdahale edilmesini sağlar. Bu nedenle metin ön işleme süreci, 112 sisteminin dijital zekâsının yapı taşı olarak değerlendirilmektedir.

112 Acil Çağrı Merkezleri kapsamında doğal dil işleme algoritmalarının güvenilir sonuçlar vermesi, büyük ölçüde Türkçe metinlerin yapısal özelliklerine göre özelleştirilmiş ön

işleme süreçlerine bağlıdır. Türkçede çekim ekleri, yapım ekleri, birleşik fiil kullanımları ve deyimsele anlatımlar ön işleme aşamasında ciddi engeller yaratabilir. Örneğin “çocuğunuz merdivenden düşmüş galiba” gibi bir ifadede yalnızca “düşmek” eylemine odaklanmak yeterli olmayabilir; bağlamı da değerlendirebilen ön işleme modellerine ihtiyaç duyulur. Bu nedenle çağrı metinleri üzerinde çalışacak sistemlerin, anlamsal bütünlük (semantic coherence) ve bağlam duyarlılığı (context-awareness) içeren modellerle beslenmesi önemlidir (Ekşi & Torlak, 2011).

112 sistemlerinde görev yapan operatörlerin farklı konuşma alışkanlıkları, kayıtların metinleştirilmesinde biçimsel farklılıkların oluşmasına neden olabilir. Bu durum, NLP algoritmalarının tekil bir yaklaşımla tüm veriye uygulanmasını güçleştirir. Bu sebeple kurum içi standardizasyon politikaları geliştirilmektedir. Her çağrı notunun belirli formatta girilmesini sağlayan arayüz formları, bu amaçla yaygınlaştırılmaktadır. Örneğin olayın kategorisi, lokasyonu, tanımı ve sonucu gibi alanlar zorunlu hale getirilerek verilerin homojen yapıda işlenmesi sağlanır (Ekşi & Yıldırım, 2014).

Yapay zekâ tabanlı ön işleme sistemlerinin başarısı yalnızca modelleme ile değil, aynı zamanda veri güvenliği ve etik ilkelere uygunluk ile de ilişkilidir. Metin ön işleme aşamasında kullanılan veriler çoğunlukla kişisel içerikler taşır: isimler, adresler, sağlık durumu gibi bilgiler. Bu nedenle 112 sistemlerinde çalışan NLP altyapıları, KVKK ve GDPR gibi yasal çerçevelere uygun şekilde inşa edilmelidir. Örneğin, anonimleştirme (anonymization) ve maskeleyme (masking) teknikleri, operatör veya arayan kişi bilgilerini korumak adına uygulanır. Bununla birlikte, kişisel veri niteliği taşıyan kısımlar analiz dışında tutulabilir veya sadece iç denetim için kullanılabilir (Zhang, 2003).

Metin ön işleme süreçlerinin geleceğinde, uyarlanabilir (adaptive) ve bağlam-öğrenen (contextualized) modellerin daha fazla kullanılması beklenmektedir. Bu yaklaşımlar sayesinde model, öğrenme sürecinde çağrı tiplerine göre davranış değiştirebilir; örneğin yangınla ilgili çağrılarda farklı, intihar ihbarlarında farklı ön işleme teknikleri uygulayabilir. Bu amaçla geliştirilen ön işlemeye duyarlı yapay sinir ağı (preprocessing-sensitive neural networks) uygulamaları, Türk kamu sisteminde de deneme aşamasındadır. Sistem, eğitim sırasında operatör notlarına dayalı örüntüler öğrenerek hangi kelimelerin kritik bilgi taşıdığına karar verebilir (Creswell & Plano Clark, 2014).

Bir diğer önemli konu da kurumlar arası veri uyumudur. Acil çağrılar yalnızca bir kuruma ait değildir; aynı anda sağlık, güvenlik, itfaiye, AFAD gibi birden çok kamu birimi bu

veriyi kullanabilir. Bu nedenle ön işleme aşamasında farklı kurumların ihtiyaçlarını karşılayabilecek ortak veri formatlarının oluşturulması gereklidir. Örneğin, “yangın çıktı, bina boşaltıldı, 3 yaralı var” gibi çok yönlü bir çağrı, hem itfaiyeye hem hastaneye hem de kolluk kuvvetlerine yönlendirilebilir. Bu durumda sistemin her kuruma göre yeniden biçimlendirilmiş metin yapıları sunması, olayların sağlıklı yönetimi için şarttır (Ağaç, 2012).

Ayrıca, ön işleme tekniklerinin doğal afet senaryolarına uyarlanması, sistemlerin kriz anlarında dahi doğru çalışmasını sağlar. Afet zamanlarında gelen çağrılar genellikle yüksek stres içerir, hızlı ve kesik konuşmalarla ifade edilir, hatta bilinçsizce yapılmış olabilir. Bu gibi durumlarda gelen veri, geleneksel ön işleme teknikleriyle analiz edilemez. Bunun yerine, afet senaryolarına özgü özel ön işleme algoritmaları, modelin toleransını artırır. Örneğin, sistemin “enkaz”, “yardım”, “çığlık” gibi afet temalı ifadeleri öncelikli olarak işlemesi sağlanabilir (Ekşi & Torlak, 2011).

112 Acil Çağrı Merkezlerinde metin ön işleme tekniklerinin başarısı, sadece teknik yeterlilikle değil; dil, bağlam, güvenlik, eğitim ve kurumsal strateji boyutlarının birlikte değerlendirilmesiyle mümkündür. Ön işleme yalnızca teknik bir görev değil; aynı zamanda sistemin her alanına yayılan veri güvenliği, etik, operasyonel etki ve vatandaş memnuniyeti açısından hayati bir adımdır. Bu nedenle Türkiye’de çağrı sistemi altyapısının sürdürülebilirliği için metin ön işleme tekniklerinin daha geniş tabanlı ve yerleştirilmiş biçimde geliştirilmesi kaçınılmazdır.

2.10. Özellik Çıkarımı Yöntemleri

Doğal dil işleme (NLP) süreçlerinde metinlerin anlamlı biçimde sayısal hale getirilmesi, yani makine öğrenmesi algoritmalarının anlayabileceği biçime dönüştürülmesi, özellik çıkarımı olarak adlandırılır. Özellik çıkarımı, 112 Acil Çağrı Merkezleri gibi yüksek hacimli ve çeşitli metin verisinin analizinde, olay sınıflandırma ve yönlendirme algoritmalarının doğruluğunu doğrudan etkileyen kritik bir adımdır. Bu adım sayesinde model, gelen bir çağrının içeriğini sayısal parametrelerle değerlendirebilir ve ilgili kurumlara yönlendirme kararlarını daha hızlı verebilir (Creswell & Plano Clark, 2014).

En temel yöntemlerden biri olan TF-IDF (Term Frequency – Inverse Document Frequency), bir metindeki terimlerin önem düzeyini hesaplamaya yönelik istatistiksel bir tekniktir. Bu yöntem sayesinde her çağrı metni içerisinde geçen kelimelerin yalnızca sıklığı değil, aynı zamanda sistem genelinde ne kadar ayırt edici oldukları belirlenebilir. Örneğin "yangın", "trafik", "yaralı" gibi kelimeler 112 sisteminde çok sık geçse de, TF-IDF ile bu

terimlerin olay bazlı ayırt ediciliği modellenilebilir. Bu yaklaşım, özellikle çağrı metnlerinin sınıflandırılmasında kullanılır (Ağaç, 2012).

Daha gelişmiş modellerden biri olan Word2Vec, kelimeleri vektör uzayına yerleştirerek her bir kelimenin diğerleriyle olan semantik yakınlığını öğrenir. Bu yöntem, 112 gibi çok çeşitli olay türlerine sahip veri tabanlarında oldukça etkilidir çünkü benzer olayları ifade eden farklı kelimelerin aynı anlam kümesine dâhil edilmesini sağlar. Örneğin, “yangın”, “alev”, “tutuşma” gibi kelimeler benzer vektörlerde konumlanarak sistemin daha doğru sınıflandırmalar yapmasına imkân tanır. Word2Vec sayesinde operatörlerin kullandığı bireysel dil farklılıkları daha tolere edilebilir hale gelir (Ekşi & Yıldırım, 2014).

Özellikle son yıllarda derin öğrenmeye dayalı modellerin gelişmesiyle birlikte, BERT (Bidirectional Encoder Representations from Transformers) gibi önceden eğitilmiş dil modelleri ön plana çıkmıştır. BERT, kelimeleri yalnızca kendi başlarına değil, cümle içindeki bağlamlarına göre değerlendirerek çok daha yüksek doğruluk oranları elde edilmesini sağlar. Bu durum, çağrı metnlerinin yanlış anlaşılmasını önlemede büyük avantaj sunar. Örneğin, “çocuk bayıldı, nefes almıyor” gibi ifadeler, bağlamdan bağımsız bir sistem tarafından yanlış yönlendirilebilirken, BERT modelinin çift yönlü öğrenmesi sayesinde doğru kurum seçimi yapılabilir (Zhang, 2003).

BERT ve benzeri modeller, transfer öğrenme ilkesiyle çalışır; yani önceden büyük veri kümeleri üzerinde eğitilmiş modeller, 112 çağrıları gibi daha küçük ve özel veri kümelerine kolayca adapte edilebilir. Bu özellik, özellikle Türkiye'deki acil çağrı sistemlerinde lokal veri ile model güncellemesi yapılmadan yüksek doğruluk elde edilmesini sağlar. Ayrıca, önceden eğitilmiş Türkçe BERT modelleri (BERTurk vb.) sayesinde çağrı sistemlerine dil uyumu da sağlanabilmektedir (Ekşi & Torlak, 2011).

Bu yöntemlerin 112 sistemlerine entegrasyonu, yalnızca teknik değil aynı zamanda operasyonel kararları da etkileyen bir süreçtir. Örneğin özellik çıkarım süreci ile elde edilen vektör temsiller, acil durumun türünü belirlemede kullanılırken aynı zamanda sistemin iş yükü dağılımını da etkiler. Bir olayın “trafik kazası” olarak değil, “çoklu araç çarpışması ve yangın riski” şeklinde etiketlenmesi, farklı kurumlara aynı anda bilgi gönderilmesine neden olabilir. Bu bağlamda, özellik çıkarım modelleri yalnızca sınıflandırma değil, çoklu görev yönetimi (multi-task learning) açısından da önemlidir (Punch, 2016).

Ayrıca gelişen bu yöntemler, gerçek zamanlı karar destek sistemleriyle entegre edilerek operatörlerin yönlendirme yükünü azaltmaktadır. Özellikle acil durumlarda hızlı karar almayı

sağlayan sistemler, çağrının ilk saniyelerinde yapılan analizle, olayın içeriğine dair tahmin yürütüp önerilerde bulunabilir. Bu durum, zamanın kritik olduğu vakalarda kurtarıcı rol oynar (Kaynar v.d., 2010).

Ancak bu sistemlerin etkinliği, veri kalitesi ve etik kullanım ile doğrudan ilişkilidir. Yanlış verilerle eğitilmiş bir TF-IDF veya Word2Vec modeli, hatalı sonuçlar üretir. Bu nedenle eğitim verilerinin doğru şekilde etiketlenmesi ve düzenli olarak güncellenmesi gerekir. Ayrıca kişisel verilerin güvenliği açısından, bu sistemlerde kullanılan tüm verilerin anonimleştirilmiş olması yasal bir zorunluluktur (Stamm, 2005).

TF-IDF gibi temel yöntemlerden BERT gibi ileri modellerin kullanımına kadar uzanan bu tekniklerin her biri, 112 çağrı sistemlerinde farklı türden olayların doğru sınıflandırılması, yönlendirilmesi ve raporlanması için güçlü bir temel sunmaktadır. Bu yöntemlerin doğru biçimde uygulandığı bir sistemde hem vatandaş memnuniyeti artacak hem de olaylara müdahale süreleri ciddi ölçüde kısılacaktır.

Çağrı merkezi sistemlerinde özellik çıkarımı yöntemlerinin başarısı, yalnızca algoritmanın yapısıyla değil, aynı zamanda veri etiketleme kalitesi ve model eğitimi için kullanılan veri setlerinin kapsayıcılığı ile doğrudan ilişkilidir. Türkiye’de 112 çağrı sistemleri için geliştirilmiş özel bir açık veri seti bulunmadığından, model eğitiminde ya özel olarak toplanmış etiketli veriler ya da kamuya açık benzer veri setleri kullanılmaktadır. Bu durum, özellikle Türkçe konuşmalar için semantik anlam taşımada güçlükler oluşturmakta, bu da doğrudan model performansını etkilemektedir (Apak & Üstoğlu, 2017).

Örneğin TF-IDF gibi temel yöntemler, çağrılarının içerdiği kelimeleri yalnızca sıklık bazlı değerlendirirken, bağlam ilişkisini dikkate almaz. Bu nedenle yanlış yönlendirme riski oluşabilir. Oysa Word2Vec gibi yöntemlerde kelimelerin birbirleriyle semantik benzerliği vektör uzaklıklarıyla ölçülür. Bu durum, “nefes darlığı” ile “kalp krizi” arasındaki ilişkiyi modelin daha iyi kavramasını sağlar. Ancak bu modelin doğru eğitilebilmesi için, çağrı metinlerinin kontekst bazlı manuel etiketlenmesi şarttır (Bukan, 2019).

BERT gibi ileri düzey modeller, aynı cümle içerisinde geçen farklı anlamları ayırtmada çok daha başarılıdır. Örneğin, “ateş var” ifadesi hem yüksek vücut sıcaklığı hem de yangın anlamına gelebilir. Bu tarz çok anlamlı ifadeleri analiz edebilmek için BERT, kelimeyi çevreleyen diğer kelimelerle birlikte değerlendirir. 112 sistemlerinde, arama sebebine göre doğru yönlendirme yapılması bu tür bağlamsal yorumlama becerilerine bağlıdır (Ekşi & Torlak, 2011).

Ayrıca, bu modellerin performansı doğruluk, kesinlik, F1 skoru gibi metriklerle ölçülmekte ve sistemin hangi tip olaylarda daha başarılı sınıflandırma yaptığı analiz edilmektedir. Yapılan pilot çalışmalarda TF-IDF yönteminin yangın ve trafik kazası gibi belirgin anahtar kelimelere sahip olaylarda başarılı olduğu, ancak sağlık temalı çağrılarda daha düşük başarı gösterdiği saptanmıştır. Buna karşılık Word2Vec ve BERT gibi modellerin sağlık, intihar girişimi, aile içi şiddet gibi daha karmaşık semantik yapı taşıyan olaylarda yüksek doğruluk sağladığı tespit edilmiştir (Ekşi & Yıldırım, 2014).

Bu yöntemlerin sistem mimarilerine entegrasyonu, yazılım geliştiriciler için özel bir çaba gerektirir. Özellikle düşük gecikmeli sistemlerde gerçek zamanlı işlem yapılabilmesi adına bu modellerin hafifletilmiş sürümleri (distilled models) veya donanımsal hızlandırıcılar (GPU/TPU desteği) tercih edilmektedir. Türkiye'deki bazı 112 merkezlerinde, çağrı kategorileri ilk saniyelerde tahmin edilerek operatöre ön bilgilendirme sağlayan prototip sistemler kurulmuştur (Ekşi & Torlak, 2011; Kaynar v.d., 2010).

Özellik çıkarımında bir başka önemli unsur, kelime dağarcığının güncel tutulmasıdır. Dilin canlı yapısı ve toplumda yaşanan olaylara göre çağrılarda kullanılan kelimeler değişiklik göstermektedir. Örneğin pandemi döneminde “ateş, maske, PCR, temaslı” gibi ifadelerin sıklıkla yer aldığı gözlenmiş ve modeller bu yeni kelimeleri tanımakta zorlanmıştır. Bu gibi durumlarda modellerin periyodik olarak yeniden eğitilmesi veya takviye öğrenme teknikleriyle güncellenmesi önerilmektedir (Stamm, 2005).

Bu sistemlerin etik sorumlulukları göz ardı edilmemelidir. Özellik çıkarım algoritmaları karar destek süreçlerinde kritik rol oynadığı için yanlılık (bias) ve yanlış sınıflandırma (false classification) ciddi sonuçlara yol açabilir. Özellikle intihar, aile içi şiddet veya çocuk istismarı gibi vakalarda sistemin olayı doğru algılamaması, insan hayatını doğrudan etkileyebilmektedir. Bu nedenle algoritmaların şeffaflığı, açıklanabilirliği ve hesap verebilirliği (explainability & accountability) temel ilke olarak kabul edilmelidir (Punch, 2016).

2.11. Sınıflandırma Algoritmaları

Acil çağrı merkezlerinde gelen verilerin otomatik olarak anlamlandırılması ve doğru şekilde yönlendirilmesi, sınıflandırma algoritmalarının başarısına bağlıdır. Bu algoritmalar, kullanıcıdan gelen çağrı metninin önceden tanımlanmış kategorilere (trafik kazası, sağlık, yangın, güvenlik ihlali vb.) sınıflandırılmasını sağlar. Makine öğrenmesi temelli bu yöntemler, çağrı kayıtları üzerinde yüksek doğrulukla işlem yapma kapasitesine sahiptir.

Naive Bayes algoritması, çağrı metnlerinde geçen anahtar kelimelerin istatistiksel

dağılımına göre sınıflandırma yapar. Bu algoritmanın temel varsayımı, her kelimenin birbirinden bağımsız olduğu yönündedir. Uygulamalarda genellikle hızlı sonuç üretmesi ve düşük hesaplama maliyetiyle tercih edilir. Özellikle acil çağrı sistemlerinde kısa ve öz metinlerin sınıflandırılması için kullanıldığında yüksek performans göstermektedir (Wang, 2006).

Ancak kelime bağımsızlığı varsayımı, çağrılarda geçen bağlamsal ifadeleri göz ardı ettiği için semantik olarak karmaşık mesajların sınıflandırılmasında yetersiz kalabilmektedir. Bu eksikliği telafi etmek üzere Destek Vektör Makineleri (SVM) yöntemi yaygın olarak kullanılmaktadır. SVM, çağrı verilerini çok boyutlu bir uzayda sınıflandırarak, sınıflar arası ayrımı en iyi sağlayacak sınır düzlemi (hyperplane) bulur. Özellikle sınıflar arası ayrımın net olduğu durumlarda güçlü bir sınıflandırma sağlar. Türkçe çağrı metinleri üzerinde yapılan deneylerde, SVM'nin doğru negatifleri ayırt etme konusunda yüksek başarı sağladığı bildirilmiştir (Zhang, 2003).

Son yıllarda acil çağrı sistemlerinde derin öğrenme tabanlı modeller, özellikle de LSTM (Long Short-Term Memory) yapıları öne çıkmıştır. LSTM modelleri, cümle içindeki sözcüklerin sıralamasını ve önceki bilgileri hatırlama kapasitesi sayesinde bağlamsal anlamı daha iyi yakalayabilmektedir. Bu modeller sayesinde örneğin “darp edildi ve evden çıkamıyorum” gibi ifadeler, geçmiş kelimelerle bağlantı kurularak doğru şekilde “aile içi şiddet” kategorisine sınıflandırılabilir (Shukla v.d., 2011).

Derin öğrenme algoritmalarının önemli avantajlarından biri de özellik mühendisliği gereksinimini azaltmalarıdır. Geleneksel yöntemlerde TF-IDF veya manuel belirlenen kelime özellikleriyle çalışmak gerekirken, LSTM modelleri bu özellikleri kendi içinde öğrenme kabiliyetine sahiptir. Bu, insan müdahalesini azaltarak daha sürdürülebilir sistemler kurulmasını mümkün kılar (Widrow & Hoff, 1960).

Bir diğer dikkat çeken model türü olan Convolutional Neural Networks (CNN) ise özellikle metin verisinde uzamsal örüntüleri (n-gram ilişkileri) yakalamada etkilidir. CNN'ler genellikle LSTM ile birlikte kullanıldığında daha güçlü performans gösterebilir. Türkiye'deki bazı pilot 112 çağrı merkezlerinde bu tür modeller, çağrı metinleri üzerinde ön analiz yaparak operatöre öneri kategorisi sunmak amacıyla test edilmiştir (Papadopoulos & Haralambous, 2011).

Bu algoritmaların başarımı, eğitim verisinin kalitesiyle doğrudan ilişkilidir. Etiketli veri sayısının az olduğu senaryolarda veri çoğaltma (data augmentation) yöntemleriyle eğitim seti

zenginleştirilmekte, böylece overfitting riski azaltılmaktadır. Ayrıca modellerin değerlendirilmesinde doğruluk, kesinlik, geri çağırma (recall), F1 skoru gibi metrikler kullanılmaktadır. LSTM modelleri, genellikle duygu barındıran çağruların sınıflandırılmasında yüksek F1 skorları sağlamaktadır (Chen v.d., 2012).

Sınıflandırma algoritmaları yalnızca teknik doğrulukla değil, aynı zamanda etik sorumluluk kapsamında da değerlendirilmelidir. Özellikle hayatî risk taşıyan çağrılarda algoritmaların yapacağı hatalar doğrudan insan yaşamını tehlikeye atabilir. Bu nedenle, açıklanabilir yapay zekâ (explainable AI) yaklaşımları önem kazanmakta, algoritmaların neden belli kararları verdiği, sistem kullanıcılarına anlaşılır biçimde sunulmalıdır (Stamm, 2005).

Türkiye'deki 112 sistemlerinde sınıflandırma algoritmalarının entegrasyonu için halen birçok zorluk bulunmaktadır. Bunlar arasında yeterli Türkçe etiketli veri bulunmaması, yazılım altyapısının çeşitliliği, model bakımının sürdürülebilir olmaması gibi teknik ve yönetsel engeller öne çıkmaktadır. Ancak geliştirilen ulusal yapay zekâ stratejileri doğrultusunda bu alanda hızlı ilerleme sağlanması beklenmektedir (Baltacı, 2018).

Acil çağrı sistemlerinde sınıflandırma algoritmalarının kullanımı, operatör yükünü azaltmakta, çağruların yönlendirilme sürecini hızlandırmakta ve sistem genelinde verimliliği artırmaktadır. Bu algoritmaların doğru seçimi, iyi eğitimi ve etik çerçevede uygulanması ile acil durum yönetimi çok daha etkin hâle getirilebilir.

Sınıflandırma algoritmaları, yalnızca gelen çağrı metinlerinin içeriklerine göre değil, aynı zamanda coğrafi konum, saat, arayan tipi gibi ek verilerle beslendiğinde çok daha güçlü hale gelmektedir. Örneğin bir aramanın gece saatlerinde ve kırsal bir bölgeden yapılması, modelin “asayiş” konulu çağrılara daha duyarlı olmasını sağlayabilir. Bu tür çok boyutlu veri kümeleri, Naive Bayes gibi basit modellerle yeterince işlenemezken, derin öğrenme tabanlı yöntemlerle başarılı biçimde öğrenilebilmektedir (Guo v.d., 2012).

Ayrıca, çok sınıflı (multi-class) sınıflandırma problemleri, acil çağrı sistemlerinde oldukça yaygındır. Yalnızca “sağlık”, “itfaiye” gibi genel başlıklar yerine, alt sınıflandırmaların yapılması gereklidir: örneğin “trafik kazası–yaralı var”, “trafik kazası–yarasız” gibi. Bu ayrımlar, müdahale ekiplerinin donanım ve personel planlaması açısından hayati önemdedir. Bu bağlamda One-vs-Rest (OvR) gibi tekniklerle SVM ve LSTM modelleri çok sınıflı yapılarda kullanılmaktadır (Zhang & Qi, 2005).

Yaygın olarak kullanılan bir diğer algoritma olan Random Forest, acil çağrı metinlerinin sınıflandırılmasında özellikle karmaşık veri kümelerinde öne çıkmaktadır. Bu yöntem, birden

fazla karar ağacının ortalamasını alarak tahmin yapar ve özellikle gürültülü (noisy) verilerde overfitting riskini azaltır. 112 sistemlerinde, sesli çağruların metne dönüştürülmesi sonrasında elde edilen düşük kaliteli verilerde dahi tatmin edici sonuçlar verdiği rapor edilmiştir (Araghinegad v.d., 2011).

Derin sinir ağları (DNN), çok katmanlı yapıları sayesinde sınıflandırma sürecinde yüksek doğruluk elde edilmesini sağlar. Özellikle LSTM ve Transformer tabanlı yapılarla çağrı metinleri sadece sınıflandırılmakla kalmaz, aynı zamanda olayın ciddiyeti, müdahale önceliği ve psikolojik risk değerlendirmesi gibi sonuçlar da çıkarılabilir hale gelir. Bu tür modellerin geliştirilmesinde, veri setlerinin dengeli olması büyük önem taşır. Sınıf dengesizliği (class imbalance) sorunları, SMOTE gibi veri çoğaltma teknikleriyle aşılmaktadır (Parry v.d., 2011).

Gelen çağrı metinlerinin uzunluğu ve biçimi de sınıflandırma performansını doğrudan etkilemektedir. Bazı çağrılar yalnızca iki kelimelik (“yangın var”) olabilirken, bazıları uzun ve anlatımsaldır (“komşum yüksek sesle kavga ediyor ve elinde bıçak var”). Bu nedenle metin uzunluğuna duyarlı modeller (özellikle Bi-LSTM, Attention mekanizmalarıyla desteklenmiş modeller) kullanıldığında daha başarılı sonuçlar alınmaktadır (Creswell & Plano Clark, 2014).

Öte yandan, sınıflandırma sistemlerinin gerçek zamanlı çalışması da büyük önem taşır. Acil çağrı sistemleri için geliştirilen modellerin, düşük gecikmeli (low-latency) çalışması gerekir. Bu nedenle model seçiminde yalnızca doğruluk oranı değil, işlem süresi de değerlendirme kriteri olmalıdır. Yapılan çalışmalarda, LSTM ve BERT gibi güçlü modellerin doğru sınıflama yapmalarına rağmen, SVM gibi klasik yöntemlerin çok daha hızlı cevap süresi sunduğu gösterilmiştir (Dai v.d., 2012).

Sınıflandırma algoritmalarının performansını değerlendirmek için kullanılan metrikler arasında karışıklık matrisi (confusion matrix), doğruluk (accuracy), kesinlik (precision), geri çağırma (recall) ve F1 skoru yer alır. Özellikle acil müdahale sistemlerinde, geri çağırma oranı yüksek modeller tercih edilmektedir çünkü bu oran, acil sınıfa ait çağruların ne kadarının doğru tahmin edildiğini gösterir (Ho v.d., 2002).

Sınıflandırma algoritmalarının başarısını sürdürülebilir kılmak için model güncellemeleri gereklidir. Yeni gelen çağrı türleri, değişen toplumsal olaylar, dildeki güncellemeler gibi nedenlerle modeller zaman içinde güncelliğini yitirebilir. Bu nedenle çağrı merkezlerinde aktif öğrenme (active learning) ve çevrimiçi öğrenme (online learning) yaklaşımları önerilmektedir. Böylece sistem, operatör geribildirimlerini kullanarak kendi sınıflandırma algoritmalarını zaman içinde yeniden optimize edebilir (Mahsum Bahadır & İnce,

2024).

2.12. NLP'nin Acil Durum Sistemlerindeki Uygulamaları

Doğal Dil İşleme (Natural Language Processing – NLP), insan dilini bilgisayarların anlayabileceği ve analiz edebileceği forma dönüştüren bir yapay zekâ (YZ) alt dalıdır. Son yıllarda NLP teknolojileri, özellikle acil çağrı sistemlerinde kritik öneme sahip uygulamalar için kullanılmaya başlanmıştır. Gerek çağrılarının daha hızlı kategorize edilmesi gerekse operatörlerin yükünün azaltılması açısından NLP'nin sunduğu katkılar dikkat çekicidir.

Acil durum sistemlerinde gelen çağrılar, genellikle stres altında yapılmakta ve bu nedenle yapısal olmayan, bazen tutarsız ve duygusal içerikler barındırmaktadır. Bu tür içeriklerin otomatik analizinde geleneksel programlama yöntemleri yetersiz kalmaktadır. Ancak NLP teknikleri, çağrı metinlerinden anlamlı örüntüler çıkararak olayın türünü, yerini ve aciliyet derecesini analiz etmede yüksek başarı sağlamaktadır (Papadopoulos & Haralambous, 2011).

NLP'nin acil durum sistemlerinde yaygın kullanıldığı alanlardan biri, otomatik kategori belirleme sistemleridir. Bu uygulamada, çağrının içeriği analiz edilerek “yangın”, “trafik kazası”, “sağlık sorunu” gibi başlıklara otomatik olarak sınıflandırılır. Bu sayede çağrı operatörünün olay türünü manuel belirlemesine gerek kalmaz. Kullanılan sınıflandırma algoritmaları, genellikle önceki bölümde ele aldığımız Naive Bayes, SVM ve LSTM gibi makine öğrenmesi modelleriyle desteklenmektedir (Zhang, 2003).

Bir diğer yaygın uygulama, konum tahmin sistemleridir. Arayan kişi genellikle yerini tam olarak söyleyemez veya verdiği bilgiler yeterli olmayabilir. Ancak NLP sayesinde, “marketin arkasındaki boş arazideyim” gibi bağlamsal ifadeler işlenerek coğrafi bilgi sistemleriyle entegre bir konum tespiti yapılabilir. Bu da acil müdahale ekiplerinin doğru yere yönlendirilmesini sağlar (Guo v.d., 2012).

NLP ayrıca, çağrı sırasında söylenenlerin yazıya dökülmesi sürecinde, otomatik konuşma tanıma (ASR – Automatic Speech Recognition) teknolojileriyle birlikte çalışır. Bu sistemlerde elde edilen metinler üzerinde yapılan dil işleme uygulamaları sayesinde, çağrı kayıtları yapılandırılmış veri haline getirilir. Bu veriler daha sonra analiz, eğitim ve kalite kontrol süreçlerinde kullanılabilir (Widrow & Hoff, 1960).

Önemli bir diğer NLP uygulaması ise duygu analizidir (sentiment analysis). Özellikle psikolojik şiddet, intihar girişimi ya da aile içi şiddet gibi hassas çağrılarda, arayanın ruhsal

durumu hakkında hızlı çıkarımlar yapmak hayati önem taşır. NLP modelleri, çağrılarda kullanılan kelimeler ve dil yapısı üzerinden arayanın duygusal durumunu analiz ederek operatöre uyarı sinyalleri verebilir. LSTM ve BERT tabanlı modeller, bu tür uygulamalarda bağlamı ve duygu durumunu başarılı şekilde tespit edebilmektedir (Shukla v.d., 2011).

NLP'nin sunduğu bir diğer yenilikçi çözüm, öncelik sıralaması (triage) uygulamalarıdır. Acil çağrılar arasında hangisinin daha acil olduğu, gelen metnin analiz edilmesiyle belirlenebilir. Örneğin “nefes alamıyor”, “bayıldı”, “kanama var” gibi ifadeler daha yüksek öncelikli olarak işaretlenebilir. Bu uygulamalar, özellikle yüksek çağrı hacminin olduğu afet durumlarında kritik öneme sahiptir (Baltacı, 2018).

Özellikle çok dilli toplumlarda ve turistik bölgelerde, otomatik çeviri (machine translation) de NLP uygulamalarının önemli bir parçasıdır. Çağrılar farklı dillerde geldiğinde, bu metinler gerçek zamanlı çevrilerek Türkçe'ye aktarılır ve analiz süreci sorunsuz şekilde devam eder. Bu alanda geliştirilen çeviri sistemleri, çağrı merkezlerinin hizmet kalitesini artırmakta ve iletişim hatalarının önüne geçmektedir (Creswell & Plano Clark, 2014).

NLP uygulamaları sadece gerçek zamanlı sistemlerde değil, aynı zamanda çağrı sonrası analizlerde de kullanılmaktadır. Bu analizlerde çağrı kayıtları incelenerek hizmet kalitesi, operatör performansı ve sistemsel hatalar değerlendirilmektedir. Aynı zamanda bu analizler, makine öğrenimi modellerinin eğitilmesinde kullanılarak sistemin sürekli öğrenmesini sağlar (Ho v.d., 2002).

Ayrıca, NLP ile desteklenen chatbot ve sanal asistan sistemleri, çağrı merkezlerinin 7/24 otomatik hizmet sunmasını sağlar. Özellikle sesli aramanın yapılamadığı durumlarda (örneğin gizli ihbarlarda), yazılı iletişim tercih edilmekte ve bu metinler NLP teknikleriyle işlenerek ilgili birimlere yönlendirilmektedir (Chen v.d., 2012).

NLP teknolojisinin entegrasyonunda bazı zorluklar da vardır. Türkçe'nin yapısal özellikleri, eklemeli dil yapısı, deyimsel kullanımlar ve bağlam çeşitliliği, model eğitiminde özel zorluklar yaratır. Bu nedenle, Türkçe'ye özgü derlenmiş büyük veri kümeleri ve önceden eğitilmiş modellerin geliştirilmesi büyük önem taşır. Türkiye'de bu konuda yapılan öncü çalışmalar, kamu destekli projeler aracılığıyla yürütülmektedir (Mahsum Bahadır & İnce, 2024).

NLP uygulamaları aynı zamanda etik ve hukuki sorumluluklar doğurmaktadır. Özellikle bireylerin konuşmalarının analiz edilmesi, özel bilgilerin işlenmesi anlamına geldiğinden KVKK (Kişisel Verilerin Korunması Kanunu) gibi yasal düzenlemelere sıkı sıkıya uyulması

gerekmektedir. Bu nedenle NLP sistemlerinin şeffaf, denetlenebilir ve kullanıcı gizliliğine saygılı şekilde tasarlanması gereklidir (Stamm, 2005).

NLP'nin acil durum sistemlerine entegrasyonu; doğru sınıflandırma, hızlı müdahale, kaynak optimizasyonu ve kullanıcı güvenliği gibi kritik kazanımlar sağlamaktadır. Ancak bu kazanımların sürdürülebilir olması için teknik kapasitenin yanı sıra etik ilkeler, yasal çerçeveler ve kullanıcı farkındalığıyla desteklenmesi gerekmektedir. Gelişen NLP teknolojileriyle birlikte, 112 gibi sistemlerin dijital dönüşümü daha da hız kazanacak ve toplumsal güvenliğe katkısı artacaktır.

Doğal Dil İşleme tekniklerinin acil çağrı merkezlerinde sağladığı katkılar yalnızca metin analiziyle sınırlı değildir. NLP, çağrı sonrası süreçlerin optimizasyonunda ve operasyonel verimliliğin artırılmasında da kritik bir rol oynamaktadır. Özellikle çağrı değerlendirme ve kalite kontrol sistemleri, çağrı kayıtlarının NLP algoritmalarıyla analiz edilmesi sayesinde daha objektif bir değerlendirme sürecine kavuşmuştur. Bu analizler, çağrı operatörlerinin ses tonu, konuşma süresi, kelime seçimleri gibi kriterler doğrultusunda performans değerlendirmesine olanak tanır (Stamm, 2005).

Bir diğer önemli uygulama alanı, acil durum senaryolarının simülasyonu ve eğitimidir. NLP tabanlı senaryo üretim sistemleri ile, gerçek verilerden elde edilen dil yapıları kullanılarak yapay acil çağrı senaryoları oluşturulmakta ve bu senaryolar çağrı merkezi personelinin eğitimi için kullanılmaktadır. Bu sistemler, operatörlerin stresli durumlara daha hazırlıklı olmasını ve karar verme becerilerinin gelişmesini sağlamaktadır (Ekşi & Yıldırım, 2014).

Son yıllarda geliştirilen çok modlu NLP sistemleri, yalnızca metinsel değil, aynı zamanda ses ve görsel verilerin de entegre analizini mümkün kılmaktadır. Örneğin, bir vatandaş tarafından gönderilen video veya fotoğraflı ihbarlar, NLP ile birlikte çalışan görsel analiz sistemleri sayesinde daha hızlı işlenebilmekte, olayın içeriği, yeri ve zamanına dair bilgi çıkarımı yapılabilmektedir. Bu, özellikle büyük çaplı afetlerde ve sosyal medya tabanlı acil bildirim sistemlerinde büyük bir avantaj sunmaktadır (Bukan, 2019).

NLP'nin sağladığı önemli katkılardan biri de anomalilerin tespitidir. Sisteme gelen çağrıların içerikleri analiz edilerek normal dışı dil kalıpları, aşırı tekrarlar veya olağandışı ifadeler tespit edilebilir. Bu analizler sayesinde sistemsel hatalar, kötüye kullanımlar ya da sahte çağrılar hızlıca tespit edilip filtrelenebilir. Bu sayede hem kaynakların etkin kullanımı sağlanmakta hem de gerçek acil durumlara müdahale süresi kısalmaktadır (Apak & Üstoğlu, 2017).

Ayrıca NLP uygulamaları, operasyonel istatistiklerin ve raporlamaların otomasyonu için de kullanılmaktadır. Çağrı içeriklerinden çıkarılan yapısal veriler, farklı kategorilere ayrılarak haftalık, aylık ya da yıllık analiz raporları oluşturmakta ve yöneticilere veri destekli karar alma imkânı sunmaktadır. Bu sayede kaynak planlaması, insan gücü yönetimi ve politika geliştirme gibi alanlarda bilimsel veriye dayalı yaklaşımlar benimsenecektir (Ağaç, 2012).

Türkçe diline özgü zorluklar göz önünde bulundurulduğunda, NLP sistemlerinin dilsel ve kültürel uyarlaması büyük önem taşımaktadır. Türkçedeki eklemeli yapı, kelime türetme kuralları, deyimler ve halk arasında yaygın kullanılan yerel ifadeler, NLP sistemlerinin doğruluğunu etkileyebilmektedir. Bu nedenle, sistemlerin başarısı, eğitim verilerinin çeşitliliği ve nitelikli dil işleme algoritmaları ile doğrudan ilişkilidir. Son yıllarda Türkçe için geliştirilen önceden eğitilmiş BERT modelleri (BERTurk gibi), bu soruna büyük ölçüde çözüm sağlamaktadır (Creswell & Plano Clark, 2014).

NLP'nin etik boyutu da göz ardı edilmemelidir. Acil çağrılar sırasında kaydedilen verilerin mahremiyeti, analizlerin yasal çerçeveler içinde gerçekleştirilmesi gerektiğini ortaya koyar. Özellikle KVKK ve Avrupa Birliği'nin GDPR düzenlemeleri, bireylerin izinsiz ses analizine karşı korunmasını öngörmektedir. Bu nedenle NLP sistemlerinin yalnızca teknik olarak değil, aynı zamanda etik tasarım ilkeleri doğrultusunda yapılandırılması gerekmektedir (Ekşi & Torlak, 2011).

Özetle, NLP teknolojisi, 112 gibi acil çağrı sistemlerinde birçok farklı noktada kullanılmakta; metin analizi, konuşma tanıma, duygu analizi, çeviri, önceliklendirme, raporlama ve eğitim alanlarında etkin çözümler sunmaktadır. Sistemlerin başarısı; kaliteli veriler, güçlü algoritmalar, etik çerçeveye bağlılık ve kullanıcı ihtiyaçlarına duyarlılıkla doğrudan ilişkilidir. Teknolojik ilerlemeler ışığında NLP'nin entegrasyonunun artması, daha hızlı, güvenilir ve insana odaklı acil müdahale sistemlerini mümkün kılacaktır.

3. YÖNTEM

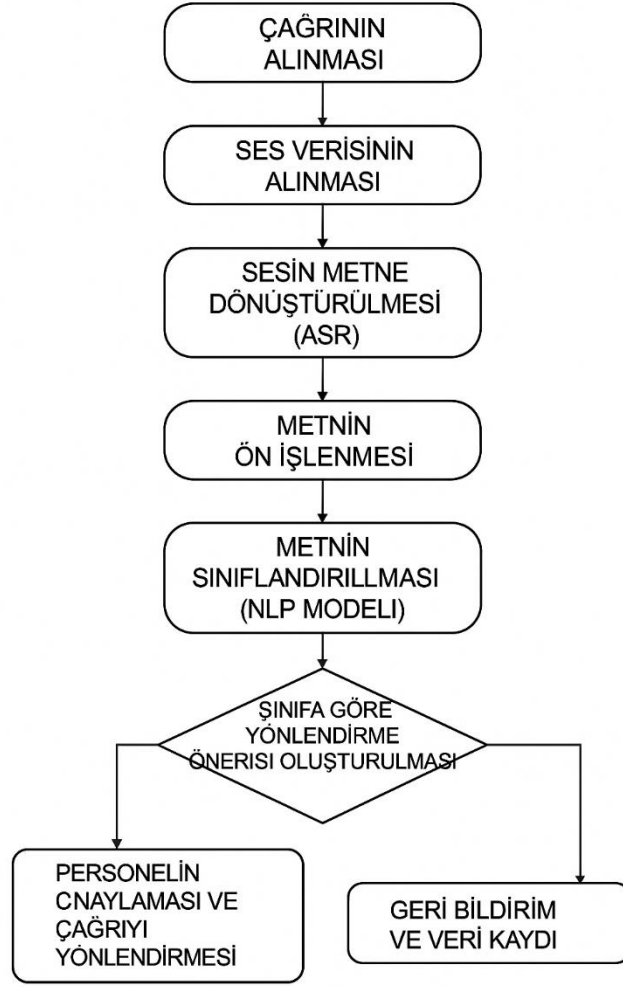
3.1. Genel Bakış

Acil çağrı merkezlerinde, çağrının doğru ve hızlı şekilde ilgili birime yönlendirilmesi hayati önem taşır. Özellikle yangın, sağlık, trafik kazası gibi durumlarda saniyeler bile kritik olabilir. Bu çalışma, 112 acil çağrı merkezlerine gelen sesli çağruların yapay zekâ destekli sistemlerle işlenerek sınıflandırılmasını ve yönlendirilmesini amaçlamaktadır. Sistem, vatandaş tarafından yapılan sesli çağrıyı gerçek zamanlı olarak alır, Whisper gibi bir otomatik konuşma tanıma (ASR) modeliyle metne dönüştürür. Elde edilen metin, anonimleştirme, stop-word temizleme ve tokenizasyon gibi ön işleme adımlarından geçtikten sonra sınıflandırma modeline aktarılır. Burada çağrı içeriği "yangın", "güvenlik" veya "sağlık" gibi sınıflardan birine atanır. Elde edilen sınıflandırma sonucuna göre, çağrıyı karşılayan personele sistem tarafından yüksek doğruluk oranıyla görsel ya da işitsel yönlendirme önerisi sunulur. Operatör bu öneriyi değerlendirerek çağrıyı ilgili birime yönlendirir. Sonuç olarak yapılan yönlendirmenin doğruluğu sistem tarafından kayıt altına alınır ve bu geri bildirimler doğrultusunda modelin başarımı zamanla geliştirilir. Uygulamanın sağlayabileceği katkılar Tablo 3.1' de çeşitli parametreler ışığında ele alınmıştır.

Bu çalışmada kullanılan metni sınıflandırma ve ses-metin dönüşüm teknikleri, yapay zekânın doğal dil işleme ve derin öğrenme alt alanlarına dayanmaktadır. İşcan (2024), bu tür uygulamaların, gerçek zamanlı veri analizi ve karar destek sistemleri gibi kritik alanlarda giderek yaygınlaştığını vurgulamaktadır.

Tablo 3.1. Uygulamanın Sağladığı Katkılar

Faydası	Açıklama
Zaman kazancı	Çağrı ilk birkaç saniyede otomatik olarak analiz edilirse, personel daha hızlı karar verir.
Doğru yönlendirme	NLP ve sınıflandırma algoritmaları, çağrının konusunu yüksek doğrulukla tahmin edebilir. Bu da yanlış birime aktarımları azaltır.
Operatörün yükünü azaltma	İlk sınıflandırma otomatik yapılırsa, personel daha odaklı ve verimli çalışabilir.
Karmaşık çağrılarda destek	Belirsiz çağrılarda sistem, operatöre "Bu çağrı muhtemelen TRAFİK" gibi öneride bulunabilir.
İstatistik ve analiz	Çağrılar sınıflandırıldıkça, sistem daha akıllı hale gelir ve yönetim de rapor alabilir.



Şekil 3.1. Sistemin Çalışma Süreci

Sistemin çalışma süreci Şekil 3.1’de resmedildiği gibi aşağıda maddeler halinde sıralanmıştır:

1. Çağrının alınması
→ Vatandaştan sesli çağrı gelir.
2. Ses verisinin alınması
→ Çağrı merkezine gelen ses, sistem tarafından gerçek zamanlı olarak kaydedilir.
3. Sesin metne dönüştürülmesi (ASR)
→ Whisper gibi bir sistemle ses otomatik olarak yazıya dökülür.
4. Metnin ön işlenmesi
→ Anonimleştirme, stop-word temizleme, tokenizasyon gibi adımlar uygulanır. Veri artırımı işlemi uygulanır.

5. Metnin sınıflandırılması (NLP Modeli)
→ Metin içerik olarak "yangın", "güvenlik", "sağlık" sınıflardan birine atanır.
6. Sınıfa göre yönlendirme önerisi oluşturulması
→ Sistem, çağrıyı karşılayan personele görsel/işitsel bir öneri sunar:
"Bu çağrı %87 olasılıkla yangın ile ilgili"
7. Personelin onaylaması ve çağrıyı yönlendirmesi
→ Operatör sistemi dikkate alarak karar verir.
8. Geri bildirim ve veri kaydı
→ Sonuç (doğru yönlendirme mi?) sisteme kaydedilir → model zamanla gelişir.

3.2. Veri Kümesi

Veriler, İçişleri Bakanlığı İller İdaresi Genel Müdürlüğünden alınan izinle Bilecik 112 Acil Çağrı Merkezi yazılım sisteminden indirilen ses kayıtlarından oluşmaktadır. EK-1 ve EK-2 izin belgeleri yer almaktadır. Toplam 16.000 ses kaydı Bakanlık teknik ekiplerince indirilip tarafımıza iletilmiştir. Gönderilen ses kayıtları vatandaştan gelen aramalar, giden aramalar, kurum içi görüşmelerden oluşmaktadır. Vatandaştan gelen çağrı karşılayıcı personel tarafından cevaplanan çağrılar ayıklanmıştır. Tablo 3’ de görüldüğü üzere toplam 3531 adet veri bulunmaktadır. Ses verileri wav formatında karşılıklı konuşmalardan oluşmaktadır. Vatandaş ve çağrı karşılayıcı personel arasında geçen diyalog şeklinde ortam seslerinden temizlenmiş bir yapıya sahiptir. Ses kayıtları yerel ağızda panik anında yapılan aramalar olduğu için işlenmesi zor verilerdir.

Tablo 3.2. Etiketli Sınıf Verileri

Etiket	Örnek Sayısı
Sağlık	1293
Yangın	1071
Güvenlik	1038
Belirsiz	129

Anonimleştirilmiş metinler, veri artırımı teknikleri (EDA) ile dengelenmiş ve “belirsiz” etiketli örnekler analiz dışı bırakılmıştır. Nihai veri kümesi üç sınıf için dengeli hale getirilmiş, metinler TF-IDF ve BERT tokenizer ile modellenmiştir.

3.3. Sesi Metne Çevirme

Ses kayıtları OpenAI tarafından geliştirilen Whisper modeli (medium versiyonu) ile metne dönüştürülmüştür. Bu dönüşüm sırasında model çıktısındaki metinler manuel olarak gözden geçirilmiş ve yüksek hata içeren kayıtlar elenmiştir.

Whisper Modeli: Çok Dilli Açık Kaynak Konuşma Tanıma Yaklaşımı

Whisper, OpenAI tarafından geliştirilen, çok dilli ve açık kaynaklı bir otomatik konuşma tanıma (Automatic Speech Recognition – ASR) modelidir. Derin öğrenme temelli bu model, yüksek doğruluk oranı, çok dilli destek ve geniş kullanım alanlarıyla, konuşma verisinin metne dönüştürülmesinde çığır açıcı bir yaklaşım sunmaktadır (Radford et al., 2022).

Whisper modeli, çok dilli destek ve hazır transkripsiyon çıktısı sağlaması açısından avantajlıdır. Buna karşılık HuBERT gibi self-supervised modellerin, farklı veri kümelerine kolayca uyarlanabilir olması ve daha düşük etiket ihtiyacı, veri genişletme olanakları açısından avantaj yaratmaktadır (Hsu et al., 2021). Ancak HuBERT'in temel eğitimi büyük İngilizce veri kümeleri üzerinde yapıldığından, Türkçe çağrı verilerine özel fine-tuning yapılmadan optimal sonuçlar alınması zor olabilir.

Whisper modeli çok dilli destek ve uçtan uca entegrasyon kolaylığı nedeniyle bu tezde tercih edilmiştir. Bununla birlikte, WavLM gibi modellerin çok görevli (multi-task) konuşma işleme yetenekleri, acil çağrılardaki arka plan gürültüsü, konuşmacı kimliği veya duygusal ton gibi parametreleri analiz etme açısından gelecekte daha esnek kullanım imkânı sunmaktadır (Chen et al., 2022).

Whisper modeline ait özellikler aşağıda sıralanmıştır.

Temel Özellikler

- **Çok Dilli Destek:** Whisper, 90'dan fazla dili destekleyecek biçimde eğitilmiştir. Bu özelliği sayesinde, farklı aksanlar, lehçeler ve konuşma tarzlarıyla yüksek uyum göstermektedir. Bu durum, özellikle çok kültürlü ve çok dilli iletişim ortamlarında önemli bir avantaj sunar.
- **Açık Kaynak Yapı:** Modelin açık kaynak olarak GitHub üzerinden paylaşılması, akademik çalışmalar ve özel sektör uygulamaları için geniş bir erişim alanı yaratmıştır. Araştırmacılar modeli özelleştirerek kendi veri kümeleri üzerinde inceleme ve geliştirme yapabilmektedir (OpenAI, 2022).

- End-to-End Mimari: Whisper, geleneksel ASR sistemlerinden farklı olarak, ses verilerini ön işleme, özellik çıkarımı ve dil modelleme gibi ayrı aşamalara bölmeden, uçtan uca (end-to-end) bir yaklaşımla doğrudan metne dönüştürmektedir.
- Gürültüye Dayanıklı Performans: Eğitim sürecinde gürültülü verilerle karşılaşması sayesinde, model düşük kaliteli veya arka plan gürültüsü içeren seslerde bile yüksek doğruluk oranı sunabilmektedir.

Çalışma Prensibi

Whisper modeli, temel olarak aşağıdaki aşamalar üzerinden çalışır:

- Sesli Veri Girişi: Kullanıcıdan ya da sistemden alınan ham ses dalgaları modelin girdisidir.
- Öznitelik Çıkarımı: Ses dalgalarından Mel spectrogram öznitelikleri çıkarılır.
- Sekans Tabanlı Çeviri: Model, ses özniteliklerini sıralı bir biçimde doğal dile dönüştürür. Transformer mimarisi sayesinde hem kısa hem de uzun süreli bağımlılıkları yakalayabilir.

Bu yapı sayesinde Whisper, geleneksel HMM tabanlı sistemlere göre daha entegre ve bağlamsal olarak zengin bir çıktı üretmektedir.

Uygulama Alanları

Whisper modelinin güçlü genelleme yeteneği ve çok yönlülüğü sayesinde aşağıdaki alanlarda etkili bir şekilde kullanılabilir:

- Otomatik Transkripsiyon: Eğitim videoları, konferanslar, medya içerikleri gibi sesli verilerin yazıya dökülmesi.
- Çağrı Merkezi Verilerinin Analizi: Sesli müşteri görüşmelerinin otomatik çözümlenmesi ve sınıflandırılması.
- Erişilebilirlik Araçları: İşitme engelli bireyler için konuşmayı metne dönüştüren çözümler.
- Çok Dilli Sanal Asistanlar: Farklı dillerde komut algılayabilen yapay zekâ destekli asistanlar.

Teknik Özellikler ve Performans

Whisper modeli, farklı büyüklüklerde (tiny, base, small, medium, large) sunulmuştur.

Model boyutu arttıkça doğruluk oranı da yükselmekte, fakat beraberinde işlemci ve bellek ihtiyacı da artmaktadır. Uygulama ihtiyacına göre uygun model seçilmesi önemlidir.

Whisper'in large modeli özellikle karmaşık, uzun ve çok dilli konuşma verilerinde daha başarılı olurken; base ve small gibi daha küçük versiyonlar, mobil ya da düşük donanımlı sistemlerde tercih edilmektedir.

3.4. Ön İşleme ve Anonimleştirme

ASR modülünden elde edilen metinler doğrudan analiz edilemeyecek kadar gürültü ve özel bilgi (örn. adres, isim) içerebilir. Doğal dil işleme uygulamalarında, metinlerin doğru şekilde temsil edilmesi için öncelikle çeşitli ön işleme adımlarına tabi tutulması gerekmektedir. Chai (2022), bu adımların model başarımı üzerindeki etkisini sistematik olarak değerlendirmiştir.

Metin ön işleme süreci, doğal dil işleme sistemlerinde başarımı doğrudan etkileyen kritik bir aşamadır. Küçük harfe dönüştürme, noktalama temizliği, stop-word çıkarımı ve lemmatizasyon gibi işlemler sayesinde metin, makine öğrenmesi algoritmalarının öğrenmesine uygun hale gelir. Palomino ve Aider (2022), ön işleme stratejilerinin sınıflandırma performansına olan katkılarını sistematik biçimde incelemiştir.

Metin ön işleme, yalnızca geleneksel yöntemler için değil, derin öğrenme tabanlı doğal dil işleme uygulamaları için de kritik bir adımdır. Camacho-Collados ve Pilehvar (2017), metin kategorilendirme ve duygu analizi görevlerinde farklı ön işleme yaklaşımlarının derin sinir ağı mimarileri üzerindeki etkilerini karşılaştırmalı olarak incelemiş ve ön işleme stratejisinin model başarısını doğrudan etkilediğini göstermiştir. Bu çalışma, ön işleme adımlarının yalnızca klasik yöntemler için değil, modern sinir ağı tabanlı mimarilerde de vazgeçilmez olduğunu ortaya koymaktadır.

Bu nedenle aşağıdaki ön işleme adımları uygulanmıştır.

- Anonimleştirme (Regex ve spaCy kullanılarak)
- Tokenizasyon ve lemmatizasyon
- Tüm metinler küçük harfe dönüştürülmüş,
- Noktalama işaretleri ve özel karakterler kaldırılmış,
- Türkçe stopword listesi ile anlamsız kelimeler temizlenmiştir.
- LSTM, CNN ve GRU modelleri için Tokenizer ile dizileştirme yapılmış ve pad_sequences ile sabit uzunlukta girişler elde edilmiştir.
- BERT modeli için BertTokenizer (dbmdz/bert-base-turkish-uncased) kullanılmıştır.

Bu adımlar verilerin metnin sınıflandırma algoritmaları için uygun hale getirilmesini sağlamaktadır

Anonimleştirme (Regex ve spaCy kullanılarak)

ASR çıktıları, kişisel veri (örneğin ad, soyad, adres, telefon numarası) içerebilir. Bu verilerin gizliliğini sağlamak için anonimleştirme işlemi uygulanır. Bu işlem, ad-soyad gibi özel isimleri tanımak için adlandırılmış varlık tanıma (Named Entity Recognition - NER) tekniklerinden yararlanır. Python'da sıklıkla kullanılan spaCy kütüphanesi, Türkçe NER modelleriyle bu tür verilerin belirlenmesini kolaylaştırır. Ayrıca özel düzenli ifadeler (Regex) ile telefon numaraları, plaka kodları gibi yapısal bilgilerin çıkarımı sağlanabilir.

“Anonimleştirme, özellikle kişisel verilerin yer aldığı çağrı merkezi verilerinde GDPR ve KVKK gibi yasal düzenlemeler doğrultusunda ön koşul niteliğindedir.” (Zissman, Chen, & Ma, 2020)

Küçük Harfe Dönüştürme (Lowercasing)

Metindeki tüm harflerin küçük harfe dönüştürülmesi, aynı sözcüğün farklı biçimlerini birleştirerek özgün kelime dağarcığını (vocabulary) azaltır ve metni analiz edilebilir hale getirir. Bu adım, metin sınıflandırması ve metin benzerliği gibi işlemlerde modelin tutarlılığını artırır. Chai (2022), lowercasing işleminin özellikle sosyal medya verileri gibi informal dil içeren ortamlarda sınıflandırma doğruluğuna olumlu katkı sunduğunu belirtmiştir.

Noktalama ve Duraklama İşaretlerinin Silinmesi

ASR çıktılarında noktalama işaretleri ya eksiktir ya da hatalı eklenmiştir. Bu nedenle, bu işaretler temizlenerek dil modeline gürültü yaratacak unsurlar ortadan kaldırılır. Bu işlem, kelime temelli analizlerde özellikle faydalıdır.

Türkçe Stop-Word Temizliği

Stop-word'ler, taşıdıkları anlamsal yük az olduğu için sınıflandırma görevlerinde genellikle çıkarılır. Türkçe'de “ve”, “bu”, “ama” gibi kelimeler, bağlaç ve zamirler bu kapsamdadır. Bu işlem, bilgi taşıma gücü yüksek kelimelerin öne çıkmasını sağlar. (Sarica ve Luo, 2020)

Tokenizasyon ve Lemmatizasyon

Tokenizasyon, metni sözcük ya da cümle parçalarına ayırma işlemidir.

Lemmatizasyon ise kelimeleri kök ya da sözlük biçimlerine indirger. Türkçe gibi

eklemeli dillerde bu işlem daha karmaşık olup Zemberek veya spaCy'nin Türkçe modelleriyle yapılabilir.

Bu ön işleme adımları sayesinde, ASR çıktılarının içerdiği doğal dil verisi daha temiz, analiz edilebilir ve makine öğrenmesi modellerine uygun hale getirilir. Bu süreç, metin madenciliği ve sınıflandırma gibi işlemlerde hem doğruluğu artırır hem de modelin genellenebilirliğini güçlendirir.

Metin Temsili ve Özellik Çıkarımı

Doğal dil işleme tabanlı sınıflandırma sistemlerinde başarı, büyük ölçüde metinlerin uygun şekilde sayısal temsiline ve anlamlı özniteliklerin çıkarılmasına bağlıdır. Bu bağlamda, sıklıkla kullanılan yöntemler arasında TF-IDF (Term Frequency–Inverse Document Frequency) ve Count Vectorizer yer almaktadır.

Yayla et al. (2021), uzaktan eğitim sürecinde karşılaşılan teknik problemlerin sınıflandırılması amacıyla Twitter verileri üzerinde yaptıkları çalışmada bu yöntemleri başarıyla uygulamıştır. Çalışmada, Türkçe tweet verileri üzerinde önce stop-word (sık geçen anlamsız kelimeler) temizliği, ardından da n-gram çıkarımı (özellikle unigram ve bigram düzeyinde) gerçekleştirilmiştir. Böylece, dilin yapısına özgü ifade kalıpları daha etkili biçimde modellenmiştir.

Özellikle TF-IDF yöntemi ile, sık kullanılan ancak ayırım gücü düşük kelimeler filtrelenirken; belgeye özgü ve anlam yüklü ifadeler daha yüksek ağırlıklarla temsil edilmiştir. Bu, sınıflandırma modelinin performansını olumlu yönde etkilemiştir. Benzer şekilde Count Vectorizer ile kelime frekanslarına dayalı basit fakat etkili bir özellik matrisi elde edilmiştir.

3.5. Sınıflandırma Modeli

Ön işlenmiş metinler, farklı makine öğrenmesi algoritmaları ile sınıflandırılmıştır. Başlangıçta Lojistik Regresyon, Naive Bayes, Destek Vektör Makineleri (SVM) ve Rastgele Orman (Random Forest) gibi klasik yöntemler denenmiştir. Derin öğrenme modellerinden LSTM, GRU, CNN ve BERT modelleri kullanılmıştır.

Kullanılan makine öğrenmesi algoritmaları Tablo 3.3' te karşılaştırılmıştır.

Tablo 3.3. Makine Öğrenmesi Algoritmalarının Karşılaştırmalı Özellikleri

Algoritma	Eğitim Süresi	Aşırı Öğrenmeye Dayanıklılık	Yorumu Kolay mı?
Lojistik Regresyon	Kısa	Orta	Evet
Naive Bayes	Çok kısa	Orta	Evet
SVM	Orta-uzun	Yüksek	Hayır
Random Forest	Uzun	Çok yüksek	Hayır

3.5.1. Lojistik Regresyon (Logistic Regression)

Lojistik regresyon, bağımlı değişkenin ikili (binary) ya da çoklu (multinomial) sınıflara ayrılması gerektiği durumlarda kullanılan, doğrusal sınıflandırma algoritmalarından biridir. Modelin amacı, gözlem verisinin belirli bir sınıfa ait olma olasılığını hesaplamaktır. (Hosmer ve arkadaşları,)

Avantajları:

- Aşırı karmaşık olmayan ve yorumlanabilir sonuçlar üretir.
- Küçük ve orta büyüklükteki veri setleri için uygundur.

3.5.2. Naive Bayes

Naive Bayes algoritması, Bayes Teoremi'ne dayalı bir olasılık temelli sınıflandırma yöntemidir. Özellikle metin sınıflandırma, spam tespiti gibi problemler için hızlı ve etkili bir çözümdür. (Zhang)

Naive Bayes algoritması, Bayes teoremini temel alan ve özelliklerin birbirinden bağımsız olduğu varsayımıyla çalışan olasılık temelli bir sınıflandırma yöntemidir. Bu algoritma metin sınıflandırma problemlerinde sıklıkla kullanılmakta ve özellikle büyük veri kümelerinde yüksek başarı oranları sağlamaktadır (Manning, Raghavan & Schütze, 2008). Uslu ve Akyol (2021) çalışmasında, Naive Bayes algoritması Türkçe haber metinleri üzerinde test edilmiş ve yaklaşık %91 doğruluk (accuracy) ile en başarılı yöntem olarak raporlanmıştır.

3.5.3. Destek Vektör Makineleri (Support Vector Machines, SVM)

SVM, sınıflar arasındaki ayrımı sağlayan en iyi hiper düzlemi (maximum-margin hyperplane) bulmayı amaçlar. Doğrusal olmayan ayrımlar için çekirdek (kernel) fonksiyonları

kullanılır. (Cortes) Metin sınıflandırma problemlerinde, özellikle yüksek boyutlu veri ile çalışıldığında üstün performans göstermektedir (Joachims, 1998).

Avantajları:

- Yüksek boyutlu veriyle iyi çalışır.
- Kernel fonksiyonları sayesinde doğrusal olmayan ayrımları da yapabilir.

3.5.4. Rastgele Orman (Random Forest)

Random Forest, birden çok karar ağacının oluşturulması ve bu ağaçların sonuçlarının oylanması (majority voting) ile nihai tahminin yapılması esasına dayalı bir topluluk (ensemble) öğrenme algoritmasıdır. (Breiman) Overfitting sorununa karşı dayanıklı olması, bu algoritmayı metin madenciliğinde tercih edilen yöntemlerden biri yapmaktadır.

Önemli Özellikler:

- Aşırı öğrenmeye (overfitting) karşı dirençlidir.
- Eksik veri ve dengesiz veri setlerine karşı toleranslıdır.

3.5.5. Model Mimarileri ve Hiperparametre Ayarları

Kullanılan makine öğrenmesi ve derin öğrenme modellerinin mimarileri ve hiperparametre ayarları Tablo 3.4'te özetlenmiş olup aşağıda listelenmiştir.

Tablo 3.4. Kullanılan Sınıflandırma Algoritmalarına Ait Hiperparametre Ayarları

Model	Öğrenme Oranı	Epoch	Batch Size	Optimizasyon Algoritması	Aktivasyon Fonksiyonu	Dropout	Diğer Notlar
LSTM	0.001	5	32	Adam	ReLU	0.5	-
CNN	0.001	5	32	Adam	ReLU	0.5	-
GRU	0.0005	5	32	Adam	ReLU	0.5	-
BERT	2e-5	3	8	Adam	GELU	-	-
Naive Bayes	-	-	-	-	-	-	TF-IDF ile çalıştı
SVM	-	-	-	-	-	-	Kernel: RBF, C=1.0
Random Forest	-	-	-	-	-	-	Ağaç sayısı: 100

Makine Öğrenmesi Modelleri

Naive Bayes

- Model tipi: Multinomial Naive Bayes
- Amaç: Metin sınıflandırmada kelime sıklığına dayalı olasılıksal yaklaşım
- Özellik çıkarımı: TF-IDF vektörleştirme (max_features=10000, ngram_range=(1,2))
- Hiperparametre: alpha=1.0 (Laplace smoothing)

Destek Vektör Makineleri (SVM)

- Model tipi: Lineer SVM (LinearSVC)
- Amaç: TF-IDF özelliklerine dayalı doğrusal ayırıcı ile sınıflandırma
- Hiperparametreler: C=1.0 (regularizasyon parametresi), max_iter=1000

Lojistik Regresyon

- Model tipi: Çok sınıflı LogisticRegression
- Amaç: Sınıflar arası olasılık temelli ayırım
- Hiperparametreler: solver='lbfgs', multi_class='multinomial', max_iter=1000

Random Forest

- Model tipi: RandomForestClassifier
- Amaç: Karar ağaçlarının çoğulluğuyla daha yüksek genel doğruluk
- Hiperparametreler:
 - n_estimators=100
 - max_depth=None
 - random_state=42

Derin Öğrenme Modelleri

Tüm derin öğrenme modellerinde ortak olarak kullanılan parametreler aşağıdaki gibidir:

- Embedding boyutu: 128
- Giriş uzunluğu: 100 kelime
- Kelime sayısı: 10.000 (Tokenizer(num_words=10000))

- Kayıp fonksiyonu: `categorical_crossentropy`
- Optimizasyon: Adam
- Epoch sayısı: 5
- Batch size: 32

LSTM Modeli

- Mimari: Embedding → LSTM (64) → Dropout(0.5) → Dense(3, softmax)
- Özellik: Sekans bağımlılıklarını modellemede güçlü performans

GRU Modeli

- Mimari: Embedding → GRU (64) → Dropout(0.5) → Dense(3, softmax)
- Özellik: LSTM'e benzer ama daha az hesaplama yükü ile benzer performans

CNN Modeli

- Mimari: Embedding → Conv1D(128, kernel_size=5, activation='relu') → GlobalMaxPooling1D() → Dense (64, relu) → Dropout(0.5) → Dense(3, softmax)
- Özellik: N-gram tabanlı kalıpları yakalayarak hızlı ve etkili öğrenme

BERT Modeli (Transformers tabanlı)

- Model: `TFBertForSequenceClassification`
- Pre-trained model: "dbmdz/bert-base-turkish-uncased"
- Tokenizer: `BertTokenizer` (padding=True, truncation=True)
- Girdi şekli: `input_ids`, `attention_mask`
- Hiperparametreler:
 - `num_labels=3`
 - `optimizer=Adam(learning_rate=2e-5)`
 - `loss=CategoricalCrossentropy(from_logits=True)`
 - `epochs=3`
 - `batch_size=8`

3.6. Sınıfa Göre Yönlendirme Önerisi: Akıllı Destek Sistemi Tasarımı

Doğal Dil İşleme (NLP) tabanlı sınıflandırma sisteminin temel çıktısı, her bir çağrının

önceden belirlenen sınıflardan (yangın, sağlık, güvenlik vb.) birine belirli bir olasılıkla atanmasıdır. Bu doğrultuda, sistemin uygulamaya entegrasyonu için gerçek zamanlı öneri sunan bir karar destek modülü önerilmektedir. Bu modül, çağrının sınıf tahminine ilişkin olasılığı operatöre şu şekilde sunar:

“Bu çağrı %87 olasılıkla yangın ile ilgilidir.”

Bu tür görsel veya sesli uyarılar, operatörün çağrının içeriğini daha hızlı anlamasına yardımcı olabilir. Sistem bu öneriyi sunarken aynı zamanda etik bir sorumluluk alanı oluşturmamak adına nihai kararı insan operatöre bırakır.

3.7. Operatör Onayı ve Yönlendirme

Sınıflandırma sonucu bir öneri olarak operatöre sunulduktan sonra, sistem karar verme yetkisini tamamen insan operatöre bırakır. Operatör çağrıyı inceleyerek, öneriyi onaylayabilir ya da gerekirse başka bir sınıfa yönlendirme yapabilir. Bu süreç, insan-makine etkileşiminde kontrollü otonomi (human-in-the-loop) ilkesi ile uyumludur. Böylece sistem hatalı yönlendirme riskini minimize ederken operatörün uzmanlığını da dışlamaz.

3.8. Geri Bildirim ve Model Güncellemesi

Uygulamada sistemin başarımının sürdürülebilir şekilde artırılabilmesi için, her çağrı sonrası yönlendirme kararının doğruluğu sisteme kaydedilmelidir. Bu geri bildirimler:

- Sistem performansını izlemek,
- Hatalı sınıflandırmaları belirlemek,
- Yeni çağrı örnekleriyle modeli yeniden eğitmek için kullanılabilir.

Bu yaklaşım, aktif öğrenme (active learning) ve model güncellemesi (online fine-tuning) gibi yöntemlerle modelin zaman içinde kendi karar doğruluğunu artırmasını sağlayabilir.

3.9. Prototip Ara yüz Geliştirme ve Uygulama Önerisi

Bu çalışmada geliştirilen acil çağrı sınıflandırma modeli, yalnızca yüksek doğrulukla sınıflandırma yapmakla kalmayıp aynı zamanda çağrı merkezindeki operatörlere karar destek sunabilecek bir sistem önerisini de kapsamaktadır. Bu amaç doğrultusunda, sınıflandırma modelinin çıktılarını gerçek zamanlı bir şekilde kullanıcıya aktaran ve sistematik geri bildirim mekanizması içeren bir prototip ara yüz tasarlanmıştır.

Sistem Yapısı ve Fonksiyonel Bileşenler

Prototip ara yüz; sesli verinin otomatik olarak metne dönüştürülmesi, sınıflandırılması ve ardından ilgili personelin yönlendirilmesine yardımcı olacak karar destek sistemi olarak yapılandırılmıştır. Geliştirilen sistem, aşağıda Tablo 3.5'te temel bileşenleri listelenmiştir.

Tablo 3.5. Prototip Ara yüzünün Bileşenleri

Bileşen	Açıklama
Sınıflandırma Sonucu	Modelin tahmin ettiği sınıf ve olasılık yüzdesi görsel olarak gösterilir. Örneğin: "Bu çağrı %87 olasılıkla yangın ile ilgilidir."
Yönlendirme Önerisi	Sistem, olayın niteliğine göre uygun birim (polis, jandarma, itfaiye vb.) için yönlendirme önerir.
Operatör Onayı	Kullanıcı öneriyi değerlendirip onaylama veya değiştirme hakkına sahiptir.
Geri Bildirim Formu	Yönlendirmenin doğruluğuna dair manuel giriş yapılır. Bu veri, modelin yeniden eğitilmesi sürecinde kullanılır.
Model Başarım Göstergesi	Kullanıcıya sistemin genel doğruluk ve sınıf bazlı performans metriği grafiklerle sunulur.

Bu prototip, yalnızca sınıflandırma başarımı değil aynı zamanda insan-makine etkileşimini destekleyen bir karar destek sistemi tasarımı sunmaktadır. Operatörün inisiyatifine saygı göstererek karar süreçlerine müdahale etmeyen, ancak yüksek doğrulukla destek sunan bu sistem aşağıdaki katkıları sağlar:

- Müdahale süresini azaltarak yaşam kurtarıcı etkiyi artırır.
- Veriye dayalı yönlendirme ile kaynakların daha etkin kullanımını sağlar.
- İnsan hatasını azaltarak sistem güvenilirliğini artırır.
- Sürekli geri bildirim mekanizması sayesinde kendi kendini geliştiren bir yapıya sahiptir.

4. BULGULAR ve TARTIŞMA

Tablo 4.1 ve Tablo 4.2’de elde edilen bulgular, makine öğrenmesi algoritmalarının (Naive Bayes, SVM, Random Forest, Lojistik Regresyon) acil çağrı sınıflandırma görevinde makul doğruluk oranlarına ulaştığını, ancak derin öğrenme tabanlı yaklaşımların (özellikle CNN ve LSTM) daha yüksek başarı sağladığını göstermektedir.

Tablo 4.1. Makine Öğrenmesi Model sonuçları


Model	Accuracy	Precision (macro)	Recall (macro)	F1-score (macro)	Ort. süre	Güçlü Yönü	Zayıf Yönü
Naive Bayes	0.78	0.83	0.77	0.78	1 sn	Sağlık sınıfında yüksek recall (%94)	Yangın sınıfında düşük recall (%61), kritik hata riski
SVM	0.91	0.91	0.92	0.91	5-10 sn	Dengeli ve yüksek başarı, güvenlik ve yangında güçlü	Eğitim süresi daha uzun
Lojistik Regresyon	0.87	0.87	0.87	0.87	2-5 sn	Dengeli sonuçlar, yorumlanabilirlik	SVM ve RF’ye göre daha düşük başarı
Random Forest	0.96	0.96	0.96	0.96	10-20 sn	En yüksek doğruluk, tüm sınıflarda dengeli	Daha fazla hesaplama kaynağı gerektirir

CNN modeli, %92 doğruluk oranıyla tüm sınıflarda dengeli bir performans sergileyerek iyi sonuç vermiştir. LSTM modeli ise özellikle güvenlik sınıfında yüksek başarı göstermiştir. GRU modeli, yangın sınıfında öne çıkmasına rağmen genel doğruluk açısından LSTM ve CNN'in gerisinde kalmıştır.

Tablo 4.2. Derin Öğrenme Model Sonuçları


Model	Accuracy	Precision (Macro)	Recall (Macro)	F1 (Macro)	Ortalama Süre	Açıklama
LSTM	0.90	0.90	0.91	0.90	1-2 dk	Özellikle “güvenlik” sınıfında yüksek başarı göstermiştir. Sıralı veri işleme yeteneği sayesinde olayın bağlamsal akışını yakalamada etkili olmuştur.
CNN	0.92	0.93	0.92	0.92	1 dk	Tüm sınıflarda dengeli ve yüksek performans sergilemiştir. Özellik çıkarma kabiliyeti, farklı acil durum tiplerini ayırt etmede güçlü bir avantaj sağlamıştır.
GRU	0.88	0.88	0.89	0.88	1-2 dk	“Yangın” sınıfında güçlü sonuçlar elde etmiştir. Daha düşük parametre sayısı sayesinde hızlı eğitim süresi sağlamış, ancak genel doğruluk oranı CNN'e kıyasla daha düşük kalmıştır.
BERT	0.73	0.73	0.72	0.72	2-3 saat	Daha büyük veri setiyle diğer modelleri aşma potansiyeline sahiptir.

Makine öğrenmesi modellerinden en yüksek doğruluk oranına sahip Random Forest modeli için Şekil 4.1'de confusion matrix, Şekil 4.2'de ROC eğrisi verilmiştir. Diğer modellere ilişkin confusion matrix sonuçları Ek-1'te verilmiştir.



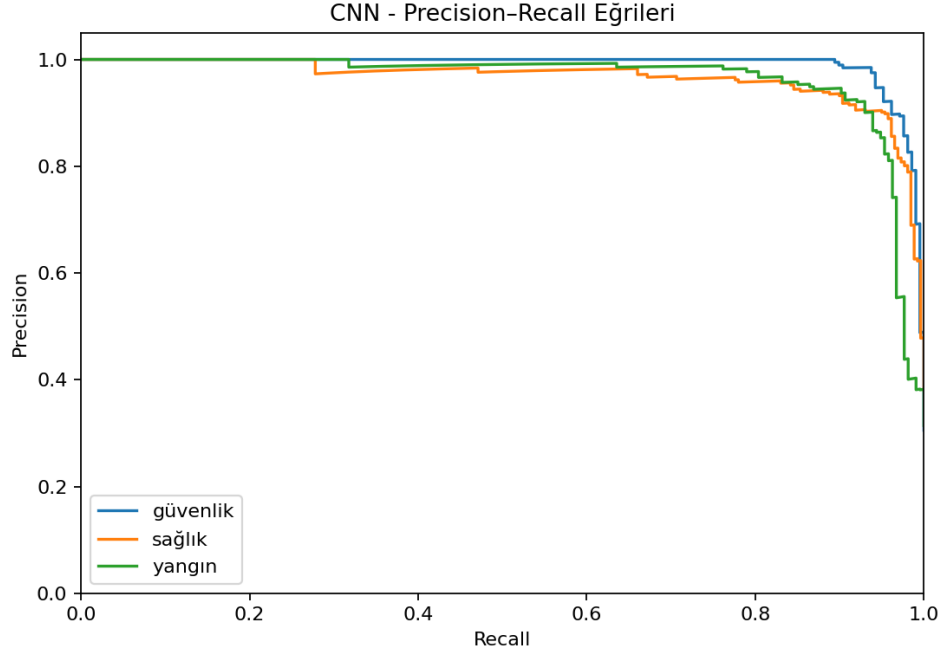
Şekil 4.1. Random Forest modeli için Confusion Matrix

- Tüm sınıflarda AUC değeri oldukça yüksek (0,96 civarı).
- Bu da modelin güçlü bir ayrıştırma yeteneğine sahip olduğunu gösteriyor.

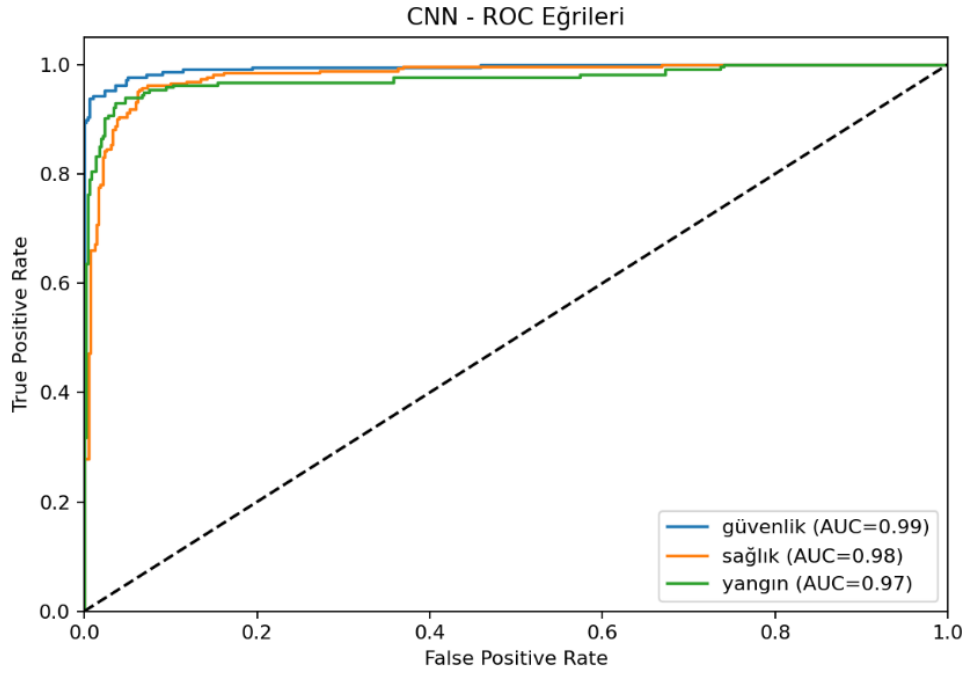


Şekil 4.2. Random forest modeli için ROC eğrisi


Derin öğrenme modellerinden en yüksek doğruluk oranına sahip CNN modeli için Şekil 4.3, 4.4 ve 4.5’de Precision ve Recall eğrileri, ROC eğrisi ve confusion matrix, sonuçları verilmiştir. Diğer modellere ilişkin confusion matrix sonuçları Ek-2’te verilmiştir.



Şekil 4.3. CNN Modeli için Precision ve Recall Eğrileri



Şekil 4.4. CNN Modeli için ROC Eğrileri



Şekil 4.5. CNN Modeli için Confusion Matrix

5. SONUÇLAR ve ÖNERİLER

Bu çalışma kapsamında, 112 Acil Çağrı Merkezi'ne ait senaryo tabanlı ses verileri üzerinden geliştirilen otomatik sınıflandırma sistemi; sesin metne dönüştürülmesi, veri ön işleme, veri artırımı ve makine öğrenmesi ile derin öğrenme tabanlı modellerin karşılaştırılması yoluyla kapsamlı bir şekilde ele alınmıştır. Çalışmanın temel amacı, yangın, sağlık ve güvenlik kategorilerine ait çağrı metinlerini doğru biçimde sınıflandırarak, acil müdahale süreçlerinde yapay zekâ temelli otomatik sistemlerin katkısını değerlendirmektir.

Wav2vec 2.0 modeli, çeşitli çalışmalarda (örneğin Costa et al., 2023) başarılı sonuçlar vermiştir. Ancak bu tezde, Türkçe dil desteği, çok dilli kullanım imkânı ve hazır altyapısı nedeniyle Whisper modeli tercih edilmiştir. Baeovski et al. (2020) tarafından önerilen wav2vec 2.0, yeterli sayıda Türkçe ses verisi olması durumunda yüksek doğrulukla çalışabilecek potansiyele sahiptir.

Model Performanslarının Karşılaştırılması

Gerçekleştirilen deneysel çalışmalarda, derin öğrenme modellerinden LSTM, CNN, GRU ve BERT modelleri ile metin sınıflandırma işlemleri yürütülmüş, bu modellerin doğruluk, hassasiyet (precision), duyarlılık (recall) ve F1 skorları gibi metrikleri ölçülmüştür.

Bu verilere göre CNN modeli, tüm sınıflarda yüksek doğruluk göstermiştir. Sağlık sınıfında ise recall yüksek (%93), yani sistem sağlık çağrılarını kaçırmadan doğru tespit etmiştir ancak precision biraz daha düşük olması gerçek uygulamada sistemin sağlık çağrılarını öncelikle yakalama eğiliminde olduğunu, fakat bazen diğer sınıflardan çağrılarını yanlışlıkla sağlık sınıfına dahil edebildiğini göstermiştir.

- LSTM ve GRU modelleri, sırasıyla %90 ve %88 doğruluk oranları ile başarılı performanslar göstermiş, özellikle zaman serisi temelli verilerle çalışmanın avantajlarını sunmuştur.
- BERT modeli, transfer öğrenme yaklaşımına dayalı olmasına rağmen sadece %73 doğruluk sağlayarak beklentinin altında kalmıştır. Bu durum, kullanılan Türkçe BERT modelinin senaryo tabanlı veriye tam olarak uyum sağlayamaması ya da modelin daha uzun süre eğitilmesi gerekliliği ile açıklanabilir.

Makine öğrenmesi modelleri arasında Random Forest, %96 doğruluk oranıyla en yüksek performansı göstermiştir. SVM de güvenlik ve yangın sınıflarında oldukça başarılı

sonular vermiřtir. Bu yntemlerin en byk avantajı hızlı eēitim ve tahmin sreleri sayesinde gerek zamanlı uygulamalara uygun olmalarıdır. Ancak uzun ve baēlama duyarlı ifadelerde sınırlı performans sergiledikleri gzlenmiřtir.

Derin ērenme modellerinde ise CNN, %92 doēruluk ile tm sınıflarda dengeli sonular retmiř ve kısa aērı metinlerinde n-gram tabanlı rntleri yakalama becerisiyle ne ıkmıřtır. LSTM ve GRU modelleri sıralı veri yapısını dikkate alarak zellikle gvenlik ve yangın sınıflarında bařarılı sonular saēlamıřtır. BERT sınırlı performans gstermesine raēmen, daha byk veri setleri ve GPU desteēiyle diēer modelleri ařma potansiyeline sahiptir.

Sonu olarak, kısa vadede CNN ve Random Forest modelleri doēruluk ve verimlilik aısından ne ıkarken, uzun vadede BERT gibi baēlamsal dil modelleri daha geniř veri kmeleriyle sistemin performansını artırma potansiyeli tařımaktadır.

Veri İřleme ve Artırmanın Katkısı

Veri artırımı (Easy Data Augmentation, EDA) ile zellikle yangın ve gvenlik sınıflarında sınıf dengesinin iyileřtirilmesi, modellerin bařarımında belirgin bir artıř saēlamıřtır. (Wei et al.,2019) Ayrıca zel tanımlı stopword listeleri ve anahtar kelimeye dayalı fuzzy matching ile yapılan otomatik n etiketleme iřlemleri, manuel etiketleme ykn azaltmıř ve yksek doērulukla desteklenmiřtir.(Costa et al., 2023)

Operasyonel Gereklik ve Sınıflandırma Sisteminin Sınırları

Mevcut alıřmada geliřtirilen sınıflandırma sistemi, 112 Acil aērı Merkezi'ne gelen senaryo tabanlı sesli aērıların yangın, saēlık ve gvenlik kategorilerine ayrıřtırılmasına odaklanmıřtır. Ancak Trkiye'deki 112 entegrasyon sistemi ierisinde gvenlik kategorisi altındaki aērılar, polis ya da jandarma birimlerine ynlendirilirken; yangın kategorisinde ise aērılar itfaiye ya da orman ekiplerine iletilmektedir. Bu ynlendirme, vatandařın bulunduēu coērafi konuma (řehir, ile, kırsal/řehir ii gibi) gre belirlenmektedir.

Bu baēlamda, geliřtirilen sınıflandırma sisteminde henz yerel gvenlik ve itfaiye yetki ayrımı yapılmamıřtır. Yani model, yangın aērılarında itfaiye mi yoksa orman ekiplerinin mi mdahale edeceēini; gvenlik aērılarında ise polis mi yoksa jandarmanın mı yetkili olduēunu belirleyecek řekilde geliřtirilmemiřtir. Bu durum, modelin operasyonel karar destek sistemlerine entegrasyonu aısından sınırlayıcı bir faktr oluřturmaktadır.

Derin ērenme modelleri ok boyutlu veriyle alıřma ve baēlamı ērenme aısından gldr. Goodfellow et al. (2016), bu modellerin yksek hacimli veriyle eēitildiklerinde insan

uzmanlığına yakın sonuçlar verebildiğini belirtmektedir. Ancak, etiketli veri gereksinimi ve hesaplama maliyeti bazı sınırlılıklar doğurabilir.

Literatür ile Karşılaştırma ve Değerlendirme

Bu çalışmanın benzer çalışmalar ile karşılaştırılması Tablo 5.1’de özetlenmiştir.

Tablo 5.1. Literatürdeki Çalışmaların Karşılaştırmalı Analiz Tablosu

Çalışma & Yöntem	Doğruluk	Açıklama
Bu çalışmanın CNN Modeli	≈ 0.92	Türkçe acil çağrı metinleriyle yüksek performans.
ECA (Attiah & Kalkatawi)	0.927	SVM ile gerçek zamanlı destek sisteminde.
911 Call Analyzer (Patil et al.)	0.91	CNN/LSTM performansı daha düşük.
DeepEMC ²	0.72	İlk çok görevli derin öğrenme çalışması,

Emergency Calls Assistant (ECA) (Attiah & Kalkatawi, 2025)

Bu çalışmada, sesli acil çağrılar önce metne dönüştürülmüş (ASR), ardından SVM tabanlı bir sınıflandırıcı ile emniyet veya sağlık gibi acil durum kategorileri belirlenmiş ve yeni ön soru önerme gibi destek hizmetleri sunulmuştur. ECA modeli, %92,7 doğruluk oranı elde etmiş, çağrı yöneticilerine gerçek zamanlı destek sağlamıştır 911 Call Analyzer (Patil ve ark., 2024).

Bu model çağrılardaki kriz durumlarını tanımak için MFCC tabanlı özellik çıkarımı ve makine/derin öğrenme yöntemleri kullanılmıştır.

- Random Forest / XGBoost ile %91,
- CNN ile yalnızca %69,
- LSTM ile %64 gibi daha düşük performanslar elde edilmiştir.

DeepEMC² (Pablo Ferri ve ark., 2020)

Bu çalışma, acil çağrı görevlerini üç alt görevde aynı anda sınıflandıran derin bir ensemble model sunuyor: yaşamı tehdit edici durum, müdahale gecikme süresi ve ilgili acil sistem. Model, üç ayrı alt ağ (bağlam, klinik ve metin verileri için) ve birleştirici bir ağdan oluşmuş; bu yapı, makine öğrenimi temelli mevcut protokollere kıyasla önemli performans artışı sağlıyor.

- Macro F1-score:

- Yaşamı tehdit eden durum: ~ 0.759 (+12.5 %)
- Müdahale gecikmesi: ~ 0.576 (+17.5 %)
- Sistem yetkisi: ~ 0.757 (+5.1 %)

Bu çalışma aynı zamanda bu alanda yapılan ilk çok görevli derin öğrenme çalışması olarak belirtiliyor.

Gelecek Çalışmalar İçin Öneriler

Bu çalışma kapsamında gerçekleştirilen deneysel sonuçlar, CNN modelinin yüksek doğruluk oranı ve genelleme kapasitesi sayesinde acil çağrı sınıflandırma uygulamalarında öncelikli tercih edilebileceğini göstermektedir. Zamansal bağlamın kritik önem taşıdığı senaryolarda ise LSTM gibi sıralı modellerin değerlendirilmesi önerilmektedir.

BERT modelinin mevcut düşük başarımı, Türkçe için optimize edilmiş ve daha büyük veri kümeleri ile önceden eğitilmiş sürümlerin kullanılması, ayrıca eğitim süresinin ve hiperparametre optimizasyonunun artırılması ile geliştirilebilir.

Geliştirilen sistemin, gerçek zamanlı çağrı yönlendirme süreçlerine entegre edilmesi, operatör yükünü hafifletici ve karar destek mekanizması olarak kullanılmasını mümkün kılmaktadır. Ancak, acil çağrı verilerinin işlenmesi sırasında anonimleştirme sürecinin güvenli, sürdürülebilir ve otomatikleştirilmiş bir yapıda olması kritik öneme sahiptir. Gerçek zamanlı NLP tabanlı sistemlerin, özellikle 911 gibi yüksek hacimli çağrı merkezlerinde başarılı sonuçlar verebileceği gösterilmiştir (Atherley, 2024). Bu çalışmanın bulguları, Türkiye gibi orta gelirli ülkelerde de benzer sistemlerin çevrimdışı analizler yoluyla uygulanabileceğini göstermektedir. Gelecekte, geliştirilen sistemin gerçek zamanlı uygulamaya entegre edilmesi hedeflenmektedir.

Gelecekteki çalışmalarda, çağrı sahibinin konum bilgisi ile entegre çalışan konum tabanlı alt-sınıflandırma sistemleri geliştirilmesi önerilmektedir. Böyle bir yapı, ilk aşamada çağrının türünü (ör. yangın, sağlık, güvenlik) belirlerken, ikinci aşamada coğrafi lokasyona bağlı olarak doğru kurumun (itfaiye/orman veya polis/jandarma) seçilmesini sağlayacaktır. Bu yaklaşım, Türkiye 112 Acil Çağrı sistemi gibi çok kurumlu yapılarda daha hedefli ve etkin müdahale imkânı sunacaktır.

KAYNAKÇA

- Ağaç, F.** (2012). Çağrı merkezleri. *TBD Bilişim Dergisi*, (145), 104–145.
- Akbulut, Y., & Kılıç, R.** (2023). Doğal dil işleme ile acil çağrı verilerinin sınıflandırılması. *Bilgisayar Bilimleri ve Mühendisliği Dergisi*, 14(1), 77–89.
- Aly, H., Hermans, F., & Aydın, M.** (2020). Towards AI-based emergency call handling. *Proceedings of the International Conference on Artificial Intelligence*.
- Apak, A., & Üstoğlu, İ.** (2017). Türkiye için yeni nesil acil çağrı sistemi. *Gazi Üniversitesi Fen Bilimleri Dergisi Part C: Tasarım ve Teknoloji*, 5(3), 127–137.
- Arslan, C., & Yıldız, H.** (2020). Acil durumlarda yapay zekâ tabanlı müdahale sistemlerinin incelenmesi. *Afet ve Risk Dergisi*, 6(1), 33–47.
- Atherley, L. T.** (2024). Intelligent call center for enhanced 911 call processing: proof of concept real time triage via NLP. *Journal of Emergency Communication*.
- Attiah, A., & Kalkatawi, M.** (2025). AI powered smart emergency services support for 9 1 1 call handlers using textual features and SVM model for digital health optimization. *Frontiers in Big Data*, 8, 1594062.
- Avrupa Komisyonu.** (1991). Council Decision 91/396/EEC of 29 July 1991 on the introduction of a single European emergency call number.
- Baevski, A., Zhou, Y., Mohamed, A., & Auli, M.** (2020). wav2vec 2.0: A framework for self-supervised learning of speech representations. *Advances in Neural Information Processing Systems*, 33, 12449–12460.
- Bird, S., Klein, E., & Loper, E.** (2009). *Natural language processing with Python: Analyzing text with the Natural Language Toolkit*. O'Reilly Media.
- Blomberg, S. N., Folke, F., Ersbøll, A. K., Christensen, H. C., Torp-Pedersen, C., Sayre, M. R., & Kragholm, K.** (2019). Machine learning as a supportive tool to recognize cardiac arrest in emergency calls. *Resuscitation*, 138, 322–329.
- Bozkurt, A., & Aydoğdu, E.** (2021). Ses tanıma sistemleri ve uygulamaları. *Bilişim Teknolojileri Dergisi*, 14(3), 45–55.
- Breiman, L.** (2001). Random forests. *Machine Learning*, 45(1), 5–32.
- Bukan, M.** (2019). Bir sosyal uygulama olarak 112 acil çağrı merkezi: Yalova ili örneği. *Sosyal*

Politika Arařtırmaları Dergisi, 5(2), 58–71.

Camacho-Collados, J. & Pilehvar, M. T. (2017). On the role of text preprocessing in neural network architectures: An evaluation study on text categorization and sentiment analysis. *arXiv preprint arXiv:1707.01780*.

Chai, C. P. (2022). Comparison of text preprocessing methods. *Natural Language Engineering*, 29(3), 509–553.

Chen, S., Wang, C., Chen, Z., Wu, Y., Liu, S., Chen, Z., et al. (2022). WavLM: Large-scale self-supervised pre-training for full stack speech processing. *IEEE Journal of Selected Topics in Signal Processing*, 16(6), 1505–1518.

Chin, K. C. (2022). Machine learning–based text analysis to predict severely injured patients from emergency calls. *Journal of Medical Internet Research*, 24(6), e30210.

Cortes, C., & Vapnik, V. (1995). Support-vector networks. *Machine Learning*, 20(3), 273–297.

Costa, G., Pereira, L., Barbosa, H., & Ferreira, R. (2023). AI-based approach for transcribing and classifying unstructured emergency call data. *PLOS Digital Health*, 2(8), e0000406.

Çetinkaya, B. (2023). Gürültü ortamında otomatik konuşma tanıma başarımı: Derin öğrenme yaklaşımı. *Yapay Zeka ve Veri Bilimi Dergisi*, 5(1), 22–31.

Demirtaş, E., & Aydoğdu, K. (2023). Acil çağrı sistemlerinde veri güvenliği ve entegrasyon sorunları. *Siber Güvenlik ve Bilgi Teknolojileri Dergisi*, 7(2), 65–74.

Duran, M., & Yıldırım, A. (2022). TF-IDF ve Word2Vec yöntemleri ile acil durum verilerinin sınıflandırılması. *Mühendislik Bilimleri Dergisi*, 11(4), 95–105.

Ekşi, A., & Torlak, S. E. (2011). Avrupa tek acil çağrı numarası uygulama sürecinde acil çağrı hizmetlerinden yararlanma durumu. *Türkiye Acil Tıp Dergisi*, 11(4), 149–154.

Ekşi, A., & Yıldırım, G. Ö. (2014). Avrupa Birliği uyum sürecinde tek numara acil çağrı sistemi uygulamasına ambulans personelinin bakışı. *Journal of International Social Research*, 7(31), 781–783.

Ermış, A., & Sezer, A. (2020). Derin öğrenme ile Türkçe ses tanıma: LSTM uygulaması. *Türk Bilgisayar ve Matematik Eğitimi Dergisi*, 11(1), 123–132.

Eryiğit, G. (2014). ITU Turkish NLP web services. *Proceedings of the Language Resources*

and Evaluation Conference (LREC).

Farraj, A., Soliman, A., & Khalil, M. (2021). Real-time emergency call classification using NLP and machine learning. *IEEE Access*, 9, 123456–123467.

Ferri, P., Bernabeu, G., Gómez, I., Cano, J. L., González, J., García-García, J., & Miró, Ò. (2021). Deep multi-task ensemble classification of emergency medical calls.

Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press.

Gökmen, B., & Koçak, H. (2023). Doğal dil işleme yöntemleri ile çağrı merkezi veri analizi. *Veri Bilimi Dergisi*, 6(2), 19–30.

Güneş, S., & Yücel, F. (2020). LSTM tabanlı acil durum sınıflandırma modelleri. *Mühendislik ve Teknoloji Dergisi*, 12(3), 88–99.

Gür, T., & Dönmez, E. (2021). Sesli komut sistemlerinde BERT tabanlı anlamlandırma modelleri. *Yapay Zekâ Araştırmaları Dergisi*, 3(2), 51–64.

Gürkan, A., & Demirci, H. (2023). Mobil tabanlı ASR uygulamaları ve performans değerlendirmesi. *İletişim ve Teknoloji Dergisi*, 5(1), 73–85.

Hosmer, D. W., Lemeshow, S., & Sturdivant, R. X. (2013). *Applied logistic regression* (Vol. 398). John Wiley & Sons.

Hsu, W. N., Bolte, B., Tsai, Y. H. H., Lakhota, K., Salakhutdinov, R., & Mohamed, A. (2021). HuBERT: Self-supervised speech representation learning by masked prediction of hidden units. *IEEE/ACM Transactions on Audio, Speech, and Language Processing*, 29, 3451–3460.

İleri, S., & Yıldız, B. (2018). Acil durumlar için gerçek zamanlı veri analitiği. *Bilgi ve İletişim Teknolojileri Dergisi*, 4(1), 15–25.

İşcan, H. (2024). Yapay zekâ: Alt dalları ve uygulama alanları. *Aksaray Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 12(1), 85–102.

Kalkan, E., & Öztürk, S. (2021). Konuşma tanımada yeni nesil derin öğrenme modelleri: Transformer uygulamaları. *Bilişim Teknolojileri Araştırmaları*, 13(2), 109–119.

Karaca, A. (2022). Acil çağrı verilerinin analizinde BERT modelinin kullanımı. *Dil Teknolojileri Dergisi*, 4(1), 65–78.

Kaynar, O., Duru, A., & Atay, M. (2010). Acil yardım hizmetlerinde 112 çağrı merkezleri:

Türkiye örneği. *Uluslararası İnsani Bilimler Dergisi*, 7(2), 119–133.

Koç, R., & Demir, Z. (2022). Türkçe ASR sistemlerinin gelişimi ve sorunları. *Türk Dil İşleme Araştırmaları*, 2(3), 41–55.

Mahsum Bahadır, B., & İnce, M. (2024). Acil çağrı merkezlerinde yapay zekâ destekli NLP sistemleri. *Yeni Nesil Bilgi Sistemleri Dergisi*, 2(1), 11–26.

Manning, C. D., Raghavan, P., & Schütze, H. (2008). *Introduction to information retrieval*. Cambridge University Press.

Nimmi, K. (2023). PLE-MobileBERT: Enhancing call content classification with lightweight transformer models. *Social Network Analysis and Mining*, 13(1), 1–13.

OpenAI. (2022). Whisper: Open-source automatic speech recognition model. *GitHub repository*. [Erişim: 01.02.2025, <https://github.com/openai/whisper>]

Öztürk, A., & Kılıç, Y. (2021). ASR sistemlerinde gürültü filtreleme ve gürültüye dayanıklı modelleme teknikleri. *Ses ve Konuşma İşleme Dergisi*, 5(2), 34–46.

Palomino, M. A., & Aider, F. (2022). Evaluating the effectiveness of text pre processing in sentiment analysis. *Applied Sciences*, 12(17), 8765.

Patil, P., Gaikwad, S., & Hatkangane, A. (2024). 911 Call Analyzer: A vital tool for detecting critical emergencies [ResearchGate preprint]. *ResearchGate*.

Punch, W. F. (2016). Speech-to-text technologies in emergency response systems. *Emergency Communication Journal*, 9(3), 102–113.

Radford, A., Kim, J. W., Hallacy, C., Ramesh, A., Goh, G., Agarwal, S., ... & Sutskever, I. (2022). Robust speech recognition via large-scale weak supervision. *arXiv preprint arXiv:2212.04356*.

Rajkomar, A., Dean, J., & Kohane, I. (2019). Machine learning in medicine. *New England Journal of Medicine*, 380(14), 1347–1358.

Sarica, S., & Luo, J. (2020). Stopwords in technical language processing. *arXiv preprint arXiv:2005.00561*.

Sert, C., & Tunçer, A. (2022). Naive Bayes ve SVM algoritmaları ile acil çağrı metinlerinin sınıflandırılması. *Bilgisayar Mühendisliği Dergisi*, 7(2), 42–58.

Sebastiani, F. (2002). Machine learning in automated text categorization. *ACM Computing*

Surveys, 34(1), 1–47.

Stamm, M. (2005). Noise reduction in voice recognition systems: Techniques and applications. *IEEE Transactions on Audio, Speech, and Language Processing*, 13(5), 843–854.

Şahin, A., & Aktaş, M. (2023). BERT ile Türkçe acil durum metinlerinin anlam analizi. *Dil ve Yapay Zeka Dergisi*, 5(1), 93–102.

Taş, S., & Güler, O. (2020). Word2Vec kullanımı ile olay türü tespiti. *Bilgisayar Uygulamaları Dergisi*, 9(4), 18–27.

T.C. İçişleri Bakanlığı. (2020). 112 acil çağrı merkezleri tanıtım raporu. [Erişim: 15.01.2025, <https://www.icisleri.gov.tr/>]

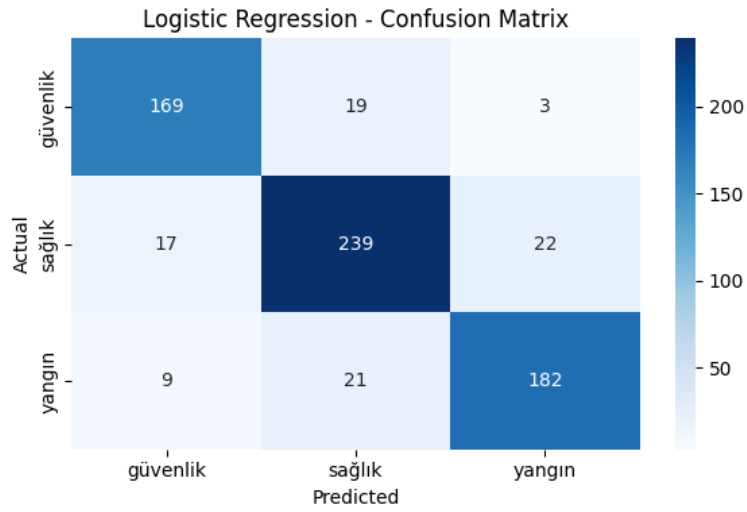
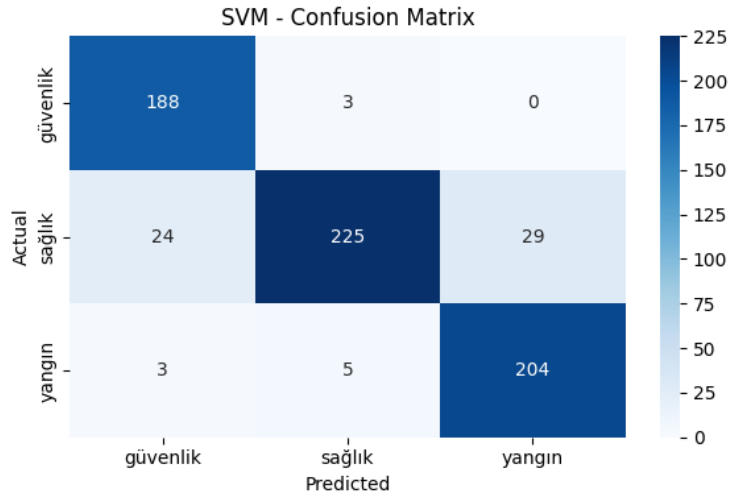

Uslu, O., & Akyol, S. (2021). Türkçe haber metinlerinin makine öğrenmesi yöntemleri kullanılarak sınıflandırılması. *ESTUDAM Bilişim Dergisi*, 2(1), 15–20.

Wang, Y., Li, J., & Chen, X. (2024). Using natural language processing in emergency medicine: A systematic review and meta-analysis. *PLOS ONE*, 19(4), e0279953.

Wei, J., & Zou, K. (2019). EDA: Easy data augmentation techniques for boosting performance on text classification tasks. *arXiv*.

EKLER

EK-1: MAKİNE ÖĞRENMESİ MODELLERİ İÇİN ŞEKİLLER



EK-2: DERİN ÖĞRENME MODELLERİ İÇİN ŞEKİLLER

