



Support vector machine and edge computing enhanced real-time ambulance siren detection system

Yeliz Durgun¹ , Mahmut Durgun^{2*} 

¹Department of Electronics and Automatization, Turhal Vocational School of Higher Education, Tokat Gaziosmanpaşa University, Turhal, Tokat, Türkiye

²Department of Electronic Commerce and Management, Turhal Faculty of Applied Sciences, Tokat Gaziosmanpaşa University, Turhal, Tokat, Türkiye

Highlights:

- Developed an SVM-based sound classification model effectively detecting ambulance sirens in traffic
- The model enables real-time processing using edge computing, suitable for embedded systems
- High-dimensional data processed using UMAP and PCA, distinctly identifying sirens from traffic noises

Keywords:

- Ambulance Siren Detection
- Edge Computing
- Sound Classification
- Embedded Systems
- Polynomial Support Vector Machine

Article Info:

Research Article

Received: 08.01.2024

Accepted: 15.09.2024

DOI:

10.17341/gazimmfd.1416188

Correspondence:

Author: Mahmut Durgun

e-mail:

mahmut.durgun@gop.edu.tr

phone: +90 546 432 8808

Graphical/Tabular Abstract

The graphical abstract illustrates the real-world application of the sound classification system developed in this study. It depicts a driver inside a vehicle equipped with an advanced detection system that identifies the sound of an ambulance siren. The vehicle's dashboard displays an alert, indicating the detection of an ambulance, alongside a visual cue on the navigation map (Figure A). This smart system integrates the Polynomial SVM algorithm and edge computing technology to provide real-time alerts, enhancing driver awareness and promoting timely responses in traffic.

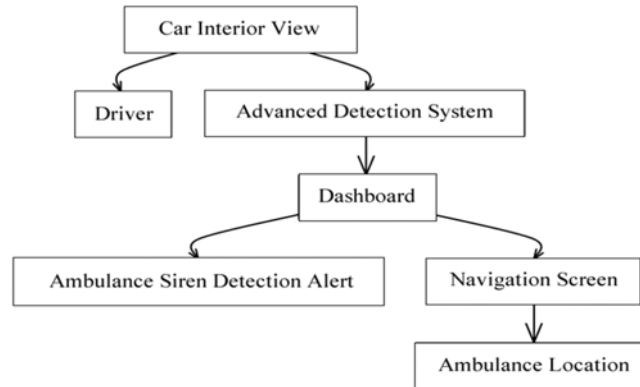


Figure A. Integrated fan-server-mobile monitoring system layout

Purpose:

The primary aim of this research is to develop a robust sound classification system focused on the detection of ambulance sirens in traffic environments. Leveraging the capabilities of Polynomial SVM and edge computing, this study seeks to enhance real-time responsiveness in embedded systems, contributing to improved traffic management and emergency response efficiency.

Theory and Methods:

At the heart of this study is the Polynomial Support Vector Machine (SVM) algorithm, tailored for high-precision sound classification. By integrating this algorithm with edge computing, the study ensures rapid processing of sound data with minimal latency. This approach combines the SVM's analytical strength with the speed and resource-efficiency of edge computing, making it ideal for deployment in embedded systems with limited computational resources.

Results:

The developed model exhibited high accuracy in distinguishing ambulance sirens from general traffic noise, as evidenced by extensive testing and validation. The application of UMAP and PCA analyses further affirmed the model's capability to process and classify high-dimensional sound data effectively. Performance metrics such as the Confusion Matrix, ROC Curve, and F1 Score consistently demonstrated the model's reliability and precision in real-world scenarios.

Conclusion:

This study successfully demonstrates the potential of combining Polynomial SVM with edge computing for efficient and accurate sound classification in traffic environments. The results underscore the viability of this approach for real-time ambulance siren detection, highlighting its significance for traffic safety and emergency response systems. Future work will focus on further refining the model and exploring its adaptability to various real-world applications, especially in smart city infrastructures.



Destek vektör makinesi ve kenar bilişim ile güçlendirilmiş gerçek zamanlı ambulans sireni algılama sistemi

Yeliz Durgun¹ , Mahmut Durgun^{2*}

¹Tokat Gaziosmanpaşa Üniversitesi, Turhal Meslek Yüksekokulu, Elektronik ve Otomasyon Bölümü, Turhal, Tokat, Türkiye

²Tokat Gaziosmanpaşa Üniversitesi, Turhal Uygulamalı Bilimler Fakültesi, Elektronik Ticaret ve Yönetimi Bölümü, Turhal, Tokat, Türkiye

ÖNEÇIKANLAR

- Trafikte ambulans sirenlerini etkin tespit eden SVM tabanlı ses sınıflandırma modeli geliştirildi
- Model, kenar bilişim kullanarak gerçek zamanlı işleme sağlar ve gömülü sistemlere uygundur
- UMAP ve PCA ile yüksek boyutlu veriler işlenerek sirenlere ve trafik sesleri ayrıştırıldı

Makale Bilgileri

Araştırma Makalesi

Geliş: 08.01.2024

Kabul: 15.09.2024

DOI:

10.17341/gazimmfd.1416188

Anahtar Kelimeler:

Ambulans siren tespiti,
kenar bilişim,
ses sınıflandırma,
gömülü sistemler,
polinom destek vektör
makinesi

ÖZ

Bu araştırma, Türkiye'nin trafik yönetimi altyapısında, ambulans sirenlerinin ve genel trafik seslerinin etkin bir şekilde tespiti için kenar bilişim ve Polinom Destek Vektör Makinesi (SVM) temelli bir ses sınıflandırma modelinin geliştirilmesi ve uygulanması sürecini detaylandırmaktadır. Model, gelişmiş algoritmalar ve yenilikçi teknikler kullanarak trafik ortamındaki seslerin ayrıştırılmasında önemli bir başarı göstermiştir. Tekdüze Çokkatman Yaklaşımı ve Projeksiyonu (UMAP) ve Temel Bileşenler Analizi (PCA) analizleri, modelin yüksek boyutlu verileri etkin bir şekilde düşük boyutlu uzaylarda işleyerek sınıflar arasında net bir ayrım yapabilme yeteneğini göstermektedir. Çalışma, kenar bilişim teknolojisiyle entegre edilmiş bir ses sınıflandırma sistemi sunarak, trafik yönetimi için gerçek zamanlı çözümler sağlama potansiyelini ortaya koymaktadır. Bu teknoloji, özellikle yoğun trafik koşullarında ve dar şehir içi yollarında, ambulans sirenlerinin hızlı ve doğru tespitini sağlayarak acil müdahale sürelerinin kısaltılmasına ve hayat kurtarılmasına katkı sunmaktadır. Modelin genel sınıflandırma başarısı, ROC Eğrisi ve F1 Skoru gibi güvenilir metriklerle ölçülmüştür ve bu metrikler modelin yüksek doğruluk oranları ve dengeli performansını ortaya koymaktadır. Araştırmanın sonuçları, trafik güvenliği ve acil durum müdahale süreçlerinin iyileştirilmesi için önemli adımlar atılmasına olanak tanıyan yenilikçi çözümleri vurgulamaktadır. Gelecekteki çalışmaların, modelin çeşitlendirilmiş uygulamaları senaryolarına adapte edilmesi ve geliştirilmesi, trafik yönetimi ve acil durum araçlarının tespiti alanlarında daha fazla ilerleme sağlaması beklenmektedir.

Support vector machine and edge computing enhanced real-time ambulance siren detection system

HIGHLIGHTS

- Developed an SVM-based sound classification model effectively detecting ambulance sirens in traffic
- The model enables real-time processing using edge computing, suitable for embedded systems
- High-dimensional data processed using UMAP and PCA, distinctly identifying sirens from traffic noises

Article Info

Research Article

Received: 08.01.2024

Accepted: 15.09.2024

DOI:

10.17341/gazimmfd.1416188

Keywords:

Ambulance siren detection,
edge computing,
sound classification,
embedded systems,
polynomial support vector
machine

ABSTRACT

This research details the development and implementation of an edge computing and Polynomial Support Vector Machine (SVM)-based sound classification model for effective detection of ambulance sirens and general traffic noises within Turkey's traffic management infrastructure. Utilizing advanced algorithms and innovative techniques, the model demonstrates significant success in differentiating sounds in a traffic environment. Uniform Manifold Approximation and Projection (UMAP) and Principal Component Analysis (PCA) demonstrate the model's ability to effectively process high-dimensional data into low-dimensional spaces, allowing for clear distinction between classes. The study presents an integrated sound classification system with edge computing technology, highlighting its potential to provide real-time solutions for traffic management. This technology significantly contributes to rapid and accurate detection of ambulance sirens, especially in dense traffic conditions and narrow urban roads, facilitating shorter emergency response times and lifesaving outcomes. The overall classification success of the model is measured by reliable metrics such as the ROC Curve and F1 Score, underscoring high accuracy rates and balanced performance. The findings underscore innovative solutions that enable significant steps in enhancing traffic safety and emergency response processes. Future research is anticipated to further adapt and enhance the model across diversified application scenarios, promising further advancements in traffic management and emergency vehicle detection.

*Sorumlu Yazar/Yazarlar / Corresponding Author/Authors : yeliz.durgun@gop.edu.tr, *mahmut.durgun@gop.edu.tr / Tel: +90 546 432 8808

1. Giriş (Introduction)

Yirmi birinci yüzyılın en büyük kentsel zorluklarından biri, artan araç yoğunluğunun yol açtığı trafik sorunlarıdır [1, 2]. Türkiye’de yapılan bir araştırmaya göre, trafikteki gecikmeler nedeniyle acil durum araçlarının geçişinin engellenmesi, ciddi sonuçlara yol açmaktadır [3, 4]. Özellikle, İstanbul gibi yoğun nüfuslu ülkelerde bu problem daha da belirginleşmektedir. Trafikte seyreden ambulansın geçiş önceliğine özen gösterilmesine yönelik farkındalığın artırılması amacıyla 2015 yılında “Ambulansa Yol Ver” Projesi hayata geçirilmiştir. Kentsel alanda acil vakaya ilk 10 dakikada ulaşma oranını %90 dan %95 oranına, kırsal alanda ise ilk 30 dakikada ulaşma oranını %95 oranına çıkarılması hedeflenmiştir [5]. Özellikle, ambulansların trafikte sıkışması, kalp krizi vakalarının yüzde 50’sinden fazlasının hastaneye geç ulaşmasına neden olmaktadır [6, 7]. Bu sorunu ele almak amacıyla, trafik sinyalizasyon sistemlerinin acil durum araçlarını algılayarak trafik akışını optimize etmesini sağlayacak çözümler üzerinde çalışmalar yapılmıştır.

Mevcut trafik yönetim sistemleri, acil durum araçlarının hızlı bir şekilde hedeflerine ulaşmalarını sağlamak için çeşitli yöntemler kullanmaktadır [8, 9]. Bunlar arasında, araç yoğunluğunu tespit eden RFID tabanlı sistemler ve acil durum araçlarını tanımlamak için kullanılan görüntü işleme teknikleri bulunmaktadır [10]. RFID tabanlı sistemler, trafik sinyallerini değiştirebilme yeteneğine sahip olmakla birlikte, bu sistemlerin etkinliği araç yoğunluğunun doğru bir şekilde tespit edilmesine bağlıdır [11-13]. Yanılgılı tespitler, acil durum araçlarının gereksiz yere beklemesine neden olabilmektedir [14, 15].

Görüntü işleme tabanlı sistemlerde ise, özellikle Konvolüsyonel Sinir Ağları (CNN) kullanılarak, CCTV kameraları aracılığıyla trafikteki acil durum araçlarının tespiti amaçlanmaktadır. Bu yöntemin başlıca sınırlaması, büyük araçların arkasında kalan acil durum araçlarının tespit edilememesidir. Ayrıca, bu sistemlerin kurulum ve işletme maliyetleri oldukça yüksektir.

Ses tabanlı tespit yöntemleri de acil durum araçlarının trafikte hızlıca ilerlemesine yardımcı olabilecek alternatif çözümler arasında yer almaktadır [16, 17]. Bu yöntemlerden biri, siren seslerinin frekans zirvelerini kullanarak tespit yapmayı amaçlayan modifiye edilmiş minimum orta kare hata (MMSE) metodudur. Ancak, bu yöntemin sınırlaması, siren seslerine benzer frekanslara sahip diğer seslerin yanılgılılıkla siren olarak algılanmasıdır. Bu çalışma, gerçek siren ses örneklerini kullanarak bu sorunu aşmayı hedeflemektedir.

Diğer bir ses tabanlı sistem, sadece net siren ses örnekleri kullanmaktadır. Bizim önerdiğimiz sistem ise, gerçek trafik ses kayıtlarından siren seslerini ayıklayarak ve arka plan gürültüsünü en aza indirerek, siren tespiti yapma konusunda önemli bir iyileşme sağlamaktadır. Bu yöntem, Polinom Destek Vektör Makinesi (SVM) ve kenar bilişim destekli mikrodenetleyici kullanarak gerçekleştirilen gerçek zamanlı ses tanıma işlemlerine dayanmaktadır.

Kenar bilişim (Edge Computing), trafik yönetimi ve acil durum araçlarının tespitinde önemli bir rol oynamaktadır [18, 19]. Geleneksel bulut bilişim altyapıları, veri işleme ve depolama için merkezi sunuculara bağımlıyken, kenar bilişim bu işlemleri veri kaynağına daha yakın bir noktada, yani "kenarda" gerçekleştirmektedir [20, 21]. Bu yaklaşım, trafik yönetim sistemlerinde gecikme sürelerini önemli ölçüde azaltır ve daha hızlı tepki süreleri sağlamaktadır. Özellikle, acil durum araçlarının trafikte hızlı hareket edebilmesi için, siren seslerinin anında ve etkin bir şekilde tespit edilmesi gerekmektedir. Kenar bilişim, bu tür gerçek zamanlı veri işleme gereksinimlerini karşılayarak, trafik sinyalizasyon sistemlerinin daha akıllı ve duyarlı hale gelmesini

sağlamaktadır [22, 23]. Önerdiğimiz sistem, kenar bilişim teknolojisi kullanarak, trafikteki siren seslerini algılar ve bu bilgiyi anında trafik kontrol merkezlerine ileterek, trafik ışıklarının durumunu acil durum araçlarının lehine ayarlanmaktadır. Bu yaklaşım, acil durum araçlarının trafikte sıkışıp kalmasını önlemek ve onlara daha hızlı bir geçiş imkânı sunmak için kritik öneme sahiptir. Ayrıca, kenar bilişimin getirdiği düşük gecikme süresi ve yüksek veri işleme kapasitesi, trafik yönetim sistemlerinin genel verimliliğini ve güvenilirliğini artırır [24]. Bu teknoloji, özellikle yoğun trafik koşullarında ve dar şehir içi yollarda, acil durum araçlarının hızla hareket etmesine olanak tanıyarak, potansiyel olarak hayat kurtaran bir çözüm sunmaktadır.

Türkiye örneğinde, kenar bilişim tabanlı bu yaklaşım, özellikle büyük şehirlerdeki yoğun trafik akışını yönetmede büyük bir potansiyel taşımaktadır [25-27]. İstanbul, Ankara gibi metropollerde, acil durum araçlarının hızla hareket edebilmesi için trafik ışıklarının anlık olarak yönetilmesi, trafik yoğunluğunun azaltılması ve acil durum müdahale sürelerinin kısaltılması açısından hayati önem taşımaktadır [28-30]. Bu nedenle, kenar bilişim tabanlı ses tanıma sistemimiz, Türkiye'nin trafik yönetimi altyapısında önemli bir yenilik olarak değerlendirilmelidir.

Bu çalışmada, trafikteki siren seslerini gerçek zamanlı olarak tanıyabilen, kenar bilişim destekli bir mikrodenetleyici tabanlı ses tanıma sistemi öneriyoruz. Bu sistem, Polinom SVM kullanarak, trafik gürültüsünden siren seslerini ayırt edebilmektedir. Bu çalışmanın Türkiye bağlamında da önemli bir uygulama potansiyeli bulunmaktadır. Türkiye'deki trafik yoğunluğu ve şehir içi trafik düzenlemeleri göz önünde bulundurulduğunda, önerilen sistem, acil durum araçlarının hızlı ve güvenli bir şekilde hedeflerine ulaşmalarını sağlayarak, can kayıplarının önlenmesine katkıda bulunabilir. Bu bağlamda, bu çalışma, sadece teknolojik bir yenilik değil, aynı zamanda toplumsal bir ihtiyaca cevap veren bir girişim olarak da değerlendirilebilir. Sistem, özellikle Türkiye'deki trafik koşullarında test edilmiş ve acil durum araçlarının siren seslerini başarıyla tespit etmiştir. Bu girişim, trafik yönetiminde yenilikçi bir adım olup, acil servis araçlarının hedeflerine daha hızlı ulaşmalarını sağlayarak hayat kurtarmayı hedeflemektedir.

Türkiye'nin trafik yönetimi altyapısında kenar bilişim teknolojisi kullanarak trafikte siren seslerini gerçek zamanlı olarak tespit edebilen ve trafik akışını bu verilere dayalı olarak optimize eden bir sistem sunuyoruz. Bu sistem, özellikle yoğun trafik koşullarında ve acil durum araçlarının hızla hareket etmesi gerektiğinde önemli bir rol oynamaktadır. Mevcut çözümlerin sınırlamalarını aşarak, acil durum araçları için trafikte daha hızlı ve güvenli bir geçiş imkânı sağlama konusunda önemli bir ilerleme olarak değerlendirilebilir. Bu çalışmanın özgünlüğü, gerçek dünya trafik seslerini kullanarak siren tespiti yapabilen ve acil durum araçlarının hızını artırarak potansiyel olarak hayat kurtarabilecek bir yaklaşımı temsil etmesindedir. Bu yenilikçi yaklaşım, Türkiye’de ve benzer trafik sorunları yaşayan diğer ülkelerde trafik yönetimine önemli katkılarda bulunabilecek bir model sunmaktadır.

2. Deneysel Metot (Experimental Method)

Bu bölümde, acil durum aracı sirenlerinin ve gerçek dünya trafik ses örneklerinin toplanması süreci detaylandırılmıştır. Toplanan verilerin işlenmesi ve analiz edilmesi aşamaları da anlatılmaktadır.


2.1. Veri Toplama (Data collecting)

Gerçek dünya trafik senaryosunda toplam 200 adet ses klibi toplandı. ISO9001: 2015 sertifikalı bir araç alarmı satın alındı ve şehrin farklı

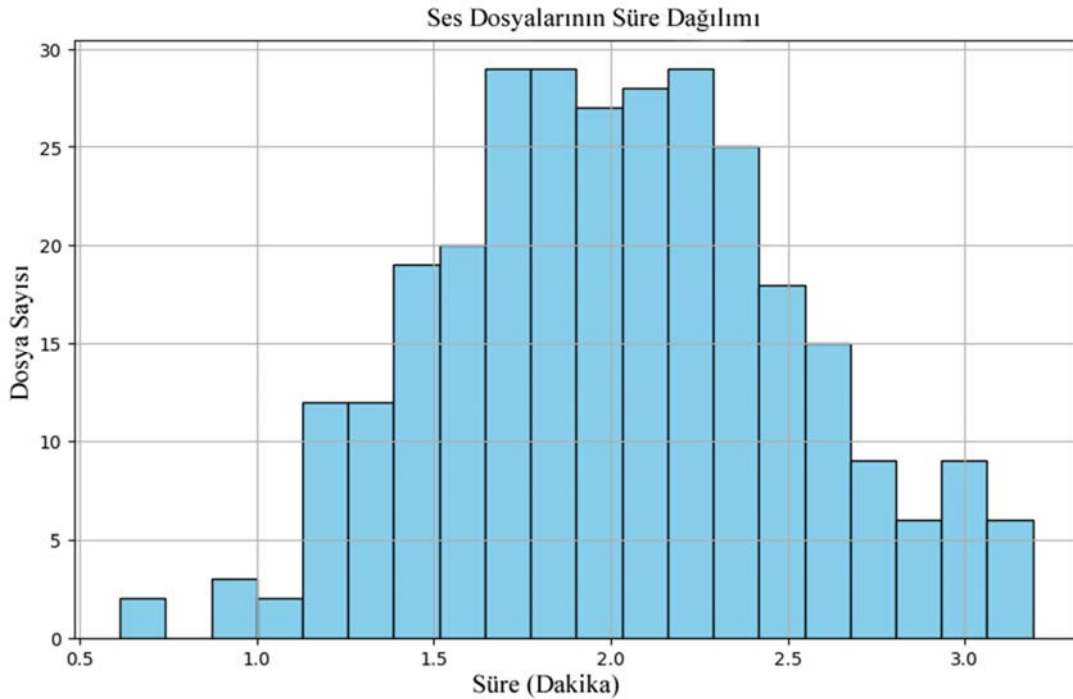
geçiş noktalarına yerleştirildi. Kayıt işlemi için Arduino Nano 33 üzerinde bulunan MP34DT05 kullanıldı. Bu, kompakt, düşük güç tüketimli, her yöne duyarlı dijital bir MEMS mikrofondur ve -40°C ile $+85^{\circ}\text{C}$ arasında çalışabilir. Mikrofon 64 dB sinyal-gürültü oranına sahiptir ve 16 KHz sesleri kaydedebilir. Ambulans sirenlerinin ses dosyaları farklı mesafe aralıklarından kaydedildi; bazı dosyalar sirenin yerleştirildiği noktadan 10 metre, bazıları ise 20, 30 ve 40 metre uzaklıktan kaydedildi. Böylece, dataset daha doğru ve çeşitlilik gösteren ses dosyalarını içermiş oldu. Toplamda 150 dosya ambulans sirenleri için, diğer 150 dosya ise ambulans sirenleri olmadan, sokaklarda yürünerek doğal çevre gürültülerinin kaydı için kullanıldı. Böylece, toplamda 300 ses dosyası toplandı ve ön işlemden geçirildi. Ses dosyalarının toplanması için kullanılan kayıt cihazı Şekil 1'de gösterilmiştir.

Bu ses dosyalarından elde edilen temel özellikler şunlardır: Frekans bileşenleri, genlik seviyeleri ve sinyal uzunluğu. Bu özellikler, Fourier dönüşümü ve spektral analiz yöntemleri kullanılarak elde edilmiştir. Elde edilen bu veriler, SVM sınıflandırma modelimizin eğitimi için kullanılmış ve ambulans sirenlerini genel trafik gürültüsünden ayırt edebilecek özelliklerin belirlenmesinde kritik bir rol oynamıştır. Özellikle, siren seslerinin karakteristik frekans aralıkları ve genlik değişimleri, modelimizin sınıflandırma başarısını artırmada önemli unsurlardır.

Bu çalışmada toplanan ses dosyalarının çeşitliliği ve gerçek dünya koşullarını yansıtmaya kapasitesi, ses dosyalarının süre dağılımını gösteren Şekil 2teki histogram ile sergilenmiştir. Histogram, toplanan ses kliplerinin çoğunun ortalama süreye yakın olduğunu, ancak yeterli



Şekil 1. Veri Toplama için Kullanılan Kayıt Cihazı (Recording Device Used for Data Collection)



Şekil 2. Ses Dosyalarının Süre Dağılımı Histogramı (Histogram of Duration Distribution of Sound Files)

sayıda kısa ve uzun süreli örneklerin de olduğunu göstermektedir. Bu dağılım, modelin farklı sürelerdeki siren seslerini tanıma ve sınıflandırma kapasitesini artırmak için önemlidir.

Histogram, ses dosyalarının büyük bir kısmının 1,5 ile 2,5 dakika aralığında yoğunlaştığını göstermektedir. Bu, trafikte yaygın olarak karşılaşılan siren seslerinin tipik sürelerini temsil eder ve modelimizin bu en yaygın senaryolar için eğitildiğini belirtir. Aynı zamanda, ses kliplerinin daha geniş bir süre aralığına yayılması, modelimizin gerçek dünya koşullarındaki değişkenliğe adapte olma yeteneğini gösterir. Bu, özellikle uzaktan ya da yakından kaydedilen siren seslerinin tespitinde ve sınıflandırılmasında modelin genelleştirme kabiliyetini göstermek için önemlidir.

2.2. Seçilen Özellikler ve SVM Modelindeki Rolü (Selected Features and Their Role in the SVM Model)

Modelimizin eğitimi sırasında, ambulans sirenlerini genel trafik seslerinden ayırt etmek için kritik ses özellikleri titizlikle seçilmiştir. Özellikle, siren seslerinin belirgin frekans aralıklarına odaklanarak, bu özelliklerin modelin doğruluk oranını maksimize etmedeki rolüne özel önem verilmiştir. Bu özellikler, SVM modelimizin eğitim aşamasında, sınıflandırma işleminin temelini oluşturmuştur ve modelin karar verme sürecinde, ses sınıflarını etkili bir şekilde ayırtmak için kritik bir rol oynamışlardır.

Şekil 3, WAV dosyasından alınan ses verilerinin zamanla genlik değişimlerini göstermektedir. Bu görsel, ses verilerinin zamana bağlı karakteristik özelliklerini ve bu özelliklerin sınıflandırma modelimizin eğitiminde nasıl bir temel oluşturduğunu açıkça ortaya koymaktadır. Grafik, özellikle sesin frekans ve genlik özelliklerinin zaman içindeki değişimlerini vurgulayarak, bu özelliklerin sınıflandırma performansına nasıl katkı sağladığını göstermektedir. Bu analiz, ses özelliklerinin incelenmesinin ve uygun bir şekilde işlenmesinin, modelimizin ambulans sirenlerini trafik gürültüsünden etkili bir şekilde ayırtma kabiliyetini nasıl artırdığını gözler önüne sermektedir.

2.3. Teknikler ve Algoritmalar (Techniques and Algorithms)

Siren seslerinden bu kritik özellikleri çıkarmak için, ileri düzey sinyal işleme teknikleri kullanılmıştır. Bu teknikler arasında, ses dosyalarının Fourier dönüşümü ve spektral analizi yer almaktadır. Bu yöntemlerin uygulanma süreçleri ve tercih sebepleri, modelimizin

genel sınıflandırma başarısını artırmaya yöneliktir. Ayrıca, bu işlemler sırasında elde edilen verilerin kalitesini maksimize etmek için özel filtreleme ve normalizasyon adımları da uygulanmıştır.

Bu çalışmada Tekdüze Çokkatman Yaklaşımı ve Projeksiyonu (UMAP) ve Temel Bileşenler Analizleri (PCA), yüksek boyutlu veri setlerinin düşük boyutlu bir uzayda nasıl etkili bir şekilde görselleştirilebileceğinin ve farklı ses sınıflarının net bir şekilde nasıl ayırt edilebileceğinin kanıtları olarak kullanılmıştır. UMAP analizi, modelin ambulans sirenleri ve trafik sesleri gibi farklı sınıflar arasındaki ilişkileri anlamak için kritik öneme sahipken, PCA analizi veri setimizdeki özneliklerin en önemli bileşenlerini vurgulamaktadır. Bu analizlerden elde edilen sonuçlar, sınıflandırma modelimizin eğitim setleri üzerindeki sınıfları nasıl etkili bir şekilde ayırt ettiğini ve bu ayırt edicilik kabiliyetinin doğruluk oranına doğrudan nasıl yansıdığını açıkça göstermektedir. Bu nedenle, modelimizin SVM eğitimi ve karar verme mekanizmasında bu analizlerden elde edilen özelliklerin kritik bir rol oynadığı sonucuna varılmıştır.

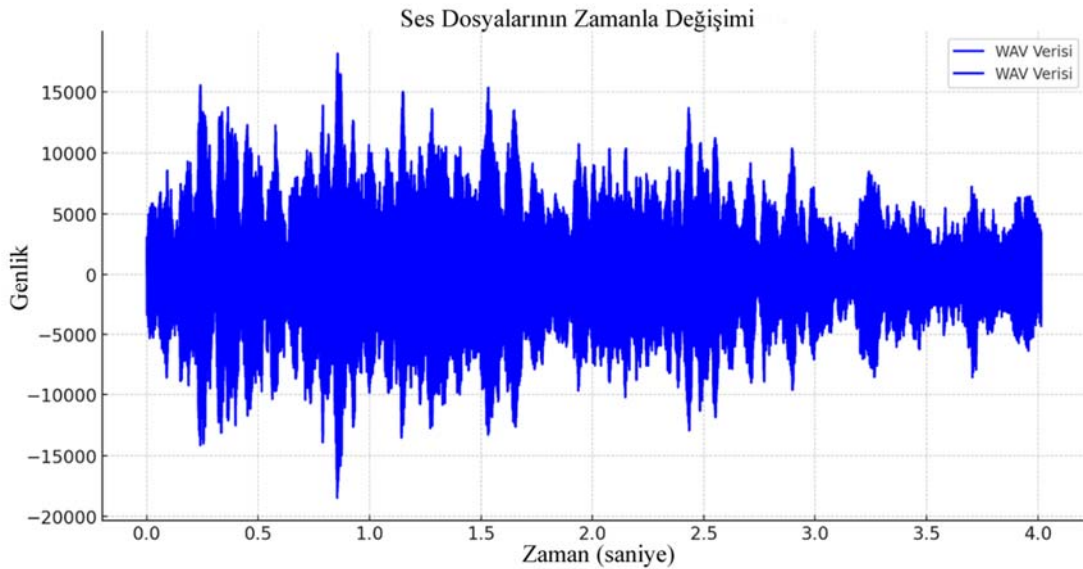
UMAP ve PCA analizlerinin uygulanmasının ardından, modelimizin eğitiminde kullanılan nihai özellik sayısı 30 olarak belirlenmiştir. Bu özellikler, ses verilerimizin frekans ve genlik gibi temel karakteristiklerini yansıtan ve sınıflandırma modelimizin doğruluğunu en üst düzeye çıkarmak için seçilen kritik öznelikleri içermektedir. Seçilen bu özellikler, SVM sınıflandırma modelimizin genel performansının ve ambulans sirenleri ile trafik seslerini ayırtma kabiliyetinin iyileştirilmesinde temel bir rol oynamıştır.

2.4. SVM Sınıflandırma Modelinin Geliştirilmesi (Development of SVM Classification Model)

Şekil 4'deki diyagram, ses verilerinin toplanmasını ve ardından frekans ve genlik analiziyle işlenmesini göstermektedir. Elde edilen veriler ön işlemeden geçirilmiş, daha sonra SVM model eğitimi için kullanılan özellikler seçilmiştir. Model eğitimi tamamlandıktan sonra, sistem sınıf kararlarını verir ve sesleri 'Ambulans Sirenleri' ve 'Trafik Gürültüsü' olarak sınıflandırır.

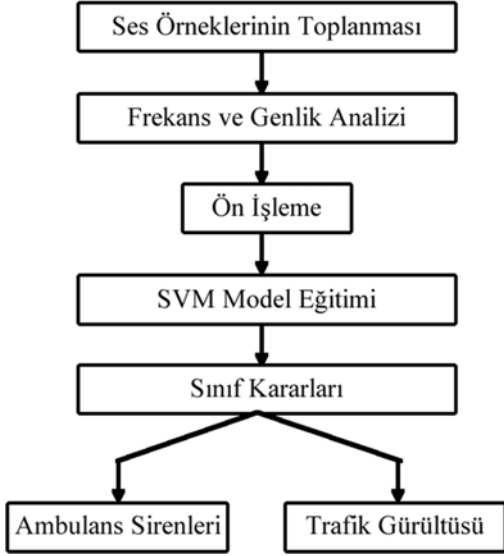
2.5. Model Performansına Etki (Impact on Model Performance)

Bu çalışmada seçilen özelliklerin modelin sınıflandırma başarısı üzerindeki etkileri kapsamlı bir şekilde incelenmiştir. Özellik seçimi sürecinde, ses verilerimizden elde edilen çeşitli özellikler arasından



Şekil 3. Ses Verilerinin Zamanla Değişimi (Time Variation of Sound Data)

sınıflandırma doğruluğunu maksimize edecek olanlar dikkatlice seçilmiştir. Bu seçim, özellikle frekans, genlik ve enerji gibi siren seslerinin ayırt edici özelliklerine odaklanmıştır. Seçilen her bir özellik, SVM sınıflandırma algoritmamızın eğitim aşamasında önemli bir rol oynamış ve bu özelliklerin her biri, modelin karar verme sürecine doğrudan etki eden kritik faktörler olarak belirlenmiştir.



Şekil 4. Ses Sınıflandırma Yönteminin Blok Diyagramı (Block Diagram of the Sound Classification Method)

Performansı artırmak için kullanılan özellikler arasında, ambulans sirenlerinin özgün frekans bileşenleri, sinyal-gürültü oranı ve

zamansal yayılım gibi özellikler bulunmaktadır. Özellik önemliliği analizi sonuçlarına göre, modelimiz bu özelliklerle trafik gürültüsünden siren seslerini başarılı bir şekilde ayırt edebilmekte ve bunları doğru sınıf etiketleriyle eşleştirebilmektedir. Bu analizler, modelimizin genel sınıflandırma doğruluğunu artıran faktörlerin belirlenmesinde yardımcı olmuş ve sonuç olarak modelin duyarlılığını ve özgüllüğünü önemli ölçüde iyileştirmiştir.

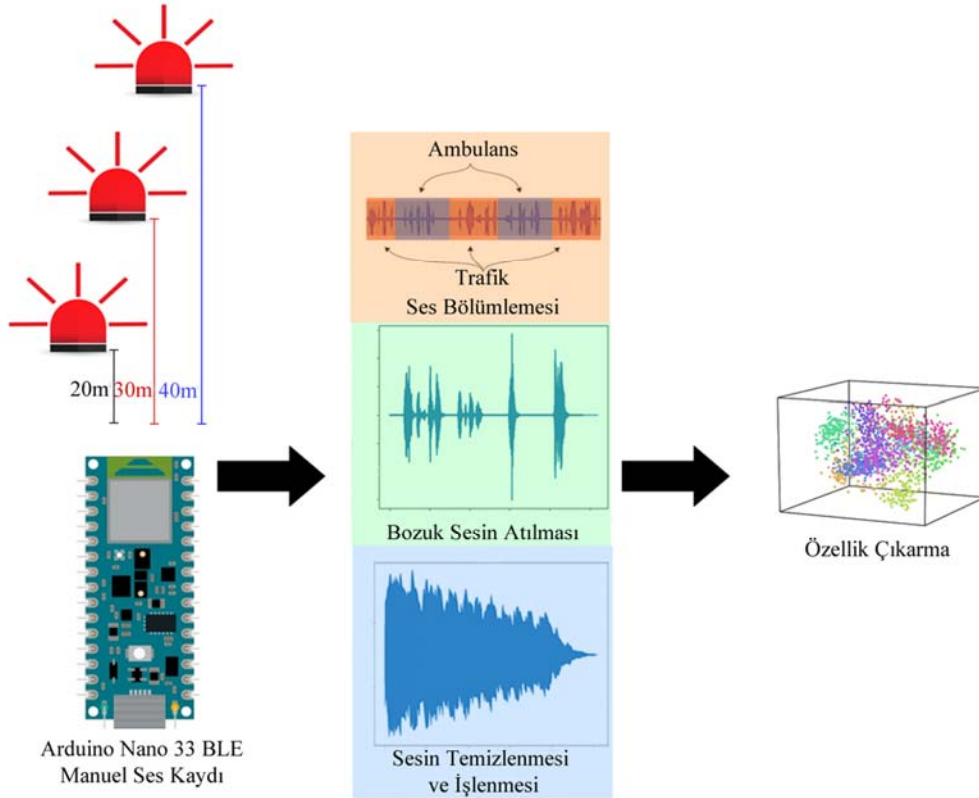
Bu süreçte, sınıflandırma başarımızın somut kanıtlarını sunmak amacıyla çeşitli karışıklık matrisleri ve ROC eğrileri gibi görsel araçlar da kullanılmıştır. Bu görseller, modelin gerçek siren seslerini çevresel gürültüler arasından ayırt etmedeki etkinliğini ve güvenilirliğini sergilemektedir. Ayrıca, farklı veri setleri üzerinde gerçekleştirilen çapraz doğrulama testleri, modelimizin sağlam ve tutarlı olduğunu göstermektedir. Bu bulgular, modelin trafik yönetim sistemlerindeki potansiyel uygulamaları için önemli bir güvenilirlik düzeyi sunmaktadır.

2.6. Veri Temizleme ve Filtreleme (Data Cleansing and Filtering)

Veri toplama aşamasından sonra önemli bir adım verilerin temizlenmesi ve bozuk ses dosyalarının atılmasıdır. Toplanan tüm ses dosyaları manuel olarak çalındı ve kontrol edilmektedir. Bozuk ve düşük örnekleme frekansına sahip sinyaller silinmektedir. Ses dosyaları için üç ila on beş saniye arasında sabit bir süre aralığı belirlendi. Böylece, üç ila on beş saniye arasında değişen 300 ses dosyasından oluşan bir veri seti elde edilmektedir. Bu tutarlılık, sistem tarafından daha yüksek doğruluk elde edilmesine yardımcı olmaktadır.

2.7. Veri Etiketleme (Data Labeling)

Veri etiketleme, makine öğrenimi modellerinin eğitimi için hayati öneme sahip bir süreçtir. Etiketlerin doğruluğu, modelin



Şekil 5. Veri Seti Oluşturmak için Kullanılan Çerçeve (Framework Used for Creating the Dataset)

performansını doğrudan etkiler ve bu nedenle, bu çalışmada veri etiketleme sürecimiz titizlikle tasarlanmış ve uygulanmıştır. Etiketlerin güvenilirliğini sağlamak adına, ses dosyaları öncelikle konusunda uzman bir ekip tarafından ön değerlendirmeye alınmıştır. Ardından, belirlenen etiketler ikinci bir ekip tarafından çapraz kontrol edilmiştir, böylece herhangi bir yanlışlık ya da hata minimize edilmiştir.

Ses dosyalarının etiketlenmesi sürecinde, öncelikle siren seslerinin varlığını ve yoğunluğunu doğru bir şekilde tespit edebilecek eğitilmiş uzmanlar tarafından bir ön inceleme gerçekleştirilmiştir. Bu ön inceleme, çeşitli trafik koşullarında ve farklı mesafelerden kaydedilen sesler üzerinde yapılmıştır. Ön inceleme sonucunda, her ses dosyasına, siren sesinin varlığına veya yokluğuna göre bir etiket atanmıştır. Daha sonra, etiketleme işlemi, bağımsız bir grup uzman tarafından ikinci bir değerlendirmeye tabi tutulmuştur. Bu ikinci değerlendirme aşaması, ilk etiketlemenin doğruluğunu kontrol etmek ve herhangi bir tutarsızlığı düzeltmek amacıyla yapılmıştır. Bu aşamada, etiketleme kriterleri ve süreçlerinin standartlaştırılması üzerinde özellikle durulmuş ve bu kriterlerin tüm uzmanlar tarafından tutarlı bir şekilde uygulanması sağlanmıştır.

Sonuç olarak, bu iki aşamalı etiketleme ve doğrulama süreci, toplanan veri setinin yüksek kalitede ve güvenilir olduğunu temin etmektedir. Bu yaklaşım, modelimizin sınıflandırma doğruluğunu artırmakta ve sonuçların gerçek dünya senaryolarına uygulanabilirliğini sağlamaktadır. Ayrıca, etiketleme sürecinin bu titiz yaklaşımı, araştırma topluluğuna sunulan veri setinin güvenilirliği konusunda da güvence sağlamaktadır.

2.8. Son Veri Seti (Final Dataset)

Veri toplama ve ön işleme için seçilen çerçeve Şekil 5'de gösterilmiştir. Hem ambulans sirenleri hem de yol gürültülerinden oluşan ham ses dosyalarının toplanmasından başlayarak, tüm ses dosyaları üç ila on beş saniye aralığına segmentlendirilmektedir. İlk olarak, toplanan veriler farklı sürelerdeydi, tutarlı bir veri seti oluşturmak için tüm dosyalar belirli aralıklara kırpılmaktadır. Daha sonra toplanan dosyalar manuel olarak dinlendi ve bozuk sinyaller çıkarılmaktadır. Düşük kaliteli ses sinyalleri, veri kalitesini artırmak ve daha iyi doğruluklar elde etmek için 16kHz olan sabit ve seçilen örnekleme frekansına yükseltilmektedir. Son olarak, makalede daha sonra açıklanan özellik çıkarma işlemi için veri seti hazır hale getirilmektedir. Ön işleme adımlarını özetleyen Tablo 1 de, kullanılan ses veritabanının detaylarını sunmaktadır.

Tablo 1. Ses Verisi Toplama İşlemine Genel Bakış (Audio Data Collection Overview)

Parametreler	Kullanılan Veritabanı
Ambulans Sesleri	150
Trafik Sesleri	150
Örnek Sayısı	300
Süre (Toplam)	79 dakika
Ses Örneklerinin Uzunluğu	3-15 saniye
Örnekleme Sıklığı	16 kHz

2.9. Polinom Destek Vektör Makinesi (SVM) Yöntemi (Polynomial Support Vector Machine (SVM) Method)

Bu çalışmada, acil durum aracı sirenlerini ve trafik seslerini ayırt etmek için Polinom Destek Vektör Makinesi (SVM) algoritmasının uygulaması esas alınmıştır. Algoritmanın matematiksel kuruluşu ve eğitim süreci aşağıda detaylandırılmıştır.

Polinom SVM, M boyutunda N adet eğitim vektörü $\{\mathbf{x}_1, \dots, \mathbf{x}_N\}$ ve bu vektörlere karşılık gelen etiketler $y_n \in \{+1, -1\}, n = 1, \dots, N$ ile tanımlanır. Eğitim çiftleri $\{\mathbf{x}_n, y_n\}_{n=1}^N$ kullanılarak bir SVM modeli

eğitilir. Bir test vektörü \mathbf{x} verildiğinde, SVM'nin çıktısına ait denklem (Eş. 1) gibi ifade edilir:

$$f(\mathbf{x}) = \sum_{n=1}^N \alpha_n y_n K(\mathbf{x}, \mathbf{x}_n) + b \\ = \sum_{n=1}^N \alpha_n K(\mathbf{x}, \mathbf{x}_n) + b \quad (1)$$

Burada $\alpha_n \equiv \alpha_n y_n, b, b$ sapma terimi, α_n 'lar Lagrange çarpanları ve $K(\mathbf{x}, \mathbf{x}_n)$ çekirdek fonksiyonudur. İkinci dereceden polinom çekirdeği durumunda denklem (Eş. 2) gibi ifade edilir:

$$f(\mathbf{x}) = \sum_{n=1}^N \alpha_n \left(1 + \frac{\mathbf{x} \cdot \mathbf{x}_n}{\sigma^2}\right)^2 + b \\ = \sum_{n=1}^N \alpha_n (\tilde{\mathbf{x}}^T \tilde{\mathbf{x}}_n)^2 + b \\ = \tilde{\mathbf{x}}^T \left(\sum_{n=1}^N \alpha_n \tilde{\mathbf{x}}_n \tilde{\mathbf{x}}_n^T\right) \tilde{\mathbf{x}} + b \\ = \tilde{\mathbf{x}}^T \mathbf{W} \tilde{\mathbf{x}} + b, \quad (2)$$

Bu denklem, SVM'nin karar fonksiyonunu ve bu fonksiyonun matematiksel ifadesini açıklar.

Eğitim sürecinde, her bir ses dosyası için bir özellik vektörü oluşturulmuş ve bu vektörler, ambulans sirenleri (+1) ve trafik gürültüleri (-1) olarak iki farklı sınıfa ayrılmıştır. SVM modeli, bu etiketli veri seti üzerinde eğitilmiştir. Eğitim sonrasında, modelin performansı test veri seti üzerinde değerlendirilmiştir. Bu aşamada, modelin siren seslerini trafik gürültülerinden ayırtabilme kabiliyeti ölçülmüştür.

3. Kıyaslama Metrikleri (Benchmarking Metrics)

Bu bölümde, çalışmamızda geliştirilen ses sınıflandırma modelinin performansını değerlendirmek için kullanılan metrikler detaylandırılmaktadır. UMAP ve PCA görselleştirmeleri, modelin ambulans sirenleri ve trafik sesleri arasındaki farkları nasıl ayırt ettiğini ve bu ses sınıflarını düşük boyutlu bir uzayda nasıl başarılı bir şekilde temsil ettiğini göstermektedir. Karışıklık Matrisi, modelin sınıflandırma doğruluğunu çapraz doğrulama ile ortaya koyarken, F1 Skoru ve ROC Eğrisi modelin öğrenme etkinliğini ve çeşitli eşik değerlerindeki tahmin güvenilirliğini göstermektedir. ROC Eğrisinin AUC değeri, modelin genel olarak sınıfları ne kadar iyi ayırt ettiğini gösterirken, F1 Skoru modelin hassasiyet ve geri çağırma dengesini ölçmektedir.

3.1. UMAP ve PCA Görselleştirmeleri (UMAP and PCA Visualization):

UMAP (Uniform Manifold Approximation and Projection) analizi, yüksek boyutlu veri setlerini düşük boyutlu bir uzayda görselleştirmek için kullanılan güçlü bir yöntemdir. Bu çalışmada, UMAP kullanılarak elde edilen görselleştirme, modelin ambulans sirenleri ve trafik sesleri gibi ses sınıflarını nasıl ayırt ettiğini ve bu sınıflar arasındaki ilişkileri anlamak için önemli bir araçtır. Modelin, ses örneklerini farklı sınıflara ait yoğunluk bölgelerine nasıl yerleştirdiği UMAP görseli Şekil 6'de açıkça görülmektedir.

Öte yandan, PCA (Principal Component Analysis) yöntemi, veri setindeki varyansın çoğunu koruyarak boyut indirgemesi yapar ve öznitelikler arasındaki en önemli ilişkileri vurgular. PCA analizine dayalı görselleştirme, ses sınıflarının temel bileşenler arasındaki varyansını ve sınıfların birbirinden ne derece ayrıldığını ortaya koyar. Modelin, PCA ile indirgenmiş boyutlarda bile sınıfları etkili bir şekilde ayırdığı Şekil 7'de görülmektedir.

Her iki görselleştirmede de modelin farklı sınıfları ayırma yeteneği vurgulanmış ve bu sınıfların modeller tarafından ne kadar net bir şekilde tanıdığı gösterilmiştir. Bu analizler, ses sınıflandırma modelinin sınıfları doğru bir şekilde nasıl ayırt ettiğini ve sınıf içi benzerliklerle sınıflar arası farklılıkları ne kadar iyi yakaladığını

kanıtlamaktadır. Bu görselleştirmeler, modelin doğruluğu ve geliştirilebilirliği hakkında önemli bilgiler sunmaktadır ve sınıflandırma performansının daha da iyileştirilmesi için potansiyel yollar önermektedir.

3.2. Karışıklık Matrisi (Confusion Matrix):

Karışıklık Matrisi, modelimizin sınıflandırma performansını derinlemesine anlamamızı sağlayan kritik bir araçtır. Bu matris, modelin her sınıf için doğru ve yanlış pozitifleri, yanlış ve doğru negatifleri nasıl tahmin ettiğini gösterir, böylece modelin hassasiyetini ve geri çağırma oranını değerlendirebiliriz.

Modelimizin ambulans sirenleri ve trafik sesleri gibi belirli ses sınıflarını ne kadar doğru bir şekilde ayırt edebildiğini Şekil 8 Çapraz Doğrulama Grafiği, modelin performansının güçlü yönlerini ve potansiyel zayıflıklarını ortaya çıkarmaktadır.


Görseldeki her hücre, modelin bir sınıfı diğer bir sınıf olarak ne kadar sık yanlış sınıflandırdığını veya doğru sınıflandırdığını gösterir. Örneğin, ambulans sirenlerinin doğru olarak ne kadar sık 'ambulans

siren' olarak sınıflandırıldığını ve ne kadar nadiren 'trafik sesi' olarak yanlış sınıflandırıldığını görebiliriz. Benzer şekilde, trafik seslerinin model tarafından doğru bir şekilde ne kadar sık doğru sınıflandırıldığını ve ambulans sirenleriyle karıştırılma durumlarını gözlemleyebiliriz.


Bu matrisin gösterdiği başarı oranları, modelin gerçek dünya senaryolarında karşılaşılabileceği çeşitli durumlar için ne kadar güvenilir ve dayanıklı olabileceğinin bir göstergesi olarak kullanılabilir. Modelimizin ambulans sirenlerini tespit etmedeki yüksek doğruluk oranı ve düşük yanlış pozitif oranı, özellikle acil durum sinyallerinin doğru bir şekilde algılanması gereken uygulamalar için önemlidir.

3.3. Katlama Doğrulukları ve Sınıflar (By-fold Accuracies vs Classes):

Bu çalışmada, modelimizin farklı sınıflar üzerindeki performansını değerlendirmek amacıyla gerçekleştirilen çapraz doğrulama sonuçları, "Katlamalı Doğruluklar ve Sınıflar" tablosunda özetlenmiştir. Tablo, modelin ambulans sirenleri ve trafik sesleri gibi farklı ses sınıflarını ayırt etme kabiliyetini ve her bir katlamada (fold) elde ettiği genel doğruluk oranlarını Tablo 2'de göstermektedir.



Şekil 6. UMAP Gösterimi (UMAP Visualization)



Şekil 7. PCA Gösterimi (PCA Visualization)

Çapraz Doğrulama Verileri

Doğru Değerler	Ambulans	Trafik
Ambulans	134 [0.99]	1 [0.01]
Trafik	2 [0.00]	413 [1.00]
	Ambulans	Trafik
Tahmini Değerler		

Şekil 8. Çapraz Doğrulama Grafiği (Cross-Validation Graph)

- Kat 0: Model, ambulans sirenlerini %100 doğrulukla sınıflandırmış, trafik seslerini ise %99,04 doğrulukla ayırt etmiştir. Genel doğruluk oranı %99,24'tür.
- Kat 1: Bu katlamada, ambulans sirenleri için doğruluk oranı %96,15, trafik sesleri için %99,04 ve genel doğruluk oranı %98,46'dır.
- Kat 2 ve 3: Her iki katlamada da model, ambulans sirenlerini ve trafik seslerini %100 doğrulukla sınıflandırmış ve genel doğruluk oranı da %100 olarak kaydedilmiştir.

Bu sonuçlar, modelin ambulans sirenlerini ve trafik seslerini ayırt etme konusunda oldukça güvenilir ve tutarlı olduğunu göstermektedir. Özellikle Kat 2 ve 3'teki mükemmel performans, modelin bu ses sınıflarını ayırt etmede yüksek bir başarıya sahip olduğunu kanıtlar. Kat 1'de ambulans sirenlerinin biraz daha düşük doğruluk oranı elde etmesi, belki de bu katlamada karşılaşılan ses örneklerinin model tarafından biraz daha zor ayırt edildiğini gösteriyor olabilir. Ancak, genel olarak modelin her iki sınıf için de yüksek doğruluk oranlarına ulaşması, algoritmanın etkili olduğunu bir göstergesidir.

3.4. ROC Eğrisi (ROC Curve):

Modelimizin performansının bir diğer önemli göstergesi olan "ROC (Receiver Operating Characteristic) Eğrisi", modelin sınıflandırma görevindeki duyarlılık ve özgüllüğünün dengesini gösterir. Bu eğri, modelin farklı eşik değerlerinde sınıflar arasında ayırım yapma yeteneğini değerlendirmemize yardımcı olmaktadır.

- ROC Eğrisi, yatay ekseninde Yanlış Pozitif Oranı (False Positive Rate) ve dikey ekseninde Doğru Pozitif Oranı (True Positive Rate) göstermektedir.
- İdeal bir ROC Eğrisi, sol üst köşeye doğru yükselir ve bu, modelin yüksek doğru pozitif oranı elde ederken düşük yanlış pozitif oranını koruduğunu göstermektedir [31]. Bu, modelin sınıfları doğru bir şekilde ayırt etme ve yanlış alarm oranını düşük tutma yeteneğinin yüksek olduğunu göstermektedir.
- Modelimizin ROC Eğrisi, sol üst köşeye doğru önemli bir yükseliş göstermektedir, bu da modelin yüksek duyarlılık (sensitivity) ve özgüllük (specificity) değerlerine sahip olduğunu gösterir. Bu, modelin siren seslerini ve trafik seslerini etkili bir şekilde ayırt edebildiğini kanıtlamaktadır.

- Eğrinin altında kalan alan (AUC- Area Under Curve), modelin genel performansını ölçer. Yüksek bir AUC değeri, modelin genel olarak iyi performans gösterdiğini ve farklı sınıflar arasında etkili bir ayırım yapabildiğini gösterir.

Şekil 9'deki ROC Eğrisi, modelimizin sınıflandırma görevindeki başarısını ve farklı durumlara nasıl adapte olduğunu gösterir. Eğrinin yüksek AUC değeri, modelin sınıfları ayırt etmede yüksek doğrulukla çalıştığını ve pratik uygulamalarda güvenilir sonuçlar verebileceğini göstermektedir. Bu eğri, modelin farklı eşik değerlerine karşı duyarlılığını ve özgüllüğünü anlamamızda önemli bir rol oynar ve modelin daha da geliştirilmesi için yol göstermektedir.

3.5. F1 Skoru (F1 Score):

F1 Skoru, modelimizin sınıflandırma performansının kapsamlı bir ölçümüdür. Hassasiyet (precision) ve geri çağırma (recall) arasındaki dengenin bir göstergesi olan F1 Skoru, her iki metriğin harmonik ortalamasını olarak hesaplanır [32]. Bu ölçüm, özellikle dengesiz veri setlerinde veya sınıflar arasındaki performansın dengeli olması gereken durumlarda önemlidir.

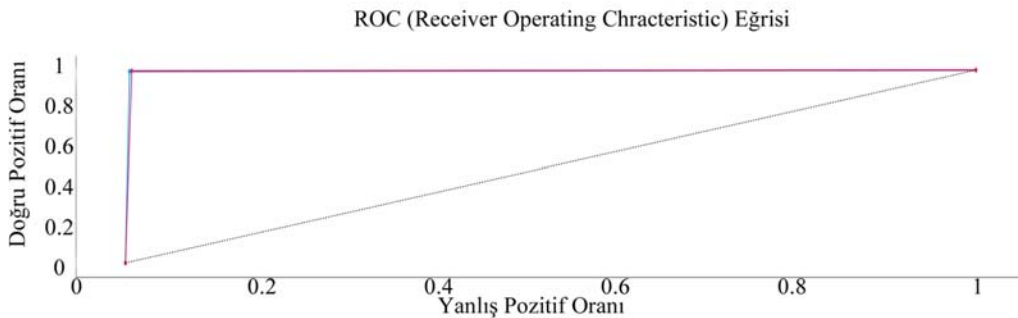
- F1 Skoru, modelin sınıflandırma yaparken hem doğru pozitif tahminlerin hem de gerçek pozitiflerin önemini dikkate alır.
- Yüksek bir F1 Skoru, modelin sınıfları doğru bir şekilde ayırt ederken az sayıda yanlış pozitif ve yanlış negatif tahmin yaptığını gösterir.
- Modelimizin F1 Skoru, her iki sınıf için de yüksek değerlere ulaşmıştır. Bu, modelin ambulans sirenleri ve trafik seslerini başarılı bir şekilde ayırt edebildiğini ve her iki sınıf için de yüksek hassasiyet ve geri çağırma oranlarına sahip olduğunu gösterir.

Modelin yüksek F1 Skorları, sınıflandırma görevinde dengeli ve güvenilir bir performans sergilediğini Şekil 10'da göstermektedir. Her iki sınıf için de yüksek F1 Skorları elde etmek, modelin bu ses sınıflarını etkili bir şekilde ayırt etme kabiliyetine sahip olduğunu ve yanlış pozitiflerin yanı sıra yanlış negatifleri de minimuma indirdiğini göstermektedir. Bu, özellikle acil durum sinyallerinin doğru bir şekilde algılanması gereken uygulamalar için önemlidir.


Sonuç olarak, F1 Skoru, modelimizin ambulans sirenleri ve trafik sesleri arasındaki ayırımı ne kadar etkili ve dengeli bir şekilde

Tablo 2. Katlamalı Doğruluklar ve Sınıflar (By-fold Accuracies vs Classes)

Katlama Sayısı	Ambulans	Trafik	Genel
0	1	0,9903846153846154	0,9923664122137404
1	0,9615384615384616	0,9903846153846154	0,9846153846153847
2	1	1	1
3	1	1	1



Şekil 9. ROC Eğrisi (ROC Curve)



Şekil 10. F1 Skoru Eğrisi (F1 Score Curve)

yaptığını göstermektedir. Bu, modelin gerçek dünya uygulamalarında karşılaşılabileceği çeşitli durumlar için ne kadar uygun olduğunu belirlemek açısından önemlidir. Ayrıca, modelin daha da optimize edilmesi için yol göstermektedir.

3.6. Mikrodenetleyici Tabanlı Model Özeti (Microcontroller Based Model Summary):

Mikrodenetleyici tabanlı modelimizin boyutları ve bellek kullanımı, gerçek dünya uygulamalarına uygunluk açısından analiz edilmiştir. Model boyutu ve bellek gereksinimleri, uygulamaların gömülü sistemlerde etkin bir şekilde çalışmasına olanak tanıyan boyutlarda tutulmuştur. Modelimiz, 378,05 KB'lık flash ve 84,13 KB'lık RAM'i kaplayan ikili bir görüntü dosyası (.bin) ve 584 B'lık makine öğrenimi modeli (ML Model) içermektedir. Ön işleme ve öznetelik çıkarımı işlemleri için toplamda 18,92 KB flash ve 12,41 KB RAM kullanılmıştır.

4. Sonuçlar ve Tartışmalar (Results and Discussions)

Kenar bilişim ve Polinom Destek Vektör Makinesi (SVM) temelli ses sınıflandırma modelimizin etkinliği, bu çalışma ile Türkiye'nin trafik yönetimi altyapısı için başarıyla ortaya konmuştur. Ses tabanlı tespit metodolojimiz, ambulans sirenlerini ve genel trafik seslerini ayırt edebilme kabiliyetiyle, gelişmiş algoritmalar ve yenilikçi teknikler kullanarak öne çıkmıştır. Literatürde trafik yoğunluğunu ve yol koşullarını belirleme üzerine odaklanan benzer çalışmalardan farklı olarak; bu çalışma siren seslerinin doğru tespiti ve trafik yönetimi uygulamalarında bu bilgilerin kullanımını hedeflemiştir [33, 34].

Modelimizin yüksek boyutlu verileri düşük boyutlu uzaylarda etkin bir şekilde işleme kapasitesi, UMAP ve PCA analizleriyle desteklenmiştir. Bu analizler, modelin farklı ses sınıflarını başarılı bir şekilde ayırt edebilme yeteneğini ve bu sınıflar arasındaki ilişkileri tanımlama kabiliyetini doğrulamış, Wang ve Gao'nun (2019) çalışmalarıyla uyum içinde bulunmuştur [35]. Ayrıca, modelimizin kenar bilişim teknolojisiyle entegrasyonu, gerçek zamanlı trafik yönetimi çözümleri sunmakta, bu da Jing vd. (2011) çalışmalarından ayrı bir yenilik olarak dikkat çekmektedir [36]. Bu entegrasyon, modelimizin trafik yönetim sistemlerinde düşük gecikme süreleri ve yüksek veri işleme kapasitesiyle genel verimliliği artırma potansiyelini vurgulamaktadır.

Modelin genel sınıflandırma başarısı, ROC Eğrisi ve F1 Skoru gibi güvenilir metrikler kullanılarak ölçülmüştür. Bu metrikler, modelin yüksek doğruluk oranlarına sahip olduğunu ve düşük yanlış pozitif ve yanlış negatif oranları ile dengeli ve güvenilir bir performans sergilediğini ortaya koymuştur. Bu başarı, modelin trafikte hızlı ve doğru bir şekilde ambulans sirenlerini tespit etme kabiliyetinin, acil müdahale sürelerinin kısaltılması ve potansiyel olarak hayat kurtarma kapasitesine sahip olduğunu göstermektedir. Ancak bu çalışmanın, modelin çeşitliliği ve kapsamı ile ilgili sınırlamaları vardır. Çalışma,

belirli bir coğrafi alan ve trafik koşulları çerçevesinde gerçekleştirilmiştir ve modelin farklı ortamlarda genelleştirilebilirliğinin test edilmesi gerekliliğine işaret etmektedir. Gelecekteki çalışmalar, modelin farklı trafik ve çevresel koşullar altında da etkili olup olmadığını değerlendirmek için daha geniş ve çeşitli veri setleri kullanmalıdır. Ses kayıtlarının toplanmasında kullanılan donanımın getirdiği sınırlamalar da göz önünde bulundurulmalı ve farklı mikrofon tipleri ve kayıt teknikleri ile yapılan testlerle sistem kararlılığı değerlendirilmelidir. Ayrıca, modelin gerçek zamanlı trafik yönetim sistemlerine entegrasyonu üzerine daha detaylı çalışmalara ihtiyaç vardır. Kenar bilişim teknolojilerinin entegrasyonu, farklı ağ yapıları ve trafik yönetim sistemleri ile uyumluluğunun yanı sıra, altyapının mevcut ve gelecekteki ihtiyaçlarına uygunluğunu test etmeyi gerektirir.

Bu çalışma, trafik yönetiminde kenar bilişim kullanımının potansiyelini ortaya koymaktadır ve önerilen modelin gerçek zamanlı trafik yönetim sistemlerine entegrasyonu ile ilgili pratik uygulamalar üzerine daha fazla araştırma yapılması gerektiğini göstermektedir. Bu, sistemimizin gerçek zamanlı trafik sinyalizasyon sistemlerine entegrasyonunu ve şehir genelinde trafik akışını iyileştirme potansiyelini detaylı bir şekilde incelemeyi içermelidir.

Sonuç olarak, bu araştırmanın sonuçları, alanda yeni ve heyecan verici bir araştırma yönünü aydınlatmakta ve önerilen modelin sağladığı faydalar, trafik güvenliği ve acil durum müdahale süreçlerinin iyileştirilmesi yönünde önemli adımlar atılmasına olanak tanımaktadır. Modelin, siren seslerinin gerçek zamanlı tespitine yönelik sunmuş olduğu yenilikçi çözüm, Türkiye'nin trafik yönetimi altyapısında önemli bir adımı temsil etmektedir. Bu yenilikçi ses sınıflandırma modeli, Türkiye'nin mevcut trafik koşulları ve şehir içi trafik düzenlemeleri göz önünde bulundurulduğunda, acil durum araçlarının hızlı ve güvenli bir şekilde hedeflerine ulaşmalarını sağlama ve can kayıplarını önleme konusunda büyük bir uygulama potansiyeline sahiptir. Elde edilen bulgular, modelin daha geniş ve çeşitlendirilmiş veri setleriyle geliştirilerek gerçek dünya uygulamalarında daha kapsamlı testlerin yapılmasının yararlı olacağını göstermektedir. İlerleyen çalışmalar, bu modelin trafik yönetimi ve acil durum araçlarının tespiti alanlarında sağlayacağı önemli gelişmeleri ve toplumsal yararları daha da genişletebilir. Bu şekilde, çalışmamız sadece teknolojik bir yenilik sağlamakla kalmıyor, aynı zamanda toplumsal bir sorunun çözümüne katkıda bulunuyor ve bu alandaki bilgi birikimini artırarak gelecek araştırmalara zemin hazırlıyor.

5. Sonuçlar (Conclusions)

Bu çalışmada, trafik ortamında ambulans sirenlerinin tespiti için geliştirilen bir ses sınıflandırma modelinin performansını kapsamlı bir şekilde analiz edilmiştir. Modelin performansını değerlendirmek üzere çeşitli metrikler ve görselleştirmeler kullanılmıştır. UMAP ve PCA analizleri, modelin yüksek boyutlu verileri başarılı bir şekilde

düşük boyutlu uzaylara indirgeyebildiğini ve farklı sınıflar arasında açık bir ayırım yapabildiğini gösterilmiştir. Karışıklık Matrisi, modelin ambulans sirenlerini ve trafik seslerini etkin bir şekilde ayırt edebildiğini, özellikle ambulans sirenleri için yüksek doğruluk oranlarına ulaştığını ortaya koymaktadır.

Katlama Doğrulukları ve Sınıflar analizi, modelin çeşitli katlamalarda tutarlı ve dengeli bir performans sergilediğini gösterirken, Öğrenme Eğrisi, modelin eğitim sürecindeki gelişimini ve kararlılığını vurgulamaktadır. ROC Eğrisi, modelin farklı eşik değerlerinde yüksek duyarlılık ve özgüllük değerlerine sahip olduğunu, dolayısıyla sınıfları etkili bir şekilde ayırt edebildiğini belirtilmektedir. F1 Skoru, modelin hassasiyet ve geri çağırma oranlarının dengesini başarıyla yansıttı ve sınıflandırma performansının güçlü olduğunu göstermektedir. Mikrodenetleyici tabanlı modelin boyutları ve bellek gereksinimleri, uygulamaların gömülü sistemlerde etkin bir şekilde çalışmasına olanak tanıyan boyutlarda tutuldu. Modelin küçük bellek kullanımı ve düşük işlemci gereksinimleri, gömülü sistemlerde uygulanabilirliğini artırarak, gerçek dünya uygulamalarında kullanımını mümkün kılmaktadır. Sonuç olarak, bu çalışma, ses sınıflandırma algoritmalarının ambulans sirenlerinin tespiti ve genel trafik seslerinin sınıflandırılması alanında önemli bir adım temsil etmektedir. Elde edilen sonuçlar, modelin gerçek zamanlı senaryolarda nasıl performans göstereceğini değerlendirmek için daha geniş ve çeşitli bir veri seti kullanılarak saha testleri yapılmasını gerektirmektedir. Gelecekteki çalışmalar, modelin daha da geliştirilmesi ve çeşitli uygulama senaryolarına adapte edilmesi için fırsatlar sunmaktadır.

Kaynaklar (References)

- Buchanan, C., *Traffic in Towns: A study of the long term problems of traffic in urban areas*, Routledge, 2015.
- Ziegler, E.H., *The case for megapolitan growth management in the twenty-first century: Regional urban planning and sustainable development in the USA*, *International Journal of Law in the Built Environment*, 1 (2), 105–129, 2009.
- Nellore, K., Hancke, G.P., *A survey on urban traffic management system using wireless sensor networks*, *Sensors*, 16 (2), 157, 2016.
- Kaygisiz, Ö., Senbil, M., Yildiz, A., *Influence of urban built environment on traffic accidents: The case of Eskisehir (Turkey)*, *Case studies on transport policy*, 5 (2), 306–313, 2017.
- TC Sağlık Bakanlığı, *Yaşama Yol Ver*, <https://acilafet.saglik.gov.tr/TR-4647/yasama-yol-ver.html>, Erişim: 2024.
- Bhagchandani, K., Augustine, D.P., *IoT based heart monitoring and alerting system with cloud computing and managing the traffic for an ambulance in India*, *International Journal of Electrical and Computer Engineering*, 9 (6), 5068, 2019.
- Nallamothu, B.K., Bates, E.R., Wang, Y., Bradley, E.H., Krumholz, H.M., *Driving times and distances to hospitals with percutaneous coronary intervention in the United States: implications for prehospital triage of patients with ST-elevation myocardial infarction*, *Circulation*, 113 (9), 1189–1195, 2006.
- Avatefipour, O., Sadry, F., *Traffic management system using IoT technology-A comparative review*, *İçinde*, 2018 IEEE International Conference on Electro/Information Technology (EIT), 1041–1047. IEEE, 2018.
- Papageorgiou, M., Ben-Akiva, M., Bottom, J., Bovy, P.H.L., Hoogendoorn, S.P., Hounsell, N.B., Kotsialos, A., McDonald, M., *ITS and traffic management*, *Handbooks in operations research and management science*, 14, 715–774, 2007.
- Özcan Tatar C., Yılmaz E., Efe A., Sönmez B., Özdemir Y., Danişan B., Beyaz H.İ., Yegnidemir E., *Mobilenet based traffic sign detection system for mobile mapping: Crowdsourced geographical data collection system*, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 39 (4), 2305–2315, 2024.
- Roy, S., Bandyopadhyay, S., Das, M., Batabyal, S., Pal, S., *Real time traffic congestion detection and management using Active RFID and GSM technology*, *ITSC*, Kyoto, Japan, 48, 2010.
- Garcia Oya, J.R., Martín Clemente, R., Hidalgo Fort, E., González Carvajal, R., Muñoz Chavero, F., *Passive RFID-based inventory of traffic signs on roads and urban environments*, *Sensors*, 18 (7), 2385, 2018.
- Qin, H., Chen, W., Chen, W., Li, N., Zeng, M., Peng, Y., *A collision-aware mobile tag reading algorithm for RFID-based vehicle localization*, *Computer Networks*, 199, 108422, 2021.
- Bell, M.G.H., *Future directions in traffic signal control*, *Transportation Research Part A: Policy and Practice*, 26 (4), 303–313, 1992.
- Buchenscheit, A., Schaub, F., Kargl, F., Weber, M., *A VANET-based emergency vehicle warning system*, *İçinde*, 2009 IEEE Vehicular Networking Conference (VNC), 1–8, IEEE, 2009.
- Choudhury, K., Nandi, D., *Review of Emergency Vehicle Detection Techniques by Acoustic Signals*, *Transactions of the Indian National Academy of Engineering*, 8 (4), 535–550, 2023.
- Chandra, A., Singh, G., *Various Acoustic-Based Emergency Vehicle Detection Techniques: A Review*, *İçinde*, 2023 2nd International Conference on Computational Modelling, Simulation and Optimization (ICCMO), ss. 107–113. IEEE, 2023.
- Chen, S., Wen, H., Wu, J., *Artificial Intelligence Based Traffic Control for Edge Computing Assisted Vehicle Networks*, *Journal of Internet Technology*, 23 (5), 989–996, 2022.
- Durgun, M., *An Acoustic Bird Repellent System Leveraging Edge Computing and Machine Learning Technologies*, *İçinde*, 2023 Innovations in Intelligent Systems and Applications Conference (ASYU), 1–8, IEEE, 2023.
- Pan, J., McElhannon, J., *Future edge cloud and edge computing for internet of things applications*, *IEEE Internet of Things Journal*, 5 (1), 439–449, 2017.
- Hong, C.-H., Varghese, B., *Resource management in fog/edge computing: a survey on architectures, infrastructure, and algorithms*, *ACM Computing Surveys (CSUR)*, 52 (5), 1–37, 2019.
- Wan, S., Ding, S., Chen, C., *Edge computing enabled video segmentation for real-time traffic monitoring in internet of vehicles*, *Pattern Recognition*, 121 108146, 2022.
- Ning, Z., Huang, J., Wang, X., *Vehicular fog computing: Enabling real-time traffic management for smart cities*, *IEEE Wireless Communications*, 26 (1), 87–93, 2019.
- Gökdemir A., Çalhan A., *Deep learning and machine learning based anomaly detection in internet of things environments*, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 37 (4), 1945–1956, 2022.
- Durgun, Y., *Air Pollution Assessment in Turhal District: Temporal Analysis of Pollutants*, *International Scientific and Vocational Studies Journal*, 7 (2), 161–169, 2023.
- Deepa, R., *A role of an edge computing technologies for the internet of things in smart cities*, *Turkish Journal of Computer and Mathematics Education (TURCOMAT)*, 12 (9), 1321–1330, 2021.
- Liu, Y., Peng, M., Shou, G., Chen, Y., Chen, S., *Toward edge intelligence: Multiaccess edge computing for 5G and Internet of Things*, *IEEE Internet of Things Journal*, 7 (8), 6722–6747, 2020.
- Meshur, H.F.A., *Understanding Smart City Solutions in Turkish Cities From the Perspective of Sustainability*, *İçinde*, *Smart Grid Analytics for Sustainability and Urbanization*, 236–266. IGI Global, 2018.
- Babalik-Sutcliffe, E., Cengiz, E.C., *Bus rapid transit system in Istanbul: a success story or flawed planning decision?*, *Transport Reviews*, 35 (6), 792–813, 2015.
- Nellore, K., Hancke, G.P., *Traffic management for emergency vehicle priority based on visual sensing*, *Sensors*, 16 (11), 1892, 2016.
- Carrington, A.M., Manuel, D.G., Fieguth, P.W., Ramsay, T., Osmani, V., Wernly, B., Bennett, C., Hawken, S., McInnes, M., Magwood, O., *Deep ROC analysis and AUC as balanced average accuracy to improve model selection, understanding and interpretation*, *arXiv preprint arXiv:2103.11357*, 2021.
- Chicco, D., Jurman, G., *The advantages of the Matthews correlation coefficient (MCC) over F1 score and accuracy in binary classification evaluation*, *BMC genomics*, 21 (1), 1–13, 2020.
- Jadhav, P., Sawarkar, S.D., Pete, D.J., *Roadside Acoustic Signals Based Road Traffic Density Estimation*, *İçinde*, 2018 Fourth International Conference on Computing Communication Control and Automation (IC3UBEA), 1–5, 2018.
- Doğan, D., *Road-types classification using audio signal processing and SVM method*, *İçinde*, 2017 25th Signal Processing and Communications Applications Conference (SIU), 1–4, 2017.

35. Zhongsheng, W., Jiaqiong, G., A New Method of Improving the Traditional Traffic Identification and Accuracy, International Journal of Advanced Network, Monitoring and Controls, 3 (3), 53–60, 2018.
36. Jing, N., Yang, M., Cheng, S., Dong, Q., Xiong, H., An efficient SVM-based method for multi-class network traffic classification, İçinde, 30th IEEE International Performance Computing and Communications Conference, 1–8, 2011.