



**TRAFİK İŞARET LEVHALARI İÇİN BİR SÜRÜCÜ
DESTEK SİSTEMİ ÖNERİSİ**

Muhammed Buğra KIZILARSLANOĞLU

Danışman: Doç. Dr. Ahmet ATALAY

Yüksek Lisans Tezi

İnşaat Mühendisliği Ana Bilim Dalı

2024

(Her hakkı saklıdır.)

T.C.
ATATÜRK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
İNŞAAT MÜHENDİSLİĞİ ANA BİLİM DALI

TRAFİK İŞARET LEVHALARI İÇİN BİR SÜRÜCÜ DESTEK SİSTEMİ ÖNERİSİ
(Driver Assistance System Recommendation For Traffic)

YÜKSEK LİSANS TEZİ

Muhammed Buğra KIZILARSLANOĞLU

Danışman: Doç. Dr. Ahmet ATALAY

Erzurum
Ağustos, 2024



FEN BİLİMLERİ ENSTİTÜSÜ

Graduate School of Natural and
Applied Sciences

T.C.
ATATÜRK ÜNİVERSİTESİ
Fen Bilimleri Enstitüsü Müdürlüğü
TEZ KABUL VE ONAY TUTANAĞI

TRAFİK İŞARET LEVHALARI İÇİN BİR SÜRÜCÜ DESTEK SİSTEMİ ÖNERİSİ

Doç. Dr. Ahmet ATALAY danışmanlığında, Muhammed Buğra KIZILARSLANOĞLU tarafından hazırlanan bu çalışma, 09./08/2024 tarihinde aşağıdaki jüri tarafından İnşaat Mühendisliği Anabilim Dalı Ulaştırma Bilim Dalı'nda Yüksek Lisans tezi olarak oybirliği / oy çokluğu (3./3.) ile kabul edilmiştir.

Jüri Başkanı:	Prof. Dr. Ahmet TORTUM <i>Atatürk Üniversitesi</i>	Aslı ıslak imzalıdır
Danışman:	Doç. Dr. Ahmet ATALAY <i>Atatürk Üniversitesi</i>	Aslı ıslak imzalıdır
Jüri Üyesi:	Dr. Öğr. Üyesi Kadir Diler ALEMDAR <i>Erzurum Teknik Üniversitesi</i>	Aslı ıslak imzalıdır

Enstitü Yönetim
Kurulunun .../.../.... tarih
ve sayılı kararı.

Bu tezin Atatürk Üniversitesi Lisansüstü Eğitim ve Öğretim Yönetmeliği'nin ilgili maddelerinde belirtilen şartları yerine getirdiğini onaylarım.

Prof. Dr. Saltuk Buğrahan CEYHUN

Enstitü Müdürü

Aslı ıslak imzalıdır

ETİK BİLDİRİM VE İNTİHAL BEYAN FORMU

Yüksek Lisans Tezi olarak Doç. Dr. Ahmet ATALAY danışmanlığında sunulan “**Trafik İşaret Levhaları İçin Bir Sürücü Destek Sistemi Önerisi**” başlıklı çalışmanın tarafımızdan bilimsel etik ilkelere uyularak yazıldığını, yararlanılan eserlerin kaynakçada gösterildiğini, Fen Bilimleri Enstitüsü tarafından belirlenmiş olan Turnet’in Programı benzerlik oranlarının aşılmadığını ve aşağıdaki oranlarda olduğunu beyan ederiz.

Tez Bölümleri	Tezin Benzerlik Oranı (%)	Maksimum Oran (%)
Giriş	8	30
Kuramsal Temeller	2	30
Materyal ve Metot	30	35
Araştırma Bulguları ve Tartışma	10	20
Sonuçlar	1	20
Tezin Geneli	13	25

Not: Yedi kelimeye kadar benzerlikler ile Başlık, Kaynakça, İçindekiler, Teşekkür, Dizin ve Ekler kısımları tarama dışı bırakılabilir. Yukarıdaki azami benzerlik oranları yanında tek bir kaynaktan olan benzerlik oranlarının %5'den büyük olmaması gerekir.

Beyan edilen bilgilerin doğru olduğunu, aksi halde doğacak hukuki sorumlulukları kabul ve beyan ederiz.

Tez Yazarı (Öğrenci)	Tez Danışmanı
Muhammed Buğra KIZILARSLANOĞLU	Doç.Dr. Ahmet ATALAY
12.8.2024	12.8.2024
İmza: Aslı ıslak imzalıdır	İmza: Aslı ıslak imzalıdır

* Tez ile ilgili YÖKTEZ’de yayınlamasına ilişkin bir engelleme var ise aşağıdaki alanı doldurunuz.

☐ Tezle ilgili patent başvurusu yapılması / patent alma sürecinin devam etmesi sebebiyle Enstitü Yönetim Kurulunun/....../.... tarih ve sayılı kararı ile teze erişim 2 (iki) yıl süreyle engellenmiştir.

☐ Enstitü Yönetim Kurulunun/....../.... tarih ve sayılı kararı ile teze erişim 6 (altı) ay süreyle engellenmiştir.

TEŞEKKÜR

Yüksek lisans eğitiminin tüm safhalarında tecrübelerini benimle paylaşan, tez çalışmam boyunca beni destekleyen, bana inanan ve cesaretlendiren danışmanım Doç. Dr. Ahmet ATALAY'a; yazılım konusunda desteğini esirgemeyen eşim, Bilgisayar Mühendisi Şeyda KIZILARSLANOĞLU'na; Elektrik Elektronik Mühendisleri Ahmet Sinan YARALI ve Engin KÜLEKÇİ'ye emekleri ve destekleri için teşekkür ederim.

Muhammed Buğra KIZILARSLANOĞLU



ÖZET

YÜKSEK LİSANS TEZİ

TRAFİK İŞARET LEVHALARI İÇİN BİR SÜRÜCÜ DESTEK SİSTEMİ ÖNERİSİ

Muhammed Buğra KIZILARSLANOĞLU

Danışman: Doç. Dr. Ahmet ATALAY

Amaç: Akıllı Ulaşım Sistemleri, gün geçtikçe ülkelerin gündeminde daha fazla yer bulmaktadır. Bu sistemler, yalnızca şehir içi veya şehirler arası hareketliliğin iyileştirilmesine değil, aynı zamanda ekonomik büyümeyi desteklemeye ve vatandaşların yaşam kalitesini artırmaya yönelik önemli bir rol oynamaktadır. Altyapı ve teknolojiyi entegre ederek maksimum verimi elde etmeyi hedefleyen Akıllı Ulaşım Sistemleri, gelişen teknoloji ile birlikte etki alanını giderek genişletmekte, sürekli olarak güncellenmekte ve gelişmektedir. Akıllı Ulaşım Sistemlerinin Yapay Zeka uygulamaları ile entegre olması ile Akıllı Ulaşım Sistemlerinin alt kolu olan Sürücü Destek Sistemlerinin daha etkin kullanılabilmesinin önünü açmıştır.

Bu çalışmada, öncelikli olarak trafik kazalarının sebepleri incelenmiş ve Karayolları 2023 kaza istatistiklerine göre, kazaların büyük çoğunluğunun sürücü hatalarından kaynaklandığı belirlenmiştir. Özellikle trafik levhalarına uyulmamasından kaynaklanan kazaları minimize etmek amacıyla, sürücülerini uyararak bir sistemin geliştirilmesi hedeflenmiştir.

Yöntem: Bu çalışmada, taşıt kameralarından elde edilen görüntüler üzerinde nesne tanıma ve tespiti gerçekleştirmek için VGG-16 tabanlı bir Convolutional Neural Network (CNN) yöntemi kullanılmıştır. Bu yöntem, TensorFlow kütüphanesi kullanılarak Python dilinde geliştirilmiş ve veri setimizdeki görüntüler üzerinde test edilmiştir. VGG-16, özellikle görüntü işleme ve sınıflandırma görevlerinde yaygın olarak kullanılan güçlü bir derin öğrenme modelidir. Bu sayede, trafik levhalarının doğru bir şekilde tanınması ve sürücülere gerekli uyarıların yapılması hedeflenmiştir. VGG-16'nın seçilmesinin en önemli sebebi, modelin basitliği ve anlaşılabilirliği olup, bu sayede modelde daha kolay iyileştirmeler yapılabilmesidir.

Bulgular: Derin öğrenme yöntemlerinden Convolutional Neural Network (CNN) kullanılarak oluşturulan trafik levhası veri seti üzerinde geliştirilen model başarıyla test edilmiştir. Model, Trafik Tanzim ve Trafik Uyarı İşaretlerini tanıma görevlerinde %99,98 başarı elde etmiş ve 12 farklı levha grubunda %99,16 oranında doğruluk sağlamıştır.

Sonuç: Bu tez çalışması, Sürücü Destek Sistemi olarak geliştirilen modelin araçlara entegre edilmesiyle sürücülerin trafik levhalarını daha doğru tanımasını ve bu levhalara uygun tepki göstermelerini sağlamayı amaçlamaktadır. Bu sayede, trafik güvenliğinin artırılması ve kazaların azaltılması hedeflenmektedir.

Anahtar Kelimeler: Sürücü Destek Sistemleri, Trafik Levha Tanıma Sistemleri, Akıllı Ulaşım Sistemleri, Yapay Zeka, Derin Öğrenme

2024 Ağustos, 61 sayfa

ABSTRACT

MASTER'S THESIS

DRIVER ASSISTANCE SYSTEM RECOMMENDATION FOR TRAFFIC SIGN

Muhammed Buğra KIZILARSLANOĞLU

Supervisor: Assoc. Prof. Dr. Ahmet ATALAY

Purpose: Intelligent Transportation Systems (ITS) are increasingly becoming a key agenda for countries. These systems play a significant role not only in improving urban and interurban mobility but also in supporting economic growth and enhancing citizens' quality of life. Aiming to achieve maximum efficiency by integrating infrastructure and technology, ITS are expanding their impact with evolving technology, continuously updating and developing. The integration of Artificial Intelligence applications with ITS has paved the way for more effective use of Driver Assistance Systems, a subfield of ITS.

In this study, we primarily examined the causes of traffic accidents and determined that the majority of accidents are due to driver errors according to the 2023 traffic accident statistics of the Highway Authority. To minimize accidents resulting from non-compliance with traffic signs, the goal is to develop a system that alerts drivers.

Method: In this study, a Convolutional Neural Network (CNN) method based on VGG-16 has been used for object recognition and detection on images obtained from vehicle cameras. This method was developed in Python using the TensorFlow library and tested on images in our dataset. VGG-16 is a powerful deep learning model widely used for image processing and classification tasks. The goal is to accurately recognize traffic signs and provide necessary alerts to drivers. The main reason for selecting VGG-16 is its simplicity and comprehensibility, allowing for easier improvements in the model.

Findings: The model developed on the traffic sign dataset using deep learning methods, specifically Convolutional Neural Networks (CNNs), has been successfully tested. The model achieved 99.98% accuracy in recognizing Traffic Regulation and Traffic Warning Signs and provided 99.16% accuracy across 12 different sign categories.

Conclusion: This thesis aims to enhance traffic safety and reduce accidents by integrating the developed Driver Assistance System model into vehicles, thereby enabling drivers to more accurately recognize traffic signs and respond appropriately to them.

Keywords: Driver Assistance Systems, Traffic Sign Recognition Systems, Intelligent Transportation Systems, Artificial Intelligence, Deep Learning

August 2024, 61 pages

İÇİNDEKİLER

KABUL VE ONAY TUTANAĞI.....	i
ETİK BİLDİRİM VE İNTİHAL BEYAN FORMU	ii
TEŞEKKÜR	iii
ÖZET	iv
ABSTRACT	v
TABLolar DİZİNİ.....	viii
ŞEKİLLER DİZİNİ	ix
KISALTMALAR VE SİMGELER DİZİNİ.....	x
GİRİŞ.....	1
KURAMSAL TEMELLER.....	3
Akıllı Ulaşım Sistemleri.....	3
Yolculuk bilgi sistemi	4
Trafik yönetimi.....	5
Sürücü destek sistemleri.....	6
Yük taşımacılığı	7
Ulusal güvenlik	8
Yapay Sinir Ağları (YSA).....	8
Yapay sinir ağları tarihçesi	9
Yapay sinir ağları temel kavramları.....	10
Makine öğrenmesi.....	12
Derin Öğrenme.....	15
Convolutional neural networks (CNNs).....	16
Rekurrent sinir ağları (Recurrent neural networks-RNNs)	18
Derin yapay sinir ağları (Deep neural networks -DNNs).....	19
Derin öğrenme üzerine yapılan çalışmalar.....	19
MATERYAL VE METOD	22
Materyal	22
Karayollarında kullanılan trafik işaret levhaları ve veri setinde kullanılan trafik işaret levhaları.....	22
Veri setindeki trafik işaret levhaları.....	26
Kullanılan Kütüphane ve Programlama Dili.....	29
Yöntem.....	31

ARAŖTIRMA BULGULARI	33
Yapılan Testler ve Sonuların Analizi	33
Birinci aŖama testleri.....	34
İkinci aŖama testleri.....	35
SONU, TARTIŖMA VE ÖNERİLER	42
Sonu ve TartıŖma.....	42
Öneriler	43
KAYNAKA	45
ÖZGEMİŖ.....	48



TABLÖLAR DİZİNİ

Tablo 1. Yerleşim Yeri Durumuna Göre Ölümlü ve Yaralanmalı Trafik Kazalarındaki Kusur Oranları 2023	1
Tablo 2. Yıllar İtibarıyla Meydana Gelen Ölümlü ve Yaralanmalı Trafik Kazalarındaki Kusur Oranları (2012-2023).....	2
Tablo 3. Tehlike Uyarı İşaretleri.....	22
Tablo 4. Trafik Tanzim İşaretleri.....	24
Tablo 5. Veri Setindeki Trafik İşaret Levhaları	27
Tablo 6. Modelde Eğitim ve Teste Sokulan Levhalar	29
Tablo 7. VGG16 Konvolüsyon ve Pooling Sistemi.....	30
Tablo 8. Epoch 10 ve Step Per Epoch 10'a göre Modelden Alınan Yüzde Sonuçları	35
Tablo 9. Epoch 20 ve Step Per Epoch 30'a göre Modelden Alınan Yüzde Sonuçları	36
Tablo 10. Epoch 20 ve Step Per Epoch 40'a göre Modelden Alınan Yüzde Sonuçları	37
Tablo 11. Epoch 25 ve Step Per Epoch 40'a göre Modelden Alınan Yüzde Sonuçları	38
Tablo 12. Epoch 30 ve Step Per Epoch 45'a göre Modelden Alınan Yüzde Sonuçları	39

ŞEKİLLER DİZİNİ

Şekil 1. Nöron yapısı	9
Şekil 2. Derin sinir ağlarının bir örneği.....	11
Şekil 3. Yapay sinir ağı örneği	12
Şekil 4. VGG-16 mimarisi	30
Şekil 5. Yöntem akış şeması	31
Şekil 6. Aşama 1 test 1 sonuçları	34
Şekil 7. Aşama 1 test 2 sonuçları	34
Şekil 8. Aşama 2 test 1 sonuçları	35
Şekil 9. Aşama 2 test 2 sonuçları	36
Şekil 10. Aşama 2 test 3 sonuçları	37
Şekil 11. Aşama 2 test 4 sonuçları	38
Şekil 12. Aşama 2 test 5 sonuç grafiği	39

KISALTMALAR VE SİMGELER DİZİNİ

ALC	: Adaline Linear Combiner(Adaline Lineer Kombinör)
AMTICS	: Advanced Mobile Traffic Information and Communication System(Gelişmiş Mobil Trafik Bilgi ve İletişim Sistemi)
AUS	: Akıllı Ulaşım Sistemleri
BelguimTS	: Belgium Traffic Sign(Belçika Trafik Levhası)
CALTRANS	: Kaliforniya Ulaştırma Bakanlığı
CCTSDB	: Chinese City Traffic Sign Database(Çin Şehri Trafik Levhası Veritabanı)
CNN	: Convolutional Neural Network(Evrimli Sinir Ağı)
CNNS	: Convolutional Neural Networks(Evrimsel Sinir Ağları)
CSUST	: Changsha University of Science and Technology Traffic Sign Detection Benchmark (Changsha Bilim ve Teknoloji Üniversitesi Trafik İşareti Tespiti Ölçütü)
DNNs	: Deep Neural Networks(Derin Yapay Sinir Ağları)
Faster R-CNN	: Faster Region-based Convolutional Neural Network(Daha Hızlı Bölge Bazlı Evrimsel Sinir Ağı)
GPU	: Grafik işlem girimleri
GTSDB	: German Traffic Sign Detection Benchmark(Alman Trafik Levhası Tespiti Ölçütü)
GTSRB	: German Traffic Sign Recognition Benchmark(Alman Trafik Levhası Tanıma Ölçütü)
ISTEA	: Federal Ulaşım Yasası
ITS	: Intelligent Transportation Systems(Akıllı Ulaşım Sistemleri)
MatConvNet	: MATLAB Convolutional Neural Network(MATLAB Evrimsel Sinir Ağı)
MATLAB	: MATrix LABoratory(MATris LABoratuvarı)
MNIST	: Modified National Institute of Standards and Technology (Değiştirilmiş Ulusal Standartlar ve Teknoloji Enstitüsü)
PCA	: Principal Component Analysis (Temel Bileşen Analizi)
RACS	: Road Traffic Information and Control System(Yol Trafik Bilgi ve Kontrol Sistemi)
ReLu	: Rectified Linear Unit(Düzeltilmiş Doğrusal Birim)

R-FCN	: Region-based Fully Convolutional Networks(Bölge Bazlı Tam Evrimsel Ağlar)
RNNs	: Recurrent Neural Networks(Rekurrent Sinir Ağları)
SSD	: Single Shot MultiBox Detector(Tek Atışta Çoklu Kutu Dedektörü)
TRTSD	: Turkish Road Traffic Sign Dataset(Türk Yol Trafik Levhası Veri Seti)
t-SEN	: t-distributed Stochastic Neighbor Embedding(t-dağılımlı Stokastik Komşu Gömme)
TÜİK	: Türkiye İstatistik Kurumu
VGG-16	: Visual Geometry Group 16-layer (Görsel Geometri Grubu 16-katmanlı)
YOLO	: You Only Look Once
YSA	: Yapay Sinir Ağları



GİRİŞ

Trafik işaret levhaları, trafik akışının düzenli bir şekilde ilerlemesine katkıda bulunarak trafik güvenliğini sağlamada önemli bir rol oynamaktadır. Sürücülerin bu işaretlerin anlamlarını doğru bir şekilde anlamaları ve gerektiğinde doğru tepkiyi vermeleri, trafik kazalarının önlenmesinde kritik bir faktördür (Kurt 2020). 2023 yılı kaza istatistiklerine göre, yerleşim yerlerinde düz yolda meydana gelen kazaların oranı %94,35 iken, yerleşim dışı alanlarda bu oran %70,13 olarak belirlenmiştir. Tehlikeli virajlarda ise yerleşim yerlerindeki kazaların oranı %0,96 iken, yerleşim dışı alanlarda %10,82 olarak görülmüştür. Bu veriler, düz yolda meydana gelen kazaların diğer alanlara göre belirgin şekilde daha fazla olduğunu göstermektedir, bu durumun sebeplerinin ayrıntılı olarak incelenmesi gerekliliğini ortaya koymaktadır (TÜİK, 2023).

TÜİK verilerine göre, kaza oranları gündüz ve gece saatlerine göre incelendiğinde, gündüz kazalarının oranı %65,9, gece kazalarının oranı %31,8 ve alacakaranlıkta meydana gelen kazaların oranı ise %2,3 olarak belirlenmiştir. Ayrıca, hava koşulları dâhil olmak üzere TÜİK'in yayınladığı istatistiklere göre kazalara en fazla sebep olan unsurun sürücüler olduğu ortaya konmuştur; bu oranın şehir içi trafikte %87,96, şehirler arası yollarda ise %94,4 olduğu belirtilmiştir (TÜİK, 2023).

Tablo 1. Yerleşim Yeri Durumuna Göre Ölümlü ve Yaralanmalı Trafik Kazalarındaki Kusur Oranları 2023 (TÜİK, 2023)

KAZA FAKTÖRLERİ				
KAZA FAKTÖRLERİ	YERLEŞİM YERİ		YERLEŞİM YERİ DİŞİ	
Faktörler	Kusur Sayısı	%	Kusur Sayısı	%
Sürücü	204.459	87,96	45.397	94,4
Yaya	24.548	10,56	807	1,68
Yolcu	1.268	0,55	486	1,01
Taşıt	1.852	0,8	1,297	2,7
Yol	322	0,14	104	0,22

Tablo 2. Yıllar İtibarıyla Meydana Gelen Ölümlü ve Yaralanmalı Trafik Kazalarındaki Kusur Oranları (2012-2023) (TÜİK, 2023)

İNSAN FAKTÖRÜ				
YILLAR	SÜRÜCÜ%	YAYA %	YOLCU %	TOPLAM %
2012	88,86	9,75	0,44	99,05
2013	88,97	8,91	0,43	98,31
2014	89,12	9,21	0,48	98,81
2015	89,76	8,67	0,45	98,88
2016	90,02	8,6	0,41	99,03
2017	90,29	8,35	0,37	99,01
2018	89,64	8,28	1,09	99,01
2019	88,89	7,92	0,85	97,65
2020	88,65	6,93	1,46	97,04
2021	87,23	8,21	1,76	97,2
2022	87,03	9,47	1,17	97,67
2023	89,06	9,04	0,63	98,72

Trafik yoğunluğu, değişen hava koşulları, sürücünün psikolojik durumu gibi faktörler sürücülerin trafik işaretlerini doğru anlamalarını ve doğru tepki vermelerini olumsuz etkileyebilmektedir. Bu nedenle sürücülerin, trafik işaretlerini yanlış anlama, yanlış yorumlama veya göz ardı etme gibi hataları, trafik güvenliğini ciddi şekilde tehlikeye atabilmektedir (Murat ve Çakıcı 2017).

Sürücü kaynaklı hataların giderilmesi konusunda birçok çalışma yapılmıştır. Özellikle Yapay zekanın kullanım alanının genişlemesi ve Sürücü Destek Sistemlerine entegrasyonu sayesinde, insan davranışlarını taklit edebilen yapay zeka, elde ettiği verilerle kendini geliştirmekte ve olası kazalar için gerekli tedbirlerin alınmasını sağlamaktadır (Tüzün 2022).

Bu çalışmada, şehir içi ve şehirler arası yollardan elde edilen görüntülerden oluşan bir veri seti kullanılarak TensorFlow kütüphanesi ve VGG-16 modeli ile Python dilinde bir model eğitilmiş ve test edilmiştir. VGG-16, önceden eğitilmiş bir model olarak sunduğu performans avantajları ve basit yapısı sayesinde seçilmiştir; bu sayede modelin daha kolay iyileştirilmesi mümkün olmuştur. Modelin amacı, sürücülere bu destek sistemi aracılığıyla verilen uyarılarla daha güvenli ve konforlu bir sürüş deneyimi sağlamaktır (Kızrak ve Bolat 2018).

KURAMSAL TEMELLER

Akıllı Ulaşım Sistemleri

Akıllı Ulaşım Sistemleri (AUS), trafik güvenliği, trafik sıkışıklığı, yakıt tüketimi ve hava kirliliği gibi karmaşık ve küresel ölçekli sorunların çözümüne yönelik geliştirilen, çözüm odaklı ve entegre sistemlerdir. Bu sistemler, trafik akışının optimize edilmesi, kazaların azaltılması ve çevresel etkilerin en aza indirilmesi gibi hedefler doğrultusunda dünya genelinde giderek yaygınlaşan bir şekilde uygulanmaktadır (Dilek vd. 2023). AUS, bu amaçlara ulaşabilmek için ileri düzey telekomünikasyon, veri analitiği, yapay zeka ve bilgisayar teknolojileri gibi yenilikçi araçları kullanarak, ulaşım altyapısının daha verimli, güvenli ve sürdürülebilir hale getirilmesini sağlar (Korkmaz 2022). AUS ile öncelikli olarak sorunların kaynaklarının tespiti yapılır. Ardından çözüm için yapılması gerekenler planlanır ve çözüm yollarına gidilir. Bu süreçte çözüm elemanlarının birbirleri ile uyum içerisinde çalışması, verimlilik sağlanması hedeflenir. Tabi Akıllı Ulaşım Sistemlerinde çözüm elemanları irdelendiğinde karşımıza ülke de yaşayan nüfusun alışkanlıkları da göz önüne alınmaktadır (Tufan 2014).

AUS daha hızlı, konforlu ve güvenli bir ulaşım hizmeti sunmak için sadece altyapı değil kullanıcılar da işin içine dahil edilir ve kullanıcılar da AUS'un bir parçası olur. AUS için en önemli başlıklar; doğru planlamanın yapılması, AUS elemanlarının uyum içerisinde çalışması ve değişen koşullarda AUS'un kendisini güncelleyebilir olmasıdır (Dilek vd 2023). Bunun için sürekli olarak AUS elemanları da birbirleri ile bilgi akışı sağladığından dolayı gerekli önemlerin alınması ve mevcut durumun revize edilebilmesi amaçlanmaktadır (Çevik 2022).

Bölgesel olarak sorunlar ve kültürel alışkanlıklar farklılık gösterdiğinden dolayı dünya genelinde AUS mimarisine yaklaşımlar da farklılık göstermektedir. Bunun yanında mevsimsel değişimler ve arazi şartları da AUS'un farklı şekillenmesindeki diğer etmenlerdir. Bu yüzden evrensel bir AUS'dan bahsetmek doğru olmayacaktır. Fakat kullanılan AUS mimarileri bize sorun çözümünde kullanılabilecek AUS sistemleri hakkında da bilgi verecektir (Tufan 2014).

Her ne kadar AUS için kullanılan yöntemler değişiklik gösteriyor olsa da ortak özellikler de bulunmaktadır. Bunlar; uyumluluk, genişletilebilir olması, birlikte çalışabilmesi, standardizasyon ve kolaylıkla entegre edilebilir olmasıdır (Dilek vd 2023). Özellikle birlikte çalışabilir ve entegre olması son derece önem arz etmektedir. Sonuç itibari ile AUS birçok

elemandan oluşmaktadır ve bunların birlikte uyum içinde olması son derece önemlidir (Korkmaz 2022).

Akıllı Ulaşım Sistemleri üzerine çalışmalar ilk olarak Japonya'da 1970'lerde trafikte meydana gelen kaza ve sıkışlıkların artması ile trafik yönetimi üzerine bir sisteme yatırım yapması ile başladı. Sinyalizasyonların optimizasyonu ve trafik akışının izlenilmesi konularına ağırlık verilmiştir. 1980'lere gelindiğinde ise RACS (Road Traffic Information and Control System) ve AMTICS (Advanced Mobile Traffic Information and Communication System) geliştirilmeye başlandı (Çevik 2022). RACS daha çok trafik yönetimi konularına odaklanırken AMTICS ise daha çok sürücülerin bilgilendirilmesine odaklanmıştı. Aynı şekilde 1970'li yıllarda Kaliforniya otoyollardaki hızlı büyüme ve trafik sorunlarının çözülmesi için çalışmalara başlamıştır. Kaliforniya Ulaştırma Bakanlığı (CALTRANS) yaptığı çalışmalar ile trafikte meydana gelen sorunların üzerine yoğunlaşmışlardı (Cirit 2014).

AUS mimarisi üzerine çalışmalara 1990 yılında başlanılmış ve ABD tarafından 1996 yılında önemli adımlar atılmıştır. ISTEA (Federal Ulaşım Yasası) ulaşım yeni teknolojilerin entegrasyonu için bir dizi düzenleme getirmiştir (Çevik 2022). Bu yasa ile Akıllı Ulaşım Sistemleri tanımlanmış ve geliştirilmesi desteklenmiştir. Amaç, trafik yoğunluğunu azaltmak, seyahat bilgisi sağlamak ve güvenliği artırmak gibi konuları içermektedir. Üzerinde çalışılan Akıllı Ulaşım Sistemleri (AUS), özellikle acil durumlarda daha hızlı ve etkili yanıtlar için trafik kameraları ve sensörler gibi güvenlik sistemleri kullanılarak geliştirilmiştir. Her ne kadar Japonya, 1960'lı yıllarda bazı teknikler üzerinde çalışmış olsa da, AUS olarak resmi olarak 1999 yılında kullanılmaya başlandığı söylenebilir (Dilek vd. 2023).

Türkiye'de ise AUS tarihçesine baktığımızda 1985 yılından günümüze kadar uzanmaktadır. 1985-1995 yıllarında otomatik ücretlendirme sistemleri ile ülke gündemine girmiştir. 1995-2005 yıllarında elektronik ödeme sistemleri, trafik kontrol merkezleri gibi akıllı sistemler kullanılmaya başlanılmıştır. 2015-2020 yıllarında AUS pik noktalara ulaşmış ve Ulusal AUS Strateji Belgesi ve 2020-2023 Eylem Planı'nın yürürlüğe girmesi ile büyük ilerleme sağlanmıştır (Çevik 2022).

Yolculuk bilgi sistemi

Seyahat bilgisi sağlama

Bu sistem, yolcuların seyahatleri sırasında ihtiyaç duydukları kritik bilgileri sunar. Güzergâh detayları, tahmini seyahat süresi, olası gecikmeler ve yolculuk sırasında meydana gelen aksaklıklar gibi önemli bilgileri sağlar. Bu sayede yolcular, seyahatlerini daha etkili bir şekilde planlayabilir, gerçek zamanlı güncellemelerle varış saatlerini tahmin edebilir ve yol

kapanışları ya da aksaklıklar hakkında bilgi sahibi olarak alternatif güzergâhlar seçebilir (Tufan 2014).

Yolcu rehberliği

Seyahat sırasında yolculara en uygun vasıtaları ve durakları sunan bu sistem, yolculuk seçenekleri hakkında bilgi vererek durakların konumlarını gösterir ve güzergâhtaki olası aksaklıklar konusunda uyarılarda bulunur. Böylece yolcular, seyahatleri esnasında daha bilinçli ve konforlu bir deneyim yaşar (Dilek vd 2023).

Trafik durumu ve tahmini varış süreleri

Bu sistem, trafik sıkışıklığı ve diğer olumsuz koşulları dikkate alarak seyahat süresini tahmin etmeye çalışır. Trafik verilerini gerçek zamanlı olarak analiz ederek, mevcut trafik yoğunluğunu ve potansiyel gecikmeleri değerlendirir (Tufan 2014). Bu değerlendirmeler sonucunda, yolculara daha doğru tahminler sunarak varış sürelerini belirlemelerine yardımcı olur. Ayrıca, trafik akışındaki değişiklikler veya beklenmedik aksaklıklar hakkında bilgi vererek, yolcuların daha iyi planlama yapabilmelerini ve alternatif güzergâhlar seçebilmelerini sağlar. Bu özellik, seyahatlerin daha öngörülebilir ve verimli hale gelmesine katkıda bulunur (Çevik 2022).

Bilet satışı ve ödeme hizmetleri

Yolcuların çevrim içi veya fiziksel olarak bilet almalarını ve ödeme yapmalarını sağlayan hizmetlerdir (Dilek vd 2023).

Trafik yönetimi

Trafik yoğunluğu ve akışının takibi

AUS için en önemli konulardan birisidir. Trafik yoğunlukları takip edilerek çözümlerin oluşturulması açısından büyük öneme sahiptir. Bunun için sensörler ve kameralar vasıtası ile takip sağlanır ve trafik akışı hakkında bilgiler elde edilir. Bunun sonucu olarak da elde edilen veriler ile çözüm yollarına gidilir (Korkmaz 2022).

Trafik sinyalizasyonu ve kontrolü

Trafik sinyalizasyon sistemleri, trafik akışını optimize etmek ve tıkanıklıkları azaltmak için trafik ışıkları ve sinyalizasyon ekipmanlarını dinamik bir şekilde yönetir. Bu sistemler, trafik yoğunluğu, zaman dilimleri ve acil durumlar gibi faktörlere göre trafik ışıklarının sürelerini ve sıralarını ayarlar (Tufan 2014). Bu düzenlemeler, araçların bekleme sürelerini minimize eder ve trafik akışını daha düzenli hale getirir. Ayrıca, trafik sinyalizasyon sistemleri,

sensörler ve kameralar kullanarak gerçek zamanlı trafik verilerini toplar ve analiz eder. Bu veriler, trafik akışında meydana gelen anormalliklere hızlı bir şekilde müdahale edilmesini sağlar. Sonuç olarak, bu sistemler şehir içi trafiğin daha verimli yönetilmesine katkıda bulunur ve trafik kazalarının önlenmesine yardımcı olur (Dilek vd 2023).

Alternatif rotalar

Sürücülere alternatif rotalar sunarak sıkışık olan rotadan sürücülerin uzaklaşmasını sağlar (Dilek vd 2023).

Sürücü destek sistemleri

Navigasyon sistemleri

Navigasyon sistemleri, hedef konum için en uygun güzergahı belirleyerek sürücülerin istenilen noktaya en hızlı ve verimli şekilde ulaşmalarını sağlar. Bu sistemler, güzergâh üzerindeki trafik yoğunluğunu, yol koşullarını ve olası aksaklıkları analiz ederek sürücüye en iyi rotayı sunar (Tufan 2014). Ayrıca, gerçek zamanlı trafik verileri ve yol durumu bilgileri sağlayarak sürücülerin varış sürelerini tahmin etmelerine yardımcı olur. Sistem, alternatif güzergahlar önererek trafik sıkışıklığı gibi olumsuz durumlara karşı çözümler sunar, bu sayede sürücüler hem zaman hem de yakıt tasarrufu sağlayabilir. Bu özellikler, navigasyon sistemlerinin kullanıcıların seyahat deneyimlerini daha rahat ve etkili hale getirmelerini sağlar (Dilek vd 2023).

Güvenlik uyarı sistemleri

Güvenlik uyarı sistemleri, sürücülerin yolda karşılaşılabilecekleri tehlikeler hakkında bilgilendirme yaparak daha güvenli bir sürüş deneyimi sağlar. Bu teknolojiler, sürücünün dikkatini çekmek ve sürüş güvenliğini artırmak amacıyla çeşitli uyarılar sunar. Şerit değiştirme uyarı sistemleri, sürücünün şerit değiştirdiği sırada karşı şeride geçiş yapma riskini algılar ve bu konuda uyarılarda bulunarak çarpışma olasılığını azaltır (Tufan 2014).

Trafik levhaları tanıma sistemleri

Trafik levhaları tanıma sistemleri, sürücülerin yolda karşılaştıkları trafik levhalarını tespit ederek onlara önemli bilgiler sunan teknolojilerdir. Bu sistemler, trafik işaretlerinin ve levhalarının üzerinde bulunan hız limitleri, yönlendirme bilgileri, yasaklar ve uyarılar gibi bilgileri doğru bir şekilde tanımlayarak sürücülere aktarır. Sürücüler, bu bilgileri kullanarak hızlarını ve sürüş davranışlarını trafik düzenlemelerine uygun olarak ayarlayabilirler. Ayrıca, sistemler, olası yol engelleri, tehlikeli virajlar veya yol bakım çalışmaları gibi durumlar

hakkında da uyarılarda bulunarak sürücülerin güvenliğini artırır. Bu özellikler, sürücülerin yolda karşılaşılabilecekleri çeşitli durumlara daha hazırlıklı olmalarını sağlar ve trafik kurallarına uyumu destekler, böylece yolculukların daha güvenli ve düzenli hale gelmesine katkıda bulunur.

Kör nokta uyarı sistemleri

Kör nokta uyarı sistemleri, sürücülere araç aynalarında veya doğrudan görme alanında göremedikleri tehlike unsurları hakkında bilgi veren teknolojilerdir. Bu sistemler, araç çevresindeki kör noktaları izleyerek, özellikle yan veya arka bölgelerde bulunan diğer araçları ve potansiyel tehlikeleri tespit eder. Kör nokta sensörleri, radar veya kamera gibi algılayıcılar kullanarak, bu bölgelerdeki araçların veya engellerin varlığını sürücüye bildirir. Sistemdeki görsel veya sesli uyarılar sayesinde, sürücüler kör noktalarda bulunan tehlikeleri fark edebilir ve buna göre manevra yapabilirler. Bu teknoloji, sürücülerin daha güvenli bir şekilde şerit değiştirip, park etmesine ve trafik akışını daha dikkatli yönetmelerine yardımcı olur, böylece kaza riskini azaltır ve yol güvenliğini artırır (Tufan 2014).

Yük taşımacılığı

Yük takip ve yönetim sistemleri

Yük takip ve yönetim sistemleri, taşınan yüklerin etkili bir şekilde izlenmesini ve yönetilmesini sağlayan gelişmiş teknolojilerdir. Bu sistemler, yüklerin gerçek zamanlı konum bilgilerini sunarak teslimat sürelerinin tahmin edilmesine yardımcı olur. Ayrıca, yüklerin hareketlerini ve yerleşim durumlarını detaylı bir şekilde izleyerek, lojistik süreçlerin optimize edilmesini destekler (Tufan 2014). GPS ve çeşitli sensör teknolojileri kullanarak, yüklerin taşıma sürecindeki her aşamasını ayrıntılı olarak raporlar. Bu sayede, lojistik yöneticileri ve taşıma şirketleri, yüklerin mevcut durumunu anlık olarak görebilir, olası gecikmeleri önceden belirleyebilir ve operasyonel verimliliği artırabilir. Ek olarak, bu sistemler yüklerin güvenliğini ve zamanında teslimatını sağlamak için gerekli önlemleri alır, böylece müşteri memnuniyetini artırır (Dilek vd 2023).

Rota yazılımları

En uygun rotaları belirler ve trafik durumuna göre sürücüyü uyararak lojistik süresini düzenlemeye yardımcı olur.

Güvenlik sistemleri

Özellikle hırsızlık, hasar, kayıp gibi durumların yönetilmesi için acil planlar oluşturmayı sağlar (Tufan 2014).

Ulusal güvenlik

Sınır güvenliği ve gözetimi

Sınırlardan gelebilecek tehlikeler konusunda uyarıcı sistemlerdir. Olası bir saldırı ya da sızma konusunda takip ve gözetleme faaliyeti yapan sistemlerdir (Dilek vd 2023).

Şüpheli kişi ya da araçların tespiti

Şüpheli kişi ve araçların tespiti, genellikle kamera teknolojileri kullanılarak yapılan bir güvenlik uygulamasıdır. Bu sistemler, potansiyel tehlike oluşturabilecek kişileri veya trafiği riske atabilecek araçları izleyip tanımlamak amacıyla tasarlanmıştır. Gelişmiş görüntü işleme ve analiz yöntemleriyle donatılmış kameralar, şüpheli davranışları veya tehlikeli hareketleri algılamak için kullanılır (Dilek vd 2023). Bu sistemler, gerçek zamanlı olarak izleme yaparak, gerekli güvenlik birimlerine veya trafik yönetim merkezlerine bilgi iletir. Böylece, güvenlik tehditleri ve trafik ile ilgili sorunlar hızla tespit edilip gerekli müdahaleler yapılabilir. Ayrıca, bu sistemler suç öncesi ve sonrası analizlerde etkinlik sağlar ve güvenlik operasyonlarının etkinliğini artırır. Şüpheli kişi ve araçların tespiti, genel güvenlik seviyesinin artırılmasına ve trafik düzeninin sağlanmasına önemli katkıda bulunur (Tufan 2014).

Yapay Sinir Ağları (YSA)


Teknolojik gelişmeler insanın çevresi ve kendisini incelemesi ile gerçekleşmiştir. Uçakların uçuş mekanizmasından helikopter teknolojilerine kadar yapılan icatlar doğadan ilham alınarak gerçekleşmiştir. Yapay sinir ağları(YSA) da insanın nöron sistemi incelenilerek ortaya çıkmıştır (Öztemel 2006).

Bir işlemi insan sinirleri milisaniyede cevaplarken, bilgisayarlarda bu süre nanosaniyeye kadar düşmüştür. Buna rağmen insan beyni daha verimlidir. Bunun sebebi incelendiğinde insan beyninin bilgileri paralel işlediği tespit edilmiştir. Sonuç olarak bu sonuçlar ışığında YSA geliştirilmeye başlanılmıştır. YSA biyolojik sinir ağlarının bir taklididir (Taghi 2022).

İnsanın sinir sistemi sinirlerden meydana gelmektedir. $10^{10} - 10^{11}$ adet olan bu sinirler tüm vücuda dağılmış durumda ve birbirleri ile etkileşim halindedir. Örnek vermek gerekirse

hayati organların sinirlerinin kulak ve ayak tabanındaki sinir uçlarından uyarılabilir olması bu sinir yapısının bütün vücuda nasıl yayıldığıнын en şaşırtıcı örneğidir (Şen 2004).

Biyolojik sistemde öğrenme nöronlar arasındaki sinaptic bağlantı ile gerçekleşir. İnsan hayatı boyunca bir öğrenme sürecinin içerisindeydir. Öğrenilen bilgiler başka bilgilerin de öğrenilmesinde referanslık yapmasının yanında çağrışım da yapar ve bu şekilde nöronların aktifliğini de sağlar. Bunu bir evin lambaları gibi düşünebiliriz. Nasıl ki kullanılmayan odaların lambalarını söndürüyorsak beyin de aynı şekilde ihtiyacı olmadığı, kullanmadığı nöronları inaktif eder. Yani insan beynindeki nöronların fazla olması hepsinin aktif kullanıldığı anlamına gelmemektedir. Bu yüzden öğrenme süreci başladığında nöronlar aktif hale gelir ve bu nöronlar aynı zamanda birbirleri ile etkileşim haline gelir. Yani snapslar arası yeni bağlar kurulur. Beyin ne kadar zorlanırsa snapslar arasında bağ o kadar artar ve aktif nöron sayısında artış meydana gelir (Şen 2004).



Şekil 1. Nöron yapısı (Koptur 2017)

YSA da aynı şekilde nörolardan meydana gelir. Her bir bilgi alınıp işlenir ve sonucunda bir sayısal veriye dönüştürülür. İşlem birimleri yani insanda karşılığı olan nörona karşılık gelen birimler arasında bir bağ oluşur. İşte bunlar da yapay sinir ağlarını oluşturur (Öztemel 2006).

Yapay sinir ağları tarihçesi

İlk çalışmalar 1943 yılında McCulloch ve Pitts'in çalışmalarıdır. Bu çalışmada biyolojik sinir ağlarının modeli ele alınarak sinir hücrelerinin çalışma mekanizmasını matematiksel bir modele dönüştürmeye çalışmışlardır. Bunun sonucunda temel algoritmalar ve prensipleri tanımladılar (Övün 2022).

1949 yılına gelindiğinde Hebb YSA'nın ilk kuralını ortaya koydu. Hebbian Learning sinir ağlarının bağlantılarının bir sinir hücresinin diğer bir sinir hücresini ateşlemesi ile iki hücre

arasındaki bağlantının güçleneceğini öne sürdü (Korkmaz 2022). Bu prensip Neuronsthat Fire Together,Wire Together olarak özetlenebilir (Şen 2004).

1958 yılında Rosenblatt “The Perception: A. Probabilistic Model For Information Storage and Organization in The Brain.” adlı makaleyi yayınladı. Bu makalede bir tür yapay sinir ağı olan “perception”ı ortaya koydu. Basit bir sinir ağı olan Perception girişlerden çıkışları hesaplıyordu. Perception sinir hücrelerinin davranışlarını taklit ediyordu. Perception doğrusal çok boyutlu düzlem ile ayrılan sorunları çözebilirken, eğrisel sorunlara çözüm sunamıyordu (Öztemel 2006).

1960 yılında Windrow ve Hoff “Adapline Linear Combineri” geliştirdi. ALC adaptif sinyal işlemi için oluşturulmuş bir algoritmaydı. Vektörleri, bir örüntüyü tanımlamak ve tahmin etmek için kullanıldı (Şen 2004).

ALC’nin temel amacı, bir giriş verisini beklenen çıktısını oluşturmak için uygun ağırlık vektörünü öğrenmektir. Çıktı ile gerçek çıktıyı karşılaştırıp hatayı ve hatanın oranını belirleyip minimize etmek için ağırlık vektörünü günceller.

ALC birçok algoritmanın ilham kaynağı olmuştur.

1982 yılında Hopfield “Neural Networks and Physical Systems with Emergent Collective Computational Abilities” Makalesini yayınladı. Hobfield bu makalesinde sinir ağlarının davranış ve özelliklerini inceledi. Bu makale ile bir tür yapay sinir ağı olan eğrisel ağların temeli atılmış oldu (Öztemel 2006).

1983 yılında Anderson tarafından yapılan çalışmada “The Architecture of Cognition” kitabı ortaya çıktı. Anderson bu çalışmada insan zihninin karmaşık yapısını eğitimsiz öğrenen sistemlerin nasıl kullanıldığını araştırdı (Şen 2004).


Giriş verileriyle belirli görüntü veya yapıları tanımlamak ve öğrenmek için bir sistem tasarladı. Bu çalışma eğitimsiz öğrenme sistemleri için bir kılavuz oldu.

1986 yılında Rumelhart ve arkadaşları “Parallel Distributed Processing: Explorations in The Microstructure of Cognition” adlı kitabı yayınladı. Rumelhart ve arkadaşları insan zihninin işleyişini modellemek için yapay sinir ağlarının nasıl kullanılabileceğini inceledi. Bu şekilde yapay sinir ağlarının tasarımı ve uygulanabileceği konusunda bir klavuz oldu (Övün 2022).

Yapay sinir ağları temel kavramları

Yapay sinir ağı (ArtificialNeural Network- ANN)

Birçok yapay sinir hücresinin bir araya gelmesiyle oluşan matematiksel modeldir. Buradaki yapay sinir hücreleri bilgileri işleme ve iletme gibi görevleri yerine getirmektedirler.



Şekil 2. Derin sinir ağlarının bir örneği (Öztürk 2022)

a) Girdi Katmanı

Evrişimli sinir ağları'nın başlangıç noktasıdır ve veri girişinin olduğu kısımdır. Girdi katmanının önemi görüntünün yüksek kalitede olması küçük özelliklerinin daha iyi öğrenilmesini sağlarken daha fazla bellek kullanımına neden olur ve modele yük binmesine sebep olur (Yiğit vd 2023).

b) Evrişim Katmanı

Bu katmanda giriş görüntüsünden özellikler çıkarılır. Filtre, görüntü üzerinden bölgesel özellikleri kaydeder ve özellik haritası oluşturur. Birden çok katmandan oluşur ve bu şekilde de görüntünün özellikleri daha iyi bir şekilde öğrenilir (Karaoğlu 2022).


c) Havuz Katmanı (PoolingLayer)

Hesap yükünü azaltmak için özellik haritalarının çözünürlüğü azaltılır. Görüntü detayları kaybedilse de modelin hesap yükü bu şekilde azaltılır. Burada amaç görüntünün önemli özelliklerinin çıkarımıdır (Övün 2022).

d) Aktivasyon Katmanı (ActivationLayer)

Giriş verilerindeki doğrusal olmayan özellikleri öğrenmek için bir dizi fonksiyondan ibarettir. Bu fonksiyonlar sayesinde görüntünün karmaşık ilişkileri öğrenilir (Seçkin 2021).

- a) Sigmoid Fonksiyonu: Çıktıları 0 ile 1 arasında değerlendirir. Giriş değeri arttıkça 1'e azaldıkça 0'a yaklaşır.
- b) ReLu Fonksiyonu: Giriş değeri pozitif olanları olduğu gibi tutarken negatif giriş değerlerini sıfırlar (Taghi 2022).



Şekil 3. Yapay sinir ağı örneği (Yılmaz vd 2020)

e) Tam Bağlantılı Katmanlar (FullyConnectedLayer)

Önceki katmanlardan gelen özellikler değerlendirilir ve nihai çıktı tahmini yapar. Her bir nöron, önceki katmandaki tüm nöronlardaki sinyalleri alır ve matematiksel bir kombinasyon yapar (Karaoğlu 2022).

f) Çıkış Katmanı (OutputLayer)

Nihai tahminin yapıldığı katmandır. Burada önceki katmanlardan gelen bilgilerden sonuç üretilir (Öztemel 2006).

Makine öğrenmesi

Bilgiler ve kayıtlar insanlık tarihinin erken evrelerinde kemiklere, bir zaman sonra parşömenlere yazılmaya başlanmıştır. Bu bilgi ve kayıtlar bir süre sonra kağıdın icadı ile daha uzun süre korunabilir bir hale gelse de olduğu coğrafyalardan çıkışı gerçekleşmiyordu ve bu metinlere sadece belirli kişiler ulaşabiliyorlardı.

Matbaanın icadı ile birlikte bu bilgiler daha fazla insana ulaşabilir hale gelmiş olsa da yine de yeteri kadar ulaşılabilir olmamıştı. Teknolojik gelişmeler ile birlikte özellikle internetin günümüze girmesi ile birlikte artık bilgiler internetin içerisinde daha kolay bulunabilir bir hale gelmişti. Bu her ne kadar olumlu olsa da yanında getirdiği bilgi çokluğu ve bilgi kirliliği yüzünden doğru bilgiye erişim de bir o kadar zorlu bir sürece girmişti. Eğitilmiş makineler bu bilgileri tarayarak bize rasyonel çıkarımlar yaparak en doğru veriyi bize ulaştırmakta en büyük yardımcı olmuşlardır. Bir makinenin düzgün eğitilmesi için ise verilerin bir algoritma içerisinde düzgün bir şekilde sınıflandırarak gerçekleştirilebilir. Eğitilmiş makine algoritma hiyerarşisi Şekil 3’de gösterilmiştir (Tosunoğlu vd 2021).

Makine öğrenmesini denetimli öğrenme, denetimsiz öğrenme ve pekiştirmeli öğrenme olarak üç başlıkta inceleyebiliriz. (Altun vd 2023)

Denetimli Öğrenme (Supervised Learning)

Denetimli öğrenme (Supervised Learning), makine öğrenmesi alanında, bir modelin giriş verileri ile bu verilere karşılık gelen doğru etiketler arasındaki bağlantıları öğrenmesini sağlayan bir tekniktir (Karaoğlu 2022). Bu yöntemde model, belirli bir veri seti üzerinde eğitilerek, giriş verilerinin hangi çıkışları ürettiğini öğrenir. Örneğin, bir yüz tanıma sisteminde, modele birçok farklı yüz görüntüsü ve bu görüntülerin kime ait olduğu bilgisi sunulur; model, bu bilgilerle eğitildikten sonra, yeni yüzleri tanımlama yeteneği kazanır (Altun vd 2023).

Denetimli öğrenme, iki ana alt kategoriye ayrılır: sınıflandırma ve regresyon. Sınıflandırma, verileri belirli kategorilere ayırmayı amaçlarken, regresyon ise verilerle ilişkili sürekli bir değer tahmin eder. Model, bu iki yöntemi kullanarak tekrar eden eğitim süreçlerinden geçer ve böylece yeni veriler üzerinde doğru tahminlerde bulunma kapasitesini geliştirir(Altun vd 2023).

Sınıflandırma (Classification)

Modelin giriş verisini bir kategori ya da sınıflandırma ataması amaçlanır.

Regresyon (Regression)

Modele verilen girdinin çıkış değerinin tahmini yapılır.

Görüntü tanıma, doğal dil işleme, tıbbi teşhis gibi konularda denetimli öğrenme kullanılmaktadır (Altun vd 2023).

Denetimsiz öğrenme

Denetimsiz öğrenme, makine öğrenmesinde verilerin etiketlenmediği durumlarda kullanılan bir yaklaşımdır. Bu yöntemde, modelin verilerdeki gizli yapıları ve örüntüleri kendi kendine keşfetmesi beklenir. Modele herhangi bir doğru cevap veya sınıflandırma bilgisi verilmez; bunun yerine, model veriler arasındaki ilişkileri ve benzerlikleri analiz ederek anlamlı sonuçlar çıkarmaya çalışır. Özellikle büyük ve karmaşık veri setlerinde, bu yaklaşım veriler arasında doğal bağlantılar ve gruplar oluşturmayı sağlar (Karaoğlu 2022).

Denetimsiz öğrenme, genellikle iki ana yöntemle uygulanır: kümeleme ve boyut indirgeme. Kümeleme, benzer özelliklere sahip verileri aynı gruplar altında toplarken, boyut indirgeme, yüksek boyutlu verilerin daha sade bir şekilde temsil edilmesine olanak tanır. Bu

yöntemler, verilerin içsel yapısını ortaya çıkarmada ve daha derinlemesine bir analiz yapmada önemli rol oynar (Karakuş 2023).

Kümeleme (Clustering)

Kümeleme, etiketlenmemiş verileri gruplandırarak, veri setindeki doğal yapıları keşfetmeye çalışan bir makine öğrenimi tekniğidir. Denetimsiz öğrenme yöntemleri arasında yer alır ve veri kümesi içindeki benzerliklere dayanarak örnekleri anlamlı alt gruplara ayırmayı hedefler (Daş vd 2019).

Örneğin, trafik levhalarının etiketlenmediği bir senaryoda, bir makine öğrenme modeli, bu levhaların özelliklerini analiz ederek benzer olanları aynı gruba toplar. Bu süreçte, model her bir trafik levhasının hangi gruba ait olduğunu öğrenir ve bu gruplar, levhaların sahip olduğu ortak özelliklere dayanır. Sonuç olarak, model, etiket olmadan bile farklı trafik levhası türlerini ayırt edebilir ve bu gruplama işlemi, levhaların daha iyi anlaşılmasını sağlar (Tosunoğlu vd 2018).

Özellikle sürücülere yönelik uyarı ve yardım sistemlerinde, kümeleme algoritmaları, farklı trafik işaretlerinin birbirine olan benzerliklerini otomatik olarak tespit etmek için kullanılabilir. Bu şekilde, levhaların doğru bir şekilde tanımlanması ve sürücülere doğru uyarıların yapılması sağlanabilir. Bu tür bir sistem, sürücülerin trafik işaretlerini daha iyi algılamalarına yardımcı olabilir ve trafik kazalarının önlenmesine katkıda bulunabilir (Karakuş 2023).

Boyutsal küçültme (Dimensionality reduction)

Veri setindeki karmaşıklığın basite indirgenmesi ve modelin daha iyi çalışmasını ön görür. Örnek vermek gerekirse bir trafik levhasının tanınması üzerine bir çalışma yaptığımızda levhanın yuvarlak mı yoksa üçgen mi olduğunun incelenmesi değil önemli olan levhanın tanzim mi yoksa tehlike uyarı işareti mi olduğunun tespiti için şekil özelliklerine bakılmaksızın sadece içeriğine bakılıyorsa bu boyutsal küçültmeye girer. Yani önemli olan konuların işleme alınması ve diğer detayların makine tarafından yok sayılması durumudur(Altun vd 2023).

-Özellik seçimi: Özellikler arasından en önemli olanlar seçilir ve geri kalan detaylar önemsizdir.

-Özellik çıkarma: Burada veri setinin boyutu azaltılırken verinin önemli noktaları ön plana çıkarılır.

Burada şu tekniklerden bahsedebiliriz;

PCA(Principal Component Analysis): Verilerden özellik çıkarımı yaparak benzerlikler ve farklar üzerine yoğunlaşır. Bu yüzden veri analizinde oldukça büyük bir önem sahiptir. Çünkü veri kaybı olmadan sıkıştırılmasına olanak sağlar (Smith L.,2002).

t-SNE(t-distributed Stochastic Neighbor Embedding): Burada veri setindeki bilgiler düşük boyutlu bir düzleme aktarılır ve bunları düşük düzlemde bir noktada benzer özelliklere göre toplanılır. Benzer özelliği olmayanlar oradan uzaklaştırılır. Örneğin trafik levhaları ile ilgili bir veri setimiz varsa bunlar düşük düzleme aktarılır ve hız sınır levhaları bir noktada temsil edilirken diğer veriler oradan uzaklaştırılır şeklinde düşünebiliriz (Müller and Guido 2016).

Pekiştirmeli öğrenme

Burada ajan bir görevi başarmak için etkileşim halinde olur ve etkileşim sonucunda değişen durumlardan geri bildirim alır (Karaoğlu 2022). Bu geri bildirimleri değerlendirerek en uygun eylemi öğrenir. Üç temel bileşeni vardır;

- a) Ajan(Agent)Karar veren yapay zeka unsuru
- b) Çevre(Environment): Ajanın etkileşimde olduğu ve ajanın pozisyonuna göre kendini değiştirip geri bildirimde bulunan dış dünya.
- c) Ödül(Reward): Ajanın çevreden aldığı ödül.

Sürücü destek sistemleri otonom sürüş için oldukça önemli bir öğrenme şeklidir. Ajan olarak izah ettiğimiz yapay zeka dış dünya ile etkileşim halinde olduğundan dolayı algoritmaları kullanarak sürüş için kendisine bir davranış şekli belirler ve bu davranış şeklini dış dünyaya göre şekillendirmeye devam eder. Bu şekilde en güvenli sürüşü dış dünyadan aldığı geri bildirimler ile revize etme imkanına sahip olur. Dış dünya ile etkileşiminde olacağı için aslında insan ile aynı deneyim sürecinden geçtiğini söyleyebiliriz (Altun vd 2023)

Derin Öğrenme

Derin öğrenme, makine öğrenmesinin bir alt dalı olarak kabul edilir ve karmaşık görevlerin çözümünde kullanılan gelişmiş bir yöntemler kümesini ifade eder. Derin öğrenme modelleri, genellikle yapay sinir ağları kullanarak verilerden öğrenir. Bu modeller, verilerin çeşitli katmanlarda işlenmesi yoluyla yüksek seviyede soyutlama ve özellik çıkarımı yapar (Yiğit vd 2023).

Bu süreçte, derin öğrenme algoritmaları verilerle eğitilir ve bu eğitim süreci sırasında elde ettikleri bilgileri kullanarak çeşitli görevleri yerine getirirler. Örneğin, bir görüntü sınıflandırma modelinde, ağın ilk katmanları temel özellikleri (kenarlar, köşeler) öğrenirken,

daha derin katmanlar daha karmaşık yapıları (nesne türleri) öğrenir. Bu şekilde, derin öğrenme sistemleri büyük veri kümesine dayalı olarak karmaşık desenleri ve ilişkileri tanıma kapasitesine sahip olur (Karaoğlu 2022).

Derin öğrenme yöntemleri, büyük veri setleri ve güçlü hesaplama kaynakları ile optimize edilerek, özellikle görsel tanıma, ses işleme ve dil anlama gibi alanlarda yüksek performans gösterir (Övün, 2022). Bu yaklaşımlar, çeşitli görevlerde üstün sonuçlar elde etmek için geniş veri setleri üzerinden öğrenme yeteneği sağlar.

Convolutional neural networks (CNNs)

Convolutional Neural Networks (CNNs), genellikle görüntü analizi ve bilgisayarla görme görevlerinde kullanılan güçlü bir derin öğrenme yapısıdır. CNN'ler, görüntülerdeki önemli özellikleri belirlemek için özel olarak tasarlanmış evrişimli katmanlar içerir (Somuncu ve Atasoy 2022). Bu katmanlar, görüntü üzerinde küçük alanlarda filtreler (veya çekirdekler) uygulayarak yerel özellikleri algılar. Her filtre, görüntüde kaydırılarak işlem görür ve bu süreç sonucunda çeşitli özellikleri temsil eden "özellik haritaları" (feature maps) oluşturur. Bu yöntem, modelin görüntünün temel öğelerini tanımasını ve analiz etmesini sağlar (Yiğit vd 2023).

CNN'lerdeki evrişimli katmanlardan elde edilen özellikler, doğrusal olmayan aktivasyon fonksiyonları ile işlenir; bunlar arasında **ReLU** (Rectified Linear Unit) en yaygın olanıdır. ReLU, negatif değerleri sıfıra indirerek ve pozitif değerleri değiştirmeyerek, modelin karmaşık ve soyut özellikleri öğrenmesine olanak tanır (Somuncu ve Atasoy 2022). CNN'ler, bu özellik haritalarını daha yüksek seviyeli analizler ve sınıflandırmalar için genellikle havuzlama (pooling) ve tam bağlı (fully connected) katmanlarla birleştirir. Havuzlama katmanları, özellik haritalarının boyutlarını küçültür ve önemli bilgileri özetleyerek hesaplama yükünü hafifletir; tam bağlı katmanlar ise, bu özetlenmiş bilgileri kullanarak nihai sınıflandırma ve tahmin işlemlerini gerçekleştirir (Kızrak ve Bolat 2018).

Evrişimli katmanların görüntü işlemedeki avantajları

a) Özellik Çıkarma Yeteneği

Girdi görüntülerinden belli özellikleri irdelenir. Renk değişimleri, basit ayırt edici özellikler (köşe, kenar vb.) gibi özelliklere göre özellik çıkarımı sağlanarak karmaşık görselleri daha düşük boyutlarda ama anlamlı bir temsile dönüştürür (Seçkin 2021).

b) Hiyerarşik Özellik Öğrenimi

Evrişimli katmanlar sayesinde her bir katmanda daha yüksek seviyeli özelliklere yoğunlaşır. Nasıl ki ilk katmanda basit özelliklere göre sınıflandırma başladıysa ilerleyen katmanlarda daha da detaylara iner ve bu sayede karmaşık görevlerde daha yüksek performans sağlar (Gürbüz ve Yılmaz 2023).

c) Parametre Azaltma

Gerek filtreler ve evrişimli katmanlar sayesinde özellikler öğrenilirken parametreler azaltılır ve bu şekilde daha az veri ile daha etkili öğrenme sağlanır (Seçkin 2021).

d) Davranış İstikrarlılığı

Evrişimli katmanlar, nesnelerin çeşitli varyasyonlarını da tanıyabilme yetenekleri vardır. Buda modelin daha istikrarlı ve doğru sonuçlar vermesine olanak sağlamaktadır (Gürbüz ve Yılmaz 2023).

e) Hız ve Verimlilik

Evrişimli katmanlar, özellik haritaları oluştururken paralel işlemlerde yapabilirler. Grafik işlem girimleri (GPU) gibi donanımları da kullandığından dolayı süreç oldukça hızlanır. Özellikle modelin eğitilmesi ve tahmin süreçlerinin hızlı çalışmasını büyük ölçüde hızlandırmaktadır (Akgün 2020).

Convolutional Neural Networks (CNNs) uygulama alanları

a) Nesne Tanıma

Bir görüntüdeki nesnelerin tespit edilmesi ve sınıflandırmasında kullanılır. Nesne tanıma da ilk olarak görüntülerin iyileştirilmesi için bir takım çalışmalar gerçekleşir ve görüntü daha anlaşılır bir hale getirilir. Bu ön işleme adıdır. Ardından netleşen görüntülerden özellik çıkarımı yapılır. Bundan sonrasında YOLO(youonlylookonce) gibi algoritmalar ile nesne tespiti yapılır. Ardından bu nesneler sınıflandırılır. Sınıflandırılan bu görüntüler kayıp fonksiyonları kullanılarak model eğitilir (Daş vd 2019).

b) Yüz Tanıma

Bir görüntüdeki kişilerin yüzleri sayesinde tanınmasını ve tespit edilmesinde kullanılır. Özellikle güvenlik sistemleri için oldukça önem arz etmektedir.

Yüz tanıma sistemi geliştirilirken bazı sorunlar meydana gelmektedir. Bunlar; zayıflama, sınırlı bant genişliği, gecikme bozulması ve gürültü sorunlarıdır. Özellikle görüntünün etrafında parazit oluşturabilecek öğelerin varlığı modelin görüntüye

odaklanmasında bazı sorunlara neden olabilmektedir. Bu konu da gürültülerin giderilmesi konusunda CNN mimarisine başvurmak mümkündür. Burada kastedilen gürültü, girdi olan görüntüde meydana gelen bozulmalara verilen genel bir addır (Yapıcı ve Akçayol 2022).

c) Hareket Tanıma

Bir görüntüdeki veya videodaki insan hareketlerine odaklanarak hareket tarzını inceler ve belirli hareketleri algılayarak tanımlar. Bu yapılırken model nesne hareketine odaklanır ve arka plandaki gereksiz arka planı çıkarır ve bu şekilde asıl nesnenin hareketlerine odaklanır (Algur vd 2018).

d) Doğal Dil İşleme

İnsan dilini anlamayı ve analiz ederek etkileşim içinde bulunmasını sağlar. Her ne kadar CNN genellikle görüntü işleme de kullanılıyor olsa da dilsel verilerde de gerek metin gerek konuşma analizlerinde de kullanılmaya başlanmıştır. Duygusal ton da dahil olmak üzere konuşmaların ya da metinlerin çözümlemesinde oldukça gelişme göstermiştir (Dolu ve Şen 2024).

e) Tıbbi Görüntüleme

Tıbbi kayıtların analizlerini kapsar. Özellikle tümör araştırmalarında ve kanser hücrelerinin yayılımı incelenmesinde kullanılmaya başlanılmıştır. Özellik çıkarımı yapabiliyor olması sebebi ile gerek tümörlerin gerekse de kanser hücrelerinin incelenmesi ve iyi huylu ya da kötü huylu olup olmadığı hakkında bilgi alınabilmektedir (Şeker vd 2017).

f) Otomatik Sürüş

Otonom araçların çevreyi algılamasını ve analizini yapmasını kapsar. Bunu yaparken sensörler ve algoritmalar kullanır. Buradaki amaç; otonom araçların çevreden aldığı geri bildirimler ışığında güvenli, konforlu ve etkin bir şekilde yol alınmasını sağlamaktır (Tüzün vd 2022).

Rekurrent sinir ağları (Recurrent neural networks-RNNs)

Geri beslemeli yapılı sayesinde önceki adımlarda elde ettiği verileri hatırlayabilir ve sonraki adımlarda kullanan bir yapay sinir ağı modelidir. Her adımda bir önceki durumda elde ettiği veri ile yeni girdiği birleştirilerek yeni bir çıktı üretir. Özellikle zaman serileri ve sıralı verilerde CNN den daha etkilidir. Dinamik ve uzun vadeli bilgileri daha iyi yönetir (Somuncu ve Atasoy 2022).

Derin yapay sinir ağıları (Deep neural networks -DNNs)

Derin yapay sinir ağlarının derinleştirilmiş versiyonlarıdır. Çok fazla katmana ve bu katmanlarda da binlerce nörona sahiptirler. Tabi bu nöron sayısı yapılan işlemlere ve ihtiyaçlara göre değişkenlik göstermektedir. Katmanlar bir önceki katmandan aldığı çıktıyı soyut özellikleri öğrenmek için kullanır ve bu sayede daha karmaşık problemlerin çözümü gerçekleşir (Kızrak ve Bolat 2018).

Derin öğrenme üzerine yapılan çalışmalar

De La Escalera ve ekibi 1997 de trafik işaretlerinin tanınması konusunda yapay zeka ile görüntü işleme tekniklerinin kullanarak yaptıkları çalışma trafik güvenliği alanında öncü niteliğindedir. Yaptıkları çalışma 4 basamaktan oluşmaktadır. Bunların birincisi veri toplama aşamasıdır. Trafik işaretleri farklı açılardan ve farklı ışık koşullarında görüntülenerek veri seti oluşturulmuştur. İkinci basamakta özellik çıkarımı yapılmıştır. İşaretlerin belirgin özellikleri çıkarılmıştır. Renkleri, kenarları ve diğer özellikleri üzerinde durulmuştur. Üçüncü basamakta ise trafik işaretleri sınıflandırılmıştır. Bu adımda yapay zeka teknikleri ve derin öğrenme modelleri tercih edilmiştir. Son adımda da performansın değerlendirmesi gerçekleştirilmiştir (Övün 2022).

2019 yılında Tiryaki MatConvNet araç kutusunu kullanmış ve veri seti olarak GTSRB(German Traffic Sign Recognition Benchmark) seçmiştir. MatConvNet, MATLAB üzerinde bir derin öğrenme kütüphanesidir ve evrişimli sinir ağları için tercih edilen bir araçtır. Mekansal Dönüşüm Ağları kullanarak daha yüksek başarı oranı elde edilmesi amaçlanmıştır. Mekansal Dönüşüm Ağları tekniğinde model veriler üzerinde dönüşümler yapabilir ve bu sayede giriş görüntülerini düzeltebilir veya olumsuzlukları yok ederek daha yüksek başarı elde edilmesini sağlar. (Akt., Övün 2022)

2020 yılında Sichkar ve Kolyubin tarafından yapılan çalışmada YOLO (You Only Look Once) algoritması seçilmiş ve veri seti olarak GTSDDB (German Traffic Sign Detection Benchmark) kullanılmıştı. Bu veri setinin seçilmesinin en önemli nedeni diğer sistemlerle karşılaştırmak ve performansını rahatlıkla kıyaslayamaktır. LeNet, AlexNet, VGGNet, GoogleNet mimarileri kullanılarak karşılaştırmaları yapılmıştır. (Akt, Övün 2022)

Yıldıran (2019) tarafından yapılan çalışmada Türkiye'de toplanan görüntü ve videolar kullanılarak trafik işaretleri veri setinin oluşturulması ve derin öğrenme ve görüntü işleme yöntemleri ile eğitilmiş bir sistem geliştirilerek, sürücü yardım sistemleri ve otonom araçlar için kullanılabilen bir trafik işareti tespit sistemi oluşturulmuştur. Kullanılan veri setleri; BelguimTS, GTSRB ve TRTSD veri setleridir. Eğitim sonucunda BelguimTS %63,33 doğruluk

oranı, GTSDDB veriseti %39,07, TRTSD gündüz veriseti %74,26 değerleri elde edilmiştir. TRTSD veri seti her ne kadar daha çok doğruluk oranına sahip olsa da derin öğrenme için yeterli değildir.

Seçkin (2021) yaptığı çalışmada bir kamera ve mesafe sensörü yardımı ile küçük bir aracın otonom hale getirilip getiremeyeceği ve sürüş başarısının test edilmesi amaçlanmıştır. Derin öğrenme tabanlı bir sinir ağı ile yaklaşık 1400 görüntü üzerinden veri seti oluşturulmuş ve eğitim verisi ile fiziksel ortamda güvenilir tahmin yeteneğine sahip bir model oluşturulmaya çalışılmıştır. Kullanılan veri seti; 0'dan 9'a kadar olan sayılardan meydana gelen MNIST veri setidir. Bu set kullanılarak bir evrişimli sinir ağı modeli oluşturulmuştur. Sonuçlar incelendiğinde yeterli iterasyon sonucunda kayıp değerinin 0,0807'ye kadar düştüğü ve sinir ağının %97,51'lik bir doğruluk oranı verdiği tespit edilmiştir.

Masache Narvaez (2019) çalışmasında; trafik işareti tespiti için daha yüksek doğruluk ve hız elde etmek için R-FCN, Faster R-CNN, YOLO ve SSD algoritması ve varyasyonlarından esinlenerek özellikle bir trafik işareti tespit algoritması geliştirmektedir. Bu algoritmaların içerisinde en hızlı, ekonomik ve doğru olan algoritmasının tespiti ve eğitilmesi amaçlanmıştır.

Yapılan değerlendirme sonucunda; SSD'nin en uygun algoritma olduğu ön çalışmada belirlendikten sonra SSD üzerinde çalışmalar başlamış;

SSD ve türevlerinde orijinal olarak ağın temelinde VGG-16 kullanıldığından, temel ağ olarak MobileNet V1 kullanıldı. MobileNet mimarisi, ImageNet veri setinde eğitilmiş VGG-16 ile benzer doğruluk (70.6% vs 71.5%) sağlamasına rağmen, daha az hesaplama içerdiği için MobileNet V1 kullanılmıştır.

Bu tez için kullanılan veri kümesi, CSUST Çin trafik işareti algılama benchmark (CCTSDDB)'dir. Veri kümesi, 10000 görüntü ve üç kategori (veya sınıf) içermektedir: zorunlu trafik işaretleri, yasaklayıcı trafik işaretleri ve uyarı trafik işaretleri. Her görüntü, hedef nesnenin sınıf ID'si ve yerleşim kutusunun koordinatlarını içeren bir açıklama dosyasına sahiptir. Bir örnek görüntüde bir veya daha fazla trafik işareti olabilir. Değerlendirme amaçları için, veri kümesi eğitim seti için %80 ve test seti için %20 olarak bölünmüştür.

Bu tez için kullanılan veri kümesi olan CSUST Çin trafik işareti algılama benchmark (CCTSDDB) hakkında genel bilgi;

CSUST Çin trafik işareti algılama benchmark (CCTSDDB), Çin'de Changsha Üniversitesi Bilgisayar Bilimi ve Teknolojisi Bölümü tarafından hazırlanmış bir trafik işareti algılama veri kümesidir. Veri kümesi, gerçek trafik ortamında çekilen görüntülerden oluşur ve Çin trafik işaretleri ile ilgilidir. Toplamda 3.980 trafik işareti görüntüsü içerir ve bu görüntülerin

çoğu güneşli ve yağmurlu hava koşullarında çekilmiştir. CCTSDB, trafik işareti algılama algoritmalarının performansını değerlendirmek ve karşılaştırmak için kullanılan bir standart veri kümesidir.

Bu tezde, bir nesne algılayıcı inşa ederken, temel ağın seçimi ile ilgili sorunlar ele alınmıştır. Daha derin evrimsel sinir ağı mimarileri yüksek doğruluk sağlasa da hesaplama maliyetleri yüksek olduğu için gerçek dünya senaryolarında kullanımı zorlaşmaktadır. Bu nedenle, MobileNet gibi daha hafif mimariler tercih edilmiştir.

MobileNet, geleneksel evrimsel katmanı iki bölüme ayıran derinlik ayrıştırılabilir evrimsel katmanları kullanır. Bu katmanlar, geleneksel evrimsel katmanlara göre daha az hesaplama maliyetine sahip olup aynı zamanda yüksek doğruluk sağlar. Bu nedenle, MobileNet, özellikle gerçek zamanlı uygulamalar için uygun bir temel ağ olarak kullanılabilir.

Bu tez, trafik işaretlerinin tespiti için kullanılan bir nesne tespit algoritmasının MobileNet ağ mimarisi ile yeniden tasarlanması konusunda odaklanmıştır.

VGG-16 ağ mimarisi yerine daha hafif bir ağ mimarisi olan MobileNet kullanılarak hesaplama gücü ve algılama hızı dengesi sağlanmıştır. Ayrıca, trafik işaretlerinin düzenli şekillerde ve tanımlı renklerde geldiği gerçeği de göz önüne alınarak, özellik haritaları sayısı orijinal SSD algoritmasındaki altıdan ikiye indirilmiştir.

Deneyler, özellik haritalarının görselleştirilmesinin en iyi özellik haritası adaylarını belirlemede ve evrimsel katmanların nasıl çalıştığı konusunda faydalı bir araç olduğunu kanıtlamıştır. Sonuçlar, residual blokların sık katmanlarda bağlamsal bilgiyi artırmak için iyi bir teknik olduğunu göstermiştir, ancak ağın boyutunu, karmaşıklığını ve algılama süresini artırdığı için hesaba katılmalıdır.

Bu tezde önerilen süreç, sokak lambası tespiti, çöp kutusu tespiti, hedef nesnelerin belirli bir şekle ve sınırlı renk aralığına sahip olduğu uygulamalar gibi özel uygulamalar için nesne dedektörleri tasarlamak için kullanılabilir. Gelecekteki çalışmalar, LIDAR verilerinin kullanılması ile daha sağlam bir nesne tespit sistemi oluşturmayı hedefleyebilir.

Taghi (2022) Bu çalışmada YOLOv3 ve YOLOv7 modeline dayalı olarak geliştirilen mimari için Alman Trafik İşareti Algılama Kıyaslaması(GTSDB) kullanılmıştır. Modeli eğitmek için Google Colab Notebook ve Darknet çerçevesi kullanılmış. Algılama doğruluğunu artırmak için varsayılan 416x416 giriş boyutu yerine 608x608 giriş boyutu seçilmiş. Görüntüler her biri 64 adetlik gruplar halinde toplanmıştır. Sonuç olarak YOLOv3 %99,46, YOLOv7 %97,3 mAP değeri elde edilmiştir.

MATERYAL VE METOD

Materyal

Karayollarında kullanılan trafik işaret levhaları ve veri setinde kullanılan trafik işaret levhaları

Trafik işaret levhaları sürücülere bilgilendirmek ya da yönlendirmek amacıyla kullanılan işaretlemelerdir. Amaçları ve işlevleri bakımında 5 grupta inceleyebiliriz;

Tehlike uyarı işaretleri

Tehlike uyarı işaretleri, sürücülere yaklaşan potansiyel riskler ve tehlikeler hakkında bilgi vermek amacıyla kullanılan levhalardır. Bu levhalar, yolda karşılaşılabilecek tehlikeleri veya riskli durumları işaretleyerek sürücülerden dikkatli olmalarını bekler. Genellikle canlı renkler ve dikkat çekici semboller kullanılarak tasarlanan bu işaretler, sürücünün dikkatini çekmek ve kritik bilgileri hızlı bir şekilde fark etmelerini sağlamak için optimize edilmiştir (Murat ve Çakıcı 2017).

Tablo 3. Tehlike Uyarı İşaretleri (KGM 2020)

Tehlike Uyarı İşaretleri			
	T-1a Sağa Tehlikeli Viraj		T-22e Ana Yol-Tali Yol Kavşağı
	T-1b Sola Tehlikeli Viraj		T-23a Sağdan Ana Yola Giriş
	T-2a Sağa Tehlikeli Devamlı Viraj		T-23b Soldan Ana Yola Giriş
	T-2b Sola Tehlikeli Devamlı Viraj		T-24 Dönel Kavşak
	T-3a Tehlikeli Eğim(İniş)		T-25 Kontrollü Demiryolu Geçidi
	T-3b Tehlikeli Eğim(Çıkış)		T-26 Kontrolsüz Demiryolu Geçidi
	T-4a İki Taraftan Daralan Kaplama		T-27a Kontrolsüz Demiryolu Geçidi(Tek Hat)
	T-4b Sağdan Daralan Kaplama		T-27b Kontrolsüz Demiryolu Geçidi (En az 2 hat)

Tablo 3. (devamı)

	T-4c Soldan Daralan Kaplama		T-28a Demiryolu Geçidi Yaklaşım Levhaları(Sağ)
	T-5 Açılan Köprü		T-28b Demiryolu Geçidi Yaklaşım Levhaları(Sol)
	T-6 Deniz veya Nehir Kıyısında Biten Yol		T-29a Demiryolu Geçidi Yaklaşım Levhaları(Sağ)
	T-7 Kasisli Yol		T-29b Demiryolu Geçidi Yaklaşım Levhaları(Sol)
	T-8 Kaygan Yol		T-30a Demiryolu Geçidi Yaklaşım Levhaları(Sağ)
	T-9 Gevşek Malzemeli Zemin		T-30b Demiryolu Geçidi Yaklaşım Levhaları(Sol)
	T-10 Gevşek Şev		T-31a Köprü Başı Levhası(Sağ)
	T-11 Yaya Geçidi		T-31b Köprü Başı Levhası(Sol)
	T-12 Okul Geçidi		T-32 Engel İşareti
	T-13 Bisiklet Geçebilir		T-33a Tehlikeli Viraj Yön Levhası
	T-14a Ehli Hayvanlar Geçebilir		T-33b Tehlikeli Viraj Yön Levhası
	T-14b Vahşi Hayvan Geçebilir		T-33c Tehlikeli Viraj Yön Levhası
	T-15 Yolda Çalışma		T-33d Onarım Yaklaşım Levhası(Sağ)
	T-16 Işıklı İşaret Cihazı		T-33e Onarım Yaklaşım Levhası(Sol)
	T-17 Havalimanı(Alçak Uçuş)		T-33f Onarım Yaklaşım Levhası
	T-18 Yandan Rüzgar		T-34a Refüj Başı Ek Levhası(Sağ)

Tablo 3. (devamı)

	T-19 İki Yönlü Trafik		T-34b Refüj Başı Ek Levhası(Sol)
	T-20 Dikkat		T-35 Dönüş Adası Ek Levhası
	T-21 Kontrolsüz Kavşak		T-36 Düşük Banket
	T-22a Ana Yol-Tali Yol Kavşak		T-37 Gizli Buzlanma
	T-22b Ana Yol-Tali Yol Kavşak		T-38 Trafik Sıkışıklığı
	T-22c Ana Yol-Tali Yol Kavşak		T-39 Tramvay Hattı İle Oluşan Kavşak
	T-22d Ana Yol-Tali Yol Kavşağı		

Trafik tanzim işaretleri

Trafik tanzim işaretleri, trafik akışını düzenlemek ve sürücülerin belirlenen kurallara uymasını sağlamak için kullanılan levhalardır. Bu işaretler, yol üzerindeki trafik düzenlemelerini ve yönlendirmeleri belirlemek amacıyla tasarlanmıştır. Genellikle geometrik şekiller ve dikkat çekici renklerle hazırlanan bu işaretler, talimatları açık ve anlaşılır bir biçimde sunmayı amaçlar. Örneğin, dikdörtgen veya kare biçimleri genellikle bilgi verme amacı taşırken, daireler ve üçgenler genellikle uyarı ve yönlendirme işaretleri olarak kullanılır. Renkler de işaretlerin anlamını belirlemede kritik bir rol oynar; yeşil genellikle ilerlemeyi, kırmızı durmayı ve sarı ise dikkatli olmayı ifade eder. Bu levhalar, kavşaklarda, yol kesişimlerinde, park alanlarında ve diğer önemli noktalar üzerinde yer alarak sürücülere gerekli yönlendirmeleri ve talimatları sağlar. Bu sayede, trafik akışının düzenli ve güvenli bir şekilde sürdürülmesine katkıda bulunur (Kurt 2020).

Tablo 4. Trafik Tanzim İşaretleri (KGM 202)

Trafik Tanzim İşaretleri			
	TT-1 Yol Ver		TT-35a Sağa Mecburi Yön
	TT-2 Dur		TT-35b Sola Mecburi Yön
	TT-3 Karşıdan Gelen Yol Ver		TT-35d İleri ve Sağa Mecburi Yön

Tablo 4. (devamı)

	TT-4 Girişi Olmayan Yol		TT-35c İleri Mecburi Yön
	TT-5 Taşıt Trafiğine Kapalı Yol		TT-35e İleri ve Sola Mecburi Yön
	TT-6 Motosiklet Hariç Motorlu Taşıt Trafiğine Kapalı Yol		TT-35f Sağa ve Sola Mecburi Yön
	TT-7 Motosiklet Giremez		TT-35g İleriden Sağa Mecburi Yön
	TT-8 Bisiklet Giremez		TT-35h İleriden Sola Mecburi Yön
	TT-9 Motorlu Bisiklet Giremez		TT-36a Sağdan Gidiniz
	TT-10a Kamyon Giremez		TT-36b Soldan Gidiniz
	TT-10b Otobüs Giremez		TT-36c Her İki Yandan Gidiniz
	TT-11 Treyler Giremez		TT-37 Ada Etrafında Dönünüz
	TT-12 Yaya Giremez		TT-38a Mecburi Bisiklet Yolu
	TT-13 At Arabası Giremez		TT-38b Mecburi Bisiklet Yolu Sonu
	TT-14 El Arabası Giremez		TT-39a Mecburi Yaya Yolu
	TT-15 Traktör Giremez		TT-39b Mecburi Yaya Yolu Sonu
	TT-16b Tehlikeli Madde Taşıyan Taşıt Giremez		TT-40a Mecburi Atlı Yolu
	TT-18 Motorlu Taşıt Giremez		TT-41a Mecburi Asgari Hız
	TT-19 Taşıt Giremez		TT-41b Mecburi Asgari Hız Sonu

Tablo 4. (devamı)

	TT-26a Sağa Dönülmez		TT-42a Zincir Takmak Mecburidir
	TT-26b Sola Dönülmez		TT-42b Zincir Takma Mecburiyeti Sonu
	TT-26C U Dönüşü Yapılmaz		TT-33b Azami Hız Bölgesi Sonu
	TT-27 Öndeki Taşıtı Geçmek Yasaktır		TT-34a Geçme Yasağı Sonu
	TT-29a Azami Hız Sınırlaması		TT-34b Kamyonlar İçin Geçme Yasağı Sonu
	TT-29b Azami Hız Bölgesi		TT-32 Bütük Yasaklama ve Kısıtlama Sonu

Bilgi işaretleri

Sürücülere çevredeki önemli alanlar hakkında bilgi sağlayan işaretlemelerdir. Bu işaretlere örnek olarak; hastaneler, varış noktaları, otel gibi noktaları verebiliriz. Beyaz zemin üzerine siyah yazı ve semboller genellikle tercih edilir (Kurt 2020).

Durma ve park etme işaretleri

Sürücülerin belirli alanlarda park etmeleri yada park etme yasak bölgeleri belirten işaretlerdir (Murat ve Çakıcı 2017).

Yatay işaretlemeler



Yolun üzerine çizilen işaretlerdir. Trafik akışına yön vermek için kullanılırlar. Sürücülerin başka sürücüler için tehlike oluşturacak eylemlerde bulunmasına engel olmak için kullanılır (Kurt 2020).

Veri setindeki trafik işaret levhaları

Türkiye şehirlerarası ve şehir içi trafik videoları ve fotoğraf çekimlerinden elde edilen görüntülerden çoğaltma teknikleri kullanılarak toplamda 30.000 adet görüntü elde edilmiştir.

Çoğaltma tekniği olarak renk dönüşümleri, döndürme ve ayna çevirme teknikleri kullanıldı.

Tablo 5. Veri Setindeki Trafik İşaret Levhaları (Karayolları Standart Trafik İşaret Levhaları T.C. Ulaştırma ve Altyapı Bakanlığı Karayolları Genel Müdürlüğü 2023)

Trafik İşaret Levhası	Etiketleme	Trafik İşaret Levhası	Etiketleme
	B-14a Yaya Geçidi		B-52a İki Yönlü Yol
	B-14b Okul Geçidi		B-53 U Dönüşü
	B-38 Anayol		P-1 Park Etmek Yasaktır
	B-48 Bölünmüş		P-2 Duraklamak ve Park Etmek Yasaktır
	B-50h Şerit Düzenleme		T-1a Sağa Tehlikeli Viraj
	B-50ı Şerit Düzenleme		T-1b Sola Tehlikeli Viraj
	T-2a Sağa Tehlikeli Devamlı Viraj		T-2b Sola Tehlikeli Viraj
	T-3a Tehlikeli Eğim		T-3b Tehlikeli Eğim
	T-4a İki Taraftan Daralan Kaplama		T-4b Sağdan Daralan Kaplama
	T-4c Soldan Daralan Kaplama		T-7 Kasisli Yol
	T-8 Kaygan Yol		T-9 Gevşek Malzemeli Zemin
	T-10 Gevşek Zemin		T-11 Yaya Geçidi
	T-12 Okul geçidi		T-14a Ehli Hayvanlar Geçebilir
	T-14b Vahşi Hayvan Geçebilir		T-15 Yolda Çalışma Var

Tablo 5. (devamı)

	T-16 Işıklı İşaret Cihazı		T-19 İki Yönlü Trafik
	T-20 Dikkat		T-22a Anayol-Tali Yol Kavşağı
	T-22b Anayol-Tali Yol Kavşağı		T-22c Anayol-Tali Yol Kavşağı
	T-23a Sağdan Ana Yola Giriş		T-25 Kontrollü Demiryolu Geçidi
	T-33a Tehlikeli Viraj		T-33b Tehlikeli Viraj
	T-33f Onarım Yaklaşım		T-34a Refüj Başı
	T-34b Refüj başı		T-35 Dönüş Adası
	T-36 Düşük Banked		T-37 Gizli Buzlanma
	TT-1 Yol Ver		TT-2 Dur
	TT-26c U Dönüşü Yapılmaz		TT-27 Öndeki Taşıtı Geçmek Yasaktır
	TT-29a Azami Hız Sınırlaması (30)		TT-29a Azami Hız Sınırlaması (50)
	TT-29a Azami Hız Sınırlaması (70)		TT-29a Azami Hız Sınırlaması (90)
	TT-32 Bütün Yasaklama Ve Kısıtlamaların Sonu		TT-33a Hız Sınırlaması Sonu (50)
	TT-34a Geçme Yasağı		TT-35d İleri ve Sağa Mecburi Yön

Elde edilen görüntülerden oluşturduğum veri setinin tamamı kullandığım cihazın kapasitesi nedeniyle eğitime sokulamamış ve 2 grup halinde 1200 adet görüntü 1. gruba dâhil edilmiş 2. gruba ise 3000 adet görüntü modelde eğitim ve teste tabi tutulmuştur.

Birinci grupta Trafik Tanzim İşaretleri ve Trafik Uyarı İşaretleri altında modelde 1200 adet görüntü kullanılmıştır.

İkinci grupta ise 12 farklı gruptan alınan 3000 adet görüntü modelde kullanılmıştır. Bunların 360 adedi test için, 480 adedi eğitim destekleme için, 2160 adedi ise eğitim için kullanılmıştır.

Tablo 6. Modelde Eğitim ve Teste Sokulan Levhalar

1. Grupta Eğitim ve Teste Tabi Tutan Levhalar	
T-2a Sağa Tehlikeli Viraj	T-33a Tehlikeli Viraj
T-2b Sola Tehlikeli Viraj	TT-29a Azami Hız Sınırlaması
2. Grupta Eğitim ve Teste Tabi Tutan Levhalar	
B-14a Yaya Geçidi	T-35 Dönüş Adası
B-53 U Dönüşü	TT-27 Öndeki Taşıdı Geçmek Yasaktır
T-1a Sağa Tehlikeli Viraj	TT-29a Azami Hız Sınırlaması (50)
T-2b Sola Tehlikeli Devamlı Viraj	TT-29a Azami Hız Sınırlaması (70)
T-7 Kasisli Yol	T-33a Tehlikeli Viraj
T-22a Anayol- Tali Yol kavşağı	TT-36a Sağdan Gidiniz

Kullanılan Kütüphane ve Programlama Dili


Testler için TensorFlow kütüphanesi kullanılmıştır. Model olarak VGG16 (Visual Geometry Group 16) ve programlama dili olarak Python 3.7 tercih edilmiştir. Bu seçimlerin nedeni, TensorFlow ile uyumluluk sorunlarından kaçınmaktır. TensorFlow, derin öğrenme modelleri için kapsamlı araçlar sunan güçlü ve esnek bir kütüphanedir. Ayrıca, geniş topluluk desteği ve kapsamlı dokümantasyonu sayesinde, karşılaşılabilecek sorunların hızlıca çözülmesini ve gelişmiş modellerin etkili bir şekilde uygulanmasını sağlar.

VGG16 modelinin tercih edilmesindeki ana neden, programlama sürecinde yaşanabilecek zorlukları azaltmaktır. VGG16, iyi belgelenmiş ve önceden eğitilmiş bir mimariye sahip olduğundan, modelin uygulanması sırasında karşılaşılabilecek sorunları minimize eder ve hızlı sonuçlar elde edilmesini kolaylaştırır. Ayrıca, geniş kabul görmüş bir model olması, özelleştirme ve test aşamalarında güvenilir bir temel sunar. TensorFlow'un güncellenmiş sürümleri ve Python'un daha yeni versiyonları, ileride daha iyi performans ve başarı sağlayabilir. Bu nedenle, Python 3.7 gibi eski bir sürüm tercih edilerek uyumluluk sağlanmış ve TensorFlow ile VGG16'nın sağladığı avantajlardan yararlanılmıştır.

VGG16 konvolüsyon ve pooling sistemi

Tablo 7'de görüldüğü üzere, Konvolüsyon 1-1 katmanı, görüntünün orijinal halini 224x224 boyutlarında ve 3 kanallı (RGB) olarak alır. Bu katmandan çıkan veriler, 224x224 boyutlarında 64 farklı özellik haritası oluşturur.

Konvolüsyon 1-2 katmanında ise giriş olarak 224x224 boyutlarında 64 adet özellik haritası kullanılır ve aynı boyutlarda çıkış elde edilir. Bu aşamada boyut değişmez, ancak ağı daha derin özellikleri öğrenmesi sağlanır (Karaoğlu, 2022).



Şekil 4. VGG-16 mimarisi (Nsrk 2023)

Tablo 7. VGG16 Konvolüsyon ve Pooling Sistemi

Katman Tipi	Girdi Boyutu	Çıktı Boyutu
Konvolüsyon 1-1	224x224x3	224x224x64
Konvolüsyon 1-2	224x224x64	224x224x64
Pooling 1	224x224x64	112x112x64
Konvolüsyon 2-1	112x112x64	112x112x128
Konvolüsyon 2-2	112x112x128	112x112x128
Pooling 2	112x112x128	56x56x128
Konvolüsyon 3-1	56x56x128	56x56x256
Konvolüsyon 3-2	56x56x256	56x56x256
Konvolüsyon 3-3	56x56x256	56x56x256
Pooling 3	56x56x256	28x28x256
Konvolüsyon 4-1	28x28x256	28x28x512
Konvolüsyon 4-2	28x28x512	28x28x512
Konvolüsyon 4-3	28x28x512	28x28x512
Pooling 4	28x28x512	14x14x512
Konvolüsyon 5-1	14x14x512	14x14x512
Konvolüsyon 5-2	14x14x512	14x14x512
Pooling 5	14x14x512	7x7x512

Pooling 1 katmanında, görüntü boyutu küçültülerek 224x224 olan haritalar 112x112 boyutuna düşer. Bu işlem, hesaplama yükünü azaltmak için yapılır (Taghi, 2022).

Konvolüsyon 2-1 katmanında, giriş boyutu 112x112x64 iken, kanal sayısı artırılarak çıkış boyutu 112x112x128 olur. Konvolüsyon 2-2 katmanında da benzer şekilde, çıkış boyutu korunur ancak ağın öğrenmesi devam eder (Karaoğlu, 2022).

Pooling 2 katmanında harita boyutu tekrar küçültülür; giriş boyutu 112x112x128 iken, çıkış boyutu 56x56x128 olur.

Konvolüsyon 3-1 katmanında, 56x56x128 boyutundaki veri işlenir ve kanal sayısı artırılarak 56x56x256 boyutunda çıkış alınır. Konvolüsyon 3-2 katmanında da çıkış boyutu aynı kalır. Bu işlem, ağın öğrenme sürecini derinleştirmek amacıyla yapılır (Taghi, 2022).

Son olarak, Konvolüsyon 5-1'den Konvolüsyon 5-3'e kadar giriş ve çıkış boyutları aynıdır, çünkü modelin öğrenmesi artık iyice derinleştirilmek istenmektedir. Pooling 5 katmanında ise son bir küçültme işlemi yapılır ve işlem tamamlanır (Duman ve Akın 2019).

Yöntem



Şekil 5. Yöntem akış şeması

Öncelikli olarak Türkiye şehirler arası ve şehir içi trafiğinden çekilen taşıt kameralarından ve fotoğrafları çekilen trafik levhalarından oluşturulan bir veri seti hazırlanmıştır. Python yazım dili kullanılarak derin öğrenme modeli oluşturuldu.

Model olarak VGG-16 modeli seçildi. Bu model özellikle nesne sınıflandırma ve nesne tespitinde oldukça kullanışlı ve analiz gerektiren durumlar için oldukça güvenli bir modeldir. Katmanlardan oluşan VGG-16; 13 adet evrişim(convolutional) katmanı ve 5 adet ortaklama yani pooling katmanından oluşur. Öğrenme kapasitesinin oldukça yüksek olması aslında bu katmanlar sayesinde. Tam bağlantı katmanı 4096 adet nörondan oluşur (Kızrak ve Bolat 2018). VGG-16 katmanlarının işlevleri Tablo-3'e deki şekilde gerçekleşmektedir. Son olarak 3 adet tam bağlantı katmanı gelir ve girdi özelliklerinin sınıflandırma işlemi gerçekleşir (Gülbüz ve Yılmaz 2023). Kütüphane olarak VGG-16'ı içinde barındırdığı için Tensorflow seçildi. Oluşturulan model, veri setinden alınan görüntüler ile eğitim ve teste tabi tutuldu.

Model oluşturulduğunda VGG-16'nın en üst katmanı hariç tutulmuş ve veri girişi ile özellik çıkarımı yapılmıştır. 224x224 boyutlarında giriş görüntüleri ile katmanlar arası dönüşüm işlemlerine tabi tutulmuş ve filtrelerin görüntü üzerinde gezinmesi ile aktivasyon haritaları oluşturulmuştur. Hesaplama açısından ReLu kullanılmış ve son katmanda sınıflandırma için Softmax fonksiyonu uygulanmıştır. Eğitim aşamasında modelin ezberinin önüne geçilmesi için modelin genelleme yeteneği arttırılması için veri artırma yöntemleri ve seyreltme katmanı kullanılmıştır. Katmanlar arasında veri dağılımı düzenlenmesi için de Yığın Normalleştirme uygulanmıştır. Son olarak model eğitimi tamamladıktan sonra belirtiren dizinde kaydedilmiştir (Somuncu ve Atasoy 2022).

Üst katmanın kapatılmasının sebebi VGG-16'nın örneğin hayvanlar yada sebzeler gibi bir sınıflandırma yapmasını engellemek ve eğitime girecek olan veri setindeki etiketlemeye göre yeniden eğitilmesini sağlamak amaçlanmıştır. “include_top=False,” kodu ile en üst katmanın sınıflandırma işlemi yapmasının önüne geçilmiştir.

ReLu fonksiyonu basit bir hesaplama ya dayanır. Girdi pozitif ise çıkış verisi kendisi değilse sıfırdır (Taghi 2022).


ARAŞTIRMA BULGULARI

Yapılan Testler ve Sonuçların Analizi

Test iki ayrı gruba ayrılmış ve incelemeye tabi tutulmuştur. Birinci aşamada Trafik Tanzim ve Trafik Uyarı işaretleri teste tabi tutulmuştur. 2 grup altında Trafik Tanzim İşaretleri ve Trafik Uyarı İşaretleri altında 1200 görüntü modelde kullanılmıştır. Bu görüntüler eğitim, eğitim doğrulama ve test olarak 3 gruba ayrılmış ve epoch değeri 10 olarak belirlenmiştir. Bir diğer parametre olan steps per epoch 10 olarak verilmiştir. Testin sonunda testin başarısı %99,97 olarak alınmıştır. Epoch değeri sabit tutulup steps per epoch değeri 15'e yükseltildiğinde başarı oranı %99,98 olmuştur. Steps per Epoch 10 olarak test yapıldığında eğitimdeki loss değeri %0,43 verirken steps per epoch 15 verildiğinde loss değeri %0,21 olarak alınmıştır.

İkinci aşamada ise 12 farklı grup levha kullanılmıştır. 3000 adet görüntü modelde kullanılmıştır. Bunların 360 adedi test için, 480 adedi eğitim destekleme için, 2160 adedi ise eğitim için kullanılmıştır. Epoch 10 ve steps per epoch değeri 10 olarak alındığında %83,33 başarı oranı yakalanmıştır. Epoch 20 ve steps per epoch değeri 30 alındığında %96,94, Epoch 20 ve steps per epoch değeri 40 alındığında %97,22, Epoch 25 ve steps per epoch değeri 40 alındığında %98,61, Epoch 40 ve steps per epoch değeri 50 alındığında %99,16 olarak başarı oranı alınmıştır. Yapılan testlerin sonucunda görülmüştür ki epoch sayısı ve steps per epoch sayısı artırıldığında testin başarı oranında büyük bir artış gözlemlenmektedir. Artış için bir diğer faktör ise veri setinde eğitime giren görüntü sayısıdır. Eğitim setindeki görüntüler artırılarak epoch ve steps per epoch sayısı azaltılabilir.


Birinci aşama testleri



Şekil 6. Aşama 1 test 1 sonuçları

Test 1

2 gruptan 800 adet eğitim 100 adet test verisinden oluşan testte epoch 10 ve step perepoch 10 olarak belirlenmiştir. Her bir step per epoch 17-23sn sürmüş ve toplamda 193sn sürmüştür. Başarı oranı %99,97'tür. Buradaki başarı oranı test başarısıdır. Eğitim başarısı ise %99,98'dir.




Şekil 7. Aşama 1 test 2 sonuçları

Test 2

2 gruptan 800 adet eğitim 100 adet test verisinden oluşan testte epoch 10 ve step perepoch 15 olarak belirlenmiştir. Her bir step perepoch 29-31sn sürmüş ve toplamda 294sn sürmüştür. Başarı oranı %99,98'tür. Buradaki başarı oranı test başarısıdır. Eğitim başarısı ise %99,99'dir.

İkinci aşama testleri

Test 1




Şekil 8. Aşama 2 test 1 sonuçları

Tablo 8. Epoch 10 ve Step Per Epoch 10'a göre Modelden Alınan Yüzde Sonuçları

Epoch	Loss	Acc
Epoch 1	28,55	15,5
Epoch 2	25,87	24,5
Epoch 3	24,29	39,5
Epoch 4	22,72	46
Epoch 5	19,8	61
Epoch 6	18,06	63
Epoch 7	16,39	65,5
Epoch 8	14,83	65,5
Epoch 9	13,54	72,5
Epoch 10	11,99	75

12 gruptan 2172 adet eğitim 360 adet test verisinden oluşan testte epoch 10 ve step perepoch 10 olarak belirlenmiştir. Her bir step perepoch 19sn sürmüş ve toplamda 190sn

sürmüştür. Başarı oranı %83,33'tür. Buradaki başarı oranı test başarısıdır. Eğitim başarısı ise %75'dir.




Şekil 9. Aşama 2 test 2 sonuçları

Test 2

Tablo 9. Epoch 20 ve Step Per Epoch 30'a göre Modelden Alınan Yüzde Sonuçları

Epoch	Loss	Acc
Epoch 1	26,73	25,84
Epoch 2	20,01	53,33
Epoch 3	15,23	61,17
Epoch 4	11,96	72,83
Epoch 5	8,66	80,83
Epoch 6	7,07	83
Epoch 7	5,74	87,17
Epoch 8	5,13	88,18
Epoch 9	4,14	91,22
Epoch 10	3,44	93,33
Epoch 11	3,05	94,43
Epoch 12	2,85	94
Epoch 13	2,65	94,83
Epoch 14	2,34	95,33
Epoch 15	2,33	95,33
Epoch 16	1,34	98
Epoch 17	1,61	97,17
Epoch 18	1,31	97,5
Epoch 19	1,2	97,97
Epoch 20	1,21	97,3

12 gruptan 2172 adet eğitim 360 adet test verisinden oluşan testte epoch 20 ve step perepoch 30 olarak belirlenmiştir. Her bir step perepoch 61-64 sn arasında değişmiştir ve toplam eğitim süresi 1204 sn sürmüştür. Eğitim başarı oranı %97,30, Test Başarı oranı %96,944'tür.




Şekil 10. Aşama 2 test 3 sonuçları

Test 3

Tablo 10. Epoch 20 ve Step Per Epoch 40'a göre Modelden Alınan Yüzde Sonuçları

Epoch	Loss	Acc
Epoch 1	26,1	29,5
Epoch 2	18,99	56,25
Epoch 3	12,59	73,62
Epoch 4	9,75	78,41
Epoch 5	6,82	85,98
Epoch 6	5,94	87,5
Epoch 7	4,67	92
Epoch 8	3,66	93,06
Epoch 9	3,36	93,06
Epoch 10	2,42	96,09
Epoch 11	2,77	94
Epoch 12	2,12	95,83
Epoch 13	2,21	95,71
Epoch 14	1,81	97,5
Epoch 15	1,61	96,75
Epoch 16	1,7	97
Epoch 17	1,21	98
Epoch 18	1,28	97,5
Epoch 19	1,21	97,87
Epoch 20	1,1	97,12

12 gruptan 2172 adet eğitim 360 adet test verisinden oluşan testte epoch 20 ve step perepoch 40 olarak belirlenmiştir. Her bir step perepoch 79-81 sn arasında değişmiştir ve toplam eğitim süresi 1600 sn sürmüştür. Eğitim başarı oranı %97,12, Test Başarı oranı %97,22'dir.



Şekil 11. Aşama 2 test 4 sonuçları

Test 4


Tablo 11. Epoch 25 ve Step Per Epoch 40'a göre Modelden Alınan Yüzde Sonuçları

Epoch	Loss	Acc
Epoch 1	25,81	32,32
Epoch 2	17,92	61,87
Epoch 3	13,17	68,5
Epoch 4	9,18	82
Epoch 5	7,07	85,61
Epoch 6	5,37	89,77
Epoch 7	4,74	89,75
Epoch 8	4,11	92,12
Epoch 9	3,07	94,32
Epoch 10	2,4	96
Epoch 11	2,65	94,44
Epoch 12	1,96	96,63
Epoch 13	1,54	97,6
Epoch 14	1,45	97,62
Epoch 15	1,4	97,62
Epoch 16	1,29	97,12
Epoch 17	1,35	97,75

Tablo 11. (devamı)

Epoch 18	0,99	98,12
Epoch 19	0,75	98,87
Epoch 20	0,95	97,98
Epoch 21	0,98	98,25
Epoch 22	0,89	98,36
Epoch 23	0,79	98,37
Epoch 24	1,07	97,95
Epoch 25	0,6	98,61

12 gruptan 2172 adet eğitim 360 adet test verisinden oluşan testte epoch 25 ve step perepoch 40 olarak belirlenmiştir. Her bir step perepoch 79-81 sn arasında değişmiştir ve toplam eğitim süresi 1997 sn sürmüştür. Eğitim başarı oranı %98,61, Test Başarı oranı %98,61'dir.

**Şekil 12.** Aşama 2 test 5 sonuç grafiği

Test 5

Tablo 12. Epoch 30 ve Step Per Epoch 45'a göre Modelden Alınan Yüzde Sonuçları

Epoch	Loss	Acc
Epoch 1	25,15	31,95
Epoch 2	16,77	62,89
Epoch 3	10,44	78
Epoch 4	7,62	83,74
Epoch 5	5,95	88,57

Tablo 12. (devamı)

Epoch 6	4,34	91,48
Epoch 7	3,77	93,33
Epoch 8	2,87	94,22
Epoch 9	2,99	94,22
Epoch 10	2,45	95,33
Epoch 11	2,13	96,11
Epoch 12	1,76	96,86
Epoch 13	1,73	96,11
Epoch 14	1,15	98,33
Epoch 15	1,05	98,54
Epoch 16	1,48	97,31
Epoch 17	0,74	98,67
Epoch 18	0,81	98,89
Epoch 19	0,64	98,54
Epoch 20	0,94	98,44
Epoch 21	0,46	99
Epoch 22	0,7	98,89
Epoch 23	0,65	98,89
Epoch 24	0,96	98,44
Epoch 25	0,48	98,99
Epoch 26	0,53	98,99
Epoch 27	0,57	98,77
Epoch 28	0,69	99
Epoch 29	0,31	99,33
Epoch 30	0,51	98,89

12 gruptan 2172 adet eğitim 360 adet test verisinden oluşan testte epoch 30 ve step pereepoch 45 olarak belirlenmiştir. Her bir step pereepoch 89-90 sn arasında değişmiştir ve toplam eğitim süresi 2688 sn sürmüştür. Eğitim başarı oranı %98,89 , Test Başarı oranı %98,8'dir.

Test 6.

12 gruptan 2172 adet eğitim 360 adet test verisinden oluşan testte epoch 40 ve step pereepoch 50 olarak belirlenmiştir. Her bir step pereepoch 102-106 sn arasında değişmiştir. Eğitim başarı oranı %99,17, Test Başarı oranı %99,16'dir.

Testlerde elde edilen Loss değeri modelin eğitime sokulduğunda gerçek etiketleri ile tahmin etiketleri arasındaki farkı ölçen parametredir. Kayıp, eğitim sırasında modeli doğru tahminler yapmaya yönlendirmenin bir yoludur. Kayıp değeri düştükçe modelin başarısı da gerçeğe bir o kadar yaklaşır. Acc değerleri ise doğru tahmin oranını verir. Doğruluk, modelin ne kadar iyi bir performans verdiğini göstermek ve anlamak için kullanılır. Örneğin %99.17'lik başarı oranı, modelin başarılı tahmin oranının %99.16 olduğunu ifade eder.



SONUÇ, TARTIŞMA VE ÖNERİLER

Sonuç ve Tartışma

Bu çalışma kapsamında elde edilen sonuçlar, Türkiye'nin şehirlerarası ve şehir içi trafiğinden elde edilen görüntülerle oluşturulan veri setinin kullanımıyla gerçekleştirilmiştir. Model, bu veri seti üzerinde çeşitli testlerden geçirilmiş ve yüksek başarı oranları elde edilmiştir. Başarı oranının yüksek olması, kullanılan veri setinin Türkiye'nin trafik koşullarına uygunluğunu ve modelin yerel koşulları doğru bir şekilde yansıttığını göstermektedir.

Testler iki ana aşamaya ayrılmıştır. Birinci aşamada, Trafik Tanzim ve Trafik Uyarı işaretleri üzerinde yapılan testlerde, toplamda 1200 görüntü kullanılmıştır. Bu görüntüler, eğitim, eğitim doğrulama ve test olmak üzere üç gruba ayrılmış ve epoch değeri 10 olarak belirlenmiştir. Ayrıca, "steps per epoch" değeri 10 olarak ayarlanmıştır. Test sonuçları, başarı oranının %100 olduğunu ortaya koymuştur. Epoch değeri sabit tutulduğunda ve steps per epoch değeri 15'e çıkarıldığında da başarı oranı %100 olarak kalmıştır. Ancak, steps per epoch değeri 10 olarak belirlendiğinde eğitimdeki "loss" değeri %0,43 iken, steps per epoch değeri 15'e yükseltildiğinde "loss" değeri %0,21 olarak gözlemlenmiştir. Bu sonuçlar, epoch ve steps per epoch değerlerinin modelin performansını nasıl etkilediğini göstermektedir.

İkinci aşamada, 12 farklı grup levha kullanılmış ve toplamda 3000 görüntü modelde test edilmiştir. Bu görüntülerin 360 adedi test için, 480 adedi eğitim doğrulama için ve 2160 adedi ise eğitim için kullanılmıştır. Epoch değeri 10 ve steps per epoch değeri 10 olarak belirlendiğinde başarı oranı %83,33 olarak elde edilmiştir. Epoch değeri 20 ve steps per epoch değeri 30 olarak ayarlandığında başarı oranı %96,94'e çıkmıştır. Epoch değeri 20 ve steps per epoch değeri 40 olduğunda başarı oranı %97,22'ye, Epoch değeri 25 ve steps per epoch değeri 40 olarak belirlendiğinde %98,61'e, ve Epoch değeri 40 ve steps per epoch değeri 50 olarak ayarlandığında başarı oranı %99,16'ya ulaşmıştır. Bu sonuçlar, epoch sayısının ve steps per epoch değerlerinin artırılmasının test başarısını önemli ölçüde artırdığını göstermektedir. Ayrıca, veri setindeki görüntü sayısının artırılmasının, epoch ve steps per epoch değerlerini azaltarak başarı oranlarını artırabileceği belirtilmiştir.

Yıldıran (2019) tarafından yapılan çalışmalar, farklı ülkelerden alınan veri setleriyle yapılan testlerde düşük başarı oranları elde edildiğini ortaya koymuştur. Seçkin (2021) ise MNIST veri seti kullanarak %97,51 başarı oranı yakalamıştır. Seçkin'in çalışmasında kullanılan veri seti el yazısı rakamları içerirken, bizim çalışmamızda araç nesne tanınması için

1400 görüntüden oluşan kendi veri setimiz kullanılmıştır. Bu durum, başarı oranının yüksek olmasının veri setinin özelliklerine bağlı olduğunu açıkça ortaya koymaktadır. Ayrıca, Seçkin (2021) epoch sayısını 50 olarak belirlemiş ve %97,51 başarı oranı elde etmiştir. Biz ise epoch değerini 40 olarak ayarlayarak %99,17 başarı oranına ulaşmış bulunmaktayız.

Taghi (2022) yılında gerçekleştirdiği çalışmada YOLOv3 ve YOLOv7 modellerini kullanarak sırasıyla %99,46 ve %97,3 başarı oranları elde etmiştir. Ancak, Taghi'nin çalışmasında kullanılan veri seti GTSDb (German Traffic Sign Detection Benchmark) olarak seçilmiştir. Bizim çalışmamızda ise veri seti tarafımızdan oluşturulan yerel görüntülerden elde edilmiştir. Modelimizin epoch ve steps per epoch değerlerinin optimize edilmesiyle yüksek doğruluk oranlarına ulaşıldığı görülmüştür. Bu, modelin veri setine ve eğitim parametrelerine duyarlılığını ve optimize edilebilirliğini göstermektedir.

Bu çalışma, yerel veri setlerinin ve eğitim parametrelerinin model performansı üzerindeki etkilerini vurgulayan önemli bulgular sunmaktadır ve gelecekteki çalışmalar için değerli bilgiler sağlamaktadır.

Öneriler

Bu çalışma, Türkiye şehirlerarası ve şehir içi trafiğinden elde edilen görüntülerle oluşturulan kapsamlı veri setlerinin, trafik işaret levha tanıma sistemlerinde başarı oranını önemli ölçüde artırabileceğini ortaya koymaktadır. Veri setinin kapsamlı olması, modelin çeşitli trafik işaretlerini doğru bir şekilde tanıma kapasitesini geliştirmekte kritik bir rol oynamaktadır. Bu nedenle, trafik işaretlerinin temsilini en iyi şekilde yansıtacak geniş ve çeşitli veri setlerinin oluşturulması büyük önem arz etmektedir.

TensorFlow kütüphanesi ve VGG-16 modelinin eğitim süreleri uzun olabilmektedir; ancak, teknolojiye gelişmeler ve yazılım optimizasyonları bu süreleri kısaltma potansiyeline sahiptir. Yazılım güncellemeleri ve optimizasyonlar yapıldıkça, mevcut olumsuzlukların hızlı bir şekilde giderilmesi muhtemeldir. Dolayısıyla, bu tür teknolojilere yatırım yapmak ve yazılım güncellemelerini takip etmek önemlidir.

Modelin sadece ezberleyen bir model haline gelmemesi için çeşitli adımların uygulanması gerekmektedir. Özellikle, modelin sadece eğitim verisine bağımlı kalmasını engellemek için uygun düzenleme tekniklerinin (regularization) ve veri artırma yöntemlerinin (data augmentation) kullanılması faydalı olacaktır. Bu, modelin genelleme yeteneğini artırarak daha sağlam ve güvenilir sonuçlar elde edilmesini sağlar.

Veri seti oluşturulurken dikkat edilmesi gereken önemli faktörlerden biri de görüntülerin aynı ölçekte olup olmadığıdır. Eğer görüntüler farklı ölçeklerdeyse, bu durum

modelin performansını etkileyebilir. Bu nedenle, veri setinde kullanılan tüm görüntülerin standart bir ölçekte olması sağlanmalıdır. Aksi takdirde, modelin doğru ve tutarlı sonuçlar üretmesi zorlaşabilir.

Optimum epoch ve steps per epoch değerlerinin belirlenmesi için birçok test ve deneme yapılması gerektiği unutulmamalıdır. Eğitim sürecinde bu parametrelerin doğru şekilde ayarlanması, modelin performansını doğrudan etkileyen bir faktördür. Bu nedenle, eğitim sürecinde çeşitli kombinasyonlar denemek ve en iyi performansı sağlayan parametreleri belirlemek önemlidir.

Sonuç olarak, çalışmamızdaki bulgular ve benzer araştırmalar incelendiğinde, trafik işaret tanıma sistemlerinin başarı oranlarının %95 ila %99 arasında değiştiği gözlemlenmiştir. Bu sistemlerin, sürücü kaynaklı hataları minimize etme ve trafik güvenliğini artırma konusunda büyük bir öneme sahip olduğu görülmektedir. Ayrıca, benzer sürücü destek sistemlerinin kazaları önleme oranlarının %50 ila %70 arasında değiştiği göz önüne alındığında, bu tür sistemlerin yaygınlaştırılması, kaza oranlarında ciddi bir azalma sağlayacaktır. Gelecekte, daha geniş veri setleri ve gelişmiş algoritmalar kullanılarak bu sistemlerin performansının daha da iyileştirilmesi ve yaygınlaştırılması, trafik güvenliğini artırmak için önemli bir adım olacaktır.

KAYNAKÇA

- Akgün, H., 2020. Trafik İşaretlerinin Derin Öğrenme ile Tespiti ve Anlamlandırılması. Yüksek Lisans Tezi, Isparta Uygulamalı Bilimler Üniversitesi Lisansüstü Eğitim Enstitüsü, Isparta.
- Algur, Ö., Tümen, V., ve Yıldırım, Ö., 2018. Dış Ortam Görüntülerindeki İnsan Hareketlerinin Hibrit Derin Öğrenme Yöntemleri Kullanarak Sınıflandırılması. Fırat Üniversitesi Mühendislik Bil. Dergisi, 30(3), 121-129.
- Altun, M., Altun, S.U. ,ve Kutlu, E., 2023. Yapay Zeka Uygulamaları Ortaokul ve Lise Öğretmen El Kitabı. Din Öğretimi Genel Müdürlüğü, Ankara.
- Anonim, 2020. Karayolları Düşey Trafik Levha işaretleri. Karayolları Genel Müdürlüğü,<https://www.kgm.gov.tr/SiteCollectionImages/KGMimages/Trafik/Isaretler/duseyisaretleme.pdf> (10.06.2024).
- Bıçakcı, K.,2020. AlexNet,VggNet, Inception ve ResNet Nedir?. Medium, <https://frightera.medium.com/alexnet-vggnet-inception-ve-resnet-nedir-bddc7482918b-> (12.07.2024).
- Çevik, H., 2022. Akıllı Ulaşım Sistemleri Unsurlarından Otonom Araçlarda Trafik Kaza Faktörlerinin Belirlenmesine İlişkin Bir Araştırma. Yüksek Lisans Tezi, İstanbul Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.
- Cirit, F., 2014. Sürdürülebilir Kentiçi Ulaşım Politikaları ve Toplu Taşıma Sistemlerinin Karşılaştırılması. Uzmanlık Tezi, T.C. Kalkınma Bakanlığı, Ankara.
- Daş, R., Polat,B., ve Tuna, G., 2019. Derin Öğrenme İle Resim ve Videolarda Nesnelerin Tanınması ve Takibi. Fırat Üniversitesi Müh. Bil. Dergisi, 31(2),571-581.
- Dilek, E., Talih, Ö., ve Ceylan, H., 2023. Ulusal Akıllı Ulaşım Sistemleri Mimarisinin Yaygınlaştırılması: Türkiye Önerisi. Bandırma Üniversitesi Akıllı Ulaşım Sistemleri ve Uygulama Dergisi, 6(2), 353-355.
- Dolu, D.G., Şen, A., 2024. Coğrafi Referanslı Sosyal Medya Verilerinden Doğal Dil İşleme ve Derin Öğrenme Kullanılarak Duygu Analizi: Kahramanmaraş Depremleri Örneği. Jeodezi ve Jeoinformasyon Dergisi, 11(1), 51-67.
- Duman, E., Akın, F.,2019. VGG-16-CNN Parametrelerinin Model Başarısına Etkilerinin Değerlendirilmesi. Mardin Artuklu Uluslar arası Multidisipliner Çalışmalar Kongresi, Mardin.
- Gürbüz, Ö., Yılmaz. T., 2023. Evrişimli Sinir Ağları Kullanarak Yüz Belirleme ve Tanıma Uygulamaları. Journal Of Investigations on Engineering & Technology, 6(2), 45-60.
- Karakuş, C. (2023) Yapay Zeka, Balbiti, İstanbul.
- Karaoğlu, B., 2022. Görüntü İşlemenin Convolutional Neural Network (CNN) Modeli Kullanılarak Tarımsal Alanda Uygulanması: Hastalıklı Yaprak Tespiti. Yüksek Lisans Tezi, Karabük Üniversitesi Lisansüstü Eğitim Enstitüsü, Karabük.
- Kızrak, M.A., Bolat, B., 2018. Derin Öğrenme ile Kalabalık Analizi Üzerine Detaylı Bir Araştırma. Bilişim Teknolojileri Dergisi, 11(3), 263-286.
- Koptur, M. , 2017. Yapay Sinir Ağları ve Derin Öğrenme-1. Makineogrenimi, <https://makineogrenimi.wordpress.com/2017/07/15/yapay-sinir-aglari-ve-derin-ogrenme-1/>-(08.02.2024).

- Korkmaz, E.S., 2022. Kenti İçi Yolcu Taşımacılığında Akıllı Ulaşım Sistemleri Uygulamaları. Bandırma Onyedi Eylül Üniversitesi Fen Bilimleri Enstitüsü, Balıkesir.
- Kurt, M.A., 2020. Trafik İşaret Levhalarının Bilinirliğinin Ölçülmesi. Yüksek Lisans Tezi, Tokat Gaziosmanpaşa Üniversitesi Fen Bilimleri Enstitüsü, Tokat.
- Masache-Narvaez, J.L., 2019. Adaptation of a Deep Learning Algorithm for Traffic Sign Detection. Yüksek Lisans Tezi, The University of Western Ontario, Western Libraries, <https://ir.lib.uwo.ca/etd/6412/>.
- Müller A., Guido S., 2016. Introduction to Machine Learning With Python A Guide for Data Scientists. O'Reilly Media, s165.
- Murat, Y.Ş., Çakıcı, Z., 2017. Trafik İşaretlerinin Bilinirliği Üzerine Bir Araştırma: Denizli Örneği. BEÜ Fen Bilimleri Dergisi, 6(1), 21-30.
- Nsrk, Teja., 2023. A Beginner's Guide to VGG16: The Visual Detective of Image Classification. Medium, <https://medium.com/@teja.nsrk97/a-beginners-guide-to-vgg16-the-visual-detective-of-image-classification-b45cd81935d7> (12.08.2024).
- Övün, B., 2022. Trafik Levhalarının Evrişimsel Sinir Ağları İle Tanınması. Yüksek Lisans Tezi, Kocaeli Üniversitesi Fen Bilimleri Enstitüsü, Kocaeli.
- Öztemel. E., 2006. Yapay Sinir Ağları. Papatya Yayıncılık Eğitim, İstanbul, Ankara, İzmir, Adana.
- Öztürk, E., 2022. Yapay Sinir Ağları. Patika Academy, <https://academy.patika.dev/blogs/detail/yapay-sinir-aglariys> (16.07.2024).
- Seçkin, M.E., 2021. Derin Öğrenme Kullanılarak Trafik Koşullarına Uygun Otonom Araç Uygulaması. Yüksek Lisans Tezi, Bursa Uludağ Üniversitesi Fen Bilimleri Enstitüsü, Bursa.
- Şeker, A., Diri, B., ve Balık H.H.. 2017. Derin Öğrenme Yöntemleri ve Uygulamaları Hakkında Bir İnceleme. Gazi Mühendislik Bilimleri Dergisi, 3(3), 47-64.
- Şen. Z., 2004. Yapay Sinir Ağları İlkeleri. Su Vakfı, İstanbul.
- Smith, L., 2002. A tutorial on Principal Components Analysis ,12.
- Somuncu, E., Atasoy, N.A. 2022. Evrişimli Tekrarlayan Sinir Ağı ile Metin Görüntüleri Üzerinde Karakter Tanıma Uygulaması Gerçekleştirilmesi. Journal of the Faculty of Engineering and Architecture of Gazi University, 37(1), 17-27.
- Taghi, M., 2022. Derin Öğrenme İle Trafik İşaretlerini Tanıyan Bir Sürücü Destek Sistemi. Yüksek Lisans Tezi, Bandırma Onyedi Eylül Üniversitesi Fen Bilimleri Enstitüsü, Balıkesir.
- Tosunoğlu, E., Yılmaz, R., Özeren, E., ve Sağlam, Z., 2021. Eğitimde Makine Öğrenmesi: Araştırmalardaki Güncel Eğilimler Üzerine İnceleme. Necmettin Erbakan Üniversitesi Ahmet Keleşoğlu Eğitim Fakültesi Dergisi, 3(2), 178-199.
- Tufan, H., 2014. Akıllı Ulaşım Sistemleri Uygulamaları ve Türkiye İçin Bir AUS Mimarisi Önerisi. Ulaştırma ve Haberleşme Uzmanlığı Tezi, T.C. Ulaştırma Denizcilik ve Haberleşme Bakanlığı, Ankara.
- Tüzün, U., Özkahraman, M., Aksoy, B., 2022. Otonom Araçlar İçin Mikro denetleyici Tabanlı Çevresel Güvenlik Sistemi Tasarımı. Uluslararası Sürdürülebilir Mühendislik ve Teknoloji Dergisi, 2(6), 39-47.
- Yapıcı, A., Akcayol, M.A., 2022. Derin Öğrenme ile Görüntülerde Gürültü Azaltma Üzerine Kapsamlı Bir İnceleme. Int. J. Adv. Eng. PureSci., 34(1), 65-90.

- Yiğit, T., Atmaca, A., Gürfıdan, R., ve Çolak, R., 2023. Evrişimli Sinir Ağı Kullanarak El yazısı Rakamların Tanımasında Hiper Parametre Analizi. Gazi Journal of EngineeringSciences, 9(4), pp. 268-277.
- Yıldıran, O., 2019. Derin Öğrenme Yöntemleri ile Trafik İşareti Tanıma. Yüksek Lisans Tezi, Marmara Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.
- Yılmaz, O., Aydın, H., ve Çetinkaya A., 2020. Faster R-CNN Evrişimsel Sinir Ağı Üzeirnde Geliştirilen Modelin Derin Öğrenme Yöntemleri ile Doğruluk Tahmini ve Analizi: Nesne Tespiti Uygulaması. European Journal of Science and Technology, 20, 783-795.



ÖZGEÇMİŞ

Kişisel Bilgiler	
Adı Soyadı:	Muhammed Buğra KIZILARSLANOĞLU
Doğum tarihi:	
Doğum Yeri:	
Uyruğu:	
Adres:	
Tel:	
E-mail:	
Eğitim	
Lise:	Mecidiye Anadolu Lisesi
Lisans:	Atatürk Üniversitesi, Mühendislik Fakültesi İnşaat Mühendisliği
Yabancı Dil Bilgisi	
İngilizce:	İyi
Almanca:	
Rusça:	
Diğer	
Üye Olunan Mesleki Kuruluşlar	
	İnşaat Mühendisleri Odası
Tezden Üretilmiş Yayınlar	
Derin Öğrenme Algoritması Kullanılarak Trafik Levha Tanıma Sistemi Geliştirilmesi	