

ACİL DURUM ÇAĞRILARININ DOĞAL DİL İŞLEME TEKNİKLERİ İLE SINIFLANDIRILMASI

Y. Lisans öğrencisi, Özlem TAN¹/ Dr. Öğr. Üyesi, Rıdvan YAYLA²

¹Bilecik 112 Acil Çağrı Merkezi Müdürlüğü, Mühendis, ozlem.tan@icisleri.gov.tr, 0009-0006-0303-3360

²Bilecik Şeyh Edebali Üniversitesi, Bilgisayar Mühendisliği, ridvan.yayla@bilecik.edu.tr, 0000-0002-1105-9169

Özet

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. Çalışmada, "ambulans talebi", "trafik kazası", "yangın ihbarı", "polis yardımı", "tıbbi acil durum" ve "diğer" şeklinde tanımlanan geniş kapsamlı bir sınıflandırma şeması geliştirilmiştir. Makine öğrenmesi yaklaşımı olarak Naive Bayes, destek vektör makineleri (SVM), random forest ve Logistic Regresyon algoritmaları ile birlikte derin öğrenme tabanlı LSTM, GRU ve BERT modelleri karşılaştırmalı olarak değerlendirilmiştir. Model performansları kesinlik, duyarlılık ve F1-skor standart doğruluk metrikleri ile ölçülmüştür. 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 servislerin dijital dönüşüm çalışmalarına katkı sağlayacağı öngörülmektedir.

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

CLASSIFICATION OF EMERGENCY CALLS USING NATURAL LANGUAGE PROCESSING TECHNIQUES

Abstract

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. In the study, a comprehensive classification scheme defined as "ambulance request", "traffic accident", "fire report", "police assistance", "medical emergency" and "other" was developed. 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 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

GİRİŞ

Acil durumlar, anında müdahale ve etkili yönetim gerektiren, beklenmedik ve genellikle yıkıcı olaylardır. Depremler, sel felaketleri, yangınlar, salgın hastalıklar gibi çeşitli acil durumlar, hem bireylerin hem de toplumların hayatlarını ve güvenliğini ciddi şekilde tehdit edebilir. 112 Acil Çağrı Merkezleri, kamu düzeni, toplumsal güvenlik ve bireysel sağlık gibi hayati alanlarda acil müdahale gerektiren durumlara yanıt verebilmek amacıyla yapılandırılmış entegre sistemlerdir (İçişleri Bakanlığı, 2020). Türkiye’de yürürlüğe giren tek numara sistemi ile yangın, sağlık, güvenlik ve trafik gibi farklı kategorilerdeki acil çağrılar tek merkezde toplanmakta, bu da daha hızlı ve koordineli müdahaleyi mümkün kılmaktadır (AFAD, 2018). Ancak çağrı yoğunluğunun artması ve operatör kaynaklarının sınırlı oluşu, bu merkezlerin iş yükünü artırmakta ve müdahale sürelerini olumsuz etkileyebilmektedir (Bukan, 2019).

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 (Bahadır & İnce, 2024).

Amaç

Bu çalışmanın temel amacı, yapay zekâ ve doğal dil işleme (NLP) tekniklerinden faydalanarak 112 Acil Çağrı Merkezlerinde ilk değerlendirme sürecini otomatikleştiren bir ön sınıflandırma sistemi geliştirmektir. Geliştirilen sistem, çağrının ilk saniyelerinde sesli veriyi metne çevirerek içerik analizi yapmakta ve çağrıyı yangın, trafik kazası veya sağlık gibi kategorilere ayırarak ilgili birimlere hızlı yönlendirme yapılmasını sağlamaktadır. Bu süreç, insan operatörleri destekleyecek biçimde tasarlanmış olup, operatör yükünü azaltmayı ve müdahale süresini kısaltmayı hedeflemektedir. Bilecik ili özelinde geliştirilen bu yapay zekâ temelli model, gerçek senaryolara dayalı veriler kullanılarak test edilmekte ve acil çağrı yönetim süreçlerine entegre edilebilir bir çözüm sunmaktadır.

Acil çağrı merkezleri, hayat kurtarıcı müdahalelerin ilk adımı olan kritik altyapılar arasındadır. Artan çağrı hacmiyle birlikte, gelen aramaların hızlı ve doğru biçimde analiz edilip yönlendirilmesi, hem hizmet kalitesi hem de müdahale süresi açısından büyük önem taşımaktadır. Bu çalışmada, çağrı merkezlerine gelen sesli aramaların otomatik olarak sınıflandırılmasını amaçlayan bir doğal dil işleme (NLP) tabanlı sistem önerilmektedir. Önerilen sistem, ses dosyalarının metne dönüştürülmesi, otomatik sınıflandırılması, veri artırımı yapılması ve elde edilen verilerle eğitilen makine öğrenmesi ve derin öğrenme modellerinin başarılarının karşılaştırılmasını içermektedir. Bu sayede, müdahale sürelerinin kısaltılması ve operasyonel verimliliğin artırılması hedeflenmektedir.

Literatür Taraması

Acil çağrı merkezleri, kamu hizmetlerinde vatandaşla ilk temas noktası olarak konumlanmakta ve bilgi teknolojileri ile yapay zekâ (YZ) destekli sistemlerle kamu güvenliğinin artırılmasında kritik rol oynamaktadır (Apak & Üstoğlu, 2017). Bu merkezlerde doğal dil işleme (NLP), sınıflandırma algoritmaları ve veri madenciliği gibi yöntemlerin entegrasyonu giderek artmaktadır.

Türkiye bağlamında yapılan çalışmalarda, 112 sisteminin teknik yapısı kadar sosyal boyutları da ele alınmıştır. Örneğin, Ekşi ve Yıldırım (2014), sağlık personelinin sisteme yönelik algılarını analiz etmiş ve NLP tabanlı analiz araçlarının gerekliliğini vurgulamıştır. Bukan (2019) ise çağrı merkezlerini yalnızca teknik değil, aynı zamanda sosyal bir iletişim ağı olarak tanımlamış, makine öğrenmesi ile insan faktörünün birlikte çalışması

gerektiğini belirtmiştir. Benzer şekilde, Ekşi ve Torlak (2011), sistemin vatandaşlar üzerindeki etkilerini incelemiş ve farkındalık düzeyinin artırılmasının önemine dikkat çekmiştir.

Çağrı verilerinin analizinde karar destek sistemleri ve kurumsal yapılar da önemlidir. Ağaç (2012), Türkiye’deki çağrı merkezlerinin performans ölçütlerini değerlendirerek dijital karar destek sistemlerinin entegrasyonunu önermiştir. Stamm (2005), çağrı operatörlerinin duygusal yükünü analiz etmek için “ProQOL” ölçeğini kullanmış, NLP ile bu verilerin içerik analizi yapılabileceğini göstermiştir.

NLP’nin başarısı, veri etiketleme kalitesi ve güncelliğiyle doğrudan ilişkilidir. Mahsum Bahadır ve İnce (2024), aktif ve çevrimiçi öğrenme yöntemlerinin 112 sistemlerine uygulanabilirliğini inceleyerek, veri tazeliğinin model başarısına etkisini ortaya koymuştur.

Karma yöntem araştırmaları (Creswell & Plano Clark, 2014; Punch, 2016), NLP uygulamalarının yalnızca nicel değil, aynı zamanda nitel analizlerle desteklenmesi gerektiğini ortaya koymuştur. Etik ve güvenlik açısından, çağrı metinlerinde kişisel verilerin bulunması nedeniyle yasal düzenlemelere (ör. KVKK) tam uyumun sağlanması gerekmektedir (Stamm, 2005; Bahadır & İnce, 2024). Bu bağlamda, NLP sistemlerinin yalnızca algoritmik değil, aynı zamanda etik ve hukuki çerçevede de optimize edilmesi zorunludur.

Acil durum yönetimi, hızlı ve etkili müdahalelerin hayati öneme sahip olduğu durumlarda kritik bir rol üstlenmektedir. Bu süreçte, acil çağrı merkezleri halktan gelen yardım taleplerini almakta, değerlendirmekte ve ilgili müdahale birimlerine yönlendirmektedir. Doğal dil işleme (DDİ) teknikleri, bu sürecin hızlandırılması ve doğru bir şekilde yürütülmesi için önemli katkılar sunmaktadır. Özellikle çağrıların metne dönüştürülmesi ve sınıflandırılması, kriz anlarında zamanında müdahaleyi kolaylaştırarak etkin karar alma süreçlerini desteklemektedir (Jurafsky & Martin, 2023).

Metin sınıflandırma, DDİ’nin diğer önemli bir bileşenidir. Çağrı metinleri üzerinde yapılan analizler sayesinde olayın türü ve aciliyet derecesi belirlenebilmektedir. Liu ve arkadaşları (2016), destek vektör makineleri (SVM) ve derin öğrenme yöntemlerinin bu amaçla başarılı bir şekilde kullanılabileceğini göstermiştir..

Gerçek zamanlı veri işleme sistemleri, acil müdahale süreçlerinde zaman kaybını en aza indirerek çağrılarının anında analiz edilmesine olanak tanımaktadır. Li ve arkadaşları (2020), gerçek zamanlı sistemlerin kriz yönetimindeki avantajlarını detaylandırmıştır.

Doğal dil işleme (NLP) ve makine öğrenmesi gibi yapay zekâ tabanlı yaklaşımlar, çağrı merkezlerinin bu zorluklarla başa çıkmasına katkı sağlayan teknolojik çözümler sunmaktadır. NLP sistemleri, çağrı metinlerinin otomatik sınıflandırılması, aciliyet düzeyinin belirlenmesi ve operatör kararlarının desteklenmesi gibi alanlarda etkin biçimde kullanılmaktadır (Apak & Üstoğlu, 2017). Avrupa Birliği uyum sürecinde uygulanan 112 sisteminin değerlendirmesinde de, dijital analiz araçlarının entegrasyonunun hizmet kalitesini artırdığı ortaya konmuştur (Ekşi & Yıldırım, 2014).

Çağrı merkezlerinin yalnızca teknik altyapılar değil, aynı zamanda sosyal etkileşim alanları olduğu ve insan faktörünün sistem işleyişinde kritik bir rol oynadığı çeşitli saha araştırmalarında vurgulanmıştır (Bukan, 2019). Bu bağlamda, NLP tekniklerinin yalnızca çağrı içeriği analiziyle sınırlı kalmayıp, aynı zamanda çağrının duygusal tonu ve operatör üzerindeki psikolojik etkiler gibi parametreleri analiz edebilecek kapasitede olması gerektiği belirtilmektedir (Stamm, 2005).

Çağrı verilerinin kısa, eksik ve bağlamdan yoksun yapısı, metin sınıflandırmasında özel algoritmaların kullanılmasını zorunlu kılmaktadır. Derin öğrenme tabanlı modeller (LSTM, Transformer) bu noktada geleneksel yöntemlere göre daha başarılı sonuçlar vermektedir. Ayrıca, veri etiketi doğruluğu ve veri tazeliği gibi faktörler, NLP sistemlerinin başarısında belirleyici unsurlar arasında yer almaktadır (Bahadır & İnce, 2024).

Bu çerçevede, acil çağrı merkezlerinde NLP tabanlı sistemlerin kullanımı, sadece operasyonel verimlilik değil, aynı zamanda etik uygunluk, kullanıcı memnuniyeti ve kamu güvenliğine katkı bakımından da kritik bir öneme sahiptir.

Tüm bu çalışmalar, doğal dil işleme tekniklerinin acil çağrı merkezlerinde çağrılarının metne dönüştürülmesi ve sınıflandırılması süreçlerinde önemli avantajlar sağladığını ortaya koymaktadır. Konuşma tanıma ve metin sınıflandırma sistemleri, hızlı ve doğru müdahaleyi mümkün kılar; veri güvenliği, çok dilli destek ve gerçek zamanlı işleme gibi alanlarda hâlen çözülmesi gereken zorluklar mevcuttur. Gelecekte yapılacak araştırmalar, bu teknolojilerin etkinliğini artırarak toplumların krizlere karşı daha dirençli hale gelmesine katkı sağlayacaktır.

1. KURAMSAL ÇERÇEVE

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, çağrılarının içeriği, zamanlaması, konumu ve yönlendirme bilgileri gibi çok boyutlu verileri barındıran gelişmiş bilgi sistemleriyle donatılmıştır. Bu veriler yalnızca operasyonel süreçlerde değil, uzun vadeli stratejik planlama ve kamu politikalarının oluşturulmasında da kullanılmaktadır (Stamm, 2005).

- Veri Yapısı ve Kategorileri

Acil çağrı verileri çok katmanlı bir yapıya sahiptir. Gelen çağrı sayısı, çağrı türü (asayiş, sağlık, yangın vb.), çağrının gerçeklik durumu, olay yeri, yönlendirme süresi, müdahale süresi ve sonuç bilgileri gibi parametreler sistemli biçimde kayıt altına alınır. Her veri kaydında tarih, saat, GPS koordinatları ve operatör bilgileri de tutulur. Bu sayede hem veri bütünlüğü sağlanır hem de olaylar geriye dönük olarak denetlenebilir hale gelir (Ağaç, 2012).

- Gerçek Zamanlı Analiz Özellikleri

112 sistemlerinde yer alan karar destek panelleri ve dashboard uygulamaları aracılığıyla çağrı yoğunluğu, lokasyon bazlı vaka dağılımı ve yönlendirme oranları anlık olarak izlenebilir. Bu özellik, örneğin aynı bölgeden arka arkaya gelen trafik kazası ihbarlarında sistem yöneticisinin hızlı müdahale kararı almasını sağlar. Yerel yönetimler de bu verilerle afet planlaması ve kamu güvenliği stratejilerini oluşturabilmektedir (Zhang ve arkadaşları 2014).

- Veri Güvenliği ve KVKK Kapsamı

112 Acil Çağrı Merkezi verileri, Kişisel Verilerin Korunması Kanunu (KVKK) kapsamında özel önlemlerle korunmaktadır. Erişim yetkileri sınırlandırılmış, veri analizi yapacak personel özel yetkilendirme süreçlerine tabi tutulmuştur. Günlük yedekleme ve şifrelenmiş sunucu sistemleriyle veri güvenliği sağlanmakta; ses kayıtları ise dijital ortamda saklanarak adli süreçlerde delil olarak kullanılabilir (Ekşi & Yıldırım, 2014).

- Asılsız Çağrılar ve Önleme Mekanizmaları

Türkiye’de acil çağrı sistemlerinde en büyük sorunlardan biri asılsız aramalardır. 2023 yılı verilerine göre bu oran yaklaşık %60’tır. Bu çağrılar arasında telefon şakaları, yanlış tuşlamalar ve bilgi amaçlı aramalar yer almaktadır. Sistem, bu tür çağrılarını analiz ederek kamuya yönelik bilinçlendirme kampanyaları (örneğin kamu spotları) düzenlenmesini mümkün kılar (Bahadır & İnce, 2024). Ayrıca çocuklar tarafından yapılan asılsız çağrılar velilere bildirilmektedir.

- Stratejik Kullanım Alanları

Toplanan veriler yalnızca olayın takibi için değil, ülke genelinde kamu hizmetlerinin planlanması için de kritik rol oynar. Sağlık Bakanlığı, ambulans hizmetlerinin dağılımında; Emniyet Genel Müdürlüğü ise suç yoğunluğu haritalarının çıkarılmasında bu verilere başvurmuştur. Orman yangını ihbarlarının mekânsal analizine dayanarak erken uyarı sistemleri ve mobil ekip konuşlandırmaları da yapılmaktadır (Baltacı, 2018).

- Sosyal Etkiler ve Psikolojik Yorumlama

Acil çağrı verileri aynı zamanda toplumun genel psikolojik durumunun da bir göstergesidir. Örneğin deprem sonrası gelen panik çağrılar, toplumda oluşan stres düzeyine dair çıkarımlara olanak tanır. Kentleşmenin yoğun olduğu bölgelerde artan asılsız ihbarlar ise güvenlik algısındaki zayıflamanın bir göstergesi olabilir (Ağaç, 2012).

112 Acil Çağrı Merkezleri, yalnızca olaylara müdahale eden yapılar değil, aynı zamanda büyük ve anlamlı bir veri havuzudur. Toplanan veriler; teknolojik, yönetsel, toplumsal ve hukuki boyutlarıyla çok disiplinli kullanım alanına sahiptir. Özellikle büyük şehirlerde on binleri bulan günlük çağrı sayısı düşünüldüğünde, bu verilerin doğru analiz edilmesi hem kriz yönetimi hem de hizmet kalitesinin artırılması açısından kritik önemdedir. Giderek dijitalleşen kamu hizmetleri içinde 112 verilerinin geleceğe dönük şekilde kullanımı, stratejik bir gereklilik halini almıştır (Stamm, 2005; Ağaç, 2012).

Sesi Metne Çevirme

Sesi metne çevirme (SMÇ) sistemleri, konuşulan dili otomatik olarak yazıya döken teknolojilerdir. Bu sistemler, insan-makine etkileşimini daha doğal hale getirerek özellikle çağrı merkezleri, asistan sistemleri, toplantı transkripsiyonları ve sağlık sektörü gibi pek çok alanda yaygın biçimde kullanılmaktadır (Jurafsky & Martin, 2023). SMÇ 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.

- Ses Sinyalinin İşlenmesi ve Özellik Çıkarımı

SMÇ sistemlerinin ilk adımı, ses sinyalinden anlamlı öznitelikler (features) çıkarmaktır. Bu süreçte genellikle **Mel Frekans Kepstrum Katsayıları (MFCC)**, **Linear Predictive Coding (LPC)** ya da **Filter Bank** temelli teknikler kullanılır (Rabiner & Schafer, 2011). MFCC, insan kulağının frekans algısına benzer bir şekilde sinyali analiz eder ve bu sayede tanıma başarısını artırır. Bu teknik, sesin kısa zamanlı enerji yoğunluğunu temsil eden spektral özniteliklerin çıkarılmasına olanak tanır (Gales & Young, 2008).

- Otomatik Konuşma Tanıma Yaklaşımları

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

1. **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).
2. **Gaussian Mixture Models (GMM):** HMM'lerle birlikte öznitelik dağılımını modellemede kullanılmıştır. Ancak bu yöntemler karmaşık dil yapılarını modellemede yetersiz kalmıştır.
3. **Derin Öğrenme Modelleri:** Özellikle **Derin Sinir Ağları (DNN)**, **Uzun Kısa Süreli Bellek (LSTM)** ve **Transformer** tabanlı modeller konuşma tanıma devrim yaratmıştır. Özellikle **Whisper** (Radford et al., 2022) gibi açık kaynaklı büyük dil modelleri, hem çok dilli hem de çok amaçlı kullanım için tasarlanmış ve SMÇ başarımını önemli ölçüde artırmıştır.

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

- Dil Modeli Entegrasyonu

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.

- Değerlendirme Ölçütleri

SMÇ 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.

- Güncel Uygulamalar ve Etik Boyutlar

Whisper, OpenAI tarafından geliştirilen ve geniş hacimli çok dilli konuşma verisiyle eğitilmiş açık kaynaklı bir SMÇ modelidir. Model hem düşük kaynaklı dillerde hem de gürültülü ortamlarda yüksek performans göstermektedir (Radford et al., 2022). Bununla birlikte, SMÇ sistemlerinin kullanımında veri gizliliği, konuşmacı rızası ve anonimleştirme gibi etik hususlar da göz önünde bulundurulmalıdır. Özellikle kamu kurumlarına ait çağrı verilerinde, konuşmacı kimliğini açığa çıkarabilecek içeriklerin dikkatle işlenmesi gerekmektedir.

- Acil Durumlarda Gerçek Zamanlı Ses-Metin Dönüşümünün Önemi

Gerçek zamanlı ses-metin dönüşüm sistemleri (ASR), acil çağrı merkezlerinde sözlü iletişimin hızlı ve doğru şekilde yazıya aktarılmasını sağlar (Apak & Üstoğlu, 2017). Operatörlerin yükünü azaltır, karar süreçlerini hızlandırır ve müdahale süresini kısaltır (Ekşi & Torlak, 2011; Bukan, 2019). Ayrıca kayıtların standartlaşmasına, veri analizine, hukuki süreçlere ve kapsayıcılığa (ör. işitme engelliler için) katkıda bulunur. Gürültü, lehçeler, çoklu dil, kanal çeşitliliği gibi zorluklar, gelişmiş algoritmalar, yerel modeller ve operatör onaylı hibrit sistemlerle aşılar (Bahadır & İnce, 2024). Erişilebilirlik, veri güvenliği, kalite kontrol ve sürekli eğitim de sistemin başarısında önemli rol oynar (Punch, 2016; Creswell & Plano Clark, 2011).

Tablo 1: ASR Zorlukları ve Çözümleri

ZORLUKLAR	ÇÖZÜM ÖNERİLERİ
Arka plan gürültüsü	Gürültü azaltma
Türkçeye özgü yapı	Türkçe dil modelleri
Lehçeler, argo kelimeler	Çevrimiçi öğrenme
Çoklu kanal	Hibrit sistem
Veri gizliliği	KVKK uyumu

112 Acil Çağrı Merkezlerinde Doğal Dil İşleme (NLP) Yöntemleri

Günümüzde 112 Acil Çağrı Merkezlerinde, artan çağrı hacmi ve veri çeşitliliği, yalnızca sayısal değil, metin tabanlı veri analizlerini de zorunlu hale getirmiştir (Ekşi & Yıldırım, 2014). Çağrılarının ses ve metin içerikleri üzerinde yapılan analizlerde, Doğal Dil İşleme (NLP) teknikleri önemli bir rol oynamaktadır. NLP, insan

dilinde ifade edilen veriyi bilgisayarların işleyebileceği biçime dönüştürerek, olay sınıflandırma, aciliyet derecelendirme, özetleme ve duygu analizi gibi işlemleri mümkün kılmaktadır (Jurafsky & Martin, 2023).

112 çağrılarında NLP uygulamaları, çağrının içeriğine bağlı olarak olayın türünün otomatik belirlenmesi (ör. yangın, trafik kazası, sağlık), aciliyet derecesinin saptanması (Ekşi & Torlak, 2011) ve arayan kişinin ruh halinin (sentiment/stres düzeyi) analiz edilmesi gibi amaçlarla kullanılmaktadır (Creswell & Plano Clark, 2011). Özellikle yoğun saatlerde, NLP destekli otomatik sınıflandırma sistemleri, operatörlerin iş yükünü azaltmakta ve müdahale hızını artırmaktadır (Kaynar et al., 2010).

• NLP'nin 112 Çağrı Sistemlerindeki Önemi

Artan çağrı hacmi ve veri çeşitliliği, yalnızca sayısal değil metin temelli analizleri de gerekli hale getirmiştir (Ekşi & Yıldırım, 2014). NLP, insan dilinde ifade edilen veriyi bilgisayarların işleyebileceği yapıya dönüştürerek olay sınıflandırma, aciliyet derecelendirme, özetleme ve duygu analizi yapılmasını mümkün kılar (Jurafsky & Martin, 2023). Yoğun saatlerde NLP destekli sistemler, operatörlerin iş yükünü azaltarak müdahale hızını artırır.

• Metin Ön İşleme Teknikleri

NLP süreçlerinin temelini oluşturur; ham metni temizleyip standardize ederek analiz edilebilir hale getirir (Ağaç, 2012). Türkçe'deki eklemeli yapı ve ağız farklılıkları nedeniyle özel ön işleme teknikleri gerektirir (Ekşi & Yıldırım, 2014).

Yaygın teknikler:

1. Küçük harfe çevirme.
2. Noktalama işaretlerini temizleme.
3. Durak kelimelerin çıkarılması (stop words).
4. Gövdeleme (lemmatization) ve kök bulma (stemming).
5. Gürültü (noise) temizleme ve tokenizasyon (Zhang, 2003).

Bölgesel dil farklılıkları için yerel sözlükler ve özel corpus'lar kullanılır (Apak & Üstoğlu, 2017).

• Özellik Çıkarımı Yöntemleri

Metinleri sayısal temsillere dönüştürerek makine öğrenmesi için kullanılabilir hale getirir (Creswell & Plano Clark, 2011). Yöntemler:

1. **TF-IDF**: Kelimelerin belgeler üzerindeki önemini istatistiksel olarak hesaplar (Ağaç, 2012).
2. **Word2Vec**: Kelimelerin semantik yakınlıklarını öğrenerek anlam kümeleri oluşturur (Ekşi & Torlak, 2011).
3. **BERT**: Bağlama duyarlı, kelimeleri çevresindeki sözcüklerle birlikte değerlendirir (Jurafsky & Martin, 2023).
4. **BERTurk**: Türkçe'ye özgü önceden eğitilmiş BERT modeli ile daha iyi uyum sağlar (Stamm, 2005).

Özellik çıkarımı sayesinde olay türü daha doğru belirlenir ve çoklu görev yönetimi yapılabilir (Punch, 2016).

• NLP'nin Uygulama Alanları

1. Olay sınıflandırması: Yangın, trafik kazası, sağlık vb. olayları doğru sınıflandırır.
2. Aciliyet derecesi belirleme: Kritik çağrılara öncelik verilmesini sağlar.
3. Duygu/stres analizi: Arayanın ruh hali tespit edilerek uygun destek sağlanır (Ekşi & Torlak, 2011).
4. Otomatik özetleme: Çağrı notlarının özetlenmesi ve anahtar kelimelerin çıkarılması (Creswell & Plano Clark, 2011).

- **Etik ve Yasal Gereklilikler**

Kişisel verilerin anonimleştirilmesi, KVKK/GDPR uyumu zorunludur (Creswell & Plano Clark, 2011). Yanlılık, yanlış sınıflandırma ve açıklanabilirlik sorunlarına karşı dikkatli olunmalıdır (Bukan, 2019; Punch, 2016).

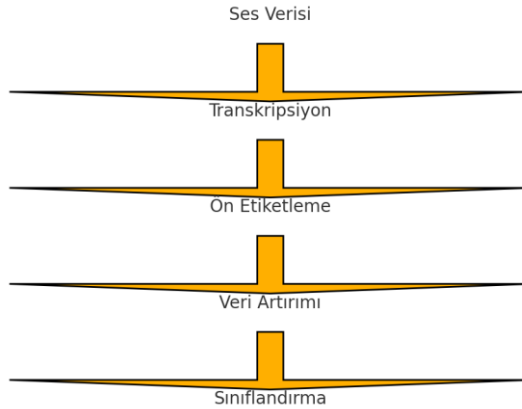
- **Başarıyı Etkileyen Faktörler**

1. Veri kalitesi: Gürültülü, eksik ve düzensiz veriler performansı düşürür.
2. Etiketleme: Doğru ve bağlama uygun etiketleme şarttır (Ekşi & Yıldırım, 2014).
3. Model Güncellemeleri: Yeni kelimeler ve olaylara karşı modellerin güncel tutulması gerekir (Stamm, 2005)

2. YÖNTEM

Bu çalışmada geliştirilen otomatik acil çağrı sınıflandırma sistemi, dört temel aşamadan oluşmaktadır: ses verisinin metne dönüştürülmesi, ön etiketleme, veri artırımı ve makine öğrenmesi ile derin öğrenme modelleriyle sınıflandırma. Kullanılan yöntem adımları aşağıda detaylandırılmıştır.

Şekil 1: Kullanılan Yöntem Adımları



- **Ses Verisinin Metne Dönüştürülmesi**

Araştırmada kullanılan veri seti, gerçek çağrı merkezi ortamından toplanan toplam 316 adet `.wav` formatındaki ses kaydından oluşmaktadır. Ses verileri üzerinde öncelikle kalite standartlarını sağlamak amacıyla 16-bit PCM formatına dönüştürme işlemi uygulanmıştır. Ardından her bir ses dosyası için Türkçe konuşma tanıma desteği sunan Google Speech Recognition API'si kullanılarak transkripsiyon işlemi gerçekleştirilmiş ve sonuçlar `transcriptions.csv` dosyasında saklanmıştır (Jurafsky & Martin, 2023; Graves et al., 2013).

- **Ön Etiketleme**

Transkripsiyon işleminin ardından elde edilen metinler üzerinde, ön etiketleme işlemi anahtar kelime tabanlı olarak gerçekleştirilmiştir. Her metin, içerdiği kelimelere göre öncelikli olarak yangın, polis, ambulans ya da diğer sınıflardan birine atanmıştır. Anahtar kelimeler Türkçe acil durum literatüründen belirlenmiş ve öncelik sırasına göre etiketleme yapılmıştır (Ramesh et al., 2021). Etiketlenmiş veri `transcriptions_with_labels.csv` dosyasına kaydedilmiştir.

- **Veri Artırımı ve Dengeleme**

Etiketlerin dağılımında dengesizlik gözlemlendiğinden, sınıflar arası eşitliği sağlamak ve modelin eğitimi sırasında önyargıları azaltmak amacıyla sentetik veri artırımı uygulanmıştır. Faker kütüphanesi kullanılarak, Türkçe cümle yapısına uygun, sınıfları temsil eden yeni metin örnekleri üretilmiştir. Böylece toplam veri sayısı 400'e tamamlanmış ve her sınıftan yaklaşık eşit sayıda örnek içeren bir veri seti elde edilmiştir (Chawla et al., 2002).

- Sınıflandırma ve Model Eğitimi

Dengelenmiş veri seti üzerinde hem klasik makine öğrenmesi hem de derin öğrenme modelleri eğitilmiş ve karşılaştırmalı olarak değerlendirilmiştir. Klasik yöntemlerde metinler, TF-IDF vektörleştirme yöntemiyle sayısallaştırılmış ve Naive Bayes, Destek Vektör Makineleri (SVM), Random Forest ve Lojistik Regresyon modelleri ile eğitilmiştir (Sebastiani, 2002). Derin öğrenme yöntemlerinde ise metinler Tokenizer ile dizileştirilmiş ve LSTM, GRU, CNN mimarileri denenmiştir (Goodfellow et al., 2016). Tüm modellerin performansı doğruluk, kesinlik, duyarlılık ve F1-skor metrikleri ile değerlendirilmiştir.

BB. Tablo 2: Örnek Etiketlenmiş Veriler

Dosya Adı	Metin	Etiket
ses_001.wav	112 acil, iki araç kaza yaptı	polis
ses_045.wav	Çatıdan dumanlar çıkıyor, yangın var	yangın
ses_122.wav	Bir kişi bayıldı, ambulans lazım	ambulans

3. BULGULAR

Çalışmada geliştirilen sınıflandırma sisteminin performansı, klasik makine öğrenmesi ve derin öğrenme tabanlı farklı modellerle karşılaştırmalı olarak değerlendirilmiştir. Toplamda 400 dengelenmiş ve etiketlenmiş metin üzerinde yapılan deneylerde, modellerin doğruluk (accuracy) oranları Tablo 3'te sunulmuştur.

Tablo 3: Modellerin Doğruluk Karşılaştırması

Model	Doğruluk (%)
Naive Bayes	75.28
SVM	71.91
Random Forest	79.78
Logistic Regression	69.66
LSTM	64.04
GRU	62.92
CNN	75.28

Elde edilen sonuçlara göre, klasik makine öğrenmesi modellerinden Random Forest, %79.78 doğruluk oranı ile en iyi performansı göstermiştir. Naive Bayes ve CNN modelleri ise %75.28 doğruluk oranı ile başarılı sonuçlar sunmuştur. Destek Vektör Makineleri (SVM) ve Lojistik Regresyon, sırasıyla %71.91 ve %69.66 oranlarında doğruluk sağlamıştır.

Derin öğrenme modelleri olan LSTM ve GRU, sırasıyla %64.04 ve %62.92 doğruluk oranları ile klasik modellere kıyasla daha düşük performans göstermiştir. Bu durum, sınırlı ve küçük ölçekli veri setlerinde klasik

yöntemlerin daha etkili olduğunu ortaya koymaktadır. Özellikle LSTM ve GRU modellerinin daha yüksek performans gösterebilmesi için daha büyük ve çeşitli veri setlerine ihtiyaç duyulduğu düşünülmektedir.

Sonuç olarak, bu çalışma kapsamında geliştirilen sistemde klasik yöntemlerin daha avantajlı olduğu, ancak derin öğrenme modellerinin de daha büyük veri kümeleriyle eğitildiklerinde potansiyel taşıdığı görülmüştür. Random Forest modelinin başarısı, özelliği yüksek boyutlu ve sınırlı veri kümelerinde sağlam bir alternatif olduğunu göstermektedir.

4. SONUÇ, TARTIŞMA VE ÖNERİLER

Bu çalışma, 112 Acil Çağrı Merkezi verilerinin doğal dil işleme (NLP) ve makine öğrenmesi teknikleri kullanılarak otomatik sınıflandırılmasını amaçlamıştır. Geliştirilen sistem; ses verilerinin metne dönüştürülmesi, ön etiketleme, veri artırımı ve çeşitli makine öğrenmesi ile derin öğrenme modelleriyle sınıflandırma olmak üzere dört temel adımdan oluşmaktadır.

Elde edilen bulgular, klasik makine öğrenmesi modellerinin derin öğrenme modellerine kıyasla daha iyi sonuçlar verdiğini göstermektedir. Özellikle Random Forest modeli %79.78 doğruluk oranı ile en başarılı model olurken, Naive Bayes ve CNN modelleri de %75.28 doğruluk oranıyla tatmin edici sonuçlar sunmuştur. Derin öğrenme modelleri (LSTM, GRU) ise %62–64 doğruluk oranlarında kalmıştır. Bu durum, veri setinin büyüklüğü ve sınıf dağılımının klasik modeller için daha uygun olmasından kaynaklanıyor olabilir.

Araştırmada kullanılan yöntem, hem operasyonel verimliliği artırmak hem de operatör üzerindeki yükü azaltmak için umut vaat eden bir çözüm sunmaktadır. Ancak, sistemin gerçek ortamda uygulanabilmesi için daha geniş, dengeli ve çeşitli veri setleri üzerinde test edilmesi ve modellerin sürekli güncellenmesi gerekmektedir.

Çalışmanın bulguları, yapay zekâ destekli sınıflandırma sistemlerinin acil çağrı yönetim süreçlerinde önemli avantajlar sağlayabileceğini ve insan kaynaklı hataları azaltabileceğini ortaya koymaktadır. Ancak etik sorumluluklar, veri güvenliği ve açıklanabilirlik gibi konular da dikkate alınmalıdır. Özellikle Türkçe gibi eklemeli dillerde morfolojik analiz ve yerelleştirilmiş modellerin kullanımı doğruluğu daha da artırabilir.

Öneriler

- Veri seti genişletilerek daha fazla örnekle modellerin eğitilmesi ve değerlendirilmesi önerilmektedir.
- Derin öğrenme modelleri için veri artırma yöntemleri ve transfer öğrenme teknikleri kullanılabilir.
- Özellikle Türkçe için geliştirilen BERTurk veya benzeri önceden eğitilmiş dil modelleri kullanılabilir.
- Sistem, gerçek zamanlı olarak test edilerek operatörlerin geri bildirimleriyle iyileştirilmelidir.
- Gelecekte, sistemin duygusal analiz yapabilmesi ve arayan kişinin stres düzeyini de tespit edebilmesi için çalışmalar yapılabilir.
- KVKK ve GDPR gibi yasal düzenlemelere tam uyum için anonimleştirme ve veri güvenliği önlemleri daha da geliştirilmelidir.

Sonuç olarak, bu çalışma, acil çağrı yönetimi süreçlerinin dijital dönüşümüne katkıda bulunabilecek önemli bir adım olarak değerlendirilmektedir. Gelecek çalışmalarla birlikte sistemin daha da geliştirileceği ve farklı acil durum senaryolarında uygulanabilir hale geleceği öngörülmektedir.

KAYNAKLAR

- Ağaç, F. (2012). *Çağrı merkezleri*. TBD Bilişim Dergisi, (145), 104–145.
- 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.
- Baltacı, A. (2018). Nitel araştırmalarda örnekleme yöntemleri ve örnek hacmi sorunsalı üzerine kavramsal bir inceleme. *Bitlis Eren Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 7(1), 231–274.
- Bahadır, S. M., & İnce, A. (2024). Yeni nesil 112 acil çağrı merkezleri projesi ve bileşenleri üzerine bir değerlendirme. *Afet ve Risk Dergisi*, 7(2), 525–545. <https://doi.org/10.35341/afet.1360759>
- Bukan, M. (2019). Bir sosyal uygulama olarak 112 acil çağrı merkezi: Yalova ili örneği. *Sosyal Politika Araştırmaları Dergisi*, 5(2), 58–71.
- Chawla, N. V., Bowyer, K. W., Hall, L. O., & Kegelmeyer, W. P. (2002). SMOTE: Synthetic minority over-sampling technique. *Journal of Artificial Intelligence Research*, 16, 321–357. <https://doi.org/10.1613/jair.953>
- Creswell, J. W., & Plano Clark, V. L. (2011). *Designing and conducting mixed methods research* (2nd ed.). Sage Publications.
- 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.
- Gales, M., & Young, S. (2008). The application of hidden Markov models in speech recognition. *Foundations and Trends in Signal Processing*, 1(3), 195–304. <https://doi.org/10.1561/2000000004>
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press.
- Graves, A., Fernández, S., Gomez, F., & Schmidhuber, J. (2006). Connectionist temporal classification: Labelling unsegmented sequence data with recurrent neural networks. In *Proceedings of the 23rd International Conference on Machine Learning* (pp. 369–376). <https://doi.org/10.1145/1143844.1143891>
- Graves, A., Mohamed, A., & Hinton, G. (2013). Speech recognition with deep recurrent neural networks. In *IEEE International Conference on Acoustics, Speech and Signal Processing* (pp. 6645–6649). <https://doi.org/10.1109/ICASSP.2013.6638947>
- Jurafsky, D., & Martin, J. H. (2023). *Speech and language processing* (3rd ed., draft). Stanford University. <https://web.stanford.edu/~jurafsky/slp3/>
- Li, J., Zhao, R., Sun, E., McGraw, I., Guo, H., & Wu, Y. (2020). High-accuracy and low-latency speech recognition with two-head contextual layer trajectory LSTM model. *arXiv*. <https://arxiv.org/abs/2003.07482>
- Liu, P., Qiu, X., & Huang, X. (2016). Recurrent neural network for text classification with multi-task learning. *arXiv*. <https://arxiv.org/abs/1605.05101>
- Mikolov, T., Karafiát, M., Burget, L., Černocký, J., & Khudanpur, S. (2010). Recurrent neural network based language model. *INTERSPEECH 2010*, 1045–1048.
- Morris, A., Maier, V., & Green, P. (2004). From WER and RIL to MER and WIL: Improved evaluation measures for connected speech recognition. In *Proceedings of the INTERSPEECH* (pp. 2769–2772).
- Punch, K. (2016). *Introduction to social research: Quantitative and qualitative approaches* (3rd ed.). Sage.

- Rabiner, L. R. (1989). A tutorial on hidden Markov models and selected applications in speech recognition. *Proceedings of the IEEE*, 77(2), 257–286. <https://doi.org/10.1109/5.18626>
- Rabiner, L. R., & Schafer, R. W. (2011). *Theory and applications of digital speech processing*. Pearson.
- Radford, A., Kim, J. W., Xu, T., Brockman, G., McLeavey, C., & Sutskever, I. (2022). Robust speech recognition via large scale weak supervision. *arXiv*. <https://doi.org/10.48550/arXiv.2212.04356>
- Ramesh, A., Pavlov, M., Goh, G., et al. (2021). Zero-shot text-to-image generation. *arXiv preprint arXiv:2102.12092*. <https://arxiv.org/abs/2102.12092>
- Sebastiani, F. (2002). Machine learning in automated text categorization. *ACM Computing Surveys*, 34(1), 1–47. <https://doi.org/10.1145/505282.505283>
- Shi, Y., Wang, Y., Wu, C., Chan, J., Zhang, F., Le, D., & Seltzer, M. (2021). Emformer: Efficient memory transformer based acoustic model for low latency streaming speech recognition. *arXiv*. <https://arxiv.org/abs/2010.10759>
- Stamm, B. H. (2005). *The Pro-QOL manual: The Professional Quality of Life scale: Compassion satisfaction, burnout & compassion fatigue/secondary trauma scales*. Sidran Press.
- Zhang, J., Liang, Y., Yu, H., Wang, D., & Ma, H. (2014). Real-time identification and monitoring of abnormal events based on microblog and emergency call data using SMART system. In *Proceedings of the IEEE Conference on Visual Analytics Science and Technology (VAST), 2014* (pp. 25–32). <https://doi.org/10.1109/VAST.2014.7042484>