

GAZİ

JOURNAL OF ENGINEERING SCIENCES

Using Artificial Intelligence Methods in Detecting Deformed Highway Lines Using Unmanned Aerial Vehicles

Bekir Aksoy^a, Muzaffer Eylence^b, Asım Sinan Yüksel^c, Seyyit Ahmet İnan^d

Submitted: 19.11.2023 Revised: 15.12.2023 Accepted: 15.12.2023 doi:10.30855/ gmbd.0705S20

ABSTRACT

With the rapid advancement of technology, the use of artificial intelligence (AI) is increasing in various sectors such as education, health, security and defense. A critical application of AI is highway management, especially with the rise of autonomous vehicles. The focus of this study is to address the problem of deformations in highway marking lines that pose challenges for autonomous vehicles and affect traffic safety. The research involves using unmanned aerial vehicle (UAV) to create an original image dataset of highway lines. This data set will be processed with image enhancement techniques and deep learning models. The first stage involves cleaning the images from foreign matter. Deep learning models will then identify potential line deformations. These models will be developed and trained for optimum accuracy using various performance metrics. In the study, the mobilenet v3 model, trained with the images in the data set, reached an accuracy rate of 89.58%, the resnet50 v2 model 77.78% and the Convolutional Neural Network model 92.55%. The ultimate goal is to implement a real-time system to accurately detect and report differences in highway lines by combining the UAV with the computer system on the ground. This will ensure timely notification to authorities and help prevent traffic safety problems related to line deformations. This approach demonstrates the practical applications of artificial intelligence in improving road safety and autonomous vehicle navigation.

İnsansız Hava Araçları Kullanılarak Deforme Olmuş Karayolu Çizgilerinin Tespitinde Yapay Zekâ Yöntemlerinin Kullanılması

ÖZ

Teknolojinin hızla ilerlemesiyle birlikte yapay zekanın (YZ) eğitim, sağlık, güvenlik ve savunma gibi çeşitli sektörlerde kullanımı giderek artıyor. Yapay zekanın kritik bir uygulaması, özellikle otonom araçların yükselişiyle birlikte otoyol yönetimidir. Bu çalışmanın odak noktası, otonom araçlar için zorluklar oluşturan ve trafik güvenliğini etkileyen otoyol işaretleme çizgilerindeki deformasyonlar sorununu ele almaktır. Araştırma, otoyol hatlarının orijinal bir görüntü veri kümesini oluşturmak için insansız hava aracının (İHA) kullanılmasını içeriyor. Bu veri seti, görüntü iyileştirme teknikleri ve derin öğrenme modelleriyle işlenecektir. İlk aşama, görüntülerin yabancı maddelerden temizlenmesini içerir. Daha sonra derin öğrenme modelleri potansiyel hat deformasyonlarını belirleyecektir. Bu modeller, çeşitli performans ölçümleri kullanılarak optimum doğruluk için geliştirilecek ve eğitilmiştir. Yapılan çalışmada veri setindeki görüntüler ile eğitimi gerçekleştirilen MobileNet v3 modeli %89,58, Resnet50 v2 modeli %77,78 ve Evrişimsel Sinir Ağı modeli ise %92,55 doğruluk oranına ulaşılmıştır. Nihai hedef, İHA'yı yerdeki bilgisayar sistemiyle birleştirerek otoyol hatlarındaki farklılıkları doğru bir şekilde tespit etmek ve raporlamak için gerçek zamanlı bir sistem uygulamaktır. Bu, yetkililere zamanında bildirim yapılmasını sağlayacak ve hat deformasyonlarıyla ilgili trafik güvenliği sorunlarının önlenmesine yardımcı olacaktır. Bu yaklaşım, yapay zekanın yol güvenliğini ve otonom araç navigasyonunu iyileştirmedeki pratik uygulamalarını gösteriyor.

Keywords: Deep Learning, Unmanned Aerial Vehicle, Image Processing

^a Isparta Uygulamalı Bilimler Üniversitesi, Teknoloji Fakültesi, Mekatronik Mühendisliği 32200 - ISPARTA, Türkiye
Orcid: 0000-0001-8052-9411
e mail: bekiraksoy@isparta.edu.tr

^b Isparta Uygulamalı Bilimler Üniversitesi, Teknoloji Fakültesi, Mekatronik Mühendisliği 32200 - ISPARTA, Türkiye
Orcid: 0000-0001-7299-8525

^c Süleyman Demirel Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği 32200 - ISPARTA, Türkiye
Orcid: 0000-0003-1986-5269

^d Isparta Uygulamalı Bilimler Üniversitesi, Teknoloji Fakültesi, Mekatronik Mühendisliği 32200 - ISPARTA, Türkiye
Orcid: 0000-0002-9489-7714

^{*}Corresponding author: bekiraksoy@isparta.edu.tr

Anahtar Kelimeler: Derin Öğrenme, İnsansız Hava Aracı, Görüntü İşleme

1. Giriş (Introduction)

Otonom araçlar, insan müdahalesine ihtiyaç duymadan hareket edebilen, gelişmiş sensörler, yapay zeka ve robotik sistemler ile donatılmış araçlardır. Otonom araç teknolojisinin temelleri, 1980'lerde başlamış ve özellikle DARPA (Defense Advanced Research Projects Agency) tarafından desteklenen yarışmalar aracılığıyla geliştirilmiştir. Carnegie Mellon Üniversitesi'nde geliştirilen ALVINN sistemi, yapay sinir ağlarını kullanarak temel düzeyde otonom sürüş yeteneklerini sergilemiştir [1]. 2004 ve 2005 yıllarında gerçekleştirilen DARPA Grand Challenge, otonom araç teknolojisinin gelişiminde de önemli bir rol oynamıştır. Bu yarışmalar sırasında, Stanford ve Carnegie Mellon üniversiteleri tarafından geliştirilen Stanley ve Boss araçları, çöl ortamında belirlenen rotaları başarıyla tamamlamıştır [2]. 2009'da başlayan Google'ın Otonom Araç Projesi (günümüzdeki adıyla Waymo), bu teknolojiyi daha geniş çapta tanıtmış ve alanın öncü şirketlerinden biri haline getirmiştir [3]. Sensör ve yapay zeka teknolojilerindeki ilerlemeler, lidar, radar ve kamera destekli otonom araçların daha güvenli ve verimli çalışmasını sağlamıştır. Gelecekte, otonom araçların yaygınlaşması için yasal ve düzenlemelerin oluşturulması, güvenlik standartlarının oluşturularak toplumda daha geniş bir çerçevede kullanılması hedeflenmektedir [4].

Otonom araçlardaki teknolojik ilerlemelerin yanı sıra, İnsansız Hava Araçları (İHA) sistemleri ile birçok alanda yaygın olarak kullanılacağı düşünülmektedir. Ticari ve özel kullanımlar, İHA'ların mahremiyet, kabul ve güvenlik özelliklerinden ziyade diğer hava sahası kullanıcılarıyla etkileşimi içermektedir. Kentsel hava hareketliliği alanındaki çalışmalar, İHA'ların yeni bir ulaşım aracı olarak kullanılmasına olan talebide arttırmaktadır [5]. Son yıllarda, küçük İHA'larda, tasarım, çalışma metodolojileri, uçuş özellikleri ve navigasyon kontrolünde önemli gelişmeler kaydedilmiştir. İHA'lar fotoğrafçılık, rotalama, arama-kurtarma operasyonları, güç hatları ve sivil yapıların denetimi gibi alanlarda yaygın olarak kullanılması ile yeteneklerini ve verimliliklerini artırmıştır [6]. Son yıllarda İHA sistemleri mikroişlemci teknolojisindeki gelişmeler ile birlikte sıklıkla akıllı otonom kontrol sistemlerinde kullanılmaya başlanmıştır [7]. İHA'larda akıllı otonom sistemlerin kullanılmaya başlanması ile birlikte İHA'ların gövdesine monte edilen kamera veya sensörler vasıtasıyla elde edilen veriler toplanarak yapay zeka teknolojileri ile analiz edilip anlamlı sonuçlar çıkartılarak toplum hayatına önemli katkılar sağlamıştır.

Yapay Zeka (YZ), insan benzeri zeka gösteren makineleri, özellikle bilgisayar sistemlerini tasarlamak ve geliştirmek için kullanılan bilim ve mühendislik alanıdır [8]. Bu alandaki gelişmeler, özellikle makine öğrenimi ve derin öğrenme alanlarında, son yıllarda önemli bir ivme kazanmıştır. Yapay Zeka, veri analizi, desen tanıma ve öğrenme süreçlerini içermekte ve bu süreçler, doğal dil işleme, robotik ve algılama gibi birçok alanda uygulanmaktadır [9]. Derin öğrenme, yapay sinir ağlarına dayalı bir öğrenme yöntemi olup YZ'nin gelişiminde büyük bir dönüm noktası olmuştur [10]. YZ'nin önemli bileşenlerinden olan makine öğrenimi, algoritmaların veri setleri üzerinde eğitilerek, veri analizi ve tahmin yapabilme yeteneklerini geliştirme süreci olarak tanımlamak mümkündür. Breiman ve diğerleri tarafından geliştirilen rastgele ormanlar ve boosting gibi makine öğrenme yöntemleri, sınıflandırma ve regresyon problemlerinin çözümünde yaygın olarak kullanılmaktadır [11]. Makine öğreniminin alt bileşeni olan derin öğrenme ise çok katmanlı yapay sinir ağlarını kullanarak daha karmaşık öğrenme problemlerinin çözümünde kullanılmaktadır. Derin öğrenme, görüntü, ses tanıma, doğal dil işleme gibi karmaşık görevlerde sıklıkla kullanılmaktadır.

Gerçekleştirilen çalışma ile ilgili akademik çalışmalar incelendiğinde Na ve diğerleri çalışmalarında Görüntü İşleme ve Derin Öğrenme ile Demiryolu Aracının Pantograf Kontak Şeridi Üzerindeki Deformasyonun tahmininde %94 doğruluk oranı ile başarı elde etmişlerdir [12]. Bir diğer çalışmada ise karmaşık yol koşullarında yol sürüş videosu ve Tusimple veri seti kullanılarak şerit tespit algoritması için simülasyon test deneyleri yapmışlardır. Deneysel sonuçlar, yolda sürüş videosuna dayalı ortalama tespit doğruluğunun %98,49'a, ortalama işlem süresinin ise 21,5 ms'ye ulaştığını tespit etmişler, Tusimple veri setinde ise ortalama tespit doğruluğu %98,42'ye, ortalama işlem süresi ise 22,2 ms'ye olarak elde etmişlerdir [13]. Liu ve diğerleri çalışmalarında düşük ışık koşullarında görüntüler oluşturarak üretken rekabetçi ağları kullanan ve şerit dedektörünün çevresel uyarlanabilirliğini artıran, stil aktarımına dayalı bir veri geliştirme yöntemi önermişlerdir. Yöntem SIM-CycleGAN, ışık koşulları aktarımı ve şerit algılama ağı olmak üzere üç bölümden oluşmaktadır [14]. Punagin ve Punagin yapmış oldukları çalışmada OpenCV kullanılarak yapılandırılmış yollarda şerit tespit tekniklerinin analizi gerçekleştirmede Udacity'den almış oldukları görüntüler üzerinde görüntü ön işleme sırasında Laplacian, Sobel ve Canny kenar tespit yöntemleri gibi farklı kenar tespit yöntemleri incelemişlerdir. İnceleme sonucunda Canny kenar tespitinin diğerlerine göre daha başarılı olduğunu ifade etmişlerdir [15]. Bir diğer çalışmada ise Joy ve diğerleri bilgisayarlı görme tekniklerini kullanarak gerçek zamanlı yol şeridi tespitini gerçekleştirmişlerdir. Çalışmada RGB görüntüsü gri tonlamaya

dönüştürüldükten sonra gürültü giderme işlemini gerçekleştirmek için Gaussian filtreleme yöntemini kullanmışlardır. Canny Kenar Dedektörü vasıtasıyla da yoğunlukta önemli değişiklikler olan kenarları algılamışlardır [16]. Chng ve diğerleri yapmış oldukları çalışmada RONELD: aktif şerit tespiti için güçlü sinir ağı çıkışı geliştirmişlerdir. Çalışmalarında derin öğrenme olasılık haritası çıktılarında aktif şeritleri tanımlamak, izlemek ve optimize etmek için aktif şerit algılama (RONELD) yöntemine yönelik gerçek zamanlı, sağlam bir sinir ağı çıktı geliştirmesi sunmuşlardır [17]. Bibi ve diğerleri yapmış oldukları çalışmada derin öğrenme yöntemleri kullanarak VANET'teki Yol Anormalliklerinin Edge Yapay Zeka Tabanlı Otomatik Tespiti ve Sınıflandırılması işlemlerini gerçekleştirmişlerdir. Çalışmalarında Otonom araçlar tarafından yol anormalliklerinin otomatik olarak algılanması ve Edge AI ve VANET'e dayalı olarak gelecek araçlara yol bilgisi sağlanması için yeni bir sistem önermişlerdir [18]. Luo ve diğerleri çalışmalarında derin öğrenme yaklaşımlarıyla yol anomalisi tespit etmişlerdir. Çalışmalarında geleneksel yol anormalliklerinin yanı sıra, araç perspektifinden ek anomaliler de eklemiştir. Veri setini Derin Beslemeli Ağ, Evrişimli Sinir Ağı ve Tekrarlayan Sinir Ağı ile sınıflandırma problemini çözmüşlerdir [19].


Gerçekleştirilen çalışmada, otonom uçuş gerçekleştirebilen İHA'nın gövdesinde yer alan kamera vasıtasıyla karayolu çizgilerine ait özgün bir veri seti oluşturulmuştur. Oluşturulan veri seti bozulmuş, silinmiş ve renklendirilmiş görüntü olmak üzere etiketlenerek YZ eğitimi için hazırlanmıştır. Etiketlenen veri seti MobileNet v3, Resnet50 v2 ve Evrişimsel Sinir Ağı (ESA) derin öğrenme modelleri ile eğitilmiş ve en yüksek doğruluk sonucunu veren ESA modeli çalışmada kullanılmıştır.

2. Materyal ve Metot (Material and Method)

2.1. Materyal (Material)

2.1.1. Verisetinin oluşturulması (Creating the dataset)

Gerçekleştirilen çalışmada, otonom araçların silinmiş veya hasar görmüş karayolu şeritlerini tespit etmelerine yardımcı olmak amacıyla, İHA kullanılarak veri seti oluşturulmuştur. Veri seti, silinmiş, bozulmuş veya yeniden renklendirilmiş karayolu şeritlerinden oluşmaktadır. İHA'nın, trafiğe kapalı yollarda farklı hava koşullarında, günün farklı saatlerinde ve farklı yüksekliklerden toplanan görüntülerle veri setinin çeşitliliği artırılarak toplam 437 adet görüntü elde edilmiştir Şekil 1'de çalışmada kullanılan görüntülere ait örnek bir görsel verilmiştir.



Şekil 1. Verisetinden örnek görüntüler
(Sample images from the Dataset)

2.1.2. MobileNet v3 (MobileNet v3)

MobileNet v3, Howard et al. tarafından 2019 yılında tanıtılan ve derin öğrenme ile bilgisayarlı gözü alanlarında kullanılan sinir ağı mimarisidir [20]. Bu mimari, özellikle mobil ve edge cihazları gibi kaynak kısıtlı ortamlar için tasarlanmıştır. MobileNet v3'ün temel amacı, az sayıda parametre ve düşük hesaplama gereksinimi ile yüksek verimlilik sağlamaktır [21]. MobileNet v3 mimarisinin en dikkat çekici özelliklerinden birisi de derinlik bazlı ayrılabilir konvolüsyonların kullanılmasıdır. Bu yaklaşım, modelin boyutunu ve hesaplama yükünü önemli ölçüde azaltmaktadır [22]. Ayrıca, MobileNet v3, Neural Architecture Search (NAS) teknolojisi kullanarak optimal ağ yapısını belirlemede ve bu sayede modelin verimliliğini ve performansını artırmaktadır [23].

MobileNet v3, H-Mish adı verilen yeni bir aktivasyon fonksiyonu kullanmaktadır. Bu fonksiyon, modelin doğruluk oranını artırırken hesaplama maliyetini düşürmektedir. Böylece kaynak kısıtlı cihazlarda önemli bir avantaj sağlamaktadır [24]. Mimarinin kullanıldığı başlıca uygulama alanları arasında görüntü sınıflandırma, nesne algılama ve yüz tanıma problemleri bulunmaktadır [25].

2.1.2. Resnet50 v2 (Resnet50 v2)


Bu ağ, Microsoft Research tarafından 2016 yılında tanıtıldı ve hızla görüntü işleme ve makine öğrenimi toplulukları arasında popülerlik kazandı [26]. ResNet50 v2'nin başarısı, özellikle görüntü tanıma ve sınıflandırma görevlerinde yüksek doğruluk oranlarına ulaşmasından kaynaklanmaktadır. Bu model, çeşitli görüntü sınıflandırma yarışmalarında ve gerçek dünya uygulamalarında etkili bir şekilde kullanılmıştır [27]. ResNet50 v2'nin temel özelliği, "kalıntı öğrenme" veya "artık öğrenme" olarak bilinen bir yaklaşım ile derin ağ katmanlarının etkin bir şekilde eğitilmesine imkân sağlamaktadır [28].

2.1.3. Evrişimsel sinir ağları (Convolutional neural networks)

ESA, derin öğrenme alanında yaygın olarak kullanılan, özellikle görsel veri işlemede etkili olan derin öğrenme modelidir. ESA, insan görsel korteksinin çalışma şeklinden esinlenerek geliştirilmiştir [10]. ESA'lar, çok katmanlı yapay sinir ağları olup evrişimsel katmanlar, havuzlama (pooling) katmanları ve tam bağlı (fully connected) katmanlarında oluşmaktadır [29]. Evrişimsel katmanlar, veri üzerinde yerel filtreler uygulayarak özellik haritaları oluşturur. Havuzlama katmanları ise bu özellik haritalarını küçültür, hesaplama yükünü azaltır ve ağız öğrenme kapasitesini artırır. Son olarak, tam bağlı katmanlar, sınıflandırma veya regresyon görevlerini gerçekleştirir. ESA'lar, görsel nesne tanıma, yüz tanıma, tıbbi görüntü analizi gibi birçok alanda başarıyla kullanılmaktadır [30]. Özellikle görüntü ve video analizi alanında, ESA'lar diğer yapay sinir ağlarına göre daha başarılı sonuçlar vermektedir. ESA'ların kullanımı, büyük veri setleri ve güçlü bilgisayar kaynakları gerektirir. Ağın eğitimi sırasında, büyük miktarda etiketlenmiş veri ile ağız ağırlıkları iteratif olarak ayarlanır. Bu süreç, genellikle arka yayılım (backpropagation) algoritması ile gerçekleştirilir [31]. Ayrıca, ağız performansını artırmak için veri artırma (data augmentation) ve düzenleme (regularization) teknikleri gibi farklı yöntemler kullanılmaktadır [32].

2.2. Metot (Method)

Gerçekleştirilen çalışmanın iş akış diyagramı Şekil 2'de gösterilmiştir.



Şekil 2. İş akış diyagramı (Workflow diagram)

Çalışmada ilk olarak İHA kullanılarak, karayollarındaki bozulmuş veya silinmiş trafik şeritlerine ait toplam 437 adet görüntü toplanmıştır. Elde edilen görüntüler derin öğrenme modelleri ile uyumlu hale getirilmek üzere 512x512x3 piksel boyutlarına yeniden boyutlandırılmıştır. Yeniden boyutlandırılan görüntüler üzerinde, poligon etiketleme teknikleri kullanılarak etiketlenmiş ve sınıflandırılmıştır. Çalışmanın ikinci aşamasında veri seti, eğitim, doğrulama ve test olmak üzere %80, %15 ve %5'lik oranlarda bölünmüştür. Çalışmanın üçüncü aşamasında MobileNet v3, ResNet50 v2 ve özelleştirilmiş bir ESA tabanlı modeli kullanılarak eğitilmiştir. Eğitim esnasında 20 epoch ile eğitim gerçekleştirilmiştir. Her bir eğitim için

modellerin cevap süreleri saniye açısından ölçülmüştür. 20 epochdan sonra sonuçlar önemli bir değişim görülmediği için eğitim işlemi sonlandırılarak eğitim sonuçları ile doğrulama veri setindeki sonuçlar karşılaştırılarak aşırı öğrenmenin olmadığı tespit edilmiştir. Çalışmanın son aşamasında ise elde edilen sonuçlar grafik, tablo ve karmaşıklık matrisi olarak verilmiştir.

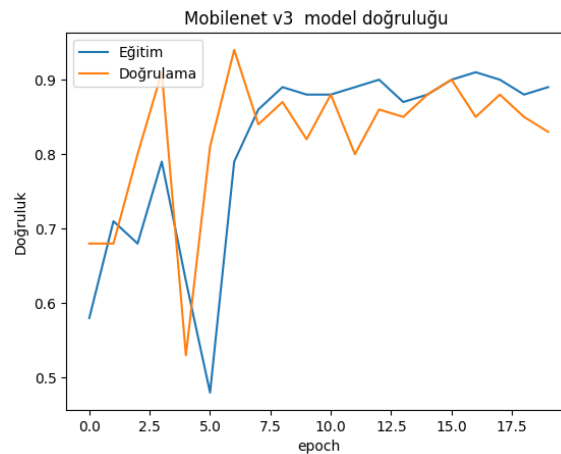
3. Bulgular ve Tartışma (Results and Discussion)

Yapılan çalışmada derin öğrenme modellerinin eğitim sonuçları tablo 1 de gösterilmiştir.

Tablo 1. Derin öğrenme modellerinin doğruluk sonuçları (Accuracy results of deep learning models)

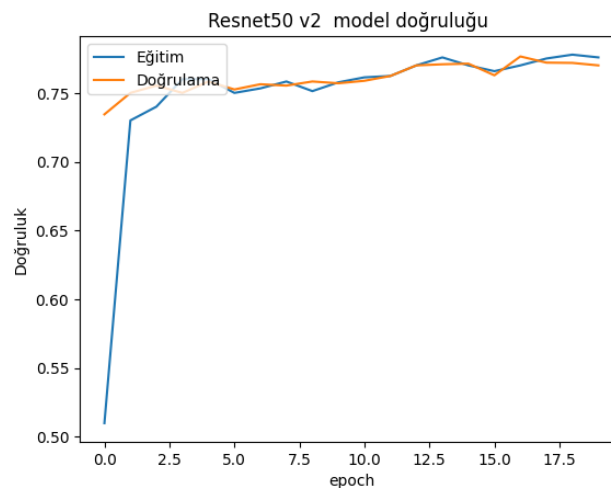
Derin Öğrenme Modelleri	Doğruluk Değeri	Eğitim Süresi (saniye)
MobileNet v3	%89,58	763
Resnet50 v2	%77,78	795
ESA	%92,55	835

Tablo 1 incelendiğinde üç farklı derin öğrenme modelinden ESA modelinin diğer modellere göre daha yüksek bir doğruluk sonucu verdiği görülmektedir. Ayrıca tablo 1’de derin öğrenme modellerinin zamansal açıdan kıyaslandığında MobileNetv3 modelinin en başarılı model olduğu görülmektedir. Gerçekleştirilen çalışmada Şekil 3 ile Şekil 5 arasında verilen grafikler ile modellerinin doğruluk değerleri izlenmiştir.



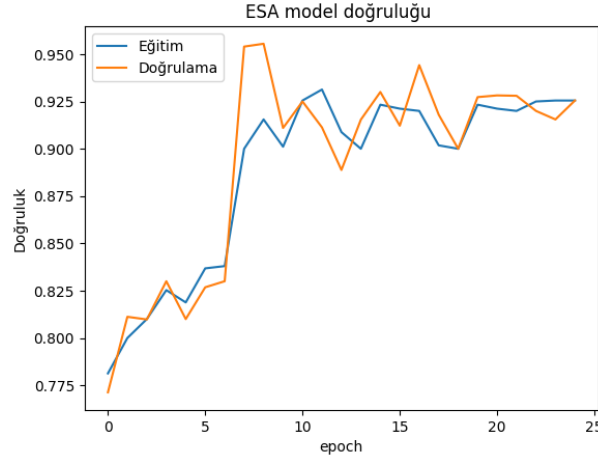
Şekil 3. MobileNet v3 doğruluk grafiği (MobileNet v3 accuracy chart)

Şekil 3 incelendiğinde MobileNet v3 derin öğrenme modelinin eğitim sonucu oluşan doğruluk grafiği verilmiştir. Grafik incelendiğinde modelin doğruluk oranı %89,58 de kaldığını ve modelin bu değerden daha yüksek bir doğruluk değerine ulaşamadığı tespit edilmiştir.



Şekil 4. Resnet50 v2 doğruluk grafiği (Resnet50 v2 accuracy chart)

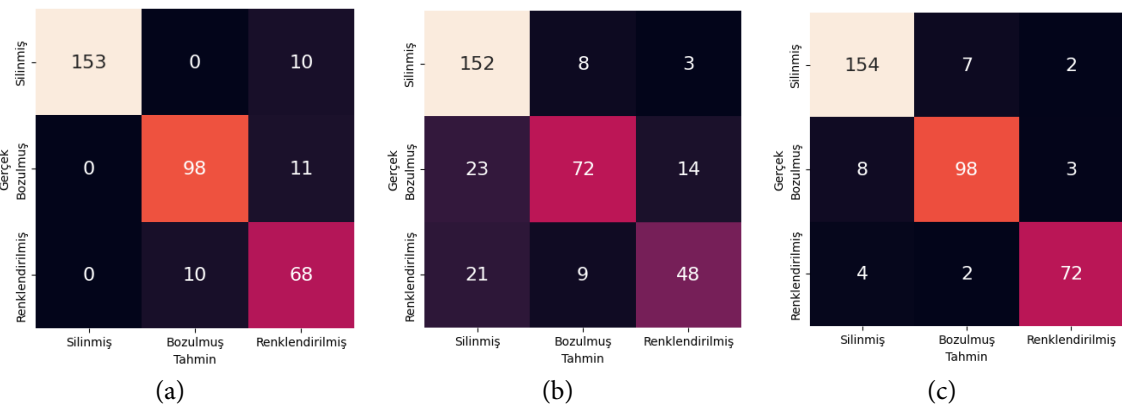
Şekil 4 incelendiğinde ResNet50 v2 derin öğrenme modelinin eğitim sonucu oluşan doğruluk grafiği verilmiştir. Grafik incelendiğinde modelin doğruluk oranı %77,78 de kaldığını ve modelin bu değerden daha yüksek bir doğruluk değerine ulaşamadığı tespit edilmiştir.



Şekil 5. ESA modelinin doğruluk grafiği (Accuracy graph of ESA model)

Şekil 5 incelendiğinde ESA yöntemine ait grafik incelendiğinde modelin doğruluk oranı %92,55 de kaldığını ve modelin bu değerden daha yüksek bir doğruluk değerine ulaşamadığı tespit edilmiştir.

Çalışmanın son aşamasında şekil 6 incelendiğinde MobileNet v3 modelinde silinmiş sınıfa ait olan 153 adet görüntü doğru sınıflandırılırken 10 adet görüntü renklendirilmiş sınıfa ait olarak sınıflandırılmıştır. Bozulmuş sınıfa ait olan 98 adet görüntü doğru sınıflandırılırken 11 adet görüntü ise renklendirilmiş sınıfa ait olarak sınıflandırılmıştır. Son olarak 68 adet renklendirilmiş sınıfa ait görüntü doğru sınıflandırılırken 10 adet görüntü ise bozulmuş sınıfa ait olarak sınıflandırılmıştır. Resnet50 v2 modelinde ise 152 adet silinmiş sınıfa ait görüntü doğru sınıflandırılırken, 8 adet görüntü bozulmuş, 3 adet görüntü ise renklendirilmiş sınıfa ait olarak yanlış sınıflandırılmıştır. 72 adet bozulmuş sınıfa ait görüntü doğru sınıflandırılırken 23 adet görüntü silinmiş sınıfa, 14 adet görüntü ise renklendirilmiş olarak yanlış sınıflandırılmıştır. Renklendirilmiş sınıfa ait 48 adet görüntü doğru sınıflandırılırken 21 adet görüntü silinmiş sınıfa, 9 adet görüntü ise bozulmuş sınıfa ait olarak yanlış sınıflandırılmıştır. ESA modeli ise 154 silinmiş sınıfa ait görüntü doğru sınıflandırılırken 7 adet görüntü bozulmuş sınıfa, 2 adet görüntü ise renklendirilmiş sınıfa ait olarak yanlış sınıflandırılmıştır. 98 adet bozulmuş sınıfa ait görüntü doğru sınıflandırılırken 8 adet görüntü silinmiş sınıfı, 3 adet görüntü ise renklendirilmiş sınıfa ait olarak yanlış sınıflandırılmıştır. 72 adet renklendirilmiş sınıfa ait görüntü doğru sınıflandırılırken 4 adet görüntü silinmiş sınıfa, 2 adet görüntü ise bozulmuş sınıfa ait olarak yanlış sınıflandırılmıştır.



Şekil 6. (a) MobileNet v3 (b) Resnet50 v2 (c) Kendi modelimizin karmaşıklık matrisi (confusion matrix of all models)

Gerçekleştirilen çalışma günümüzde karayollarındaki önemli problemlerden birisi olan deforme olmuş trafik

şerit çizgilerinin derin öğrenme yöntemleri ile tespiti gerçekleştirilmiştir. Derin öğrenme yöntemleri ile gerçekleştirilen eğitimlerde doğruluk ve zaman açısından kıyaslamalar gerçekleştirilmiştir. Kıyaslama sonunda doğruluk açısından ESA derin öğrenme mimarisi en başarılı mimari iken zamansal açıdan en başarılı yöntem MobileNet v3 olarak belirlenmiştir.

4. Sonuçlar (Results)

Gelişen teknoloji sayesinde, insanların gerçekleştirdiği birçok işlemin makineler tarafından daha düşük hata oranları ile yerine getirilmesi, teknolojik ilerlemenin en önemli parametrelerinden birisidir. Özellikle otonom araçların yol güvenliğini riske atmadan güvenli bir sürüş deneyimi sunabilmesi, bu alandaki temel amaçlardan biridir. İHA'lar donatıldığı kamera ve sensörler sayesinde, dış ortam şartlarından bağımsız olarak potansiyel tehditleri öngörebilmeleri ve otonom sürüş yapabilen araçların sürüş güvenliğini daha güvenli bir hale getirmek için deforme olmuş trafik şeritlerini belirleme aşamasında önemli bir rol oynamıştır. Çalışmada, otonom sürüş yapan araçların trafik şeritlerini daha detaylı algılamalarını ve özellikle hatalı, bozuk veya silinmiş şerit işaretlerini daha dikkatli bir şekilde tespit etmelerini sağlamak amacıyla derin öğrenme mimarileri yeni bir yaklaşım sunulmuştur. Derin öğrenme mimarilerden ESA tabanlı mimarinin doğruluk açısından %90'nun üzerinde doğruluk oranı ile başarılı olduğu tespit edilmiştir. Bu doğruluk oranı ile karayollarındaki deforme olmuş karayolu çizgilerinin başarılı bir biçimde tespiti gerçekleştirilmiştir. Böylece çalışma kapsamında geliştirilen derin öğrenme mimarili yöntem ile otonom araçların trafikteki güvenliğini artırmak adına önemli bir adım atılmıştır. Bu sayede, otonom sürüş teknolojisinin karşılaştığı zorlukların üstesinden gelinmesine ve yol güvenliğinin artırılmasına yönelik somut gelişmeler kaydedilmiştir. Gelecek çalışmalarda geliştirilen derin öğrenme mimarili yöntemin İHA'lar kullanılarak gerçek zamanlı olarak tespiti hedeflenmektedir.

Teşekkür (Acknowledgment)

Çalışma 5. Uluslararası Mühendislikte Yapay Zeka ve Uygulamalı Matematik Konferansı'nda özet metin olarak sunulmuştur.

Çıkar Çatışması Beyanı (Conflict of Interest Statement)

Yazarlar tarafından herhangi bir çıkar çatışması bildirilmemiştir.

Kaynaklar (References)

- [1] S. Thrun, M. Montemerlo, H. Dahlkamp, D. Stavens, A. Aron, J. Diebel, P. Fong, J. Gale, M. Halpenny, G. Hoffmann, K. Lau, C. Oakley, M. Palatucci, V. Pratt, P. Stang, S. Strohband, C. Dupont, L. E. Jendrossek, C. Koelen, C. Markey, C. Rummel, J. van Niekerk, E. Jensen, P. Alessandrini, G. Bradski, B. Davies, S. Ettinger, A. Kaehler, A. Nefian and P. Mahoney, "Stanley: the robot that won the darpa grand challenge," *J. Field Robotics*, vol. 23, pp. 661-692, 2006. [doi:10.1002/rob.20147](https://doi.org/10.1002/rob.20147)
- [2] C. Urmson, J. Anhalt, D. Bagnell, C. Baker, R. Bittner, M. N. Clark, J. Dolan, D. Duggins, T. Galatali, C. Geyer, M. Gittleman, S. Harbaugh, M. Hebert, T. M. Howard, S. Kolski, A. Kelly, M. Likhachev, M. McNaughton, N. Miller, K. Peterson, B. Pilnick, R. Rajkumar, P. Rybski, B. Salesky, Y. W. Seo, S. Singh, J. Snider, A. Stentz, W. Whittaker, Z. Wolkowicki, J. Ziglar, H. Bae, T. Brown, D. Demitriash, B. Litkouhi, J. Nickolaou, Va. Sadekar, W. Zhang, J. Struble, M. Taylor, M. Darms and D. Ferguson, "Autonomous driving in urban environments: boss and the urban challenge," *J. Field Robotics*, vol 25, pp. 425-466, 2008. [doi:10.1002/rob.20255](https://doi.org/10.1002/rob.20255)
- [3] Waymo, "Waymo's journey," <http://www.waymo.com>. [Online]. Available: <http://www.waymo.com> [Accessed September 2023].
- [4] D. J. Fagnant and K. Kockelman, "Preparing a nation for autonomous vehicles: opportunities, barriers and policy recommendations," *Transportation Research Part A: Policy and Practice*, vol. 77, pp. 167-181, 2015 [doi:10.1016/j.tra.2015.04.003](https://doi.org/10.1016/j.tra.2015.04.003).
- [5] R. Merkert and J. Bushell, "Managing the drone revolution: A systematic literature review into the current use of airborne drones and future strategic directions for their effective control," *Journal of air transport management*, vol. 89, pp. 101929, 2020. [doi:10.1016/j.jairtraman.2020.101929](https://doi.org/10.1016/j.jairtraman.2020.101929).
- [6] F. Ahmed, J. C. Mohanta, A. Keshari, and P. S. Yadav, "Recent advances in unmanned aerial vehicles: a review," *Arabian Journal for Science and Engineering*, vol. 47, pp. 7963-7984, 2022. [doi:10.1007/s13369-022-06738-0](https://doi.org/10.1007/s13369-022-06738-0)
- [7] G. Macrina, L. D. P. Pugliese, F. Guerriero and G. Laporte, "Drone-aided routing: a literature review," *Transportation Research Part C: Emerging Technologies*, vol. 120, pp. 102762, 2020. [doi:10.1016/j.trc.2020.102762](https://doi.org/10.1016/j.trc.2020.102762).
- [8] H. Wang, T. Fu, Y. Du, W. Gao, K. Huang, Z. Liu, P. Chandak, S. Liu, P. Van Katwyk, A. Deac, A. Anandkumar, K. Bergen, C. P. Gomes, S. Ho, P. Kohli, J. Lasenby, J. Leskovec, Y. Liu, A. Manrai, D. Marks, B. Ramsundar, L. Song, J. Sun, J. Tang, P. Veličković, M.

- Welling, L. Zhang, C. W. Coley, Y. Bengio and M. Zitnik, "Scientific discovery in the age of artificial intelligence," *Nature*, vol. 620, pp. 47-60, 2023. doi:10.1038/s41586-023-06221-2.
- [9] S. J. Russell and P. Norvig, "Artificial intelligence a modern approach," London: Pearson, 2021
- [10] Y. LeCun, Y. Bengio and G. Hinton. "Deep learning," *nature*, vol. 521, pp. 436-444, 2015. doi:10.1038/nature14539.
- [11] L. Breiman, "Random forests," *Machine learning*, vol. 45, pp. 5-32, 2001. doi:10.1023/A:1010933404324.
- [12] K. M. Na, K. Lee, S. K. Shin and H. Kim, "Detecting deformation on pantograph contact strip of railway vehicle on image processing and deep learning," *Applied Sciences*, vol. 10, pp. 8509, 2020. doi:10.3390/app10238509.
- [13] J. Cao, C. Song, S. Song, F. Xiao and S. Peng, "Lane detection algorithm for intelligent vehicles in complex road conditions and dynamic environments," *Sensors*, vol. 19, pp. 3166, 2019. doi:10.3390/s19143166.
- [14] T. Liu, Z. Chen, Y. Yang and H. Li "Lane detection in low-light conditions using an efficient data enhancement: Light conditions style transfer," *In 2020 IEEE intelligent vehicles symposium (IV)*, 2020, Las Vegas, NV, USA, 2020. pp. 1394-1399. IEEE. doi:10.1109/IV47402.2020.9304613.
- [15] A.Punagin and S.Punagin, "Analysis of lane detection techniques on structured roads using OpenCV," *International Journal for Research in Applied Science and Engineering Technology*, vol.8, pp. 2994-3003. doi:10.22214/ijraset.2020.5502.
- [16] S.Joy, B. S. Mamta, T. B. Mukesh, M. M. Ahmed, and U. Kiran, "Real time road lane detection using computer vision techniques in python," *In 2022 International Conference on Automation, Computing and Renewable Systems (ICACRS), December 2022, Pudukkottai, India*, 2022, pp. 1228-1232. doi: 10.1109/ICACRS55517.2022.10029238.
- [17] Z. M. Chng, J. M. H. Lew and J. A. Lee, "RONELD: Robust Neural Network Output Enhancement for Active Lane Detection," *25th International Conference on Pattern Recognition (ICPR), 2020, Milan, Italy*, 2021, pp. 6842-6849, doi: 10.1109/ICPR48806.2021.9412572.
- [18] R. Bibi, Y. Saeed, A. Zeb, T. M. Ghazal, T. Rahman, R. A. Said, S. Abbas, M. Ahmad and M. A. Khan, "Edge ai-based automated detection and classification of road anomalies in VANET using deep learning," *Computational intelligence and neuroscience*, 2021, pp. 1-16. doi:10.1155/2021/6262194.
- [19] D. Luo, J. Lu and G. Guo, "Road Anomaly Detection Through Deep Learning Approaches," *in IEEE Access*, vol. 8, pp. 117390-117404, 2020, doi: 10.1109/ACCESS.2020.3004590.
- [20] A. Howard, M. Sandler, G. Chu, L. C. Chen, B. Chen, M. Tan, W. Wang, Y. Zhu, R. Pang, V. Vasudevan, Q. V. Le and H. Adam; "CCNet: criss-cross attention for semantic segmentation," *Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV), Oct 27-Nov. 2, 2019, Seoul, Korea (South)*, 2019, pp. 1314-1324
- [21] M. Sandler, A. Howard, M. Zhu, A. Zhmoginov, and L. C. Chen, "Mobilenetv2: Inverted residuals and linear bottlenecks," *In Proceedings of the IEEE conference on computer vision and pattern recognition, 2018, Salt Lake City, USA*, 2018. pp. 4510-4520. IEEE.
- [22] F. Chollet, "Xception: Deep learning with depthwise separable convolutions." *In Proceedings of the IEEE conference on computer vision and pattern recognition, 2017, Honolulu, Hawaii*, 2017. pp. 1251-1258. IEEE.
- [23] B. Zoph, V. Vasudevan, J. Shlens, and Q. V. Le, "Learning transferable architectures for scalable image recognition." *In Proceedings of the IEEE conference on computer vision and pattern recognition, 18-23 June, 2018, Salt Lake City, USA*, 2018. pp. 8697-8710.
- [24] M. Tan, and Q. Le, "Efficientnet: Rethinking model scaling for convolutional neural networks." *In International conference on machine learning, 10-15 June, Long Beach, USA*, 2019, pp. 6105-6114.
- [25] W. Liu, D. Anguelov, D. Erhan, C. Szegedy, S. Reed, C.Y. Fu, and A.C. Berg, "Single shot multibox detector." *In Computer Vision-ECCV 2016: 14th European Conference, 11-14 Oct., 2016, Amsterdam, Netherlands*, 2016, pp. 21-37.
- [26] A. Canziani, A. Paszke, and E. Cukurciello, "An analysis of deep neural network models for practical applications", arxiv.org, 2016. [Online]. Available <https://arxiv.org/abs/1605.07678> [Accessed September 2023].
- [27] G. Huang, Z. Liu, L. Van Der Maaten and K. Q. Weinberger, "Densely Connected Convolutional Networks," *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2017, Honolulu, HI, USA*, 2017, pp. 2261-2269. doi: 10.1109/CVPR.2017.243.
- [28] K. He, X. Zhang, S. Ren, and J. Sun, "Identity mappings in deep residual networks." *In Computer Vision-ECCV 2016: 14th European Conference, 11-14 Oct., 2016, Amsterdam, Netherlands*, 2016, pp. 630-645..
- [29] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "Imagenet classification with deep convolutional neural networks." *Advances in neural information processing systems*, vol. 25, pp. 1-9, 2012.
- [30] G. Litjens, T. Kooi, B. E. Bejnordi, A. A. A. Setio, F. Ciompi, M. Ghafoorian, J.A.W.M. van der Laak, B. van Ginneken and C.I. Sánchez, "A survey on deep learning in medical image analysis." *Medical image analysis*, vol. 42, pp. 60-88, 2017. doi:10.1016/j.media.2017.07.005
- [31] D. E. Rumelhart, G. E. Hinton and R. J. Williams, "Learning representations by back-propagating errors." *nature*, vol. 32, no.6088, pp. 533-536, 1986. doi:10.1038/323533a0

[32] I. Goodfellow, Y. Bengio and A. Courville, *Deep learning*, Cambridge, MA: MIT press. 2016.

* This paper was presented at the 5th International Conference on Artificial Intelligence and Applied Mathematics in Engineering (ICALAME 2023) and the abstract was published as an e-book.

This is an open access article under the CC-BY license

