



ULUSLARARASI 3B YAZICI TEKNOLOJİLERİ  
VE DİJİTAL ENDÜSTRİ DERGİSİ

INTERNATIONAL JOURNAL OF 3D PRINTING  
TECHNOLOGIES AND DIGITAL INDUSTRY

ISSN:2602-3350 (Online)

URL: <https://dergipark.org.tr/ij3dptdi>

## YAPAY ZEKÂ KULLANILARAK TRAFİK İŞARET LEVHALARININ SINIFLANDIRILMASI: DENİZLİ İL MERKEZİ İÇİN ÖRNEK BİR UYGULAMA

### CLASSIFICATION OF TRAFFIC SIGNS WITH ARTIFICIAL INTELLIGENCE: A SAMPLE APPLICATION FOR DENİZLİ CITY CENTER

**Yazarlar (Authors):** Tolga Palandız<sup>ID</sup>, Hilmi Cenk Bayrakçı<sup>ID\*</sup>, Merdan Özkahraman<sup>ID</sup>

**Bu makaleye şu şekilde atıfta bulunabilirsiniz (To cite to this article):** Palandız T., Bayrakçı H.C., Özkahraman M., “Yapay Zekâ Kullanılarak Trafik İşaret Levhalarının Sınıflandırılması: Denizli İl Merkezi İçin Örnek Bir Uygulama” *Int. J. of 3D Printing Tech. Dig. Ind.*, 5(3): 645-653, (2021).

DOI: 10.46519/ij3dptdi.1021837

Araştırma Makale/ Research Article

Erişim Linki: (To link to this article): <https://dergipark.org.tr/en/pub/ij3dptdi/archive>

# YAPAY ZEKÂ KULLANILARAK TRAFİK İŞARET LEVHALARININ SINIFLANDIRILMASI: DENİZLİ İL MERKEZİ İÇİN ÖRNEK BİR UYGULAMA

Tolga Palandız<sup>a</sup>, Hilmi Cenk Bayrakçı<sup>a\*</sup>, Merdan Özkahraman<sup>a</sup>

<sup>a</sup>İsparta Uygulamalı Bilimler Üniversitesi, Teknoloji Fakültesi, Mekatronik Mühendisliği Bölümü, TÜRKİYE

\* Sorumlu Yazar: [cenkbayrakci@isparta.edu.tr](mailto:cenkbayrakci@isparta.edu.tr)

(Geliş/Received: 10.11.2021; Düzeltme/Revised: 08.12.2021; Kabul/Accepted: 26.12.2021)

## ÖZ

Günümüzde sürekli olarak ilerlemekte olan teknolojik gelişmeler ile yapay zeka hayatımızın vazgeçilmez bir parçası haline gelmiştir. Yapay sinir ağlarının kullanıldığı çalışma alanlarından birisi de ulaşım alanıdır. Ulaşım alanında olası kazaların azaltılması amacıyla sürücü destek sistemleri uygulamalarında yapay zeka kullanılmaktadır. Bu çalışmada hem trafik işaret levhalarının fotoğraflarının çekilmesiyle bireysel olarak oluşturulan veri seti hem de açık kaynak erişimli internet sitesinden (kaggle.com) elde edilen veri seti olmak üzere toplamda 4000 adet trafik işaret levhası görüntüsüne ait resimlerden oluşan veri seti kullanılmıştır. Veri seti 3200 adet eğitim verisi ve 800 adet test verisi içermektedir. Hazırlanan veri setleri CNN (Evrişimli Sinir Ağları) modeliyle birlikte ResNet50, MobileNetV2 ve NASNetMobile olmak üzere üç farklı derin öğrenme metoduyla eğitilerek eğitim doğruluğu, test doğruluğu, eğitim kaybı ve test kaybı faktörlerine göre performansları değerlendirilmiştir. ResNet50 metoduyla eğitim doğruluğu %97.62, test doğruluğu %78.75, eğitim kaybı %0.1 ve test kaybı %6.28 olmuştur. MobileNetV2 metoduyla eğitim doğruluğu %97.8, test doğruluğu %48.12, eğitim kaybı %0.38 ve test kaybı %38.34 olmuştur. NASNetMobile metoduyla eğitim doğruluğu %98.56, test doğruluğu %41.56, eğitim kaybı %0.1 ve test kaybı %17.28 olmuştur.

**Anahtar Kelimeler:** Yapay Zeka. Derin Öğrenme. Sınıflandırma.

## CLASSIFICATION OF TRAFFIC SIGNS WITH ARTIFICIAL INTELLIGENCE: A SAMPLE APPLICATION FOR DENİZLİ CITY CENTER

### ABSTRACT

Today, artificial intelligence has become an indispensable part of our lives with the constantly advancing technological developments. One of the fields of study where artificial neural networks are used is transportation. Artificial intelligence is used in driver support systems applications in order to reduce possible accidents in the field of transportation. In this study, a dataset consisting of images of 4000 traffic sign images in total, the dataset created both individually by taking the photos of the traffic signs and obtained from the open source website (kaggle.com) was used. The dataset contains 3200 training data and 800 test data. The prepared data sets were trained with three different deep learning methods which are ResNet50, MobileNetV2 and NASNetMobile, together with the CNN (Convolutional Neural Network) model and their performance was evaluated according to the factors of training accuracy, test accuracy, training loss and test loss. With the ResNet50 method, the training accuracy was 97.62%, the test accuracy was 78.75%, the training loss was 0.1%, and the test loss was 6.28%. With the MobileNetV2 method, the training accuracy was 97.8%, the test accuracy was 48.12%, the training loss was 0.38%, and the test loss was 38.34%. With the NASNetMobile method, the training accuracy was 98.56%, the test accuracy was 41.56%, the training loss was 0.1%, and the test loss was 17.28%.

**Keywords:** Artificial Intelligence. Deep Learning. Classification.

## 1. GİRİŞ

Yapay sinir ağları, bir bilgisayarın veya bilgisayar yardımlı bir makinenin, çoğunlukla insanlara ait özellikler, sonuca varma, kavrama ve geçmişte olan tecrübelerden öğrenme gibi lojik işlemleri yerine getirme becerisi şeklinde ifade edilmiştir [1]. Yapay sinir ağlarının alt kollarından biri olan makine öğrenmesi, makineler kendi başlarına birtakım sorunları çözüme kavuşturma yeteneğinin verilmesiyle ortaya çıkmıştır [2]. Makine öğrenmesiyle ilişkili olan zorlu problemleri hızlı bir şekilde çözüme kavuşturan derin öğrenme, yapay sinir ağlarının alt kollarından bir diğeridir [3]. Yapay zeka, işaret dili tanıma [4], veri madenciliği [5], optik karakter taşıma [6], optimum rota belirleme [7], parmak izi tanıma [8] ve iş çizelgelemesi gibi çeşitli uygulama alanlarında kullanılmaktadır [9]. Yapay sinir ağları tekniklerinden neredeyse her çalışma alanında faydalanılmaktadır. Trafik akışını daha hızlı bir şekilde sağlamak için trafik sinyalizasyon uygulamalarında yapay sinir ağlarının önemi büyüktür [10]. Bilim insanları, insan kaynaklı hataların azaltılması amacıyla yapay sinir ağlarının tahmin doğruluğunu arttırmaya çalışmaktadır [11]. Trafik işaret levhaları sürüşü daha güvenli hale getirmek için oldukça önemlidir. Günümüzde araç sürücüsünü trafik işaret levhaları için ikaz eden sistemler önem arz etmektedir [12]. Trafik işaret levhalarını tanımlamak modern sürüş destek sistemlerinin önemli bir parçasıdır [13]. Trafik levhalarının tespiti ile yapılan akademik çalışmalar incelendiğinde Serna vd. Avrupa datasetini kullanarak trafik levhalarını CNN modeliyle %99.38 oranında doğru bir şekilde sınıflandırmıştır [14]. Çalışmada Denizli iline ait trafik uyarı işaretlerinden oluşan veri setinin kullanılmasıyla trafik levhaları görüntülerinin sınıflandırılması için Evrişimli Sinir Ağları (İng. Convolutional Neural Network-CNN) modeli kullanılmıştır.

## 2. MATERYAL VE METOT

Bu çalışmada hem trafik işaret levhalarının fotoğraflarının çekilmesiyle bireysel olarak elde edilen veri seti hem de açık kaynak erişimli internet sitesinden (kaggle.com) elde edilen toplamda 4000 adet trafik işaret levhası görüntüsüne ait veri seti kullanılmıştır. Kullanılan veri seti ve derin öğrenme metodu materyal bölümünde verilmiştir [15].

### 2.1. Materyal

#### 2.1.1. Veri seti

Bu çalışmada kullanılan veri seti 3200 tanesi eğitim ve 800 tanesi test verisi olmak üzere 4000 adet trafik işaret levhasından oluşmaktadır. Veri setinde ana yol tali yol kavşağı, azami hız sınırlaması, dikkat, dur, ışıklı işaret cihazı, sağdan gidiniz, taşıt trafiğine kapalı yol ve yol ver levhalarının resimleri kullanılmıştır. Veri setinde bulunan resimlerin sayısının trafik işaret levhası türlerine göre dağılımı Çizelge 1’ de verilmiştir.

**Çizelge 1.** Kullanılan resimlerin sayısının trafik işaret levhasının türüne göre dağılımı

Trafik İşaret Levhasının Türü	Eğitim Veri Sayısı	Test Veri Sayısı
Ana yol tali yol kavşağı	400	100
Azami hız sınırlaması	400	100
Dikkat	400	100
Dur	400	100
Işıklı işaret cihazı	400	100
Sağdan gidiniz	400	100
Taşıt trafiğine kapalı yol	400	100
Yol ver	400	100

#### 2.1.2. Derin öğrenme

Derin öğrenme, özelliklerini direkt olarak veriden öğrenen bir makine öğrenme yöntemidir. Datalar görüntü, metin ve ses olabilir. Derin öğrenme yöntemi yapay sinir ağları ile makine öğrenmesinin alt kümesidir ve yapay sinir ağları çalışmalarında en popüler yöntemdir [16].

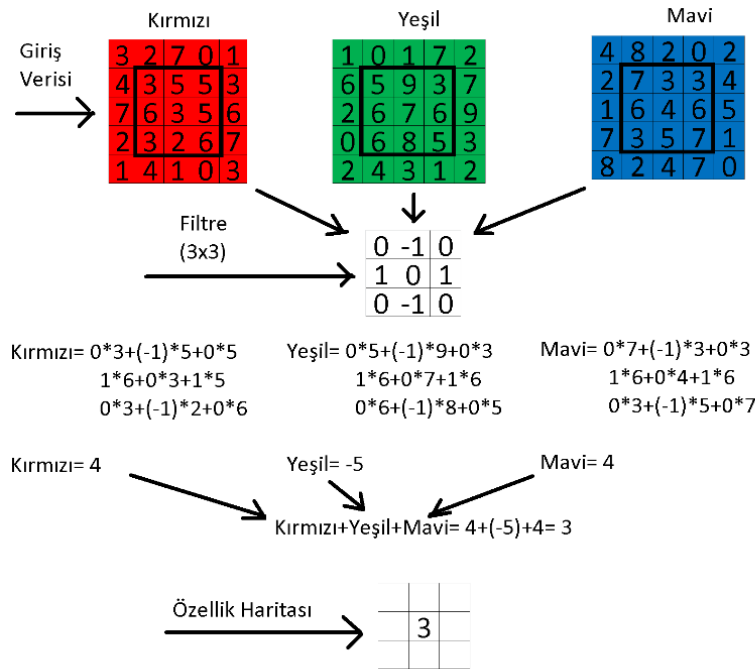
Derin öğrenme algoritmalarında giriş verisinin renkli olması kırmızı, yeşil ve mavi renklerin kullanılmasından dolayı görüntünün sahip olduğu pikselin 3 katı kadar giriş verisi kullanmasını sağlar. Gri tonlamalı görüntülerde ise sahip olunan piksel sayısı kadar giriş verisi bulunmaktadır.

Konvolüsyon, ReLu(Rektifiye Doğrusal Birim) ve havuzlama katmanları uygulanarak görüntü üzerinde özellik haritası oluşturulmaktadır. Özellik haritası oluşturulduktan sonra tam bağlantılı katmanlar ve Softmax' ten meydana gelen özel sınıflandırma katmanları uygulanmaktadır ve her piksel her sınıf için ihtimal değerleri almaktadır. İhtimal değerleri Softmax tarafından pikselin hangi sınıfa ait olduğunu tayin etmektedir [17]. Derin öğrenme algoritmasını yapay zeka ve makine öğrenmesinden ayıran fark uygulanan katmanların konvolüsyonel sinir ağı özellik haritasını oluşturmasıdır [18]. Konvolüsyon sinir ağının özellik haritasını analiz etmesiyle ilgili görüntünün sınıfı tahmin edilmektedir [19].

### 2.1.3. CNN (evrimsel sinir ağları) derin öğrenme metodu

Evrimsel sinir ağları derin öğrenmenin temel ağı olarak kabul edilir. Bu ağın çalışma prensibine göre ilk kısımlar konvolüsyon ve havuzlama katmanlarından oluşur. Son kısım ise tam bağlı katmanı ve ardından sınıflandırma katmanından oluşur. CNN modeli giriş verilerini katmanlarda işleyerek modeli eğitir. Eğitim sonunda bir sonuç değeri elde edilir. Sonuç değeri ve istenilen değer arasındaki fark hata değerini verir. Hata değeri geri yayılım algoritmasıyla her iterasyonda ağırlıklara aktarılarak güncellenir. Böylelikle hatanın azaltılması sağlanır [16].

CNN'in giriş katmanındaki veri işlenmeden kullanılmaktadır. Hazırlanacak modele göre giriş verisinin boyutu büyük veya küçük seçilebilir. Büyük seçilmesi işlemlerin daha uzun sürede tamamlanmasını ve doğruluk oranının artmasını sağlayabilir. Küçük seçilmesi ise işlemlerin daha kısa sürede tamamlanmasını ve doğruluk oranının daha azalmasına neden olabilir. CNN'in ana katmanı olarak kabul edilen konvolüsyon (dönüşüm) katmanı filtrenin işlem yapılacak görüntü üzerinde hareket etmesini sağlar. Filtreler katmandaki matrise konvolüsyon uygulayarak aktivasyon (özellik) haritasını oluşturur. Uygulanan filtrenin katsayısı her öğrenmeyle güncellenerek görüntü üzerinde kaydırılır. Filtre katsayıları her renk değeriyle ayrı ayrı çarpılıp toplanarak özellik haritasını oluşturur. Şekil 1'de renkli bir görüntünün özellik haritasının çıkarılması işlemi gösterilmektedir.



Şekil 1. Örnek bir görselin şekil olarak kullanımı [1].

Dönüşüm katmanından sonra gelen ReLu(aktifleştirme) katmanı CNN nöronlarının çıktılarını doğrultur. Bu katman giriş verisindeki eksi değerleri sıfır yapar. ReLu katmanı ağı doğrusal olmayan şekilde dönüştürerek ağın daha hızlı öğrenmesini sağlar. ReLu katmanının fonksiyonu 1'deki gibidir.

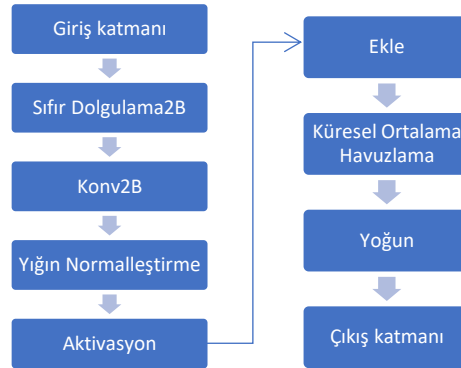
$$f(x) = \begin{cases} 0 & \text{eğer } x < 0 \\ x & \text{eğer } x \geq 0 \end{cases} \quad (1)$$

Havuzlama katmanı çoğunlukla ReLu'dan sonra gelir. Konvolüsyon katmanının giriş boyutunu azaltarak data kaybına neden olur. Bu işlem, sistemin daha kolay hesap yapmasını ve ezberden uzaklaşmasını sağlar. Dönüşüm katmanına benzer şekilde havuzlama katmanında da filtreler kullanılır. Genel olarak maksimum havuzlama filtresi çalışma niteliği açısından daha iyi olduğu için tercih edilir [20]. Tam bağlantılı katman her girişin tüm nöronlara bağlı olduğu tek boyutlu bir dizi girişini yönetir. Bu katman çoğunlukla CNN algoritmasının sonunda bulunur ve hedefleri optimize etmek için kullanılabilir [21].CNN'de çok fazla datanın eğitildiği çalışmalarda evrimsel sinir ağı ezberleme yapabilir. CNN'in ezberlemesini engellemek için dropout katmanı kullanılır [22].

Tam bağlantılı katmanın ardından sınıflandırma katmanı gelir. Bu katmanla sınıflandırma işlemi yapılmaktadır. Genellikle performansından dolayı softmax sınıflandırıcı tercih edilmektedir. Örnek olarak 15 değişik görüntünün sınıflandırılması yapılacaksa tüm görüntüler 0 ile 15 aralığında bir çıkış değeri üretir ve 1'e en yakın olan değer ağı tahmin ettiği görüntüyü oluşturur [20].

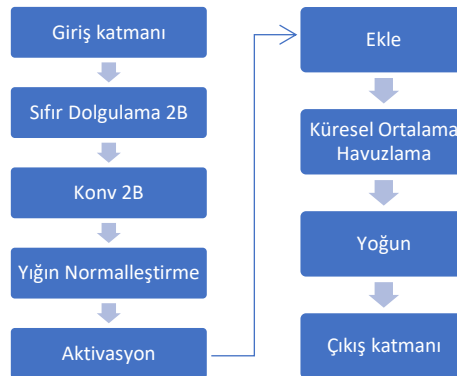
## 2.2. Metot

Çalışmada, trafik işaret levhalarının sınıflandırılması için ResNet50, MobileNetV2 ve NASNetMobile kullanılmıştır. ResNet50'ye ait CNN mimarisi Şekil 2'de gösterilmiştir.



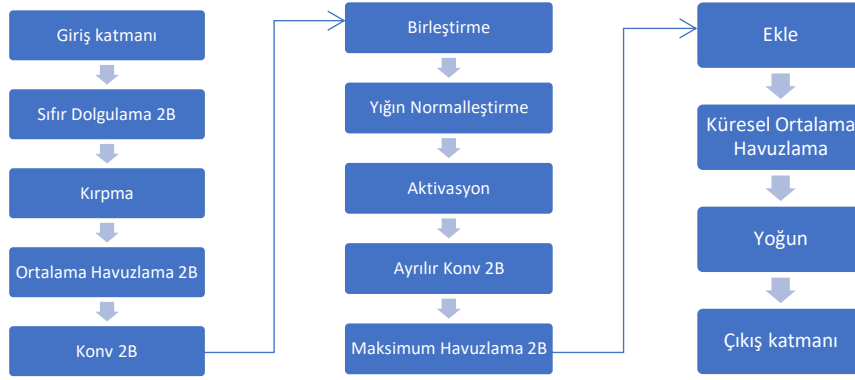
Şekil 2. ResNet50 uygulanan CNN mimarisi

MobileNetV2' ye ait CNN mimarisi Şekil 3'te gösterilmiştir.



Şekil 3. MobileNetV2 uygulanan CNN mimarisi

NASNetMobile' e ait CNN mimarisi Şekil4 gösterilmiştir.




Şekil 4. NASNetMobile uygulanan CNN mimarisi


Bu çalışmada kullanılan veri seti, kişisel olarak oluşturulan ve açık kaynak erişimli internet sitesinden (kaggle.com) olmak üzere iki tanedir.

### 3. ARAŞTIRMA BULGULARI VE TARTIŞMA

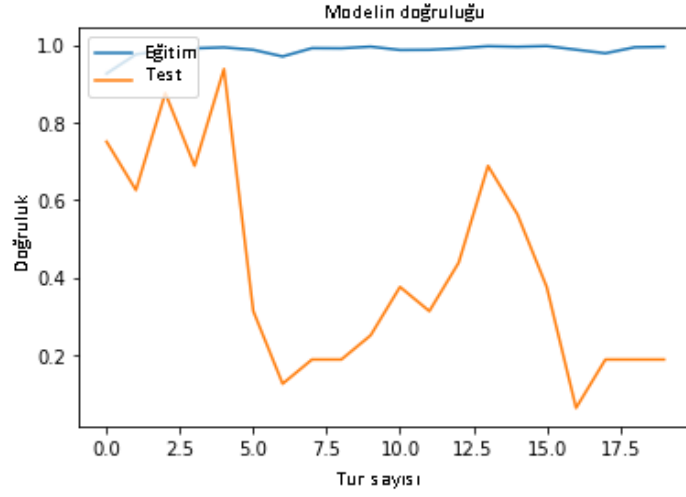
ResNet50, MobileNetV2 ve NASNetMobile yöntemleri kullanılarak oluşturulan modellerin doğruluk-tur sayısı grafiği sırasıyla Şekil 5, Şekil 6 ve Şekil 7’de gösterilmiştir.



Şekil 5. ResNet50 ile oluşturulan modelinin doğruluk-tur sayısı grafiği

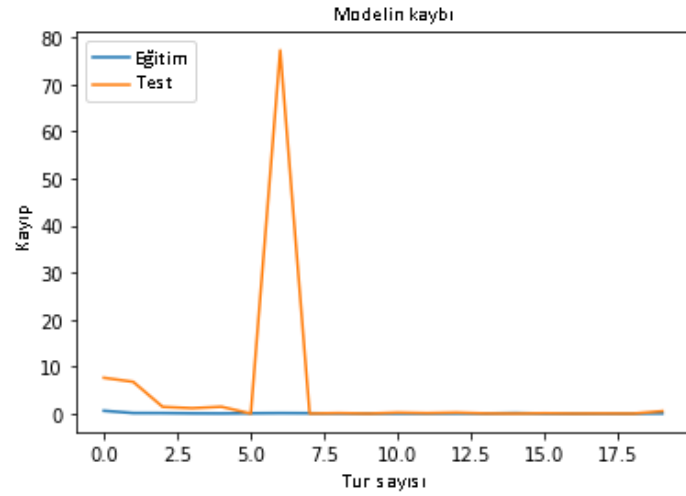


Şekil 6. MobileNetV2 ile oluşturulan modelinin doğruluk-tur sayısı grafiği

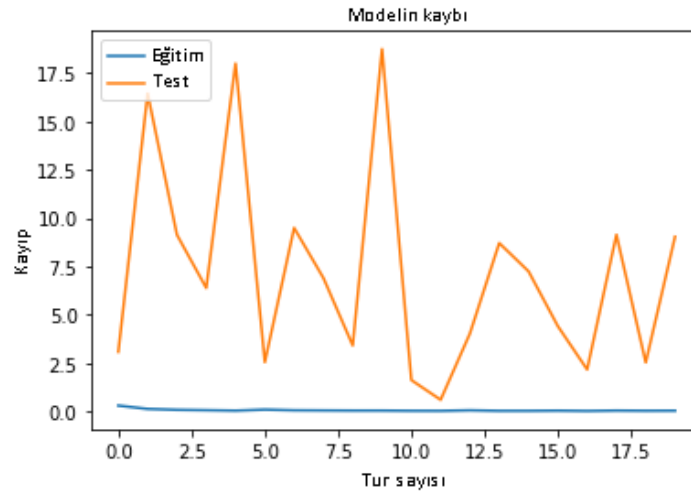


Şekil 7. NASNetMobile ile oluşturulan modelinin doğruluk-tur sayısı grafiği

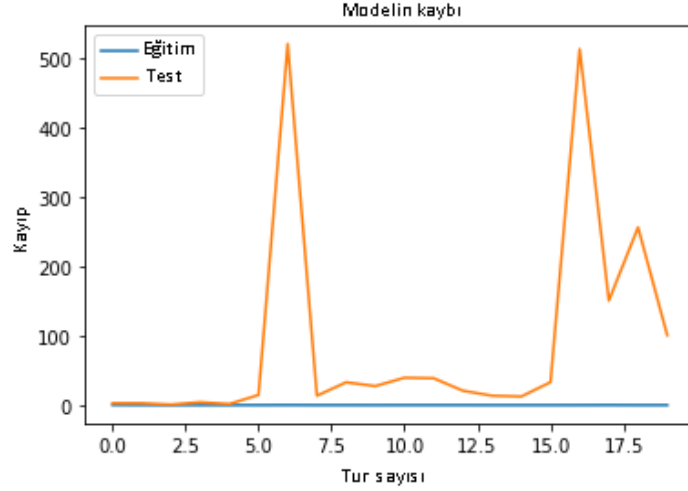
ResNet50, MobileNetV2 ve NASNetMobile yöntemleri kullanılarak oluşturulan modellerin kayıp-tur sayısı grafiği sırasıyla Şekil 8, Şekil 9 ve Şekil 10'da gösterilmiştir.



Şekil 8. ResNet50 ile oluşturulan modelinin kayıp-tur sayısı grafiği



Şekil 9. MobileNetV2 ile oluşturulan modelinin kayıp-tur sayısı grafiği



Şekil 10. NASNetMobile ile oluşturulan modelinin kayıp-tur sayısı grafiği

Grafikleri oluşturulan verilerin tablosu Çizelge 2’de gösterilmektedir.

Çizelge 2. ResNet50, MobileNetV2 ve NASNetMobile modellerinin eğitim-test doğruluğu ve kaybı

Model	Eğitim Doğruluğu (%)	Eğitim Kaybı (%)	Test Doğruluğu (%)	Test Kaybı (%)
ResNet50	97.62	0.1	78.75	6.28
MobileNetV2	97.8	0.38	48.12	38.34
NASNetMobile	98.56	0.1	41.56	17.28

Gösterilen grafikler ve tablo doğrultusunda kullanılan modeller arasında trafik işaret levhalarını sınıflandırma işlemi için performansı en iyi olan modelin ResNet50 olduğu diğer modellere oranla test doğruluğu ve kayıplardaki büyük farktan anlaşılmaktadır.

#### 4. SONUÇ

Yapay sinir ağları teknikleri birçok çalışma alanında olduğu gibi ulaşım alanında kullanılmakta ve çoğu kazanın engellenmesinde önemli bir rol oynamaktadır. Trafik işaret levhalarının hızlı ve doğru şekilde tespit edilmesiyle oluşabilecek trafik kazalarının ve buna bağlı can kayıplarının meydana gelmesi engellenecektir. Bu çalışmada, araç sürerken oluşabilecek kazaların önüne geçilmesi ve daha rahat bir sürüşün gerçekleştirilmesi için yapay zekâ kullanılarak trafik işaret levhalarının sınıflandırılması işlemi gerçekleştirilmiştir. Bu amaçla sınıflandırma işlemi için ResNet50, MobileNetV2 ve NASNetMobile olmak üzere 3 farklı model kullanılmış ve her model için 4000 görüntü kullanılarak başarısı en yüksek model belirlenmiştir. Derin öğrenme modelleri incelendiğinde ResNet50’nin performansı en yüksek model olduğu görülmüştür. Çalışmada Denizli iline ait trafik ışık levhalarının kullanılmasıyla Denizli’ye ait spesifik bir veri seti oluşturulmuştur. Böylece Denizli’de bulunan yaygın trafik ışık levhalarına odaklanarak 8 farklı trafik levhasıyla Denizli’nin çoğu bölgesinde uyumlu olan bir model ile seyahat etme imkanı oluşmaktadır. Ayrıca ileride yapılacak çalışmalarda, 8 farklı trafik işaret levhası yerine bütün trafik işaret levhalarını içeren bir sistemin kurulması düşünülmektedir. Çalışmanın Denizli ilini kapsamına karşın dünyada bulunan bütün ülkeler için trafik ışık levhası verileri toplandığında dünya genelinde ülkelere göre değişen trafik ışık levhaları da dikkate alınarak meydana gelen kazaların sayısı azaltılabilir ve yol güvenliği artırılabilir. Gelişen teknolojiyle birlikte başarıları sürekli olarak arttırılan levha sınıflandırma gibi sürüş performansını arttıran modellerin yardımıyla sürücüsüz araçların gelecekte neredeyse kusursuz biçimde sürüş yapması öngörülmektedir.

#### TEŞEKKÜR

Çalışmada “GTSRB - German Traffic Sign Recognition Benchmark” veri setini açık kaynak erişimli internet sitesine (kaggle.com) aktaran kişi/kişilere teşekkürlerimizi sunarız.



**KAYNAKLAR**

1. Nabiye, V. V., “Yapay zekâ: insan-bilgisayar etkileşimi”, Seçkin Yayıncılık, Ankara, 2012.
2. Wehle, H. D., “Machine learning, deep learning, and ai: What’s the difference?”, In International Conference on Data Scientist Innovation Day, Bruxelles, Belgium, 2017, July.
3. Goodfellow, I., Bengio, Y., Courville, A., “Deep learning”, MIT Press, 2016.
4. Aksoy, B., Salman, O. K. M. and Ekrem, Ö., “Detection of Turkish Sign Language Using Deep Learning and Image Processing Methods”, Applied Artificial Intelligence, Vol 35, Issue 12, Pages 952-981, 2021.
5. Dener, M., Dörterler, M. ve Orman, A., “Açık kaynak kodlu veri madenciliği programları: WEKA’da örnek uygulama”, 11. Akademik Bilişim Konferansı, Şanlıurfa, Cilt 9, 2009.
6. Dölek, İ., “Yapay sinir ağlarıyla optik karakter tanımı kullanılarak günümüz Türkçesinin Osmanlıcaya çevrilmesi”, Yüksek Lisans Tezi, Sakarya Üniversitesi Fen Bilimleri Enstitüsü, Sakarya, 2016.
7. Tan, K. C., Lee, L. H. and Ou, K., “Artificial intelligence heuristics in solving vehicle routing problems with time window constraint”, Engineering Applications of Artificial Intelligence, Vol 14, Issue 6, Pages 825-837, 2001.
8. Dong, X. Y., Niu, X. Q., Zhang, Z. Y., Wei, J. S. and Xiong, H. M., “Red fluorescent carbon dot powder for accurate latent fingerprint identification using an artificial intelligence program”, ACS Applied Materials and Interfaces, Vol 12, Issue 26, Pages 29549-29555, 2020.
9. Öztemel, E., “Yapay sinir ağları”, Papatya Yayıncılık, İstanbul, 2003.
10. Kadiroğulları, G., Aksoy, B., Sayın, H., Ömür, M., “Arıma yapay zeka yöntemi kullanılarak Isparta ilindeki örnek bir kavşak için araç sayısı ve araç geçiş sürelerinin tespiti”, Mühendislik Bilimleri ve Tasarım Dergisi, Cilt 8, Sayı 5, Sayfa 11-24, 2020.
11. Ateş, F., Salman, O., Şenol, R., Aksoy, B., “Determination of vehicle type by image classification methods for a sample traffic intersection in Isparta province”, The International Conference on Artificial Intelligence and Applied Mathematics in Engineering”, Springer, Cham, Pages 429-438, 2020.
12. Yavuz, A., “Derin öğrenme algoritmaları ile trafik işaret ve levhalarının tanımlanması”, Yüksek Lisans Tezi, Pamukkale Üniversitesi Fen Bilimleri Enstitüsü, Denizli, 2021.
13. Malik, Z., ve Siddiqi, I., “Detection and recognition of traffic signs from road scene images. 12th International Conference on Frontiers of Information Technology”, Pages 330-335, 2014.
14. Serna, C. G. and Ruichek, Y., “Traffic signs detection and classification for European urban environments”, IEEE Transactions on Intelligent Transportation Systems, Vol 21, Issue 10, Pages 4388-4399, 2019.
15. Mykola, “GTSRB - German traffic sign recognition benchmark”, <https://www.kaggle.com/meowmeowmeowmeowmeowmeow/gtsrb-german-traffic-sign>, November 25, 2018.
16. LeCun Y., Bengio Y., Hinton G., “Deep learning”, Nature, Vol 521, Pages 436-444, 2015.
17. Bozkurt, S., “Derin öğrenme algoritmaları kullanılarak çay alanlarının otomatik segmentasyonu”, Yüksek Lisans Tezi, Sayfa 22-25, İstanbul, 2018.
18. Le Q. V., Ngiam J., Coates A., Lahiri A., Prochnow B., Ng A. Y., “On optimization methods for deep learning”, In Proceedings of the 28th International Conference on International Conference on Machine Learning, Pages 265-272, 2011.

19. Lee H., Pham P., Largman Y., Ng A. Y., “Unsupervised feature learning for audio classification using convolutional deep belief networks”, In Advances in Neural Information Processing Systems, Pages 1096-1104, 2009.
20. Özkan, İ., Ülker, E., “Derin öğrenme ve görüntü analizinde kullanılan derin öğrenme modelleri”, Gaziosmanpaşa Bilimsel Araştırma Dergisi, Cilt 6, Sayı 3, Sayfa 85-104, 2017.
21. Amidi A., Amidi S., “Convolutional neural networks cheatsheet”, <https://stanford.edu/~shervine/teaching/cs-230/cheatsheet-convolutional-neural-networks>, November 24, 2018.
22. Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., Salakhutdinov, R., “Dropout: a simple way to prevent neural networks from overfitting”, The Journal of Machine Learning Research, Vol 15, Issue 1, Pages 1929-1958, 2014.