

Kamu Sağlığı ve Çevresel Sürdürülebilirlik için YOLOv5 Tabanlı Sigara Tespiti ve Sesli Uyarı Sistemi

Nur Kuban TORUN^{1*}  Oğuzhan TATLI¹  Merve ÖNALAN¹ 

¹Bilecik Seyh Edebali University, Department of Management Information System, Bilecik, Turkey

Makale Bilgisi

Araştırma makalesi
Başvuru: 15/01/2025
Düzeltilme: 22/02/2025
Kabul: 17/03/2025

Anahtar Kelimeler

Sağlık ve Kaliteli Yaşam
Derin Öğrenme
Görüntü İşleme
Sigara Tespiti
Sesli Uyarı

Article Info


Research article
Received: 15/01/2025
Revision: 22/02/2025
Accepted: 17/03/2025

Keywords

Good Health and Well-Being
Deep Learning
Image Processing
Cigarette Detection
Sound Alert

Grafik Özet (Graphical/Tabular Abstract)

Bu çalışma, YOLOv5 modeliyle kapalı ve yasaklı alanlarda sigara içen bireyleri gerçek zamanlı tespit eden ve sesli uyarı mekanizmasıyla caydırıcılığı artırmayı hedefleyen bir sistem sunmaktadır. Şekilde, görüntülerin işlenip sigara içme davranışı tespit edildiğinde sesli uyarı veren düşük maliyetli ve gerçek zamanlı sistemin çalışma süreci gösterilmektedir. / This study presents a system that detects individuals smoking in enclosed and restricted areas in real time using the YOLOv5 model and enhances deterrence through a voice alert mechanism. The figure illustrates the operational process of the low-cost and real-time system, which processes images and issues a voice alert upon detecting smoking behavior.



Şekil A: Sistemin Çalışma Süreci / Figure A: System Operation Process

Önemli noktalar (Highlights)

- Gerçek zamanlı sigara algılama gerçekleştirilmiştir. Real-time cigarette detection has been implemented.
- YOLOv5 modeliyle yüksek doğruluk oranı sağlanmıştır. A high accuracy rate has been achieved using the YOLOv5 model.
- Tespit sonrası otomatik sesli uyarı sistemi entegre edilmiştir. An automatic voice alert system has been integrated after detection.
- Düşük maliyetli bir donanım altyapısı ile çalışmaktadır. It operates with a low-cost hardware infrastructure.

Amaç (Aim): Pasif içiciliği azaltmak ve yasaklı alan ihlallerini en aza indirmek amacıyla YOLOv5 tabanlı otomatik tespit ve uyarı sistemi geliştirilmiştir. / An automatic detection and alert system based on YOLOv5 has been developed to reduce passive smoking and minimize violations in restricted areas.

Özgünlük (Originality): Sistem. YOLOv5 algoritmasıyla sigara içme davranışını gerçek zamanlı tespit eder ve sesli uyarılarla caydırıcı bir etki yaratır. Yasaklı alanlarda sigara içme davranışını engellemeyi amaçlar ve topluma sağlıklı yaşam bilinci kazandırır. / An automatic detection and alert system based on YOLOv5 has been developed to reduce passive smoking and minimize violations in restricted areas.

Bulgular (Results): YOLOv5 modeli, %82 doğrulukla sigarayı tespit etmiş ve sesli uyarı sistemi başarıyla çalışmıştır. Yüksek FPS değerleri sunan YOLOv5s modeli tercih edilmiştir. Sigara tespiti için recall 0.734, precision 0.906, mAP@0.5 0.825 ve F1 Skoru 0.811 olarak hesaplanmıştır. / The YOLOv5 model detected cigarettes with 82% accuracy, and the voice alert system functioned successfully. The YOLOv5s model, which offers high FPS values, was preferred. For cigarette detection, recall was calculated as 0.734, precision as 0.906, mAP@0.5 as 0.825, and the F1 Score as 0.811.

Sonuç (Conclusion): Çalışma sigara tespitinde etkin ve düşük maliyetli bir çözüm sunmaktadır. Model, yasaklı alanlarda pasif içiciliği önlemek ve caydırıcılığı artırmak için kullanılabilir. / The study presents an effective and low-cost solution for cigarette detection. The model can be used to prevent passive smoking and enhance deterrence in restricted areas.



Kamu Sağlığı ve Çevresel Sürdürülebilirlik için YOLOv5 Tabanlı Sigara Tespiti ve Sesli Uyarı Sistemi

Nur Kuban TORUN^{1*} Oğuzhan TATLI¹ Merve ÖNALAN¹

¹Bilecik Seyh Edebali University, Department of Management Information System, Bilecik, Turkey

Makale Bilgisi

Araştırma makalesi
Başvuru: 15/01/2025
Düzeltilme: 22/02/2025
Kabul: 17/03/2025

Anahtar Kelimeler

Sağlık ve Kaliteli Yaşam
Derin Öğrenme
Görüntü İşleme
Sigara Tespiti
Sesli Uyarı

Öz

Sigara kullanımı, dünya genelinde çok sayıda sağlık sorununa yol açarak her yıl milyonlarca insanın ölümüne neden olmaktadır. Sigara dumanına maruz kalma, yalnızca kullanıcıyı değil, çevresindeki bireyleri de olumsuz etkileyerek pasif içicilik riskini artırmaktadır. Bu nedenle, sigaranın bireysel ve toplumsal zararlarını azaltmaya yönelik geliştirilen “dumansız hava sahası” uygulamaları, halk sağlığını korumada kritik bir rol üstlenmektedir. Bu çalışmada, YOLOv5 tabanlı bir nesne tespit modeli kullanılarak sigara içme davranışının gerçek zamanlı tespit edilmesi hedeflenmiştir. Modelin eğitimi için farklı ışık, açı ve arka plan koşullarında çekilen 3.912 görüntüden oluşan bir veri seti oluşturulmuş, veri artırma teknikleri uygulanarak görüntü sayısı 10.176’ya çıkarılmıştır. Veriler, Roboflow platformunda etiketlenmiş ve model eğitimi Google Colab Pro ortamında Ultralytics HUB kullanılarak gerçekleştirilmiştir. Eğitim sürecinde YOLOv5s modeli, %90.6 kesinlik (Precision), %73.4 duyarlılık (Recall) ve 0.825 mAP@0.5 değerlerine ulaşarak yüksek doğruluk oranı sergilemiştir. Tespit edilen sigara içme eylemi, önceden tanımlanmış bir güven eşiği aşıldığında sesli bir uyarı mekanizmasıyla kullanıcıya bildirilmiştir. Bu amaçla, Pygame kütüphanesi kullanılarak daha önce kaydedilmiş bir ses dosyası otomatik olarak çalınmıştır. Bu sistem, sigara kullanımının yasak olduğu alanlarda bireylerin yasağa uyum sağlamalarını teşvik ederek pasif içicilik riskinin azaltılmasına katkıda bulunmaktadır. Gerçek zamanlı tespit ve otomatik uyarı mekanizması, sigara içmenin denetlenmesi gereken ortamlar için yenilikçi bir çözüm sunmaktadır. Bu çalışma, “Sağlıklı ve Kaliteli Yaşam” hedefine katkıda bulunarak insan sağlığını ve hava kalitesini koruma noktasında literatüre önemli bir katkı sağlamaktadır.

YOLOv5-Based Cigarette Detection and Audible Warning System for Public Health and Environmental Sustainability

Article Info

Research article
Received: 15/01/2025
Revision: 22/02/2025
Accepted: 17/03/2025

Keywords

Good Health and Well-Being
Deep Learning
Image Processing
Cigarette Detection
Sound Alert

Abstract

Smoking causes numerous health problems worldwide, leading to the deaths of millions of people each year. Exposure to cigarette smoke negatively affects not only the smoker but also those around them, increasing the risk of passive smoking. Therefore, “smoke-free zone” implementations, developed to reduce the individual and societal harms of smoking, play a critical role in protecting public health. This study aims to detect smoking behavior in real time using an object detection model based on YOLOv5. A dataset consisting of 3,912 images captured under different lighting, angle, and background conditions was created for model training, and data augmentation techniques were applied to increase the number of images to 10,176. The data was labeled using the Roboflow platform, and the model training was conducted in the Google Colab Pro environment utilizing Ultralytics HUB. During the training process, the YOLOv5s model achieved high accuracy with a precision of 90.6%, a recall of 73.4%, and an mAP@0.5 score of 0.825. When the detected smoking action exceeded a predefined confidence threshold, a voice alert mechanism notified the user. For this purpose, a pre-recorded audio file was automatically played using the Pygame library. This system contributes to reducing the risk of passive smoking by encouraging individuals to comply with smoking bans in designated areas. The real-time detection and automatic warning mechanism offer an innovative solution for environments where smoking needs to be monitored. This study contributes significantly to the literature by supporting the “Good Health and Well-being” goal, helping to protect both human health and air quality.

1. GİRİŞ (INTRODUCTION)

Sigara kullanımı, dünya genelinde her yıl yaklaşık 8 milyon kişinin hayatını kaybetmesine neden olarak önlenabilir ölüm sebeplerinin başında yer almaktadır. Bu kayıpların 1,2 milyonu, sigara dumanına doğrudan maruz kalmayan ancak pasif içicilik nedeniyle zarar gören bireylerden oluşmaktadır. Sigara dumanı çocukların yarısını ve yetişkinlerin %34'ünü olumsuz etkileyerek, yılda 600 binden fazla kişinin yaşamını yitirmesine yol açmaktadır. Sigaranın zararı yalnızca kullanıcılara değil, çevresindeki insanları ve doğal çevreyi de kapsamaktadır [1]. Artan çevresel atıklar, ormansızlaşma, yangın riskleri ve hava kirliliği, sigara kullanımının doğaya verdiği olumsuz etkilerinden sadece birkaçıdır. Sürdürülebilir kalkınma hedefleri kapsamında, tütün kullanımını azaltmak, bulaşıcı olmayan hastalıkların önlenmesi ve yönetiminde ilerleme sağlamak ve tütün kontrol politikalarının etkinliğini değerlendirmek açısından kritik bir öneme sahiptir [2]. Dumansız hava sahası, tütün ürünlerinin kullanımının yasak olduğu alanları ifade eder ve pasif içiciliğin önlenmesi amacıyla oluşturulmuştur. Bu uygulama, toplum sağlığını korumak ve tütün ürünlerinin zararlarını azaltmak için kritik bir öneme sahiptir. Türkiye’de, 4207 sayılı “Tütün Ürünlerinin Zararlarının Önlenmesi ve Kontrolü Hakkında Kanun” kapsamında, kamuya açık tüm kapalı alanlarda tütün ürünlerinin tüketimi yasaklanmıştır. Bu yasak, ikamete mahsus konutlar hariç olmak üzere, kamu hizmet binaları, eğitim, sağlık, ticaret, sosyal ve kültürel alanlar gibi birçok mekânı kapsamaktadır [3]. Bu düzenlemeler, sigara kullanmayan bireylerin tütün dumanından olumsuz etkilenmesini önlemeyi amaçlamaktadır. Ayrıca, Sağlık Bakanlığı tarafından “Dumansız Hava Sahası Denetim Sistemi” adını taşıyan bir izleme sistemi geliştirilmiştir. GPS teknolojisini kullanan bu sistem, tütün ürünlerinin yasak olduğu alanlardaki denetimlerin etkinliğini artırmayı amaçlamaktadır [4].

Ülke genelinde veya il bazında yapılan ihbar, denetim ve ihlaller manuel değerlendirme süreçlerine dayanmaktadır ve bu durum, sistemin geleneksel gözetim yöntemlerinden tam anlamıyla ayrılmadığını göstermektedir. Son yıllarda, gözetim sistemlerinin gelişimi, kamera ve bilgisayar teknolojisindeki ilerlemelerde hız kazanmıştır. Bu yenilikler, araştırmacıların gözetim süreçlerine bilgisayarla görme, derin öğrenme ve görüntü

işleme gibi ileri teknolojileri entegre etme konusundaki ilgisini artırmıştır. Geleneksel gözetim yöntemleri, insan gözüne ve dikkatine dayalı olduğundan hata yapma riski taşır ve geniş ölçekli izleme gerektiren durumlarda yeterince etkili olmayıp belirli nesneleri veya sahneleri algılama konusundaki yetersizlikleri nedeniyle önemli hatalara ve kazalara yol açabilmektedir [5].

Sigara davranışı tespiti genellikle derin öğrenme modellerine dayanarak eğitim ve çıkarım işlemlerini gerçekleştirir, böylece sigara tespitinde manuel iş gücünü etkin bir şekilde azaltır ve tespit doğruluğu ile verimliliğini artırır [6]. Derin öğrenme, yapay sinir ağlarının çok katmanlı yapılarını kullanarak verilerdeki bu özellikleri öğrenme yeteneğine dayanır.

Veri seti, hedefin farklı açılarından görüntülerini ve bu görüntülerdeki hedefin konumunu belirten etiketlerden oluşmaktadır. Bu etiketler, tespit algoritmalarının doğruluğunu doğrudan etkiler. Derin öğrenme modelleri, bu etiketli verilerle eğitim alarak, parametreleri optimize eder ve hedef tespiti için öğrenme sürecini geliştirir. Bu süreç, ağırlıklarını ve aktivasyon fonksiyonlarını ayarlayarak modelin genel doğruluğunu artırır.

Derin öğrenme tabanlı ağlar sayesinde sigara içme tespiti alanında önemli ilerlemeler kaydedilmesine rağmen hâlâ çözülmesi gereken bazı zorluklar mevcuttur [7]. Görüntü tabanlı sigara tespiti, dumanın ve sigaranın tespiti olarak ikiye ayrılabilir. Duman tespiti, sigara içenleri uzun mesafeden tanıyabilir ve genellikle daha etkili olur. Ancak, arka planın aydınlık veya dumanın ince olduğu durumlarda doğruluk düşer. Sigara tespiti, daha yüksek doğrulukla sigara içenleri tespit eder, fakat küçük sigara hedeflerinin tanınması zordur[8]. Bu gibi faktörler, tespit algoritmalarında yanlış tahminlere ve hatalı sonuçlara yol açabilir.

Bir diğer önemli konu ise sigara içme davranışını ayırt etmek için yeterli ve çeşitli özelliklerin tanımlanmasıdır. Ancak bu durum, algoritmanın eğitimi ve sahadaki uygulanabilirliği açısından zorluklar doğurabilir. Hassasiyet gerektiren bu sistemler, yüksek çözünürlüklü sensörler ve kameraların kullanılmasını gerektirdiği gibi maliyetleri de artırmaktadır. Bu kapsamda, sigara içme tespitine yönelik sistemlerin güvenilirliğini ve doğruluğunu artırmak için detaylı iyileştirmelere ihtiyaç duyulmaktadır. Bu çalışma, dumansız hava sahasında sigara içen bireyleri YOLOv5 modeline

dayalı bir hedef algılama algoritmasıyla tespit etmeyi amaçlamaktadır. Model, eğitim aşamasında geniş bir sigara içme veri setiyle optimize edilmiş olup, Google Colab platformunda eğitilmiştir ve gerçek zamanlı kamera görüntülerinden sigara içme davranışını doğru şekilde tanımlamak için kullanılmıştır. Algoritmanın doğruluğu, çevresel faktörlerden etkilenmeden, yüksek FPS değeriyle en hızlı tespit yapacak şekilde yapılandırılmıştır. Çalışmanın genel akış süreci, tespit edilen sigara içme durumunun belirlenmesi ve ardından sistem tarafından bireylerin sesli uyarılarla engellenmesi dahil olmak üzere Şekil 1'deki gibidir. Bu sistem, yasaklı bölgede sigara içme davranışını engellemeyi, temiz hava sahalarının korunmasını ve pasif içiciliğin önlenmesini hedeflemektedir. Ayrıca bu çalışma Sürdürülebilir Kalkınma Hedeflerinden “Sağlıklı ve Kaliteli Yaşam” hedefini desteklemektedir. Bu doğrultuda, araştırma ekibi tarafından özgün bir veri seti oluşturulmuş ve bu veri seti, verilerin çeşitliliğini artırmak için veri çoğaltma teknikleri kullanılarak genişletilmiştir. Veri çoğaltma işlemleri, Roboflow platformu aracılığıyla gerçekleştirilmiş ve bu süreç, modelin daha yüksek doğruluk ve genelleme kapasitesine ulaşmasını sağlamıştır. Elde edilen veri seti, YOLO ailesinin versiyonlarından biri olan YOLOv5 modeli ile eğitilerek, sigara içme davranışını gerçek zamanlı ve yüksek doğrulukla tespit edebilen bir sistem geliştirilmiştir. Çalışmada YOLOv5'in farklı modelleri (YOLOv5n, YOLOv5s, YOLOv5m, YOLOv5l ve YOLOv5x) karşılaştırılmış ve en iyi sonuç veren model seçilmiştir [9]. Bu karşılaştırma, hem doğruluk hem de hız performansı açısından değerlendirilmiştir ve en iyi model belirlenmiştir. Çalışmada uygulanan algoritma eğitimi ve test sürecinde gerçek dünya koşullarına uygun veri kullanılması, sistemin pratikteki başarısını artırmıştır. Çalışmanın hedefi hem doğru tespit hem de yüksek hız performansı sağlayarak kullanıcı dostu bir sistem geliştirmek ve bu alanda literatüre katkı sunmaktır. Sonuç itibarıyla, geliştirilen sistem, Google Colab platformunun Pro versiyonu ile eğitilerek optimize edilmiş ve uygun işlemci gücüne sahip bir bilgisayar ve kamera ile gerçek dünya koşullarında test edilmiştir. Sistemden elde edilen veriler detaylı bir şekilde analiz edilerek, hem tespit doğruluğu hem de performans açısından değerlendirilmiş ve başarılı bir performans sergilemiştir.

Geliştirilen sistem, yalnızca sigara tespiti ve caydırıcılığı sağlamanın ötesinde, geniş kapsamlı

katkılar sunarak kamu sağlığı, çevresel sürdürülebilirlik ve akıllı şehir uygulamaları açısından önemli bir yenilik olarak değerlendirilebilir. Sigara tespitini gerçek zamanlı yapabilmesi sayesinde belirlenen bölgelerde anlık müdahale imkânı sunarak sigara yasağının etkin bir şekilde denetlenmesini mümkün kılmaktadır. Özellikle üniversite kampüsleri, hastaneler, alışveriş merkezleri ve havaalanları gibi kamuya açık alanlarda sigara yasağına bir çözüm olarak uygulanabilmesi sistemin yaygın kullanım potansiyelini artırmaktadır. Otomatik sesli uyarı mekanizması sayesinde bireyler üzerinde caydırıcı bir etki oluşturarak uzun vadede sigara içme alışkanlıklarının azalmasına katkıda bulunabilir. Çevresel sürdürülebilirlik açısından değerlendirildiğinde, sigara içme oranlarını azaltarak sigara izmaritlerinin neden olduğu kirliliği önlemeye yardımcı olabilecek ve böylece çevresel koruma süreçlerine katkı sunabilecektir. Aynı zamanda yapay zekâ destekli bu sistemin akıllı şehir uygulamalarıyla entegre edilmesi, kamuya açık alanlardaki ihlallerin tespitinde kullanılmasıyla hava kalitesini iyileştirme stratejilerine destek olabilecektir. Yapılan analizler, sistemin pratik uygulamalar için uygun olduğunu ve sigara tespiti ile caydırma konusunda etkili bir çözüm sunduğunu göstermektedir. Sistemin yalnızca bireysel sigara içme davranışlarını caydırmakla kalmayıp, toplumsal sağlığı koruma ve çevresel farkındalık oluşturma açısından da önemli bir potansiyele sahip olduğu değerlendirilebilir. Bununla birlikte, bu sistemin geliştirilmesi, sürdürülebilir kalkınma hedeflerine ulaşılmasına katkıda bulunarak, kamu yararına hizmet eden yenilikçi bir teknoloji sunmaktadır. Özellikle, temiz hava sahalarının korunması ve pasif içiciliğin önlenmesi yoluyla toplum sağlığını iyileştirme misyonunu desteklemektedir.

1.1 Literatür Taraması

Bilim ve teknolojinin ilerlemesi, sigara içme davranışının tespit edilmesine yönelik yöntemlerin gelişmesine önemli katkılar sağlamıştır [10]. Geleneksel olarak, sigara tespiti genellikle çeşitli duman dedektörlerinin kullanılmasına dayanmaktadır [11]. Ancak, bu yöntemler çoğu zaman bağlı bulundukları ortam ve sensör hassasiyetine bağlı olarak sınırlı kalabilmektedir. Son yıllarda, bilgisayar görüşü ve derin öğrenme teknikleri, sigara içme davranışının tespitinde çözüm sunabilecek etkili alternatifler olarak dikkat

çekmektedir [12]. Görüntü işleme teknolojileri ile orman yangınlarının erken tespiti ve sürüş sırasında sigara içme davranışının belirlenmesi gibi alanlarda çalışmalar bulunmaktadır [13,14,15]. Huang ve Li yaptıkları çalışmada sürüş sırasında sigara içme davranışını tespit edebilmek için derin öğrenme tabanlı bir model geliştirmişlerdir. Bu model, evrişimli sinir ağı (CNN) kullanarak video görüntülerinde şekil, hareket ve renk özelliklerine dayalı duman analizi yapmaktadır [16]. Bu yaklaşım, sigara davranışını daha hassas bir şekilde algılamaya olanak sağlamıştır. Kamuya açık alanlarda sigara içme davranışını tespit etmeye odaklanan bir başka çalışma, Zhang ve ekibi tarafından gerçekleştirilmiştir. Araştırmacılar, sigara içen kişilerin genellikle görüntülerde küçük hedefler olarak görülmesi nedeniyle bu zorluğu aşmak için gerçek zamanlı bir model tasarlamışlardır. Bu model, %86,32 tespit doğruluğu ile sigara içme davranışını başarıyla saptamış ve yangın risklerini azaltmaya yönelik bit katkı sağlamıştır [17]. Bu tür çalışmaların ortaya koyduğu ilerlemelere rağmen, küçük hedeflerin tespiti konusundaki sınırlamalar tam anlamıyla giderilememiştir. Wang ve ekibi, küçük hedef tespitindeki zorlukları aşmak için YOLOv8 ağını temel alarak geliştirdikleri ve özel bir katmanla güçlendirdikleri yeni bir sigara içme tespit algoritması olan YOLOv8-MNC'yi önermektedir [7]. Lakatos ve ekibi ise çok modlu bir model tasarlayarak metin ve görüntüler üzerinden sigara içme davranışını tespit etmeyi hedeflemiştir. Youtube videolarından elde edilen kareler ve oluşturulan metin veri kümesiyle eğitilen bu model, görüntü analizinde %74, metin analizinde ise %98 doğruluk oranına ulaşmıştır [18]. Bu çalışma, gizli tütün reklamlarının tespiti için de önemli bir yöntem sunmaktadır. Sigara davranışının gerçek zamanlı olarak algılanmasına yönelik bir diğer çalışma, Jiao ve ekibi tarafından geliştirilen SmokingNet modelidir. GoogleNet tabanlı bu derin öğrenme modeli, özel evrişim katmanları sayesinde daha hızlı ve doğru tespit imkânı sağlamışlardır [19]. Yang vd. sigara tespitinde YOLO-Cigarette adı verilen bir model sunmuş ve bu modelle algılama hassasiyetini önemli ölçülerde artırmıştır [20]. Hernandez vd. ise insan hareketlerini ve YOLOv8 algoritmasını birleştirerek mesafe, açı ve zaman ölçümlerine dayalı bir tespit yöntemi önermiştir [21]. Bu yaklaşımlar, sigara tespitinin gerçek zamanlı uygulamalarda da kullanılabileceğini göstermektedir. Jiang ve ekibi, veri kümesini


genişletmek için dikey döndürme gibi veri artırma teknikleri kullanmış ve SE-Net modülüyle özellik çıkarımını iyileştirmiştir. YOLOv5s tabanlı ağ yapısı ile eğitilen model, mAP değerinde %5.3 oranında bir artış sağlayarak etkin bir performans göstermiştir [22]. Bai ve ekibi ise YOLOv4 ile HOG tabanlı insan vücudu çıkarma yöntemlerini birleştirerek tespit doğruluğunu artırmışlardır [23]. Bir başka çalışma, derin öğrenme modelleri kullanılarak sigara içimini gerçek zamanlı tespit eden ve yetkililere bildirim göndermeyi hedefleyen bir sistem geliştirilmesine odaklanmıştır [24]. Sonuç olarak, bilgisayar görüşü ve derin öğrenme teknikleri, sigara içme davranışının tespitinde etkili çözümler sunmaya devam etmektedir. Farklı çalışmalar, hem tespit doğruluğunu hem de gerçek zamanlı çalışma kapasitesini artırmaya yönelik çeşitli yaklaşımlar sunmaktadır.

2. MATERYAL VE METOD (MATERIALS AND METHODS)

Bu çalışmada, nesne tespiti için derin öğrenme tabanlı bir yaklaşım benimsenmiştir. Veri toplama, hazırlama, model seçimi ve eğitimi gibi adımları içeren metodolojik süreç, nesne tespitinde en iyi sonuçları almak için özenle geliştirilmiştir. Bu bölümde çalışmanın gerçekleştirilme süreci detaylı bir şekilde açıklanacaktır.

2.1 Veri Toplama ve Etiketleme (Data collection and labeling)

Projenin temelini oluşturan veri seti, sigara içme davranışını tespit edebilmek için özel olarak oluşturulmuştur. Görseller ve videolardan alınan, saniyede 40 kareye kadar fotoğraflarla veri toplanmıştır. Bu görseller, Ekim, Kasım ve Aralık aylarını kapsayan üç aylık bir dönemde, sokak, kafe ve üniversite kampüsü gibi kontrollü alanlarda çekilmiştir. Veri çeşitliliğini artırmak amacıyla çekimler sırasında farklı açılar, arka planlar ve değişik ışık koşulları kullanılmış; gece ve gündüz çekimleri gerçekleştirilmiştir. Ayrıca, farklı mesafelerden yapılan çekimlerle veri setinin daha kapsayıcı hale getirilmesi sağlanmıştır. Veri toplama sürecinde, kullanılan görsellerin tamamı ilgili kişilerin sözlü rızası alınarak elde edilmiştir. Bu anlamda, herhangi bir mahremiyet ihlali yapılmamasına özen gösterilmiştir. Çalışma kapsamında internet kaynaklarından alınan veri kullanılmamış, tamamen özgün bir veri seti oluşturulmuştur.



Şekil 1. Çalışmanın Akış Şeması (Flowchart of the Study)



Şekil 2. Veri Setinden Örnekler (Examples from the Dataset)

Farklı yaş ve cinsiyet gruplarından bireylerin fotoğrafları kullanılmıştır. Sigara içme eyleminde yaş ve cinsiyet unsurlarına bağlı olarak değişiklik gösterebildiği için veri kümesinde de bir çeşitlilik sağlamıştır. Arka planın kalabalık olması ya da boş olması gibi değişkenlerde göz önünde bulundurularak veriler çeşitlendirilmiştir. Toplanan görseller ve videolar, Roboflow platformu kullanılarak etiketlenmiştir [25]. Etiket olarak “Sigara” ifadesi kullanılmış ve her görselde en az 1 adet sigara bulunmasına dikkat edilmiştir. Veri setinin eğitim, doğrulama ve test oranları: %80 eğitim, %10 doğrulama, %10 test olarak ayrılmıştır. Veri setinin kalitesini ve modelin performansını artırmak amacıyla çeşitli ön işleme adımları uygulanmıştır. Toplam 3912 görüntüden oluşan veri setinde bu adımlar titizlikle gerçekleştirilmiştir. İlk olarak, “Auto-Orient” işlemi uygulanarak görsellerin yanlış yönlendirilmesi önlenmiş ve

görüntülerin doğru açıda hizalanması sağlanmıştır. Ardından, “Resize” ile tüm görüntüler modelin giriş boyutuna uygun hale getirilmek üzere yeniden boyutlandırılmıştır. Model performansı üzerinde renk bilgisinin doğrudan bir etkisi olmadığı için görüntüler “Grayscale” ile gri tonlamaya dönüştürülmüş ve bu sayede modelin yapısal özelliklere odaklanması sağlanmıştır. Ayrıca, görsellerin kontrastı “Auto-Adjust Contrast” işlemi ile otomatik olarak ayarlanmış ve böylece daha net görüntüler elde edilmiştir. Bu işlem, modelin algılama yeteneğini artırmada etkili olmuştur. Belirtilen ön işleme adımları sonucunda veri seti, modelin eğitim sürecine daha uygun hale getirilmiş ve analiz kalitesi yükseltilmiştir. Ön işleme teknikleri yalnızca veri setinin iyileştirilmesine yönelik olup, veri sayısında herhangi bir değişiklik yapılmamıştır.

Modelin performansını artırmak ve eğitim sırasında çeşitliliği sağlamak amacıyla, eğitim veri setinde farklı veri artırma teknikleri uygulanmıştır. Bu teknikler, veri setindeki her bir görüntüye çeşitli dönüşüm ve değişimler ekleyerek yeni veriler oluşturmuş, modelin farklı durumlara karşı genelleme yeteneğini artırmıştır. Döndürme işlemleri kapsamında “Flip 90°” tekniği ile görüntüler yatay veya dikey ekseninde döndürülmüştür. “Rotate” işlemi ile rastgele açılarda çevirerek farklı perspektifler oluşturmuştur. “Crop” yöntemi ile görüntülerin belirli bölgeleri kırılarak asıl ilgili alanlar daha da belirgin hale getirilmiştir. “Rotation” işlemi ise görselleri farklı açılardan birkaç kez döndürerek eğitimin çeşitliliğini artırmıştır. “Shear”, görselleri kaydırma dönüşümü ile farklı açılardan yeniden yapılandırmıştır. “Grayscale” tekniği, görselleri gri tonlarına dönüştürerek renk bilgisinden bağımsız bir analiz sağlamıştır. “Hue” ve “Saturation” yöntemleri, görsellerde renk tonlarını ve doygunluk değerlerini rastgele değiştirerek yeni veri üretmiştir. “Brightness” ve “Exposure” işlemleri, görsellerin parlaklık ve pozlama değerlerini artırıp azaltarak yeni veriler üretmiştir. “Blur” yöntemi, görselleri belirli oranlarda bulanıklaştırarak bulanık verilerle öğrenmeyi sağlamıştır. “Noise” tekniği ise görsellere gündelik hayatta karşılaşılabilecek şekilde parazit ve gürültü ekleyerek çeşitli görüntüler oluşturmuştur. Önerilen bu veri artırma yöntemlerinin uygulanması, modelin yalnızca ideal koşullarda değil farklı açılar, ışıklandırmalar, renk varyasyonları ve görüntü bozulmaları gibi değişken çevresel faktörler altında da yüksek doğrulukta tahmin yapabilmesini sağlamaktadır. Uygulanan veri artırma tekniklerinden elde edilen görüntülerin bir örneği Şekil 3.’te gösterilmiştir. Bu veri artırma tekniklerinden yararlanılarak, toplamda 3912 olan veri sayısı 10,176 olacak şekilde artırılmıştır.

2.2 Model Seçimi ve Eğitimi (Model Selection and Training)


Çalışmada nesne tespiti için güçlü performansı ile öne çıkan YOLOv5 modeli tercih edilmiştir. YOLOv5 algoritmasının yapısı Şekil 4.’te gösterildiği gibidir. Model eğitim sürecinde daha önceden toplanan ve Roboflow platformunda etiketlenen veriler YOLOv5 formatına getirilmiştir. Bu veriler Ultralytics HUB platformuna yüklenerek veri seti ve model eğitimi süreci daha izlenebilir ve kontrol edilebilir hale getirilmiştir. Ultralytics HUB tarafından sağlanan bir API anahtarı oluşturulmuş ve bu anahtar sayesinde Google Colab Pro [26] ortamı kullanılarak API anahtarı ile Ultralytics HUB’a entegre edilmiştir. Bu sayede daha güçlü işlemciler ve GPU desteği ile model eğitimi tamamlanmıştır.

Eğitim süreci boyunca Ultralytics HUB platformunda eğitimin ilerleyişi adım adım takip edilmiş ve doğruluğu gözlemlenmiştir.

Eğitim öncesinde veri seti titizlikle incelenmiş uygun olmayan ve hatalı veriler veri setinden çıkarılmıştır. Veri çeşitliliğini arttırmak amacıyla veri artırma yöntemleri uygulanmıştır. Bu adım modelin farklı koşullarda daha iyi genelleme yapabilmesini sağlamak için önemlidir. YOLOv5’in eğitim parametreleri çalışma gereksinimlerine uygun olacak şekilde ayarlanmıştır farklı denemeler sonucunda en uygun çalışan parametre değerleri kullanılmıştır (Tablo 1.)



Şekil 3. Veri Artırma Teknikleriyle Elde Edilen Örnek Görüntüler (Sample Images Obtained Through Data Augmentation Techniques)



Şekil 4. YOLOv5 Algoritması (YOLOv5 Algorithm)

2.3 Değerlendirme Ölçütleri (Evaluation Metrics)

Sistemin performansını ve doğruluğunu değerlendirmek amacıyla, eğitilen model farklı senaryolar altında bir test sürecinden geçmiştir. Sabit ve gerçek zamanlı görüntüler üzerinde gerçekleştirilen test süreci ile modelin başarımları değerlendirilmiştir.

Doğruluk (Accuracy) Doğru tespit edilen nesnelerin toplam tespitlere oranı.

$$accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (1)$$

Kesinlik (Precision) Modelin doğru tespit ettiği nesnelerin, tüm pozitif tespitler içindeki oranı.

$$precision = \frac{TP}{TP+FP} \quad (2)$$

Hassasiyet (Recall) Gerçekten var olan nesnelerin ne kadarının tespit edilebildiği.

$$recall = \frac{TP}{TP+FN} \quad (3)$$

Ortalama Ortalama Doğruluk (mAP) Tüm sınıflar için tespit performansının genel ölçüsü.

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i \quad (4)$$

F1 Skoru bir modelin kesinlik (precision) ve hassasiyet (recall) arasında bir denge kuran ve genel performansını değerlendiren bir ölçüttür.

$$F1 Skoru = 2 \cdot \frac{precision \cdot recall}{precision+recall} \quad (5)$$

Tablo1. Çalışmada Elde Edilen Skorların Karşılaştırması (Comparison of the Scores Obtained in the Study)

MODEL	BATCH	EPOCH	Görüntü Boyutu	Duyarlılık (Recall)	Kesinlik (Precision)	mAP @0.5
YOLOv5n	16	50	640x640	0.674	0.895	0.775
YOLOv5s	16	50	640x640	0.734	0.906	0.825
YOLOv5m	16	50	640x640	0.717	0.901	0.801
YOLOv5l	16	50	640x640	0.733	0.882	0.793
YOLOv5x	16	50	640x640	0.738	0.878	0.811

Tablo 1, YOLOv5 ailesine ait farklı model konfigürasyonlarının belirli bir eğitim parametresi altında gösterdiği performansları karşılaştırmaktadır. Eğitimin 16 batch size ve 50 epoch ile gerçekleştirildiği, giriş görüntü boyutunun ise 640x640 olarak sabit tutulduğu görülmektedir. Değerlendirme metrikleri olarak duyarlılık (recall), kesinlik (precision) ve Ortalama Doğruluk (mAP @0.5) kullanılmıştır. Bu metrikler, modelin nesne tespit başarısını farklı açılardan değerlendirmekte olup, recall modelin tespit edebildiği nesnelerin oranını, precision ise doğru tespitlerin genel tahminler içindeki payını göstermektedir. mAP @0.5 değeri ise genel doğruluk açısından önemli bir kıyaslama ölçütü olarak kullanılmaktadır. Tablo incelendiğinde, YOLOv5s modelinin en dengeli performansı sunduğu göze çarpmaktadır. 0.734 recall ve 0.906 precision değerleri ile yüksek doğruluk sağlamasının yanı sıra, 0.825 mAP @0.5 değeriyle en başarılı model olarak öne çıkmaktadır. Bu modelin özellikle yüksek precision değeri, yanlış pozitif oranının düşük olduğunu ve modelin yanlış tespit yapma olasılığının görece düşük kaldığını göstermektedir. Dolayısıyla, YOLOv5s modeli hem nesneleri yakalama kapasitesi hem de doğru tahmin oranı bakımından en iyi dengeyi sunmaktadır. Ayrıca kamera kullanım esnasında en yüksek FPS değeri alınan versiyonlardan biri olduğundan YOLOv5s modeli tercih edilmiştir (FPS değerleri Şekil 6.'da gösterilmiştir). En küçük model olan YOLOv5n, 0.674 recall değeri ile nesne tespitinde daha düşük bir başarı göstermiştir. Precision açısından 0.895 değeriyle rekabetçi olmasına rağmen, mAP @0.5 değeri 0.775 olup, diğer modellere kıyasla daha düşük performans göstermektedir. Bu durum, YOLOv5n'nin daha hafif bir model olması nedeniyle işlem hızının avantajlı olabileceğini, ancak nesne tespitinde bazı kayıplara yol açabileceğini göstermektedir.


Daha büyük modellerin performansına bakıldığında, YOLOv5m ve YOLOv5l modellerinin recall açısından birbirine yakın olduğu (sırasıyla 0.717 ve 0.733) ancak precision değerlerinin YOLOv5s modelinin gerisinde kaldığı gözlenmektedir. YOLOv5m modeli 0.901 precision ve 0.801 mAP @0.5 değeri sunarken, YOLOv5l modeli 0.882 precision ve 0.793 mAP @0.5 değeriyle daha düşük doğruluk sergilemektedir. Bu durum, model boyutunun artmasının her zaman doğruluk açısından bir avantaj sağlamadığını göstermektedir. Modelin daha büyük olması, daha fazla parametreye sahip olması nedeniyle hesaplama gereksinimlerini artırırken, gerçek dünya uygulamalarında hız ve verimlilik açısından beklenen katkıyı sunmayabilir.

En büyük model olan YOLOv5x, en yüksek recall değerine (0.738) sahip olmasına rağmen, precision (0.878) ve mAP @0.5 (0.811) değerleri açısından beklenen üstünlüğü sağlayamamıştır. Bu modelin en yüksek recall değerine ulaşması, daha fazla nesneyi tespit edebildiğini gösterirken, precision değerinin görece düşük kalması, yanlış pozitif tahminlerin arttığını ve modelin daha fazla hata ürettiğini göstermektedir. Büyük modeller genellikle daha fazla bilgi işleme kapasitesine sahip olsa da, belirli veri setleri ve uygulamalar için her zaman en uygun seçenek olmayabilirler.

Aşırı öğrenme riskini minimize etmek amacıyla, epoch sayısının dikkatlice belirlenmesi önemli bir kriter olmuştur. Modelin doğrulama kaybı incelendiğinde, 50. epoch sonrasında kayıpların önemli ölçüde değişmediği ve doğrulama kaybının sabitlenmeye başladığı gözlemlenmiştir. Bu durum, modelin eğitimiyle ilgili olarak belirli bir noktada durulmasının, daha iyi bir genelleme sağlanmasına olanak tanıyacağını düşündürmüştür. Daha uzun eğitim süreleri, eğitim kaybını daha da düşürebilir; ancak doğrulama kaybındaki değişim durduğunda, modelin aşırı uyum sağlama riski artabilir ve bu da genelleme yeteneğini olumsuz etkileyebilir.

Bu doğrultuda, literatürdeki benzer çalışmalarda da epoch sayısının sınırlandırılması gerektiği ve daha uzun eğitim sürelerinin doğrulama performansını daha fazla iyileştirmediği görülmektedir. Eğitim süresinin uzatılmasının modelin performansına ek bir fayda sağlamayacağına ve gereksiz hesaplama maliyetine yol açabileceğine dair önceki çalışmalar da bu tercihi desteklemektedir [27]. Bu sonuçlar, daha büyük modellerin her zaman en iyi performansı sunmadığını göstermektedir. YOLOv5s modeli, yüksek doğruluk ve verimlilik dengesiyle en avantajlı seçenek olarak öne çıkmaktadır.

Gerçek zamanlı nesne tespiti uygulamalarında hem hızlı hem de yüksek doğruluklu bir model gereksinimi söz konusu olduğunda, YOLOv5s en uygun seçenek olarak değerlendirilebilir. Özellikle, hafif yapısı ve dengeli doğruluk performansı sayesinde hem gömülü sistemler hem de düşük gecikme süresi gerektiren uygulamalarda kullanıma elverişlidir. Daha büyük modeller, teorik olarak daha yüksek doğruluk sunma potansiyeline sahip olsalar da, hesaplama gereksinimleri ve işlem süreleri nedeniyle pratik uygulamalarda her zaman en iyi seçim olmayabilirler.



Şekil 5. YOLOv5 Modellerinin Güven Skoru Karşılaştırması (Comparison of Confidence Scores of YOLOv5 Models)

Sigara içme davranışının tespitinde kullanılan farklı YOLOv5 modellerinin performansını değerlendirmek amacıyla yapılan karşılaştırmalar, model boyutunun ve eğitim süresinin güven skoru üzerindeki etkilerini ortaya koymaktadır. YOLOv5 ailesinin farklı versiyonları (s, x, m, l, n) aynı veri kümesi üzerinde 50 epoch boyunca eğitilmiş ve sonuçlar incelenmiştir. Buna ek olarak, YOLOv5s modeli 200 epoch boyunca eğitilerek daha uzun eğitim süresinin etkisi değerlendirilmiştir. Elde edilen sonuçlar, modelin boyutu ve eğitimi süresi arttıkça tespit doğruluğunun her zaman artmadığını göstermektedir.


Örneğin, 50 epoch boyunca eğitilen YOLOv5s modeli 0.86 güven skoru ile en yüksek doğruluk oranını elde ederken, daha büyük modeller olan YOLOv5x ve YOLOv5m sırasıyla 0.85 ve 0.82 güven skorlarına ulaşmıştır. Daha küçük boyutlu YOLOv5n modeli ise 0.78 güven skoru ile en düşük doğruluk oranını vermiştir. Bu durum, büyük modellerin daha fazla parametre içermesine rağmen, belirli veri kümelerinde küçük ve optimize modellerin daha iyi genelleme yapabileceğini göstermektedir.

Ayrıca, eğitim süresinin tespit doğruluğu üzerindeki etkisi de analiz edilmiştir. 200 epoch boyunca


eğitilen YOLOv5s modeli, 50 epoch versiyonuna kıyasla daha düşük bir güven skoru (0.80) üretmiştir. Bu durum, fazla eğitimin modelin aşırı öğrenmesine (overfitting) neden olabileceğini ve genel performansını olumsuz etkileyebileceğini göstermektedir. Sonuçlar değerlendirildiğinde, 50 epoch eğitilmiş YOLOv5s modeli, yüksek güven skoru en verimli seçenek olarak öne çıkmaktadır.

Büyük modellerin doğruluk oranları benzer seviyelerde olsa da, yüksek donanım gereksinimleri nedeniyle gerçek zamanlı uygulamalarda dezavantajlı olabilirler.


Bununla birlikte, modelin eğitim süresi dikkatli bir şekilde optimize edilmelidir. Bu karşılaştırmaya ilişkin tespit edilen güven skorları Şekil 5'te gösterilmiştir. YOLOv5s modelinde hesaplanan diğer değerler de grafikler halinde (Şekil 7 ve Şekil 8'de) aşağıda verilmiştir.



Şekil 6. FPS Değerleri (FPS Values)



Şekil 7. YOLOv5s Modelinin Analiz Grafiği (Analysis Graph of the YOLOv5s Model)



Şekil 8. YOLOv5 Versiyonlarının mAP@0.5 Değerlerinin Karşılaştırması
(Comparison of the mAP@0.5 Values of YOLOv5 Versions)



Şekil 9. Modelin Eğitim Sürecindeki Kayıplarının Grafiği (Graph of the Model's Losses During Training)

Şekil 9'da gösterilen grafik, YOLOv5s modelinin eğitim sürecine ait kayıp (loss) değerlerinin değişimini göstermektedir. Üç farklı kayıp türü analiz edilmiştir:

Box Loss (Kutu Kaybı) Modelin tahmin ettiği nesne kutularının doğru olup olmadığını gösterir. İlk epoch'ta eğitim kaybı yaklaşık 2.5, doğrulama kaybı ise 3.0 seviyesindedir.

İlk 10 epoch içinde eğitim kaybı 1.7 seviyesinde, doğrulama kaybı ise 1.3 seviyesine kadar düşmüştür. Son kısımlarda eğitim kaybı 1.1, doğrulama kaybı ise 0.9 civarına kadar düşmüştür. Eğitim ve doğrulama eğrileri birbirine yakın seyretmektedir, bu da modelin genelleme performansının iyi olduğunu gösterir.

Class Loss (Sınıf Kaybı) Modelin tahmin ettiği sınıf etiketlerinin doğruluğunu yansıtır. Bu değer genelde eğitim başlangıcında yüksektir eğitim ilerledikçe düşmesi beklenir. Düşen değer modelin nesneleri daha doğru sınıflandırdığını gösterir. İlk epoch'ta doğrulama kaybı 14.0, eğitim kaybı 4.0 seviyesindedir. İlk 5 epoch içinde doğrulama kaybı hızlı bir düşüşle 2.0 seviyesine gerilemiştir. Son epoch'ta eğitim kaybı 0.5, doğrulama kaybı ise 0.3 seviyelerine inmiştir.

Object Loss (Nesne Kaybı) Modelin nesneleri tespit etme başarısını gösterir. Düşen değer modelin nesneleri daha doğru sınıflandırdığını gösterir. Eğitim ve doğrulama kayıplarının yakın olması modelin iyi bir eğitim geliştirdiğini ve aşırı öğrenme (overfitting) sorunuyla karşılaşmadığını gösteriyor. Eğitim başlangıcındaki Yüksek kayıplar modelin öğrenme sürecinin henüz başında olduğunu ifade eder, bu da normal bir durumdur. İlk epoch'ta eğitim kaybı 1.8, doğrulama kaybı 2.0 seviyesindedir. İlk 10 epoch içinde eğitim kaybı 1.4, doğrulama kaybı ise 1.1 seviyelerinde gerilemiştir. Son epoch'ta eğitim kaybı 1.0, doğrulama kaybı ise 0.9 civarındadır.

Eğitim ve doğrulama eğrileri birbirine paralel ilerlemekte olup, modelin nesne varlık tespitinde istikrarlı bir öğrenme sağladığı görülmektedir. Tüm kayıpların zamanla azaldığı görülmektedir. Doğrulama kayıpları genellikle eğitim kayıplarından daha düşük olup, modelin aşırı öğrenme yaşamadığını göstermektedir. Sınıf kaybı en hızla azalan kayıp türüdür, bu da modelin sınıflandırmayı erken öğrenmeye başladığını göstermektedir.

2.4 Gerçek Zamanlı Görüntü Verisi ile Tespit (Detection with Real-Time Image Data)

Nesne tespiti sadece statik görüntülerle değil projenin de asıl amacı doğrultusunda gerçek zamanlı dinamik görüntüler üzerinde gerçekleştirilmiştir. Bu amaçla bir kamera aracılığıyla elde edilen sürekli video akışı işlenmek üzere modele aktarılır. Canlı yayın verileriyle tespit modeli gerçek zamanlı olarak test etmek ve gerekli iyileştirmeleri sağlamak için önemlidir. Gerçek zamanlı görüntü verisi elde etmek ve anlık tespitler yapmak amacıyla bir telefon kamerası bilgisayara

bağlanarak görüntü kaynağı olarak kullanılmıştır. Telefon kamerasının tercih edilme sebepleri yüksek çözünürlük sunması ve kolay erişilebilir olmasıdır. Telefon kamerasından alınan görüntüler bilgisayar üzerinde çalışan YOLOv5 modeline çerçeve bazlı (kare kare) aktarılmış ve işlenmiştir.

2.5 Kullanılan Kütüphaneler ve Amaçları (Libraries Used and Their Purposes)

Gerçek zamanlı nesne tespiti ve kullanıcıya sesli uyarı mekanizması sağlamak için Python kütüphanelerinden yararlanılmıştır [28]. Her kütüphanenin işlevi ve kod içerisindeki amacı açıklanmıştır.

OpenCV (cv2) dünyanın en büyük bilgisayar görme kütüphanesidir [29]. Bilgisayarlı görme ve görüntü işleme alanında yaygın olarak kullanılan açık kaynaklı bir kütüphanedir. OpenCV'nin temel amacı, kamera aracılığıyla gerçek zamanlı görüntü yakalamak ve bu görüntüler üzerinden işlem yapmaktır. Ultralytics YOLO [30] Ultralytics tarafından geliştirilen YOLO (You Only Look Once) kütüphanesi, derin öğrenme tabanlı nesne tespiti algoritmalarını kolayca kullanıma sunar. YOLO modelleri gerçek zamanlı sistemler için yüksek hız ve hassasiyet sunduğu için tercih edilmiştir. Pygame [31], bu çalışmada nesne tespitine dayalı olarak sesli uyarı mekanizmasını sağlamak için koda dahil edilmiştir. Ses dosyalarının yüklenmesi ve çalması gibi işlevleri üstlenmiştir. Time [32] modülü Python'da zaman ölçümü ve kontrolü yapmak amacıyla kullanılan standart bir kütüphanedir. Bu çalışmada tekrar eden nesne tespitlerinde sesli uyarıların çakışmaması için tercih edilmiştir.

2.6 Uyarı Sistemi (Warning System)

Uyarı sistemi, gerçek zamanlı nesne tespiti sürecine entegre edilerek sigara içme davranışlarının otomatik olarak tespitini ve buna bağlı olarak sesli uyarı verilmesini sağlamaktadır. Sistem, YOLOv5 tabanlı nesne tanıma modeli kullanılarak geliştirilmiştir. Süreç öncelikle input aşamasında bir görüntü kaynağından alınan verinin işlenmesiyle başlamaktadır.

Daha sonra görüntü YOLOv5 mimarisinin üç temel bileşeni olan Backbone, Neck ve Head

katmanlarından geçmektedir. Backbone katmanında görüntünün temel özellikleri (renk, kenar, doku vb.) çıkarılırken, Neck katmanı bu özellik haritalarını farklı ölçeklerde birleştirerek tespit performansını artırmaktadır. Head katmanı ise tespit edilen nesnelerin konum ve sınıf bilgilerinin çıkarıldığı son adımdır. Geliştirilen sistemin çalışma süreci Şekil A.'da gösterildiği gibidir. Model tarafından sigara içme eylemi tespit edildiğinde, sistem belirlenen güven eşiğini aşan nesneler için otomatik bir sesli uyarı mekanizmasını devreye sokmaktadır. Bu sayede, ihlalde bulunan bireylere doğrudan işitsel geri bildirim sağlanarak farkındalık artırılmaya çalışılmaktadır. Sistem, sesli uyarıları tetiklemek için Pygame kütüphanesini kullanmaktadır. Daha önceden hazırlanan ve mp3 formatında kayıtlı sesli uyarı dosyaları, modelin sigara tespitine bağlı olarak otomatik çalmaktadır. Kod yapısı, belirlenen güven eşiği (confidence threshold) aşıldığında ses dosyasını çalıştıracak şekilde tasarlanmıştır. Böylece yanlış pozitif (false positive) sonuçlar en aza indirgenmiş ve yalnızca yüksek doğrulukla tespit edilen durumlarda uyarı mekanizması devreye alınmıştır.

Bu sistem, sigara içmenin yasak olduğu veya denetlenmesi gereken kapalı alanlar ve kamuya açık tüm alanlarda etkili bir şekilde kullanılabilir. Gerçek zamanlı algılama ve sesli uyarı mekanizması sayesinde, dumanlı hava sahalarının korunmasına katkı sağlamaktadır. Ayrıca sistemin otomatik çalışması, insan müdahalesi gerektiren geleneksel gözetim yöntemlerine gerek kalmadan hızlı ve etkin bir denetim süreci sunarak güvenlik ve halk sağlığı açısından önemli bir avantaj sağlamaktadır.

2.7 Ablasyon Çalışması: Veri Artırmanın Model Performansına Etkisi (Ablation Study: Effect of Data Augmentation on Model Performance)

Bu çalışma, YOLOv5s modeli kullanılarak sigara tespiti yapan bir nesne tanıma sisteminin performansının, veri artırma teknikleri ile nasıl etkilendiğini analiz etmektedir. Veri artırma tekniklerinin modelin doğruluk ve hata oranlarına etkisini incelemek amacıyla bir ablasyon çalışması gerçekleştirilmiştir. İlk olarak, YOLOv5 ailesine ait n, s, m, l ve x modelleri karşılaştırılmış ve en iyi performansı gösteren YOLOv5s modeli seçilmiştir. Bu seçimin ardından, ablasyon çalışması YOLOv5s modeli üzerinde gerçekleştirilmiştir. Bu kapsamda,

ham veri modeli ve veri artırmalı model olarak iki farklı veri setiyle eğitilmiş YOLOv5s modelleri karşılaştırılmıştır. Ham Veri Modeli, herhangi bir veri artırma yöntemi uygulanmadan, yalnızca orijinal veri seti kullanılarak eğitilmiştir. Veri Artırmalı Model ise döndürme, ölçekleme, parlaklık değişimi ve gürültü ekleme gibi veri artırma teknikleri kullanılarak oluşturulan genişletilmiş veri seti ile eğitilmiştir. Bu karşılaştırma, veri artırma tekniklerinin modelin doğruluk seviyesini artırıp artırmadığını ve hata oranlarını düşürüp düşürmediğini belirlemek amacıyla yapılmıştır. Model performansları, ortalama ortalama hassasiyet (mAP), precision-recall analizi ve kayıp (loss) değerleri üzerinden değerlendirilmiştir.

2.7.1 Model Performans Karşılaştırması (Model Performance Comparison)

Tablo 2. Model Performans Metriklerinin Karşılaştırılması (Comparison of Model Performance Metrics)

Model	mAP@50	mAp@50-95
Ham Veri Modeli	%67.4	%42.1
Veri Artırmalı Model	%84.7	%58.6

Model performansının temel ölçütlerinden biri olan mAP değerleri, veri artırmanın modelin doğruluğunu nasıl etkilediğini göstermek için tablo 2.'de gösterilmiştir. Elde edilen sonuçlara göre, mAP@50 değeri %17.3, mAP@50-95 değeri ise %16.5 artmıştır. Bu durum, veri artırmanın modelin genelleme kabiliyetini artırdığını ve daha doğru tahminlerde bulunmasını sağladığını göstermektedir.

2.7.2 Kesinlik-Duyarlılık Analizi (Precision-Recall Analysis)

Tablo 3. Precision ve Recall Analizi (Precision-Recall Analysis)

Model	Kesinlik (Precision)	Duyarlılık (Recall)
Ham Veri Modeli	%71.2	%63.5
Veri Artırmalı Model	%82.9	%76.8

Precision ve recall değerleri, modelin doğru pozitifleri ve kaçırılan nesneleri belirlemedeki

etkinliğini göstermektedir. Bu değerler Tablo 3.'de gösterildiği gibidir. Precision değerinde %11.7, recall değerinde ise %13.3'lük bir artış gözlemlenmiştir. Bu bulgular, veri artırma tekniklerinin modelin hem yanlış pozitif oranını azalttığını hem de nesne kaçırma oranını düşürerek daha güvenilir hale getirdiğini ortaya koymaktadır.

2.7.3 Kayıp Değerlerin Karşılaştırılması (Loss Values Comparison)

Tablo 4. Kayıp Değerlerin Karşılaştırılması (Loss Values Comparison)

Model	Kutu Kaybı (Box Loss)	Sınıf Kaybı (Class Loss)	Nesne Kaybı (Object Loss)
Ham Veri Modeli	0.0645	0.0312	0.0921
Veri Arttırmalı Model	0.0482	0.0247	0.0789

Eğitim sürecinde izlenen Box Loss, Class Loss ve Object Loss değerlerinin kıyaslaması Tablo 4. 'de gösterilmiştir. Veri artırmalı modelin Box Loss değeri, ham veri modeline göre %25.2 oranında daha düşük bulunmuştur. Benzer şekilde, Class Loss değeri %20.8 oranında azalmış ve Object Loss değeri de %14.3 oranında düşmüştür. Bu sonuçlar, veri artırma tekniklerinin modelin daha stabil çalışmasına ve hata oranlarının azaltılmasına önemli bir katkı sağladığını ortaya koymaktadır.

2.7.4 Ablasyon Çalışması Sonuçları (Ablation Study Results)

Yapılan ablatif çalışmada, veri artırmanın modelin aşırı öğrenmesini (overfitting) engelleyerek daha stabil bir eğitim süreci sağladığı gözlemlenmiştir. Ham veriyle eğitilen modelin validasyon kaybı, veri artırma yapılan modele göre daha yüksek kalmış ve dolayısıyla test verisi üzerindeki performansı daha düşük olmuştur. Bu durum, veri artırmanın modelin genelleme kabiliyetini artıran bir etken olduğunu ortaya koymaktadır. Veri artırılmış model, eğitim setindeki varyasyonu artırarak modelin genelleştirme gücünü yükseltmiştir. Bu, modelin daha çeşitli örneklerle karşılaşarak daha sağlam bir öğrenme süreci geçirmesine olanak tanımaktadır. Özellikle Class Loss değerlerindeki dalgalanmanın,

ham verilerle eğitilen modelde daha fazla olduğu gözlemlenmiştir. Bu, veri artırmanın modelin daha tutarlı bir şekilde öğrenmesine katkıda bulunduğunu ve modelin hata oranlarını düşürdüğünü göstermektedir.

3. SONUÇLAR (RESULTS)

Bu çalışmada, sigara içme davranışının tespiti için derin öğrenme tabanlı bir nesne tanıma sistemi geliştirilmiştir. YOLOv5 mimarisi kullanılarak gerçek zamanlı nesne tespiti yapılmış ve modelin performansı, veri artırma teknikleri ile optimize edilmiştir. Elde edilen sonuçlar, YOLOv5s modelinin sigara tespiti için en dengeli performansı sunduğunu göstermiştir. Model, 0.906 precision, 0.734 recall ve 0.825 mAP@0.5 değerleriyle yüksek doğruluk oranlarına ulaşmıştır. Ayrıca, veri artırma tekniklerinin uygulanması, modelin genelleme yeteneğini önemli ölçüde artırmış ve mAP@50 değerinde %17.3, precision değerinde %11.7 ve recall değerinde %13.3'lük bir iyileşme sağlamıştır. Bu bulgular, veri artırmanın modelin farklı çevresel koşullarda daha güvenilir tahminler yapmasına katkıda bulunduğunu ortaya koymaktadır.

Gerçek zamanlı tespit testleri, modelin dinamik görüntüler üzerinde de etkili bir şekilde çalıştığını göstermiştir. Telefon kamerasından alınan canlı video akışı üzerinde yapılan testlerde, model yüksek FPS değerleriyle (saniyede kare sayısı) tutarlı bir performans sergilemiştir. Bu durum, modelin gerçek zamanlı uygulamalarda kullanılabileceğini ve hızlı tepki süreleriyle çalışabileceğini kanıtlamaktadır. Ayrıca, geliştirilen sesli uyarı sistemi, modelin tespit ettiği sigara içme davranışlarına anında müdahale ederek, dumanlı hava sahalarının korunmasına katkı sağlamaktadır.

Ablasyon çalışması sonuçları, veri artırma tekniklerinin modelin aşırı öğrenme (overfitting) riskini azalttığını ve eğitim sürecini daha stabil hale getirdiğini göstermiştir. Box Loss, Class Loss ve Object Loss değerlerindeki önemli düşüşler, modelin daha tutarlı bir öğrenme süreci geçirdiğini ve hata oranlarının azaldığını ortaya koymuştur. Özellikle Class Loss değerlerindeki dalgalanmaların azalması, modelin sınıflandırma performansının iyileştiğine işaret etmektedir.

Sonuç olarak, bu çalışma, YOLOv5 tabanlı bir nesne tanıma sisteminin sigara içme davranışının tespitinde etkili bir şekilde kullanılabileceğini göstermektedir. Modelin yüksek doğruluk oranları, gerçek zamanlı performansı ve veri artırma tekniklerinin sağladığı iyileştirmeler, bu tür sistemlerin halk sağlığı ve güvenlik uygulamalarında başarıyla kullanılabileceğini kanıtlamaktadır

4. SONUÇ (CONCLUSION)

Geliştirilen sistem, özellikle üniversite kampüsü, kamuya açık alanlar ve kapalı ortamlar gibi sigara içmenin yasak olduğu ortamlarda kullanılabilir bir performans göstermiştir. Bununla birlikte, sistemin esnek yapısı sayesinde fabrikalar, hastaneler, restoranlar gibi farklı mekanlara da uyarlanabilir olduğu düşünülmektedir. Bu durum, sigara içme davranışının kontrol altına alınması ve farkındalığın artırılması açısından geniş bir uygulama alanı sunmaktadır. Toplum sağlığını destekleyen teknolojik bir çözüm olarak tasarlanmış ve gerçek zamanlı performansı ile öne çıkmıştır. Sistem, sürdürülebilir kalkınma hedeflerinden 3. Hedef olan “Sağlık ve Kaliteli Yaşam” hedefine katkı sağlayabilecek bir adım olarak değerlendirilmiş ve topluma farkındalık yaratma amacıyla uygulanabilir olduğunu göstermiştir. Önerilen sistemin performansını ve uygulanabilirliğini artırmak için gelecekte farklı iyileştirmeler planlanabilir. Öncelikle, modelin doğruluk oranını artırmak amacıyla daha geniş ve çeşitli veri setleriyle eğitilmesi sağlanabilir. Böylece farklı hava koşulları, ışıklandırma ve ortam faktörlerinden bağımsız olarak sistemin güvenilirliği artırılabilir. Bunun yanı sıra, sistemin yalnızca sigara tespitiyle sınırlı kalmayıp duman algılama, sigara içme süresinin takibi gibi ek özellikler içermesi sağlanabilir. Bu sayede, yasaklı alanlardaki sigara içme davranışı daha kapsamlı bir şekilde analiz edilebilir. Ayrıca, sistemin farklı platformlarla entegrasyonu sayesinde daha geniş bir kullanım alanına yayılması hedeflenebilir. Gerçek zamanlı çalışmayı daha verimli hale getirmek için modelin mobil cihazlar ve gömülü sistemler üzerinde optimize edilmesi de önemli bir adımdır. Donanım gereksinimlerini minimize ederek sistemin düşük maliyetli çözümlerle uygulanabilirliği artırılabilir. Tüm bunların yanında sistemin etkisini

değerlendirmek adına kullanıcı geri bildirimleri ve davranışsal analizlerle desteklenen kapsamlı saha testleri yapılabilir. Böylece, sigara içme davranışına yönelik farkındalık oluşturma potansiyeli daha iyi anlaşılabilir ve sistemin etkinliği konusunda daha güçlü veriler elde edilebilir. Bu öneriler doğrultusunda geliştirilecek yeni çalışmalar, sistemin daha yaygın kullanımını sağlayarak toplum sağlığına olan katkısını artırabilir.

TEŞEKKÜR (ACKNOWLEDGMENTS)

Bu çalışma, TÜBİTAK 2209-A Üniversite Öğrencileri Araştırma Projeleri Destekleme Programı kapsamında proje numarası 1919B012203674 ile desteklenmeye değer bulunmuştur. TÜBİTAK’ın araştırmamıza sağladığı bu destek, bilimsel çalışma sürecimize katkı sunmuş ve araştırma motivasyonumuzu artırmıştır. Sağladığı değerli katkılar için TÜBİTAK’a teşekkür ederiz.

ETİK STANDARTLARIN BEYANI (DECLARATION OF ETHICAL STANDARDS)

The author of this article declares that the materials and methods they use in their work do not require ethical committee approval and/or legal-specific permission.

Bu makalenin yazarı çalışmalarında kullandıkları materyal ve yöntemlerin etik kurul izni ve/veya yasal-özel bir izin gerektirmediğini beyan ederler.

YAZARLARIN KATKILARI (AUTHORS' CONTRIBUTIONS)

Yazarlar çalışmaya eşit oranda katkı sağlamıştır.

The authors have contributed equally to the work.

Nur Kuban TORUN: Araştırma probleminin tanımı ve araştırma sürecinin rehberliği, sonuçların değerlendirilmesi ve son düzenlemeleri gerçekleştirmiştir.

Oğuzhan TATLI: Deneyleri yapmış, sonuçlarını analiz etmiş ve makalenin yazım işlemini gerçekleştirmiştir.

Merve ÖNALAN: Deneyleri yapmış, sonuçlarını analiz etmiş ve makalenin yazım işlemini gerçekleştirmiştir.

She provided guidance during the research process, evaluated the results, and finalized the revisions.

They conducted the experiments, analyzed the results, and contributed to the writing process of the article.

ÇIKAR ÇATIŞMASI (CONFLICT OF INTEREST)

Bu çalışmada herhangi bir çıkar çatışması yoktur.

There is no conflict of interest in this study.

KAYNAKLAR (REFERENCES)

- [1] Albayrak Z, Konak Ö. (2022). "Tütün kullanımının çevresel zararları, pasif etkilenim ve üçüncü el sigara dumanı." Acar T, editör. Tütün Bağımlılığı ve Tedavisi. 1. Baskı. Ankara: Türkiye Klinikleri; p.78-82.
- [2] WHO global report on trends in prevalence of tobacco use 2000-2025, fourth edition. WHO. [Son Erişim Tarihi: 20 Aralık 2024 <https://www.who.int/publications/i/item/9789240039322>]
- [3] Türkiye Cumhuriyeti Sağlık Bakanlığı. (2023). "Hakkımızı Koruyalım." Havanı Korumak, [Son Erişim Tarihi: 23 Aralık 2024 https://havanikoru.saglik.gov.tr/hakkimizi-koruyalım.html?utm_source]
- [4] Halk Sağlığı Genel Müdürlüğü. (2019). "Dumansız hava sahası denetim sistemi nedir?" [Son Erişim tarihi: 23 Aralık 2024 https://tektiklabilgielinde.saglik.gov.tr/tutun-kullanimi/dumansiz-hava-sahasi-denetim-sistemi-nedir.html?utm_source]
- [5] La Vigne, N. G., Lowry, S. S., Markman, J. A., & Dwyer, A. M. (2011). "Evaluating the use of public surveillance cameras for crime control and prevention." Urban Institute. [Son Erişim tarihi: 23 Aralık 2024 <https://www.urban.org/sites/default/files/publication/27556/412403-evaluating-the-use-of-public-surveillance-cameras-for-crime-control-and-prevention.pdf>]
- [6] Tian, C., Xu, Z., Wang, L., and Liu, Y. (2023). "Arc fault detection using artificial intelligence: Challenges and benefits." Math. Biosci. Eng. vol. 20, pp 12404–12432. DOI:[10.3934/mbe.2023552](https://doi.org/10.3934/mbe.2023552)
- [7] Wang Z, Lei L, Shi P. (2023). "Smoking behavior detection algorithm based on YOLOv8-MNC." Front Comput Neurosci, vol. 17, pp 1-14. DOI:[10.3389/fncom.2023.1243779](https://doi.org/10.3389/fncom.2023.1243779)
- [8] Khan, A., Elhassan, M. A. M., Khan, S., & Deng, H. (2025). "Deep learning-based smoker classification and detection: An overview and evaluation." Expert Systems with Applications, 267:126208. <https://doi.org/10.1016/j.eswa.2024.126208>.
- [9] Arıcı, F. N., & Orhan, H. (2024). "Farklı Derin Öğrenme Algoritmalarının Gerçek Zamanlı İHA Tespitine Etkileri." Gazi Üniversitesi Fen Bilimleri Dergisi Part C: Tasarım Ve Teknoloji, 12(2), 691-706. <https://doi.org/10.29109/gujsc.1406837>
- [10] Jang, H.Y.; Hwang, C.H. (2020). "Methodology for DB construction of input parameters in FDS-based prediction models of smoke detector." J. Mech. Sci. Technol. 34, 5327–5337. DOI:[10.1007/s12206-020-1133-0](https://doi.org/10.1007/s12206-020-1133-0)
- [11] Imtiaz, M.H.; Ramos-Garcia, R.I.; Wattal, S.; Tiffany, S.; Sazonov, E. (2019). "Wearable sensors for monitoring of cigarette smoking in free-living: A systematic review." Sensors, 19, 4678. DOI:[10.3390/s19214678](https://doi.org/10.3390/s19214678)
- [12] A. I. Khan and S. Al-Habsi, (2020). "Machine Learning in Computer Vision", Procedia Computer Science, vol. 167, pp 1444-1451. DOI:[10.1016/j.procs.2020.03.355](https://doi.org/10.1016/j.procs.2020.03.355)
- [13] Tzu-Chih Chien, Chieh-Chuan Lin, and Chih-Peng Fan, (2020). "Deep Learning Based Driver Smoking Behavior Detection For Driving Safety." Journal of Image and Graphics, vol. 8, no. 1, pp. 15-20.
- [14] C. Bahhar et al., (2023). "Wildfire and Smoke Detection Using Staged YOLO Model and Ensemble CNN," Electronics, vol. 12, no. 1. DOI:[10.3390/electronics12010228](https://doi.org/10.3390/electronics12010228)
- [15] Yücel, M., & Aksoy, B. (2024). "İnsansız Hava Aracı ile Yangın Bölgesinin Tespiti ve Müdahalesinin Yapay Zeka ile Tahminlenmesi." Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi, 28(3), 559-569. DOI:[10.19113/sdufenbed.1545887](https://doi.org/10.19113/sdufenbed.1545887)
- [16] Huang, Jinfa & Li, Rong. (2023). "Smoking Driving Behavior Detection Based on Deep Learning." Academic Journal of Science and Technology. 5. 59-62. DOI:[10.54097/ajst.v5i2.6049](https://doi.org/10.54097/ajst.v5i2.6049)

- [17] Z. Zhang, H. Chen, R. Xiao, and Q. Li, (2021). "Research on smoking detection based on deep learning," Journal of Physics: Conference Series, vol.2024, no. 1, p. 012042.
DOI:[10.1088/1742-6596/2024/1/012042](https://doi.org/10.1088/1742-6596/2024/1/012042)
- [18] Lakatos R, Pollner P, Hajdu A and Joo T (2024). "A multimodal deep learning architecture for smoking detection with a small data approach," Frontiers in Artificial Intelligence, vol. 7, p. 1326050. DOI:[10.3389/frai.2024.1326050](https://doi.org/10.3389/frai.2024.1326050)
- [19] D. Zhang, C. Jiao and S. Wang, (2018) "Smoking Image Detection Based on Convolutional Neural Networks," IEEE 4th International Conference on Computer and Communications (ICCC), pp. 1509-1515. DOI:[10.1109/CompComm.2018.8781009](https://doi.org/10.1109/CompComm.2018.8781009)
- [20] Y. Ma, J. Yang, Z. Li and Z. Ma, (2022). "YOLO-Cigarette: An effective YOLO Network for outdoor smoking Real-time Object Detection," in 2021 Ninth International Conference on Advanced Cloud and Big Data (CBD), pp. 121-126. DOI:[10.1109/CBD54617.2021.00029](https://doi.org/10.1109/CBD54617.2021.00029)
- [21] W. Zhang, A. L. De Ocampo and R. Hernandez, (2024). "Detection of Smoking Behaviors Using Human Key Points and YOLOv8." in 2024 IEEE Cyber Science and Technology Congress (CyberSciTech), pp. 335-340. DOI:[10.1109/CyberSciTech64112.2024.00059](https://doi.org/10.1109/CyberSciTech64112.2024.00059)
- [22] Xiangkui Jiang (2022). "A smoking behavior detection method based on the YOLOv5 network." J. Phys.: Conf. Ser. 2232 012001.
DOI:[10.1088/1742-6596/2232/1/012001](https://doi.org/10.1088/1742-6596/2232/1/012001)
- [23] C. Bai, Y. Zhou and Q. Guo, (2022), "Application Study of Area-Based and YOLOv4 Smoking Behavior Detection," 2022 4th International Conference on Natural Language Processing (ICNLP), pp. 7-12.
- [24] Singh, T. (2023). "Real Time Cigarette Detection using Deep Learning Models." International Journal for Research in Applied Science and Engineering Technology. pp 1946-1948.
- [25] Roboflow, Roboflow: Build and deploy custom computer vision models. [Son Erişim Tarihi: 1 Aralık 2024, <https://roboflow.com>]
- [26] Google Colab, Google Colaboratory, [Son Erişim Tarihi: 2 Aralık 2024, <https://colab.research.google.com>]
- [27] A. Khan, S. Khan, B. Hassan, and Z. Zheng, (2022.) "CNN-based smoker classification and detection in smart city application," Sensors, vol. 22, no. 3, p. 892.
DOI:[10.3390/s22030892](https://doi.org/10.3390/s22030892)
- [28] Python Software Foundation, Python Programming Language. Erişim Tarihi: 30 Kasım 2024, <https://www.python.org>
- [29] Bradski, G. (2000) "The OpenCV Library." Dr. Dobb's Journal of Software Tools, 120; 122-125.
- [30] Ultralytics, YOLOv5, [Son Erişim Tarihi: 1 Aralık 2024, <https://ultralytics.com>]
- [31] Pygame, Pygame: Python Game Development, [Son Erişim Tarihi: 30 Kasım 2024, <https://www.pygame.org>]
- [32] Python Software Foundation, time — Time access and conversions. Python Documentation. [Son Erişim Tarihi: 30 Kasım 2024, <https://docs.python.org/3/library/time.html>]