

Yapay Zeka Destekli Görme Engelli Bireyler için Trafik Işıkları ve Çevresel Nesnelerin Tespiti

Furkan Terzi¹, and Gulay Cicek²

^{1,2}Yazılım Mühendisliği Bölümü, Mühendislik ve Mimarlık Fakültesi

Istanbul Beykent Üniversitesi, Sarıyer, İstanbul, Türkiye

¹2203013065.student.beykent.edu.tr, ²gulaycicek@beykent.edu.tr

Abstract—Görme engelli bireylerin bağımsız ve güvenli bir şekilde hareket edebilmeleri, hem bireysel yaşam kalitesi hem de toplumsal bütünleşme açısından kritik bir öneme sahiptir. Bu çalışma, özellikle yaya trafik ışıklarının ve çevredeki nesnelerin algılanması gibi temel günlük ihtiyaçlara odaklanarak, görme engelli bireylerin şehir yaşamında karşılaştıkları zorluklara çözüm sunmayı hedefleyen bir mobil uygulama geliştirmektedir. Söz konusu uygulama, trafik ışıklarının rengini doğru bir şekilde sınıflandırmak, potansiyel çarpma tehlikesi yaratan nesneleri algılayarak sesli uyarı üretmek ve böylece bireyin güvenli hareketini desteklemek üzere tasarlanmaktadır. Problem, yalnızca teknik bir sınıflandırma problemi değil; aynı zamanda toplumsal bir kapsayıcılık ve dijital eşitlik meselesi olarak ele alınmaktadır.

Bu amaçla, hem klasik makine öğrenmesi algoritmaları (Karar Ağacı, KNN, SVM, Lojistik Regresyon, Naive Bayes) hem de modern derin öğrenme mimarileri (CNN, AlexNet, VGGNet, ResNet, MobileNet, CNN-LSTM) üzerinde karşılaştırmalı bir performans analizi gerçekleştirilmiştir. Model eğitimleri, 64x64 boyutunda normalize edilmiş özel bir görüntü veri seti kullanılarak yapılmış; öznetelik seçimi için SelectKBest, GAP ve PCA gibi yöntemler uygulanmıştır. Transfer learning ile MobileNetV2 gibi önceden eğitilmiş modeller üzerinden nesne tespiti yapılmakta olup trafik ışığı sınıflandırma algoritması CNN-LSTM hibrit modeli ile elde edilmektedir.

Geliştirilen uygulama, Android platformu üzerinde çalışmakta olup TensorFlow Lite entegrasyonu sayesinde düşük donanımlı cihazlarda da gerçek zamanlı görüntü işleme yapabilmektedir. Sistem hem offline hem de online çalışma yeteneğine sahiptir. Kullanım senaryoları arasında yaya geçitlerinde güvenli geçiş, şehir içi yön bulma ve açık alanda engel tespiti gibi örnekler yer almaktadır.

Deneyisel sonuçlar, CNN-LSTM modelinin %99'nın üzerinde doğruluk ve yüksek F1-skoru ile diğer mimarilerden üstün olduğunu ortaya koymuştur. Kesinlik analizleri, modelin ayırt edici gücünü doğrulamaktadır. Kullanıcı testlerinde, sesli yönlendirme ve arayüzün sadeliği yüksek memnuniyetle karşılanmış; ancak kamera odaklama ve görüntü netliği gibi donanım kaynaklı bazı sınırlamalar da rapor edilmektedir.

Bu çalışmanın özgün katkısı, görme engelli bireylere özel, düşük kaynak tüketimli, yüksek doğrulukta çalışan ve gerçek zamanlı uygulama potansiyeline sahip bir sistem sunmasıdır. Akademik literatüre CNN+LSTM tabanlı bir modelle hibrit mimarilerin mobil entegrasyonuna dair deneyisel katkı sağlanmakta; toplumsal düzeyde ise erişilebilir teknolojilere yönelik sürdürülebilir bir çözüm önerilmektedir. Gelecekte, bu sistemin çok dilli desteğe sahip hale getirilmesi, giyilebilir cihazlarla entegre edilmesi, kullanıcıdan geri bildirim toplayarak online öğrenme ile kendini geliştirme ve daha geniş kapsamlı kullanıcı testleriyle rafine edilmesi planlanmaktadır.

Keywords—Görme Engelli Bireyler, Mobil Uygulama, Trafik Işığı Sınıflandırması, Derin Öğrenme, CNN-LSTM, Nesne Tespiti, TensorFlow Lite, Gerçek Zamanlı Görüntü İşleme, Dijital Erişilebilirlik

I. GİRİŞ

Görme engelli bireyler için günlük yaşamda karşılaşılan en önemli zorluklardan biri, çevresel nesneleri ve trafik ışıkları gibi kritik unsurları algılayamamaktır. Güvenli bir yürüyüş deneyimi sağlamak ve kazaların önüne geçebilmek için yapay zeka destekli sistemlerin kullanımı giderek daha fazla önem kazanmaktadır [1].

Mobil tabanlı sistemler, görme engelli bireyler için çevresel farkındalığı artırma konusunda kritik bir rol oynamaktadır. Gerçek zamanlı nesne algılama ve sesli geri bildirim sistemleri, kullanıcıların çevrelerindeki potansiyel tehlikeleri algılamalarını ve bunlara uygun tepki vermelerini sağlar [2]. Ayrıca, yapay zeka destekli sesli asistan entegrasyonu ile bu sistemler daha etkileşimli ve erişilebilir hale getirilebilir [3]. Kullanıcı dostu arayüz tasarımı, görme engelli bireylerin uygulamayı kolayca kullanabilmesini ve teknolojinin hayatlarında daha fazla yer edinmesini sağlamaktadır.

Son yıllarda, yapay zeka ve bilgisayarlı görü teknolojilerindeki gelişmeler sayesinde, nesne algılama ve sınıflandırma konularında büyük ilerlemeler kaydedilmektedir. Bu doğrultuda geliştirilen SSD (Single Shot MultiBox Detector) gibi gerçek zamanlı algılama algoritmaları, mobil cihazlar üzerinde hızlı ve verimli çalışabilmektedir [4]. Bu gelişmelerin akabinde, CNN gibi derin öğrenme tabanlı sınıflandırma modelleri, trafik ışıklarının ve diğer kritik nesnelerin daha doğru ve hassas bir şekilde tanımlanmasını sağlayabilmektedir [5].

Sınıflandırma, verileri belirli kategorilere ayırarak analiz etmeye ve anlamlandırmaya yönelik temel bir makine öğrenimi tekniğidir [6]. Görme engelli bireyler için geliştirilen yapay zeka destekli sistemlerde, çevresel nesnelerin ve trafik ışıklarının doğru bir şekilde sınıflandırılması hayati öneme sahiptir. Doğru sınıflandırma sayesinde, kullanıcılar çevrelerindeki nesneleri algılayabilir ve güvenli bir şekilde yön bulabilirler [7].

Sınıflandırma algoritmaları, problem tespiti açısından büyük rol oynamaktadır. Görüntü işleme ve nesne algılama sistemlerinde yaygın olarak kullanılan Convolutional Neural Networks (CNN) ve Recurrent Neural Networks (RNN) gibi derin öğrenme modelleri, yüksek doğruluk oranları ile nesne tespiti ve sınıflandırma problemlerinde kayda değer başarılar elde etmektedir [8].

Mobil tabanlı sistemler, görme engelli bireylerin çevresel farkındalığını artırarak günlük yaşamda karşılaştıkları zorlukları en aza indirmektedir. Mobil cihazlar, sesli bildirim sağlayarak kullanıcıların çevreyle iletişim kurmasına imkan tanımaktadır [9].

Görüntü sınıflandırması, görme engelli bireylerin çevresel farkındalıklarını ve güvenliklerini artırmak için yaygın olarak kullanılan bir tekniktir. Bu alandaki çalışmalar, derin öğrenme algoritmaları kullanarak çevresel nesneleri, trafik ışıklarını, engelleri ve diğer önemli işaretleri sınıflandırmaya yöneliktir [10]. Örneğin, SSD (Single Shot MultiBox Detector) algoritması, gerçek zamanlı nesne algılama işlemleri için sıklıkla tercih edilmekte ve mobil cihazlarda düşük gecikmeyle yüksek doğruluk oranları sunmaktadır [7]. Ayrıca, görme engelli bireylerin güvenliğini arttırmak amacıyla yapılan araştırmalarda, çevresel nesneleri doğru bir şekilde sınıflandırmak önemli bir noktaya sahiptir [8].

Mobil ve web tabanlı uygulamalar, görme engelli bireylerin çevresel farkındalıklarını artıran önemli araçlardır. Bu tür uygulamalar, mobil cihazlar üzerinden çalışan yapay zeka destekli sınıflandırma sistemlerini içerir ve kullanıcıların çevresindeki nesneleri algılayıp sesli geri bildirimde bulunabilmektedir. Özellikle, bu tür uygulamalar, görme engelli bireylerin çevreleriyle etkileşimini artırırken, aynı zamanda bağımsız hareket kabiliyetlerini de geliştirmektedir [11]. Ayrıca, web tabanlı sistemler de görme engelli bireylerin çevrelerindeki verileri daha hızlı bir şekilde alıp anlamalarını sağlayarak, mobil uygulamalara entegre edilebilmektedir [12].

Literatür incelemesi, sınıflandırma yöntemlerinin görme engelli bireylerin çevresel farkındalıklarını artırmada önemli bir yere sahip olduğunu ortaya koymaktadır. Görüntü sınıflandırma yöntemleri, çevresel nesnelerin doğru bir şekilde tanınmasını sağlarken, mobil ve web tabanlı uygulamalar, kullanıcıların bu sınıflandırmalardan daha kolay faydalanmalarını sağlamaktadır.

Bu çalışma, görme engelli bireylerin çevresel farkındalığını artırmak amacıyla gerçek zamanlı nesne algılama ve sınıflandırma sağlayan bir mobil uygulama geliştirmeyi hedeflemektedir. Çalışmanın temel özgünlüğü, farklı derin öğrenme algoritmalarını birleştirmesi ve kullanıcı dostu bir arayüz ile gerçek zamanlı analiz gerçekleştirebilmesidir.

Bu çalışmada, nesne tespiti için TensorFlow Object Detection API kullanılarak SSD MobileNetV1 modeli tercih edilmektedir. SSD algoritması, tek adımda sınırlayıcı kutuların ve sınıfların tahminini gerçekleştirdiği için mobil cihazlar üzerinde hızlı ve doğru bir şekilde nesneleri tespit ederken [13], Convolutional Neural Networks (CNN) ise tespit edilen nesneleri doğru bir şekilde sınıflandırılmaktadır. Böylece sistem, çevresindeki nesneleri hem hızlı hem de doğru bir şekilde algılayarak kullanıcıya bilgi sağlamaktadır [14].

Mevcut çalışmalar genellikle bulut tabanlı çözümler sunmaktadır, ancak bu durum internet bağlantısına gereklilik yaratmaktadır. Çalışmamızda, TensorFlow Lite gibi optimizasyonlar kullanarak mobil cihazlarda çevrimdışı çalışabilen bir sistem geliştirilecektir. Bu sayede, görme engelli bireyler internet bağlantısı olmadan da nesne algılama ve sınıflandırma yapabilecektir. Bu yaklaşım, mobil uygulamaların performansını artırırken, erişilebilirliği de arttırmaktadır [15].

Görme engelli bireyler için geliştirilen uygulamanın kullanıcı dostu olması önem taşımaktadır. Bu çalışmada, mobil cihazların yerleşik metin-okuma (Text-to-Speech, TTS) motoru kullanılarak kullanıcıya anlık sesli geri bildirim sağlanmaktadır [16]. Uygulama, herhangi bir görsel arayüz gerektirmeden tüm bilgilendirmeleri Türkçe olarak sesli şekilde iletebilmekte ve görme engelli bireylerin çevresel nesneleri tanımasını kolaylaştırmaktadır [17].

Literatürde, görme engelliler için geliştirilen çoğu sistemin gerçek zamanlı performans eksikliği, yüksek donanım gereksinimleri ve kısıtlı engel tespit kapasitesi gibi sınırlamaları bulunmaktadır. Bu çalışmada ise:

- **Gerçek Zamanlı ve Çevrimdışı Çalışma:** Hafif ve optimize edilmiş derin öğrenme modelleri kullanılarak sistemin anlık olarak çalışması sağlanmaktadır. TensorFlow Lite sayesinde internet bağlantısı olmadan da nesne algılama ve sınıflandırma yapılabilir.
- **Sesli Geri Bildirim:** Uygulama, Android'in yerleşik *Text-to-Speech (TTS)* motoru ile entegre şekilde çalışmaktadır. Böylece, kullanıcı görsel arayüze ihtiyaç duymadan sesli yönlendirmeler alabilmekte ve uygulamayı tamamen işitsel olarak kullanabilmektedir.
- **SSD MobileNetV1 ve CNN Entegrasyonu:** Nesne tespiti için TensorFlow Object Detection API ile entegre çalışan SSD MobileNetV1 modeli tercih edilmiştir. Ayrıca, trafik ışıklarının sınıflandırılması gibi görevler için özelleştirilmiş CNN tabanlı bir TFLite modeli kullanılmaktadır. Bu iki yapının bir araya gelmesi, hem tespit hem de sınıflandırma süreçlerinin mobil cihaz üzerinde verimli ve hızlı bir şekilde gerçekleştirilmesini sağlamaktadır.

Bu özellikler, çalışmamızın önceki sistemlerden farklılaşmasını sağlamakta ve görme engelli bireylere daha güvenli ve erişilebilir bir çözüm sunmaktadır.

Bölüm II Literatür Taraması: Bu bölümde, daha önce yapılan çalışmalar incelenerek mevcut sistemlerin güçlü ve zayıf yönleri değerlendirilmektedir. Nesne algılama ve sınıflandırma konusunda kullanılan derin öğrenme yöntemleri, sesli asistan entegrasyonları ve gerçek zamanlı performans konularında yapılan araştırmalar ele alınmaktadır. Ayrıca, bu çalışmanın literatürdeki eksiklikleri nasıl giderdiği açıklanmaktadır.

Bölüm III Yöntem: Bu bölümde, çalışmada kullanılan yöntemler ayrıntılı olarak açıklanmaktadır. Nesne tespiti için TensorFlow Object Detection API ile entegre çalışan SSD MobileNetV1 modeli kullanılmaktadır. Trafik ışığı sınıflandırması için özelleştirilmiş bir Convolutional Neural Network (CNN) modeli, TensorFlow Lite formatında mobil cihaza entegre edilmektedir. Uygulama, Android platformunda geliştirilmiş olup çevrimdışı çalışacak şekilde optimize edilmektedir.

Bölüm IV Deneyisel Sonuçlar: Bu bölümde, geliştirilen sistemin test süreçleri ve deneysel sonuçları sunulmaktadır. Nesne tespiti ve sınıflandırma başarımı, gerçek zamanlı çalışmada karşılaşılan zorluklar ve optimizasyon tekniklerinin etkisi analiz edilmektedir. Elde edilen veriler grafikler ve tablolar ile desteklenmektedir.

Makale (Yıl)	Platform	Veri Seti	Örnek Sayısı	Yöntemler	Sonuçlar	Eksiklikler	Gelecek Katkıları
Gabriel ve ark. (2024) [1]	Mobil	COCO ve SSD-MobileNetV2 veri seti	4500 Görüntü	YOLO, VGG16, CNN, SqueezeNet	Doğruluk: %95.19 Kesinlik: %84.6	Taşınabilirlik ve geri bildirim çeşitliliği yetersizdir.	Gece görüş desteği ve çoklu geri bildirim sistemi eklenebilir.
Wang ve ark. (2024) [4]	Mobil	COCO veri seti	6276 Görüntü	R-CNN, YOLOv8-s	Doğruluk: %30.02 Hassasiyet: %31.07	Sistemin başarı oranı yeterli değildir.	Daha geniş veri setleriyle eğitim ve gece görüş desteği eklenebilir.
Lee ve ark. (2024) [8]	Mobil	Özelleştirilmiş veri seti	9045 Görüntü	YOLOv5	Doğruluk: %98.68 Hassasiyet: 88.84	Kullanılan sistemin taşınabilirlik ve geri bildirim çeşitliliği yetersizdir.	Sistemin daha taşınabilir hale getirilmesi ile daha geniş veri setleriyle eğitim yapılabilir.
Sahar ve ark.(2022) [17]	Akıllı Gözlük	LidSonic veri seti	3782 Görüntü	CNN	Doğruluk: %98.2 Hassasiyet: %92.2	Veri setinin çeşitliliği ve örnek sayısı sınırlı ve yetersiz.	Daha geniş veri setleri kullanılması beklenebilir.
Juan ve ark. (2022) [18]	Mobil	DS1, DS2 veri seti	650 Görüntü	ResNet50, RNN	Doğruluk: %95.15 Hassasiyet: %95.6	Farklı ortamlarda entegrasyon konusunda eksiklikler içermektedir.	Gerçek zamanlı performansın iyileştirilmesi gerekmektedir.
Hsieh ve ark. (2021) [19]	Giyilebilir Sistem	COCO veri seti	12534 Görüntü	CNN, YOLOv5	Doğruluk: %95.00 Kesinlik: %85.10	Sistem her hava koşulunda iyi çalışmamaktadır.	Gece, yağmurlu hava koşulları için ekstra eğitim verisi toplanabilir.
Jothi ve ark. (2022) [20]	Mobil	Flickr30k veri seti	31500 Görüntü	CNN, LTSM	Doğruluk: %86.74 Kesinlik: %83.12	Sistem, yalnızca önceden tanımlı veri kümesiyle çalıştığı için genellenebilirliği düşüktür.	Sistem gelecekte transfer öğrenme kullanılarak gerçek zamanlı olarak geliştirilebilir.
Sadik ve ark. (2024) [15]	Akıllı Çubuk	COCO ve IODR veri seti	4000 Görüntü	CNN, YOLOv5	Doğruluk: %92.5 Hassasiyet: %81.02 Duyarlılık: %93.64 Özgüllük: %92.17 F1-skoru: %98.40	Sistem, modellerini yalnızca çevrimdışı aşamada kullanmaktadır.	Sistemin gerçek zamanlı çalışabilmesi ve yapay zeka algoritmaları entegre edilerek geliştirilebilir.
Mariam ve ark. (2022) [21]	Mobil	MCIndoor20000 veri seti	1500 Görüntü	CNN, LTSM	Doğruluk: %95.40	Sistem henüz prototip aşamasındadır.	Sistem daha geniş kullanıcı gruplarıyla test edilebilir.
Jinsoo ve ark. (2021) [22]	Akıllı Gözlük	Low-Light (LOL) ve Cai veri seti	118000 Görüntü	CNN, YOLO, VGGNet16	Hassasiyet: %86.30 Hatırlama: %81.70	Sistem yalnızca yapay zeka sunucusu kullanıcı kapsamaktadır.	Donanım testleri sağlanarak kullanıcı testleri yapılabilir.
Marwan ve ark. (2023) [23]	Mobil	COCO ve IODR veri seti	159000 Görüntü	R-CNN, LSTM	Doğruluk: %85.70 Hassasiyet: %82.90	Sistem henüz gömülü cihazlara entegre edilmemiştir.	Gerçek dünya koşullarında test edilmesi planlanmaktadır.
Junjie ve ark. (2022) [5]	Giyilebilir Cihaz	COCO veri seti	4193 Görüntü	YOLOv3, NCS2 R-CNN, LSTM	Doğruluk: %96.00 Kesinlik: %83.23 Hatırlama: %84.75	Cihaz karmaşık ortamlarda yeterince başarılı performans göstermemiştir.	Daha gelişmiş nesne tespit algoritmalarıyla sistemin doğruluğu artırılabilir.
Nada ve ark. (2023) [14]	Mobil	Pascal VOC veri seti	11530 Görüntü	Mask R-CNN	Doğruluk: %83.9 Hassasiyet: %90.68 Hatırlama: %88.29	Model, gerçek zamanlı video analizini desteklememektedir.	Gerçek zamanlı video desteği ve karmaşık nesneler için veri artırılabilir.
Shabana ve ark. (2025) [24]	Gömülü Sistem	GRID Corpus veri seti	1000 Video	CNN, LSTM	Doğruluk: %98.00 Hassasiyet: %99.00, Hatırlama: %98.00, F1-skoru: %99.00	Yalnızca bir veri seti üzerinde test edilmiştir.	Donanım ile birlikte mobil cihazlara entegre edilebilir.

TABLE I: Literatür Taraması Sonuçları

Bu çalışmada kullanılan açık erişimli “[Cropped Lisa Traffic Light Dataset](#)”, toplamda 30.854 trafik ışığı görüntüsünden oluşmaktadır. Bu görüntüler, yayalar için anlam taşıyan iki temel sınıfa ayrılmıştır: “Go” (yeşil ışık) ve “Stop” (kırmızı ışık). Veri seti, eğitim (train) ve doğrulama (validation) olmak üzere iki alt kümeye ayrılmaktadır:

- **Eğitim Verisi (Train Seti)**
 - Go (Yeşil ışık): 12.840 örnek
 - Stop (Kırmızı ışık): 14.865 örnek
- **Doğrulama Verisi (Validation Seti)**
 - Go (Yeşil ışık): 1.372 örnek
 - Stop (Kırmızı ışık): 1.777 örnek

Sınıflar arasında örnek sayılarının dengeli olması, modelin her iki sınıfı da başarıyla öğrenmesini desteklemekte ve sınıf dengesizliğinden kaynaklanabilecek yanlışlıkları önlemektedir. Bu dengeli yapı sayesinde modelin doğruluk oranı artırılarak daha sağlam ve güvenilir sonuçlar elde edilmesi hedeflenmektedir.

B. Öznitelik Çıkarımı

Bu çalışmada kullanılan “[Cropped Lisa Traffic Light Dataset](#)”, doğrudan etiketlenmiş trafik ışığı görüntülerinden oluşmaktadır. Veri setinde tablo şeklinde tanımlı öznitelikler bulunmadığından, görüntü işleme temelli bir yaklaşımla öznitelik çıkartımı yapılması gerekmektedir.

Görüntüleri karakterize edecek öznitelikler, aşağıdaki teknikler kullanılarak çıkarılmaktadır:

- **Renk Histogramları:** Trafik ışığının rengi (kırmızı veya yeşil) temel alınarak her görüntüdeki renk dağılımları analiz edilmektedir. Özellikle kırmızı ve yeşil renklerin yoğunlukları hesaplanarak renk bazlı öznitelikler elde edilmektedir [42].
- **Evrişimli Sinir Ağı(CNN) Katmanları:** Derin öğrenme modelinin erken evre katmanları, kenar, şekil ve ışık yoğunluğu gibi düşük seviyeli görsel öznitelikleri otomatik olarak öğrenmekte ve çıkarmaktadır.
- **OpenCV2 Tabanlı Renk Segmentasyonu:** Görüntülerin HSV (Hue, Saturation, Value) renk uzayına dönüştürülerek, belirli eşik değerler ile yeşil ve kırmızı renk bölgeleri izole edilmektedir. Bu da renk bölgesinin yoğunluğu, alanı ve konumu gibi özniteliklerin çıkarılmasını sağlamaktadır [43].

Bu çalışma, görüntü odaklı öznitelik çıkarımını derin öğrenme tabanlı (CNN), geleneksel bilgisayarla görme teknikleri (OpenCV) ve renk analiz yöntemlerini bir arada kullanarak gerçekleştirmesi açısından multimodal ve özgün bir yaklaşım sunmaktadır.

C. Ön İşleme

Makine ve derin öğrenme modellerinin başarılı olabilmesi için, verinin modellemeye uygun hale getirilmesi büyük önem taşımaktadır. Bu nedenle, ham veriler üzerinde çeşitli ön işleme adımları gerçekleştirilmektedir [44]. Bu adımlar, hem veri kalitesini artırmakta hem de modelin doğruluğunu önemli ölçüde yükseltmektedir. Bu çalışmada kullanılan veri setinin ön işleme adımları aşağıda sıralanmaktadır:

1. Veri Temizleme

- **Klasör isimlendirmesi ve etiket kontrolü:** Bazı görsellerin yanlış klasörlerde bulunduğu tespit edilmiş, görseller doğru sınıflara taşınmıştır.
- **Yapay Zeka Destekli Temizleme:** Özellikle renk yoğunluğu analizine dayalı, sınıfa uygun olmayan (örneğin yeşil ışık klasöründe yeterli yeşil ton içermeyen görseller) örnekler, basit bir CNN modeli ile ön sınıflandırılarak filtrelenmiştir. Bu sayede, daha temiz ve tutarlı bir veri seti elde edilmiştir.
- **Bozuk görsellerin tespiti:** Açılmayan veya boyutu sıfır olan görüntüler tespit edilerek veri setinden çıkartılmıştır.

2. Ölçekleme (Normalizasyon)

- **Görüntü piksellerinin ölçeklenmesi:** Görsellerdeki pikseller genellikle 0 ile 255 arasında değer alır. Modelin daha hızlı ve stabil öğrenebilmesi için bu değerler [0, 1] aralığına indirgenmektedir [45].
- **Yöntem:** Tüm pikseller, basit bir min-max normalizasyonu ile ölçeklenmiştir:

$$X_{\text{normalized}} = \frac{X}{255}$$
- **Bu işlem sayesinde:**
 - Eğitim süresi kısılır.
 - Ağırlıklar daha kararlı öğrenilir.
 - Aktivasyon fonksiyonları (özellikle sigmoid/tanh gibi) daha verimli çalışır.

3. Veri Ayrımı

- **Eğitim, doğrulama ve test ayrımı:** Veri seti, eğitim ve doğrulama olmak üzere ikiye ayrılmıştır. Modelin test değerlendirmesi, ayrı bir aşamada yapılmaktadır [46]. Eğitim ve doğrulama verileri aşağıdaki gibi oranlanmıştır:
 - Eğitim seti: %90
 - Doğrulama seti: %10
- **Veri sayıları:** Her sınıftaki görüntü sayıları aşağıdaki gibidir:
 - **Train:** 12.840 adet ‘Go’, 14.865 adet ‘Stop’ görüntüsü
 - **Validation:** 1.372 adet ‘Go’, 1.777 adet ‘Stop’ görüntüsü
- **K-Fold Çapraz Doğrulama:** Modelin sağlamlığını test etmek amacıyla **5 katlı çapraz doğrulama (5-Fold Cross Validation)** yöntemi uygulanmıştır. Bu yöntemde:
 - Veri seti 5 eşit parçaya ayrılır.
 - Her katmanda bir parça doğrulama seti, kalan 4 parça eğitim seti olarak kullanılır.
 - Bu işlem 5 kez tekrarlanır, her parça bir kez doğrulama seti olarak görev almaktadır [47].

D. Öznitelik Seçimi

Görüntülerden elde edilen özniteliklerin fazla sayıda ve yüksek boyutlu olması, modelin hem eğitim süresini uzatmakta hem de overfitting riskini artırmaktadır. Bu durumu engellemek amacıyla ilk olarak Temel Bileşenler Analizi (PCA) yöntemi uygulanmaktadır. PCA ile yüksek boyutlu öznitelik vektörleri, bilgi kaybı minimum olacak şekilde düşük boyutlara indirgenmektedir.

Buna ek olarak, klasik yöntemlerin yanında derin öğrenme tabanlı bir öznetelik çıkarım yöntemi de uygulanmaktadır. Eğitilmiş bir CNN modelinin ara katmanlarından elde edilen öznetelik haritası (feature map) kullanılarak, görüntülerin daha soyut ve anlamlı temsilleri çıkartılmaktadır. Böylece sadece pikseller değil, kenar bilgileri, renk desenleri ve doku gibi daha derin görsel özellikler de modele aktarılmaktadır.

Bu iki yöntem birlikte kullanılarak daha anlamlı ve sade özneteliklerle çalışan, daha az kaynak tüketen ve daha yüksek doğruluğa sahip bir model elde edilmektedir.

E. Model Seçimi

Bu bölümde, çalışmamıza uygulanacak makine ve derin öğrenme modelleri detaylandırılmaktadır.

1) **A. Makine Öğrenme Algoritmaları:** Makine öğrenme algoritmaları, özellikle etiketli verilerle öğrenme yapan ve sınıflandırma ya da regresyon gibi problemleri çözmede kullanılan güçlü yöntemlerdir. Bu algoritmalar, doğru tahminler yapmak ve genelleme yeteneklerini geliştirmek amacıyla verilerden öğrenir. Verimizin özelliklerine ve hedefimize uygun algoritmalar seçilerek modelin başarısı artırılabilir. Aşağıda, bu çalışmada uygulanacak makine öğrenme algoritmaları açıklanmaktadır:

a) 1. Karar Ağaçları:

- **Tanım:** Karar ağaçları, bir veri kümesindeki sınıflandırma veya regresyon problemlerini çözmek için kullanılan bir yöntemdir. Veriyi bir dizi if-else kuralına dayalı karar noktalarına ayırarak sınıflandırma yapar [48].
- **Avantajları:**
 - Kolay anlaşılabilir ve görselleştirilebilir.
 - Hızlı eğitim ve tahmin yapabilir.
 - Veri setindeki özelliklerin anlamlı şekilde temsil edilmesine olanak tanır.
- **Uygunluk:** Bu algoritma, etiketli verilerle çalışırken güçlüdür ve karmaşık ilişkilerin açıklanmasında faydalıdır. Özellikle yüksek boyutlu verilerde, sınıflandırmaların net bir şekilde yapılabilmesi için uygundur.
- **Formül:** Karar ağacı algoritması, sınıflar arasındaki en büyük bilgi kazancını sağlamak için genellikle *Gini impurity* ya da *Entropi* hesaplamaları kullanır.

b) 2. K En Yakın Komşu (K-NN):

- **Tanım:** K-NN algoritması, sınıflandırma yaparken en yakın K adet örneğin etiketlerine bakarak tahminde bulunur. En yakın komşuların çoğunlukta olduğu sınıf, tahmin edilen sınıf olur [49].
- **Avantajları:**
 - Basit ve anlaşılır bir algoritmadır.
 - Parametre ayarlamaları minimumdur.
 - Veriye hızlıca adapte olabilir.
- **Uygunluk:** Bu algoritma, verilerdeki benzerlikleri tanımda etkilidir ve verinin hacmi arttıkça yüksek doğrulukla sonuç verebilir.

$$d(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (1)$$

- **Formül:** K-NN, verinin uzaklık ölçüsüne dayalı olarak çalışır, genellikle Euclidean mesafesi kullanılmaktadır.

c) 3. Destek Vektör Makineleri (SVM):

- **Tanım:** SVM, sınıflandırma ve regresyon görevlerinde kullanılan, veriyi farklı sınıflara ayırmak için bir hiperdüzlem kullanan güçlü bir algoritmadır [50].
- **Avantajları:**
 - Çekirdek (kernel) fonksiyonları ile doğrusal olmayan problemleri de çözebilir.
 - Genellikle overfitting yapmaz.
- **Uygunluk:** Özellikle sınıflar arasındaki sınırların net bir şekilde belirlendiği ve doğrusal olmayan veri kümeleri için uygundur.

$$w^T x + b = 0 \quad (2)$$

- **Formül:** SVM modelinde, optimal hiperdüzlemin denklemi bu şekilde tanımlanmaktadır.

d) 4. Lojistik Regresyon:

- **Tanım:** Lojistik regresyon, bağımlı bir değişkenin (y) iki sınıftan birine ait olup olmadığını tahmin etmek için kullanılan bir regresyon modelidir [51].
- **Avantajları:**
 - Kolay uygulanabilir.
 - Çıktısı olasılık değerleri olduğu için yorumlanabilir.
- **Uygunluk:** Bu model, genellikle ikili sınıflandırma problemleri için uygundur ve hızlı sonuçlar alabilmek için idealdir.

$$p(y = 1|x) = \frac{1}{1 + e^{-(w^T x + b)}} \quad (3)$$

- **Formül:** Lojistik regresyon modeli bu şekilde ifade edilmektedir.

e) 5. Naive Bayes:

- **Tanım:** Naive Bayes, her özelliğin birbirinden bağımsız olduğunu varsayarak olasılık teorisiyle sınıflandırma yapar. Özellikle metin sınıflandırma gibi görevlerde yaygın olarak kullanılmaktadır [52].
- **Avantajları:**
 - Kolay uygulanabilir ve hızlıdır.
 - Büyük veri setlerinde iyi çalışır.
 - Bellek ve işlem kaynağı açısından verimlidir.
- **Uygunluk:** Özellikle yüksek boyutlu ve bağımsız özelliklere sahip veri setlerinde oldukça başarılıdır.

$$P(C_k | x) = \frac{P(x | C_k)P(C_k)}{P(x)} \quad (4)$$

- **Formül:** Naive Bayes sınıflandırıcısının temel formülü Bayes Teoremi'ne dayanmaktadır.

2) **B. Derin Öğrenme Algoritmaları:** Bu bölümde, derin öğrenme mimarileri incelenmektedir. Derin öğrenme, büyük veri kümeleri ile çalışan ve çok katmanlı yapılar sayesinde karmaşık örüntüleri öğrenebilen yapay sinir ağı sistemidir. Özellikle görüntü işleme, doğal dil işleme gibi alanlarda yüksek başarı göstermektedir. Bu çalışmada, veri setine uygun olarak seçilen 5 derin öğrenme mimarisi detaylandırılmaktadır.

a) 1. Convolutional Neural Networks (CNN):

- **Tanım:** CNN, özellikle görüntü verilerinde yaygın olarak kullanılan bir yapay sinir ağı mimarisidir. Görüntülerden öznetelik çıkarımı yaparak sınıflandırma görevlerinde kullanılır [53].

Bu çalışmada, yöntemsel sürecin tüm aşamalarında özgünlük gözetilmektedir. Öznitelik çıkarma ve seçme aşamalarında, sınıflandırma başarımını artıracak etkili ve anlamlı özellikler belirlenmiş; bu süreçte klasik yaklaşımların ötesine geçilmektedir. Model seçiminde, problemi en iyi şekilde temsil edebilecek algoritmalar tercih edilerek parametrik optimizasyonlar yapılmakta olup, eğitim sürecinde ise overfitting riskine karşı dikkatli bir yapı izlenmektedir. Değerlendirme metriklerinin çok yönlü olarak kullanılmasıyla, geliştirilen sistemin güçlü ve zayıf yönleri detaylıca analiz edilmektedir. Tüm bu adımlar, çalışmanın sadece teknik yeterliliğini değil aynı zamanda literatürdeki benzerlerinden ayrışmasını ve özgün katkı sunmasını sağlamaktadır.

IV. DENEYSEL SONUÇLAR

A. Veri Seti ve Ön İşleme

1) *Veri Seti Tanımlaması:* Bu çalışmada kullanılan veri seti, Kaggle platformunda açık erişimli olarak bulunan “[Cropped Lisa Traffic Light Dataset](#)” olup, trafik ışıklarının renk tabanlı sınıflandırılması amacıyla etiketlenmiş toplam 30.854 adet görsel içermektedir. Veri seti, iki ana sınıf altında toplanmaktadır: “Go” (yeşil ışık) ve “Stop” (kırmızı ışık). Her bir sınıfın örnek sayısı ve veri setinin genel özellikleri Tablo III’de özetlenmektedir.

Özellik	Açıklama	Türü
Sınıf Sayısı	2	Kategorik
Örnek Sayısı (Toplam)	30.854	Sayısal
Örnek Sayısı (Go)	14.212	Sayısal
Örnek Sayısı (Stop)	16.642	Sayısal
Görüntü Boyutu	Genellikle 224x224 piksel	Görsel Veri
Renk Kanalları	RGB	Görsel Veri

TABLE III: Veri Setinin Temel Özellikleri

Veri setindeki sınıf dağılımı Şekil 1’de gösterilmektedir. Sınıflar arasında örnek sayısı bakımından dengeli bir yapı gözlenmekte olup, model eğitiminin her iki sınıf için de dengeli ve sağlıklı gerçekleşmesi sağlanmaktadır.




Fig. 1: Veri Setinde “Go” ve “Stop” Sınıflarının Dağılımı (Histogram)

2) *Veri Temizleme ve Ön İşleme:* Veri setinde bulunan eksik değerler, aykırı örnekler ve tutarsızlıklar modelin doğruluğunu olumsuz etkileyebileceğinden, veri temizleme ve ön işleme adımları dikkatle uygulanmaktadır.

- **Eksik Veri Takibi:** Eksik veri analizi kapsamında veri setinde eksik veri bulunmamaktadır
- **Aykırı Değer Yönetimi:** Sınıf etiketleri ve görüntü dosyaları incelenmiş, yanlış sınıflandırılmış veya bozuk görseller bulunmamıştır.
- **Özellik Mühendisliği:** Görüntülerin renk uzayına dönüştürülmesi, renk segmentasyonu ve normalize edilmesi gibi işlemler uygulanarak model için anlamlı öznitelikler elde edilmektedir [61].

Şekil 2’de veri temizleme ve ön işleme sürecinin adım adım akış diyagramı sunulmaktadır.




Fig. 2: Veri Temizleme ve Ön İşleme Sürecinin Akış Diyagramı

2) Kullanıcı Etkileşimi ve Uygulama Süreci:

• Başlangıç Ekranı:

Uygulama açıldığında, ekranda herhangi bir noktaya dokunulması için sesli yönlendirme yapılır. Kullanıcıya “Uygulamayı başlatmak için herhangi bir yere dokununuz.” şeklinde bilgilendirme verilir.




Fig. 7: Başlangıç ekranı tasarımı

• Başlama:

Kullanıcı ekrana dokunduğunda uygulama çalışmaya başlar. Ortam ışık değeri tespit edilerek, düşük ışıklı ortamlarda otomatik olarak flaş ışığı devreye girer ve kullanıcıya yol gösterir.




Fig. 8: Ana ekran tasarımı

• Mod Seçimi:

Kullanıcı, ekrana art arda iki kez dokunduğunda çevresel nesne tespiti modu aktif hale gelir. Bu mod sayesinde, çevredeki nesneler anlık olarak algılanıp sesli olarak bildirilmeye başlanır. Üç kez dokunma ise uygulamanın güvenli şekilde kapatılmasını sağlar, böylece kullanıcı kolayca çıkış yapabilir.

• Nesne Tespiti Modu:

Bu modda, uygulama yakındaki nesneleri algılar ve kullanıcının çevresindeki engelleri tespit etmesine yardımcı olmak için sesli uyarılar verir. Bu sayede görme engelli bireylerin çevre farkındalığı artırılır.




Fig. 9: Çevresel nesne tespiti arayüzü

• Trafik Işığı Algılama:

Uygulama, trafik ışığının renk durumunu gerçek zamanlı olarak analiz eder ve sonucu kullanıcıya sesli şekilde bildirir.




Fig. 10: Trafik ışığı durumu tespiti

• Sadelik ve Sesli Bildirim:

Uygulamanın arayüzü sade ve yalındır, karmaşık görsel unsurlardan arındırılmıştır. Tüm bildirimler tamamen sesli olarak sunulur ve böylece görme engelli kullanıcıların uygulamayı kolaylıkla kullanmaları sağlanır.

Ayrıca uygulamanın farklı platformlara (web, iOS, Android) kolayca entegre edilmesi hedeflenmektedir. Platform bağımsız yapılar ve TensorFlow Lite gibi hafif modeller, uygulamanın farklı cihazlarda performanslı çalışmasını mümkün kılar. Bu sayede, farklı işletim sistemlerinde ve donanım özelliklerinde de yüksek kullanılabilirlik sağlanabilecektir.

Sonuç olarak, modelin gerçek hayattaki başarısı ve sürdürülebilirliği için genellenabilirlik ve uyarlanabilirlik üzerine yapılan çalışmaların, veri çeşitliliğinin artırılması, gelişmiş eğitim yöntemlerinin entegrasyonu ve çoklu platform desteği ile desteklenmesi gerekmektedir.

E. Etik, Gizlilik ve Kullanıcı Güveni

Bu çalışmada geliştirilen uygulama, kullanıcıların kişisel ve çevresel verilerini işlediğinden, etik ilkeler ve veri gizliliği konuları büyük önem taşımaktadır. Özellikle, kullanıcı verilerinin anonimleştirilmesi ve KVKK (Kişisel Verilerin Korunması Kanunu) ile GDPR (Genel Veri Koruma Yönetmeliği) gibi uluslararası ve yerel yasalara uyumluluğu sağlanmaktadır.

Modelin yanlış sınıflandırma yapması durumunda ortaya çıkabilecek olumsuz etkiler de etik sorumluluk açısından değerlendirilmelidir. Örneğin, görme engelli bireylerin trafikte güvenliğini sağlama amacıyla geliştirilen bu uygulamada, hatalı sınıflandırmalar kullanıcıların yanlış yönlendirilmesine sebep olabilir. Bu nedenle, modelin hata payının minimuma indirilmesi, kullanıcıların bilgilendirilmesi ve uygulamanın destekleyici bir araç olduğu vurgulanmaktadır.

Sonuç olarak, etik ve gizlilik konuları, sadece yasal bir zorunluluk değil, aynı zamanda kullanıcıların uygulamaya olan güvenini sağlamak ve sürdürülebilir bir kullanım ortamı oluşturmak için temel gereksinimlerdir.

F. Gelecek Çalışmalar için Öneriler

Bu çalışmanın ortaya koyduğu bulgular, gelecekteki araştırmalar için çeşitli geliştirme alanlarını işaret etmektedir. Öncelikli olarak, modelin daha büyük ve çok kaynaklı veri kümeleriyle eğitilmesi, genellenabilirlik ve sınıflandırma başarımını artırmak adına önem arz etmektedir. Farklı coğrafi bölgelerden, çeşitli ışık koşullarından ve kamera açılarından elde edilecek görüntülerle zenginleştirilmiş bir veri seti, modelin gerçek hayattaki değişken koşullara uyum yeteneğini artıracaktır.

Kullanıcı testlerinden elde edilen geri bildirimler doğrultusunda, sistemin sürekli geliştirilmesi kritik bir gerekliliktir. Özellikle, testlerde nispeten düşük puan alan kamera performansı, gelecekteki çalışmalarda iyileştirilmesi gereken öncelikli alanlardan biridir. Gerçek zamanlı görüntü işleme kalitesinin artırılması, hem nesne tespitinde hem de trafik ışığı sınıflandırmasında sistemin güvenilirliğini doğrudan etkileyecektir.

Ayrıca, uygulamanın çok dillilik desteğiyle erişilebilirliğinin artırılması, görme engelli bireyler için öneri sistemleri geliştirilmesi ve kişiselleştirilebilir sesli yönlendirme özelliklerinin entegre edilmesi planlanmaktadır. Bu tür özellikler, sistemin hem kullanıcı deneyimini zenginleştirmesine hem de daha geniş bir kullanıcı kitlesine hitap etmesine olanak sağlayacaktır.

VI. SONUÇ

A. Çalışmanın Özeti ve Amaçları

Bu çalışmada, görme engelli bireylerin günlük yaşamlarını kolaylaştırmak amacıyla geliştirilen bir mobil uygulama tanıtılmış ve sınıflandırma tabanlı yapay zeka yöntemleriyle desteklenen sistem mimarisi sunulmaktadır. Uygulamanın temel hedefi; trafik ışıklarının renklerini sınıflandırmak, çevredeki nesneleri algılamak ve kullanıcıyı sesli olarak yönlendirmektir. Bu doğrultuda, Convolutional Neural Network (CNN), MobileNet gibi modern derin öğrenme mimarileri test edilmiş; ayrıca CNN-LSTM hibrit yapısı kullanılmaktadır. Özellikle dinamik ortamlarda artırılmış gerçek zamanlı performans, bu çalışmayı benzerlerinden ayıran önemli bir katkı sağlamaktadır.

B. Model Performansı ve Teknik Başarılar

Geliştirilen modellerin doğruluk, F1 skoru, kesinlik gibi metriklerle performansı değerlendirilmiş ve CNN-LSTM hibrit yapısının özellikle zaman serisi karakteri taşıyan görsel akıflarda daha yüksek başarı sağladığı görülmüştür. Öznitelik seçimi (GAP, PCA) ve veri ön işleme yöntemleriyle desteklenen bu modellerin başarı oranları literatürdeki benzer çalışmalardan daha yüksek bulunmaktadır. Modelin TensorFlow Lite formatında mobil cihaza başarıyla entegre edilmesi, sistemin teknik olgunluğunu göstermektedir.

C. Uygulamanın Pratik Kullanılabilirliği

Android platformu üzerinde çalışan uygulama, düşük donanımlı cihazlarda dahi temel işlevlerini sürdürebilmektedir. Uygulama, kırsal bölgelerde internet bağlantısı olmayan kullanıcılar için de erişilebilirlik sağlamaktadır. Kullanıcıların farklı ortamlarda karşılaştıkları zorlukları minimize etmek amacıyla, uygulamanın çevresel adaptasyon yeteneği geliştirilmiştir.

D. Kullanıcı Deneyimi ve Geri Bildirim Potansiyeli

Kullanıcı arayüzü sade, erişilebilir ve kullanıcı dostu olarak tasarlanmıştır. İlk kullanıcı testlerinde uygulamanın sesli yönlendirme, büyük ikonlar ve renk-kontrast dengesi açısından olumlu geri bildirim aldığı, ancak kamera optimizasyonu konusunda iyileştirme gerektiren alanlar tespit edilmektedir. Gelecek sürümlerde bu konuda yazılımsal optimizasyon yapılması planlanmaktadır.

E. Sınırlamalar

Mobil cihazlarda düşük çözünürlüklü kamera ve yetersiz işlem gücü, sınıflandırma doğruluğunu sınırlayan faktörlerden biri olmuştur. Veri seti, belirli ışık koşulları ve sınırlı coğrafi bölgeyi temsil ettiği için gerçek hayattaki tüm varyasyonları kapsamada yetersiz kalabilmektedir. Ancak, veri çeşitliliğinin artırılması ve daha geniş bir kullanıcı kitlesi üzerinde test edilmesiyle bu sınırlamaların aşılabileceği öngörülmektedir.

F. Gelecek Çalışmalar için Öneriler

İleride yapılacak çalışmalarda, sistemin giyilebilir cihazlarla entegrasyonu, IoT destekli sensörlerle desteklenmesi ve farklı dillerde destek sunması hedeflenmektedir. Böylece hem bireysel kullanıcı deneyimi zenginleşecek hem de modelin kararlılığı ve genellenabilirliği daha üst düzeye çıkarılacaktır. Ayrıca, kullanıcıların gerçek zamanlı geri bildirimlerini değerlendirmek için yapay zeka destekli bir analiz modülünün eklenmesi planlanmaktadır.