

KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

SÜRÜCÜ DESTEK SİSTEMLERİ İÇİN YENİ YOL VE İŞARET TANIMA
YÖNTEMLERİ

DOKTORA TEZİ

Gülcan YILDIZ

ŞUBAT 2024

TRABZON



KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

SÜRÜCÜ DESTEK SİSTEMLERİ İÇİN YENİ YOL VE İŞARET TANIMA
YÖNTEMLERİ

Gülcan YILDIZ

Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsünce
"DOKTOR (BİLGİSAYAR MÜHENDİSLİĞİ)"
Unvanı Verilmesi İçin Kabul Edilen Tezdir.

Tezin Enstitüye Verildiği Tarih : 08 / 01 / 2024

Tezin Savunma Tarihi : 07 / 02 / 2024

Tez Danışmanı : Prof. Dr. Bekir DİZDAROĞLU

Trabzon 2024

ÖNSÖZ

“Sürücü Destek Sistemleri İçin Yeni Yol Ve İşaret Tanıma Yöntemleri” isimli bu tez Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı, Doktora Programı’nda hazırlanmıştır.

Tez çalışmam boyunca hiçbir desteğini esirgemeyen ve bilim insanı olma yolundaki ilk adımlarımı atarken kıymetli bilgileriyle ve tecrübesiyle yolumu aydınlatan danışman hocam Sayın Prof. Dr. Bekir DİZDAROĞLU’na teşekkürü bir borç bilirim. Ayrıca, yapıcı eleştirileri ve önerileri ile tezime büyük katkıları bulunan saygıdeğer hocalarım Sayın Dr. Öğr. Üyesi Murat AYKUT’a ve Sayın Dr. Öğr. Üyesi Mehmet ÖZTÜRK’e, eğitim öğretim hayatımda katkısı olan tüm hocalarıma ve tez çalışması süresinde hiçbir yardımdan kaçınmayan arkadaşlarıma teşekkür ederim.

Her zaman ve her koşulda sabır, destek ve sevgileriyle yanımda olan eşim Doğan YILDIZ’a ve sevgili ailesine, doktora eğitimim sırasında hayatıma dahil olup bu zorlu süreçte yaşantıma anlam katan ve bana güç veren biricik kızım Bilge’me şükranlarımı sunarım.

Son olarak, doğduğum günden beri elimi hiç bırakmayan, hayatım boyunca aldığım tüm kararlarda bilgi ve tecrübelerinden faydalandığım ve her kararında arkamda olan, maddi ve manevi desteklerini hiçbir zaman esirgemeyen ve bugünlere gelmemde en büyük paya sahip olan annem Emine ÖZER ve babam Hüseyin ÖZER’e, abim Gökhan ÖZER ve ablam Neslihan GAYGUSUZ’a teşekkür eder, minnettarlığımı sunarım.

Bu tez çalışmasının bundan sonraki çalışmalara katkı sağlamasını temenni ederim.

Gülcan YILDIZ

Trabzon 2024

TEZ ETİK BEYANNAMESİ

Doktora Tezi olarak sunduğum “Sürücü Destek Sistemleri İçin Yeni Yol Ve İşaret Tanıma Yöntemleri” başlıklı bu çalışmayı baştan sona kadar danışmanım Prof. Dr. Bekir DİZDAROĞLU’nun sorumluluğunda tamamladığımı, verileri/örnekleri kendim topladığımı, deneyleri/analizleri ilgili laboratuvarlarda yaptığımı/yaptırdığımı, başka kaynaklardan aldığım bilgileri metinde ve kaynakçada eksiksiz olarak gösterdiğimi, çalışma sürecinde bilimsel araştırma ve etik kurallara uygun olarak davrandığımı ve aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ettiğimi beyan ederim. 07/02/2024

Gülcan YILDIZ

İÇİNDEKİLER

	<u>Sayfa No</u>
ÖNSÖZ.....	III
TEZ ETİK BEYANNAMESİ.....	IV
İÇİNDEKİLER.....	V
ÖZET	VII
SUMMARY	VIII
ŞEKİLLER DİZİNİ	IX
TABLolar DİZİNİ.....	XII
SEMBOLLER VE KISALTMALAR DİZİNİ	XIII
1. GENEL BİLGİLER	1
1.1. Trafik İşareti	1
1.1.1. Trafik İşareti Veri Seti	2
1.1.2. Trafik İşareti Algılama.....	10
1.1.3. Trafik İşareti Sınıflandırma.....	12
1.2. Trafik Işıkları.....	18
1.3. Yol Şerit	22
1.4. Evrişimsel Sinir Ağı ve Modelleri.....	25
1.4.1. VGG19.....	26
1.4.2. ResNet-50.....	27
1.4.3. MobileNet	28
1.4.4. Xception.....	29
1.5. Transfer (Aktarmalı) Öğrenme.....	30
1.6. Çalışmada Kullanılan Metrikler	32
2. YAPILAN ÇALIŞMALAR.....	34
2.1. Trafik İşareti	34
2.1.1. Trafik İşareti Algılama.....	34
2.1.2. Transfer Öğrenme Yoluyla Trafik İşareti Sınıflandırma	35
2.1.3. Renk Uzayına Dayalı Trafik İşareti Sınıflandırma	36
2.1.4. Topluluk Öğrenme ile Trafik İşareti Sınıflandırma	39
2.2. Trafik Işıkları.....	45
2.3. Yol Şerit	49

3. BULGULAR VE TARTIŞMA	51
3.1. Trafik İşareti	51
3.1.1. Trafik İşareti Algılama	51
3.1.2. Transfer Öğrenme Yoluyla Trafik İşareti Sınıflandırma	56
3.1.3. Renk Uzayına Dayalı Trafik İşareti Sınıflandırma	61
3.1.4. Topluluk Öğrenme ile Trafik İşareti Sınıflandırma	66
3.2. Trafik Işıkları	83
3.3. Yol Şerit	95
4. SONUÇLAR	100
5. ÖNERİLER	103
6. KAYNAKLAR	104
7. EKLER	117
ÖZGEÇMİŞ	

Doktora Tezi

ÖZET

SÜRÜCÜ DESTEK SİSTEMLERİ İÇİN YENİ YOL VE İŞARET TANIMA YÖNTEMLERİ

Gülcan YILDIZ

Karadeniz Teknik Üniversitesi
Fen Bilimleri Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı
Danışman: Prof. Dr. Bekir DİZDAROĞLU
2024, 116 Sayfa

Akıllı ulaşım sistemlerine ilgi gün geçtikçe artmaktadır ve bu nedenle birçok sürücü destek sistemi geliştirilmektedir. Özellikle görüntü kullanan sistemlere son zamanlarda önem verilmektedir. Trafik işaretleri, şerit çizgileri gibi yol ortamlarının tanınması ve anlaşılması üzerine araştırmalar incelenmektedir. Tez çalışması kapsamında, trafik işaretleri algılama ve sınıflandırma, trafik ışıkları sınıflandırma ve yol şerit çizgileri tespiti için yöntemler önerilmiştir. Ayrıca Türkiye'deki trafik işaretlerinden oluşan bir veri seti üretilmiş ve sınıflandırma aşamasında test edilmiştir. Yapılan işlemlerde, görüntü işleme ve derin öğrenme yöntemleri kullanılmıştır. Trafik işareti algılama konusunda araç içerisinden çekilen görüntülerde, renge ve şekle dayalı önerilen yöntemle işlemler gerçekleştirilmiştir. Trafik işareti sınıflandırma için transfer öğrenme yoluyla, renk uzayına dayalı ve topluluk öğrenme olmak üzere birden fazla çalışma yapılmış, en iyi performansa topluluk öğrenme ile ulaşılmıştır. Trafik ışıkları sınıflandırma için evrişimsel sinir ağına dayalı bir model önerilmiştir. Model parametre seçimleri için farklı denemeler yapılarak sonuçlar karşılaştırılmış ve modele en uygun parametre değerleri elde edilmiştir. Son olarak görüntü işleme ve Destek Vektör Regresyonu eğri uydurma ile şerit çizgi tespit yöntemi önerilmiştir.

Anahtar Kelimeler: Trafik işareti algılama ve sınıflandırma, Trafik ışıkları sınıflandırma, Yol şerit tespiti, Derin öğrenme, Evrişimsel sinir ağı, Görüntü işleme

PhD. Thesis

SUMMARY

NEW ROAD AND SIGN RECOGNITION METHODS FOR DRIVER ASSISTANCE SYSTEMS

Gülcan YILDIZ

Karadeniz Technical University
The Graduate School of Natural and Applied Sciences
Computer Engineering Graduate Program
Supervisor: Assoc. Prof. Bekir DİZDAROĞLU
2024, 116 Pages

The interest in intelligent transportation systems is increasing day by day and therefore many driver support systems are being developed. Especially, systems that use images have been given importance recently. Research on recognition and understanding of road environments such as traffic signs and lane markings is examined. Within the scope of the thesis study, methods have been proposed for traffic signs detection and classification, traffic light classification, and road lane line detection. Additionally, a data set consisting of traffic signs in Turkey is produced and tested at the classification stage. Image processing and deep learning methods are used in the operations. Regarding traffic sign detection, the images taken from inside the vehicle are processed using the recommended method based on color and shape. Multiple studies have been conducted for traffic sign classification, including transfer learning, color space-based, and ensemble learning, and the best performance is achieved with ensemble learning. A convolutional neural network-based model is proposed for traffic light classification. Different experiments are carried out for model parameter selection, the results are compared and the most suitable parameter values for the model are obtained. Finally, a lane line detection method with image processing and Support Vector Regression curve fitting is proposed.

Key Words: Traffic sign detection and classification, Traffic light classification, Road Lane detection, Deep learning, Convolutional neural network, Image processing.

ŞEKİLLER DİZİNİ

	<u>Sayfa No</u>
Şekil 1. Farklı ülkelerdeki durma işaretinin tasarımları	2
Şekil 2. GTSRB veri seti örnek görüntüler	5
Şekil 3. GTSRB her sınıfa ait görüntü sayıları histogramı	6
Şekil 4. BTSC veri setinin her bir sınıfı için örnek görüntüler	7
Şekil 5. BTSC her sınıfa ait görüntü sayıları histogramı	8
Şekil 6. Üretilen Türkiye veri setinde her bir sınıf için örnek görüntüler	9
Şekil 7. Türkiye veri seti her sınıfa ait görüntü sayıları histogramı	10
Şekil 8. Temel ESA mimarisi (Saha S. , 2018)	26
Şekil 9. VGG19 ağ mimarisi. Burada”evrş”, evrişimsel katmanı, “TBK” ise, tam bağlantılı katmanı ifade etmektedir.....	27
Şekil 10. Resnet-50 artık blok	28
Şekil 11. MobileNet mimarisi (Wang, ve diğerleri, 2020).....	29
Şekil 12. Xception model mimarisi (Chen, Liu, Zheng, Zhao, & Shi, 2021)	30
Şekil 13. Önerilen yöntemdeki ana işlem adımları	34
Şekil 14. Sol: GTSRB veri seti özgün örnek görüntüler. Orta: Çekirdek 1 görüntüleri. Sağ: Çekirdek 2 görüntüleri.....	42
Şekil 15. Sınıflandırma için önerilen yöntem.....	44
Şekil 16. Yığınlama topluluğu modelin ayrıntıları.....	45
Şekil 17. Önerilen ESA mimarisinin detayları.....	49
Şekil 18. Yol şerit tespit modeli	49
Şekil 19. Veri seti örnek görüntüler a) Sağa mecburi yön b) Yaya geçidi c) Duraklamak ve park etmek yasaktır d) Okul geçidi	51
Şekil 20. Önerilen yöntemin işlem adımları.....	52
Şekil 21. a) Ölçeklenmiş görüntü b) Kırmızı renk bileşenine ait gri seviye görüntü c) Mavi renk bileşenine ait gri seviye görüntü ve d) Kırmızı + mavi renk bileşenlerinin eşikleme sonrası siyah-beyaz görüntü.....	53
Şekil 22. Geometrik şekiller için karar ağacı	54
Şekil 23. a) Açma-Kapama işlemleri sonrası görüntü b) Şekilsel özelliklere uymayan nesnelerden giderilmiş görüntü c) Sonuç görüntüsü ve d) Saptanan trafik işareti.....	55
Şekil 24. Örnek görüntüye ait tüm işlem adımları	56
Şekil 25. Görüntülerde saptanan trafik işaretleri.....	56
Şekil 26. Trafik işaretleri:.....	57

Şekil 27. VGG19, MobileNet ve ResNet50 modellerine ait test doğruluk sonuçları (100 epok için)	58
Şekil 28. VGG19, MobileNet ve ResNet50 modellerine ait test kayıp sonuçları (100 epok için)	59
Şekil 29. Xception modeli için kayıp ve doğruluk sonuçları (50 epok için).....	59
Şekil 30. İkili girişlerin modele verilmesi	62
Şekil 31. a) RIQ + RGB b) RIQ + CIELab c) RGB + CIELab d) RIQ + LGI.....	63
Şekil 32. RIQ + LGI giriş görüntüsü ile görüntü boyutlarına göre test doğruluk sonuçları a) 32 x 32 b) 45 x 45 c) 60 x 60	64
Şekil 33. Öğrenme oranı düzenleyicisinden sonra 60 x 60 giriş görüntüsü için test ve eğitim kayıp ve doğruluk sonuçları	64
Şekil 34. Eğitim sırasındaki kayıp ve doğruluk sonuçları üst) Çekirdek 1 orta) Çekirdek 2 alt) Çekirdek 1 & Çekirdek	69
Şekil 35. a) Kesinlik-duyarlılık eğrisi b) ROC eğrisi	72
Şekil 36. GTSRB veri seti üzerinde ROC AUC grafiği	72
Şekil 37. Yığınlama topluluğu modeli ile GTSRB’de yanlış sınıflandırılan görüntüler	74
Şekil 38. GTSRB veri seti için önerilen yığınlama topluluğu modelinin karışıklık matrisi.....	75
Şekil 39. Grad-CAM ile elde edilen örnek görüntü sonuçları.....	77
Şekil 40. 0 ile 180 derece arasında farklı açılara göre sonuçlar. Üst: dönme sonucu olasılık ve belirsizlik, Orta: dönme sonucu sınıf tahmini, Alt: Dönmenin örnek görüntüsü.....	78
Şekil 41. 1. Satır: İstatistiksel Parametrik Haritalama, 2. satır: doğru etiketlenmiş görüntü 3. satır: yanlış etiketlenmiş görüntü, 4. Satır: Wasserstein mesafesi ölçümü (Sütunlar sırayla R, G, B renk kanallarını ifade eder.)	80
Şekil 42. BTSC veri setinde yanlış sınıflandırılan görüntüler, G: Gerçek, T: Tahmin	82
Şekil 43. Türkiye veri setinde yanlış sınıflandırılan görüntüler (G :Gerçek, T: Tahmin).....	83
Şekil 44. Modelin filtre sayısına göre test doğruluğu sonuçları.....	85
Şekil 45. Farklı sayıda filtre çekirdeği sayısı kullanarak test doğruluğu sonuçları.....	86
Şekil 46. Modelin farklı aktivasyon fonksiyonlarına göre test doğruluğu sonuçları	87
Şekil 47. Birleştirme katmanında kullanılan farklı sınıflara göre deneysel sonuçlar	88
Şekil 48. Tam bağlantılı gizli katmandaki nöron sayısına göre model test sonuçları	88
Şekil 49. Dropout oranı seçimi.....	89
Şekil 50. Yığın boyutu değerine dayalı doğruluk sonuçları.....	90

Şekil 51. Modelde kullanılan farklı optimizasyon algoritmaları için doğruluk sonuçları	90
Şekil 52. Sabit öğrenme oranı seçimi	91
Şekil 53. Kosinüs bozunumu sınıfını uygulayarak öğrenme oranı seçimi	91
Şekil 54. Farklı giriş görüntüsü boyutuyla model test sonuçları	92
Şekil 55. Giriş görüntü boyutu için a) eğitim doğruluğu, b) eğitim kaybı grafiği	93
Şekil 56. Renk uzayına göre test doğruluğu	93
Şekil 57. Renk uzayları için a) eğitim doğruluğu, b) eğitim kaybı grafiği	94
Şekil 58. Trafik ışığı sınıflandırmasının karışıklık matrisi	95
Şekil 59. Veri seti örnek görüntüler	95
Şekil 60. Örnek görüntü ön işleme sonuçları	96
Şekil 61. Örnek görüntü öznetelik çıkarım sonuçları	96
Şekil 62. Örnek görüntü yol tespit son aşamalar	97
Şekil 63. Örnek Türkiye görüntülerine ait DVR ve sonuç şerit görüntüleri	98
Şekil 64. Örnek KITTI görüntülerine ait DVR ve sonuç şerit görüntüleri	99

TABLolar DİZİNİ

	<u>Sayfa No</u>
Tablo 1. Halka açık trafik işaretleri veri setleri (Liu, Li, Chang, & Wang, 2019)	3
Tablo 2. Geleneksel makine öğrenmesi ve transfer öğreniminin kısa bir açıklaması	31
Tablo 3. Veri artırma argümanları	38
Tablo 4. Önerilen ESA mimarisinin detaylı katman bilgileri.....	38
Tablo 5. Veri artırma işlemi	42
Tablo 6. Önerilen mimarinin detayları ve katman bilgileri	43
Tablo 7. Veri artırma işlemleri	47
Tablo 8. Önerilen mimarinin detayları ve katman bilgileri	48
Tablo 9. Modellerde yapılan düzenlemeler	58
Tablo 10. VGG19 için kayıp ve doğruluk sonuçları	60
Tablo 11. ResNet50 için kayıp ve doğruluk sonuçları	60
Tablo 12. MobileNet için kayıp ve doğruluk sonuçları.....	60
Tablo 13. Xception için kayıp ve doğruluk sonuçları	61
Tablo 14. Renk uzaylarına göre test doğruluk sonuçları	61
Tablo 15. 2’li giriş görüntüleri için test doğruluk sonuçları karşılaştırma	62
Tablo 16. Görüntü boyutlarına göre test doğruluk sonuçları.....	63
Tablo 17. 3’lü giriş görüntüleri için test doğruluk sonuçları karşılaştırma	65
Tablo 18. GTSRB veri seti üzerinde performans karşılaştırması	65
Tablo 19. Çekirdek 1 kullanılarak elde edilen test doğruluk sonuçları	67
Tablo 20. Veri artırma ve ön işleme işlemlerine göre GTSRB test sonuçları	67
Tablo 21. Çekirdekler için test doğruluk sonuçları	68
Tablo 22. GTSRB veri setinde performans ve parametre sayısı karşılaştırmaları	70
Tablo 23. BTSC veri setinde performans ve parametre sayısı karşılaştırmaları	81
Tablo 24. Türkiye veri setinde performans ve parametre sayısı karşılaştırmaları.....	83
Tablo 25. Başlangıçta seçilen model parametreleri.....	84
Tablo 26. Epok sayısı ve öğrenme oranı kombinasyonlarına göre model test sonuçları (ÖO: öğrenme oranı)	92
Tablo 27. Model için metrik sonuçları	94

SEMBOLLER VE KISALTMALAR DİZİNİ

AUC	: Area Under the Curve
BN	: Yığın Normalizasyon (Batch Normalization)
BTSC	: Belgium Traffic Sign Classification
DVM	: Destek Vektör Makinesi (Support Vector Machine - SVM)
DVR	: Destek Vektör Regresyonu (Support Vector Regression - SVR)
ELU	: Üstel Doğrusal Birim (Exponential Linear Unit)
ESA	: Evrişimsel Sinir Ağı
GAP	: Global Ortalama Havuzlama (Global Average Pooling)
GPU	: Grafik İşlemci Birimi (Graphics Processing Unit)
Grad-CAM	: Gradyan Ağırlıklı Sınıf Aktivasyon Haritalaması
GSDS	: Gelişmiş Sürücü Destek Sistemleri (Advanced Driver Assistance Systems - ADAS)
GTSRB	: German Traffic Sign Recognition Benchmark
HLSGD	: Hinge Loss Stochastic Gradient Descent
HOG	: Yönlendirilmiş gradyanlar (Histogram of Oriented Gradients)
HSI	: Hue Saturation Intensity
HSV	: Hue Saturation Value
MDCNN	: Çok Sütunlu Derin Sinir Ağı (Multi-Column Deep Neural Network)
ReLU	: Doğrultulmuş Doğrusal Birim (Rectified Linear Unit)
RGB	: Kırmızı Yeşil Mavi (Red Green Blue)
ROC	: Receiver Operating Characteristic
ROI	: İlgi Bölgesi (Region of Interest)
SGD	: Stochastic Gradient Descent
SURF	: Hızlandırılmış Güçlü Özellikler (Speeded-Up Robust Features)
SEB	: Anlamsal Gömme Dalı (Semantic Embedding Branch)
Tİ	: Trafik İşareti
TKC	: Trafik Kontrol Cihazları
TSA	: Tekrarlayan Sinir Ağı (Recurrent Neural Network - RNN)
YSA	: Yapay Sinir Ağı

1. GENEL BİLGİLER

Gelişmiş sürücü destek sistemlerinde (GSDS) algılama, iletişim ve bilgi işlem teknolojilerindeki ilerlemeler sayesinde hızlı bir büyüme yaşanmıştır. GSDS, sürücünün hata yapma riskini azaltmak için uyarı vererek veya sürücüyü manuel kontrolden kurtarmak için bazı kontrol görevlerini otomatikleştirerek sürüşü desteklemeyi amaçlar. GSDS ile kazalara yol açabilecek sürücü hatalarının birçoğunun ortadan kaldırılması mümkün kılınabilir, çevresel fayda sağlanabilir, hareketliliğin verimliliği ve yol güvenliği artırılabilir. Trafiğe çıkan araç sayısının gün geçtikçe arttığı da dikkate alındığında sürücü destek sistemlerinin önemi ortaya çıkmaktadır.

Yarı otonom araçlar, yol üzerindeki durumları göz önüne alarak, hız ve direksiyon kontrolü için sürücüye sesli ve görsel uyarı yapabilmektedir. Böylece bu araçlar, sürücüye yardımcı olmak veya bazı durumlarda sürücüyü uyarıcı olarak görev yapmaktadırlar.

Gün geçtikçe trafiğe çıkan araç sayısı önemli derecede artmaktadır. Bu durum, trafik yoğunluğuna ve beraberinde trafik kazalarının artmasına sebep olmaktadır. Trafik kazalarını azaltmak için öncelikle kurallara uymak gerekmektedir. Yarı otonom araçlar ile uyarı sistemi sayesinde gerekli olan durumlarda dikkatli olunması ve kazaların önüne geçilmesi sağlanabilmektedir.

Bu tezde incelenen konu başlıkları trafik işaretleri, trafik ışıkları ve yol şerit olmak üzere 3 bölümden oluşmaktadır.

1.1. Trafik İşareti

Trafik işaretleri, sürücüleri yol koşulları ve kısıtlamaları ya da hangi yöne gidecekleri hakkında bilgilendirmek için yollara yerleştirilmiş işaretlerdir. Çevrelerinden ayırt edilebilmeleri için renk ve şekilsel olarak iyi bir şekilde tasarlanmışlardır (Mogelmose, Trivedi, & Moeslund, 2012). Trafik ortamında, işaretler trafiği düzenler, sürücüyü uyarır ve belirli eylemleri emreder veya yasaklar. Gerçek zamanlı ve sağlam bir otomatik trafik işareti tanıma özelliği sürücüyü destekleyebilir, hatalı eylemler yapmasını engelleyebilir ve böylece sürüş güvenliğini ve konforunu önemli ölçüde artırabilir (Bahlmann, Zhu, Ramesh, Pellkofer, & Koehler, 2005).

Trafik işaretlerini algılamak ve tanımak, güvenli sürüş, yol planlama, robot navigasyon vb. birçok uygulama içeren bilgisayarlı görü alanında güncel bir konudur (Zhu, ve diğerleri, 2016). Günümüzde yol algılama ve izleme adı altında yapılan çalışmalar oldukça artış göstermektedir. Böyle bir görevi yerine getirebilecek bir sistem, sürücüler için bir asistan olarak kullanılabilir, onları belirli bir işaretin (örneğin bir otoyolda önceden tanımlanmış bir çıkış) veya bazı riskli durumların (örneğin izin verilen maksimum hızdan daha yüksek bir hızda sürüş) var olduğu konusunda uyarabilir.

Trafik işareti konusu veri seti, algılama ve sınıflandırma olmak üzere 3 alt başlıkta incelenmiştir.

1.1.1. Trafik İşareti Veri Seti

Farklı ülkelerdeki trafik işaretlerini standartlaştırmayı amaçlayan, yaygın olarak Viyana Yol İşaretleri ve İşaretler Konvansiyonu olarak bilinen uluslararası bir antlaşma 1968 yılında kabul edilmiştir (Convention on Road Signs and Signals, 2024). Viyana Antlaşması'ndaki iyi tanımlanmış yasalara rağmen, anlaşmaya imza atan ülkeler arasında trafik işareti tasarımlarındaki farklılıklar varlığını sürdürmekte ve bazı durumlarda bu farklılıklar ülke içinde de olabilmektedir. Bu değişikliklerin insanlar tarafından tespit edilmesi daha kolaydır, fakat otomatik bir algılama sistemi için büyük bir zorluk teşkil edebilmektedir. Örnek olarak, farklı ülkelerdeki durma işaretinin tasarımları Şekil 1'de gösterilmiştir (Wali, ve diğerleri, 2019).

Ülke	ABD	Japonya	Pakistan	Etiyopya	Libya	Yeni Gine
İşaret						

Şekil 1. Farklı ülkelerdeki durma işaretinin tasarımları

Tablo 1. Halka açık trafik işaretleri veri setleri (Liu, Li, Chang, & Wang, 2019)

Veri seti	Amaç	Sınıf Sayısı	Toplam Görüntü	Trafik İşareti	Görüntü Boyutu	Ülke
GTSDDB	Algılama	43	900	1213	1360 x 800	Almanya
GTSRB	Tanıma	43	50-,000	50-,000	15 x 15 – 250 x 250 arası	Almanya
BTSD	Algılama	62	25634	4,627	1628 x 1236	Belçika
BTSC	Tanıma	62	7125	7125	26 x 26 – 527 x 674 arası	Belçika
TT100K	Algılama/ Tanıma	45	100000	30000	2048 x 2048	Çin
LISA	Algılama/ Tanıma	49	7855	6610	640 x 480 – 1924 x 522 arası	ABD
STS	Algılama/ Tanıma	7	20000	3488	1280 x 960	İsveç
RUG	Algılama/ Tanıma	3	48	60	360 x 270	Hollanda
Stereopolis	Algılama/ Tanıma	10	847	251	960 x 1080	Fransa
FTSD	Algılama/ Tanıma	N/A	4239	N/A	640 x 480	İsveç
MASTIF	Algılama/ Tanıma	N/A	4875	13036	720 x 576	Hırvatistan
ETSD	Tanıma	164	82476	82476	6 x 6 – 780 x 780 arası	Avrupa


Trafik işareti veri seti, herhangi bir trafik işareti algılama ve tanıma (TİAT) sisteminin geliştirilmesinde önemli bir gerekliliktir. Veri setleri, algılama ve tanıma yöntemlerini eğitmek ve test etmek için kullanılır. Trafik işareti veri seti çok sayıda trafik işareti sahnesi ve mevcut tüm trafik işareti türlerini temsil eden görüntüleri içermektedir. Bunlar, rehber, düzenleyici, geçici ve uyarı işaretleri olarak özetlenebilir. Geçtiğimiz yıllarda, tanıma ve izleme görevi için trafik işareti veri setleri oluşturulmaya çalışılmıştır. Bu veri setlerinin

bazıları araştırma topluluğu tarafından halka açık olarak sunulmaktadır. Kamuya açık veri setleri ile ilgili ayrıntılı bilgiler Tablo 1 ile özetlenmiştir.

Luo vd. (2017) 'ne göre, ilk ve en çok kullanılan veri seti, iki veri setine sahip olan Alman trafik işaretleridir. Bunlar, Alman Trafik İşaretleri Tespit Seti (German Traffic Sign Detection Benchmark - GTSDDB) (Houben, Stallkamp, Salmen, Schlipsing, & Igel, 2013) ve Alman Trafik İşaretleri Tanıma Seti (German Traffic Sign Recognition Benchmark - GTSRB) (Stallkamp, Schlipsing, Salmen, & Igel, 2011) 'dir. Bu veri setleri, üç önemli yol işareti kategorisini (yasaklayıcı, tehlike ve zorunlu) içeren çeşitli trafik sahnelerinden oluşmaktadır. Veri setinde, tüm trafik işaretleri için dikdörtgen ilgi bölgelerine ilişkin açıklamalara yer verilmiştir. Ayrıca, Luo vd. (2017)'ne göre bu veri setleri, sadece statik görüntülerdeki sembol tabanlı işaretlerin algılanmasına ve sınıflandırılmasına erişim sağlamış ve bu iki adımı ayrı olarak değerlendirmiştir. Bununla birlikte, pratik bir trafik işareti tanıma sistemi için, trafik sahnesinde mevcut işaretleri tanımak nihai görevdir. Başka bir deyişle, bir sistemin bu iki görevi bir araya getirmesi gerekmektedir. Dahası, elde edilmesi gereken veriler statik görüntüler değil genellikle videolardır. Bu nedenlerden dolayı GTSDDB ve GTSRB, pratik trafik işareti tanıma sistemlerini değerlendirmek için uygun değildir.


GTSRB:

GTSRB veri seti 43 sınıfa trafik işaret görüntülerinden oluşmaktadır. Eğitim seti içerisinde 39209 ve test seti içerisinde 12630 görüntü bulunmaktadır. Görüntü boyutları 15x15'ten 250x250'ye değişiklik göstermektedir. Veri setine ait her bir sınıf için örnek görüntüler Şekil 2 ile gösterilmiştir. Görüntüler incelendiğinde görüntülerin farklı aydınlanma, parlaklık, bulanıklık ve açı koşullarında çekildiği görülmektedir.



Şekil 2. GTSRB veri seti örnek görüntüler

Veri setinde bulunan sınıflara ait görüntü sayıları eşit dağılım göstermemektedir. Her bir sınıfa ait görüntü sayılarını ifade eden histogram Şekil 3 ile verilmiştir.




Şekil 3. GTSRB her sınıfa ait görüntü sayıları histogramı

BTSC:

BTSC (Belgium Traffic Sign Classification) veri setinde eğitim içerisinde 4591, test içerisinde 2534 trafik işareti görüntüsü bulunmaktadır. Görüntüler 11 x 10 ile 562 x 438 arasında çözünürlük değerlerine sahiptir (Saha, Kamran, & Sabbir, 2018, December). Trafik işareti sınıf sayısı 62'dir. Veri setindeki görüntüler, farklı aydınlanma koşulları, örtüşme (occlusion) gibi bozukluklar da içermektedir. Hem bu yüzden hem de sınıf sayısının fazla olmasına rağmen veri setindeki görüntü sayısının az olmasından dolayı eğitim, GTSRB veri setine kıyasla daha zordur. Veri setinde her bir sınıfa ait örnek görüntüler Şekil 4 ile verilmiştir. GTSRB veri setine benzer olarak sınıf içi görüntü sayısı dağılımı eşit değildir. Her sınıfa ait görüntü sayılarını içeren histogram Şekil 5 ile verilmiştir.




Şekil 4. BTSC veri setinin her bir sınıfı için örnek görüntüler




Şekil 5. BTSC her sınıfa ait görüntü sayıları histogramı

Üretilen Türkiye trafik işareti veri seti:

Görüntüler, Türkiye’de Karadeniz Bölgesi başta olmak üzere farklı bölgelerde, şehir içi ve şehirlerarası yollarda araç içerisinden çekilmiştir. Çekilen görüntüler 3472 x 4624 çözünürlüğe sahiptir. Yol görüntülerinden trafik işaretleri çıkarılarak veri seti oluşturulmuştur. Üretilen veri seti 42 sınıf içermektedir. Toplam görüntü sayısı 5275’tir. Görüntüler farklı çözünürlük, parlaklık vb. gibi bozukluklar içermektedir. Bu görüntüler, sıklıkla kullanılan trafik işareti sınıflarını içermektedir. Sınıflara ait örnek görüntüler Şekil 6 ile verilmiştir. Sınıflar arası görüntü dağılımı eşit değildir. Kullanım sıklığına bağlı olarak görüntü sayısı değişiklik göstermektedir. Her sınıfa ait görüntü sayılarını ifade eden histogram Şekil 7 ile verilmiştir.



Şekil 6. Üretilen Türkiye veri setinde her bir sınıf için örnek görüntüler



Şekil 7. Türkiye veri seti her sınıfa ait görüntü sayıları histogramı

1.1.2. Trafik İşareti Algılama

Otonom araçlarda trafik işaretleri, sürücülere ortamdaki kurallar, yasaklar veya uyarılar hakkında bilgi vererek yol gösterici olabilmektedir (Escalera, Moreno, Salichs, & Armingol, 1997). Tanıma ve sınıflandırma işlemleri için birçok farklı yöntem geliştirilmiştir. Trafik işaretlerini otomatik tanıma çalışmalarının temeli 1990'lı yıllara dayanmaktadır. Trafik işareti algılama yöntemleri üç ana kategoriye ayrılabilir: renk tabanlı, şekil tabanlı ve makine öğrenimi tabanlı yöntemler (Zhu, ve diğerleri, 2016). Trafik işaretleri genellikle kırmızı, sarı ve mavi olduğu için çalışmalarda renk tabanlı yöntemler yaygın olarak kullanılmıştır. Bu yöntemler aydınlatmadaki değişikliklere karşı duyarlı olduklarından, yöntemlerde normalize edilmiş RGB (Red Green Blue, Kırmızı Yeşil Mavi) (Escalera, Moreno, Salichs, & Armingol, 1997) ve HSI (Hue Saturation Intensity) (Maldonado-Bascon, Lafuente-Arroyo, Gil-Jimenez, Gomez-Moreno, & López-Ferreras, 2007) gibi birçok renk uzayı sıklıkla kullanılmıştır.

Şekil tabanlı yöntemler, aydınlatmada daha sağlam değişiklikler içeren trafik işaretlerini tespit etmek için daire, üçgen ve kare gibi trafik işaretlerinin şeklini kullanmıştır

(Zhu, ve diğerleri, 2016). García-Garrido vd.'nin (2005) çalışmasında kenar görüntüsünün Hough dönüşümüne bakılmış ve görüntüdeki şekil yalnızca açılımlarına dayanılarak algılanmıştır. Hough dönüşümü genellikle daireler ve üçgenler gibi trafik işaretlerini tespit etmek için kullanılmıştır.

Yucong ve Shuqing'in (2021) çalışmasında temel olarak gradyan özellik çıkarma yönteminin histogramı kullanılarak trafik işaretlerini tanımlanmaktadır. Görüntü, bir görme sensörü tarafından toplanır ve ön işleme tabi tutulur. Renk eşik segmentasyonu yöntemi ve morfolojik işleme, arka plan alanının girişimini azaltmak ve işaret alanının dış hatlarını geliştirmek için kullanılmıştır. Son olarak, trafik işaretlerini tanımlamak için hücre birimindeki her piksel noktasının gradyanını veya kenarın yön histogramını toplamak için HOG (Histogram of Oriented Gradients, yönlendirilmiş gradyanlar) yöntemi kullanılmıştır. MATLAB simülasyonu sayesinde HOG görüntüden özellik çıkarma yönteminin yüksek doğruluk, küçük hata ve kısa tanıma süresine sahip olduğu, bu da algoritmanın etkinliğini göstermektedir.

Son zamanlarda, trafik işaretlerini algılamak için makine öğrenmeye dayalı nesne algılama yöntemleri dikkate alınmıştır. Trafik işareti tespitinde kayan pencere tabanlı yöntemler ve ROI (Region of Interest, ilgi bölgesi) tabanlı yöntemler bulunmaktadır (Luo, Yang, Tong, Wu, & Fan, 2017). Trafik işareti tespit etmek ve iyi sonuçlar elde etmek için HOG (Creusen, Wijnhoven, Herbschleb, & With, 2010, September) ve Viola-Jones (Baro, Escalera, Vitria, Pujol, & Radeva, 2009) kullanan kayan pencere tabanlı yöntemler önerilmiştir. Fakat bu yaklaşımlar zaman alıcıdır. Ayrıca kayan pencere boyutunu ve en boy oranını belirlemek zordur (Luo, Yang, Tong, Wu, & Fan, 2017). İlâveten, gerçek zamanlı trafik işareti tespiti ve tanınması gerektiğinden, bu yöntemler pratik kullanımdan uzaktır (Zhu, ve diğerleri, 2016).

Liang vd.'nin (2013) çalışmasında ROI çıkarımı ile trafik işareti algılama gerçekleştirilmiştir. Bunların dışında evrişimsel sinir ağı ve kapsül ağları gibi farklı yöntemler de önerilmiştir. Wu vd.'nin (2013, August) çalışmasında ilk önce, destek vektör makinelerini kullanarak orijinal görüntü gri ölçeğe dönüştürülmüş, daha sonra tespit ve tanıma için sabit ve öğrenilebilir katmanlara sahip evrişimsel sinir ağları kullanılmıştır. Lee ve Kim (2018) çalışmasında evrişimsel sinir ağı kullanılarak trafik işaretlerinin yerini ve kesin sınırını aynı anda tahmin eden yeni bir trafik işareti tespit sistemi önerilmiştir. Kapsül ağlarını kullanan (Kumar, 2018) çalışmasında, bulanık, döndürülmüş ve bozuk görüntülerde

bile sınıflandırma ve tanıma işlemleri doğru şekilde gerçekleştirilerek güvenilirlik arttırılmıştır.

Yao vd. düşük aydınlatma koşullarında trafik işaretlerini tespit etme ve tanımanın zorluğu gibi sorunları çözmek için yeni bir düşük aydınlatmalı trafik işareti tespit ve tanıma algoritması önermiştir (Yao, Huang, Yang, Xiang, & Lu, 2023). İlk olarak düşük aydınlatmalı görüntüleri filtrelemek için bir aydınlatma değerlendirme algoritması, ardından düşük aydınlatmalı görüntülerin parlaklığını ve kontrastını ayarlamak için yeni aydınlatma geliştirme algoritması kullanılmıştır. Son olarak trafik işaretlerini algılamak ve tanımak için Maske Bölge Tabanlı Evrişimsel Sinir Ağı kullanılmıştır.

1.1.3. Trafik İşareti Sınıflandırma

Otomatik trafik işareti algılama ve tanıma sistemi, GSDS'nin geliştirilmesinde çok önemli bir araştırma konusudur. Görüntü temelli trafik işareti algılama ve tanıma ile ilgili çalışmalar, çoğunlukla algılama, izleme ve sınıflandırma olmak üzere üç ana kategoriye ayrılmakta ve araştırma toplulukları tarafından büyük ilgi görmektedir. Bu bağlamda, son yıllarda trafik işareti algılama ve tanıma alanında önemli sayıda çalışma yapılmıştır (Wali, ve diğerleri, 2019).

Genel olarak trafik işaretleri insanlar tarafından kolayca tanınabilir ve yorumlanabilir. Bununla birlikte, aydınlatma, hava durumu, trafik işaretlerinin dışarıdan görünüşü gibi bazı nedenlerden dolayı otomatik sistemler için trafik işaretlerini yorumlamak oldukça zor olmaktadır. Mevcut zorlukların trafik tanıma üzerindeki etkilerinin ortadan kaldırılması için, özellik ve derin öğrenme tabanlı teknikler olmak üzere, yaklaşımlar iki kategoriye ayrılmış ve bu bağlamda otomatik trafik işareti tanıma yaklaşımlarını araştırmak için literatürde bazı çalışmalar yapılmıştır (Lin, Li, Luo, Wang, & Guo, 2019). Derin öğrenme tabanlı yöntemlerde çoğunlukla yüksek doğruluk sağlayan ESA (Evrişimsel Sinir Ağı)'nın kullanıldığı görülmektedir (Sermanet & LeCun, 2011; Shustanov & Yakimov, 2017; Luo, Yang, Tong, Wu, & Fan, 2017).

Tanıma ve sınıflandırma işlemleri için pek çok farklı yöntem geliştirilmiştir. Trafik işaretlerinin sınıflandırılması genel olarak geleneksel sınıflandırma ve derin öğrenmeye dayalı yöntem yaklaşımları olmak üzere iki ana başlıkta incelenmektedir.

Geleneksel trafik işareti tanımda yaygın olarak kullanılan algoritmalar; eşleştirme algoritması, kenar analizi algoritması ve makine öğrenimi tabanlı algoritmadır (Luo, Yu, Bi, & Li, 2020).

Özellik çıkarımı için SURF (Speeded-Up Robust Features, Hızlandırılmış Güçlü Özellikler) (Bay, Tuytelaars, & Gool, 2006) yöntemi trafik işareti tanıma konusunda yaygın olarak kullanılmaktadır (Arifin, Irawan, & Setianingsih, 2017; Abedin, Dhar, & Deb, 2016; Ren, Huang, Jiang, & Klette, 2009). Ayrıca (Ren, Huang, Jiang, & Klette, 2009)'da ön işleme aşamasında RGB yerine HSV (Hue Saturation Value) renk uzayı kullanılmıştır. (Wang, Shi, & Wu, 2009, September) çalışmasının ilk aşamasında Lab renk uzayı oluşturulmuştur. Hough Dönüşümü trafik işaretlerinin yerini tespit etmek için geliştirilmiştir. Trafik işareti tanıma aşamasında şablon eşleştirme algoritması kullanılmaktadır.

Makine öğrenimi tabanlı algoritmalar arasında en çok kullanılanlar DVM (Destek Vektör Makinesi) ve sinir ağı tabanlı algoritmalarıdır. DVM, sınıflandırma ve regresyon analizi için kullanılan verileri analiz eden ilişkili öğrenme algoritmalarına sahip denetimli öğrenme modelleridir.

García-Garrido vd. (2012) çalışmasında, tespit aşamasında sınır görüntülerinden öznitelikler elde etmek için sınırlı bir Hough dönüşümü uygulanmış ve sınıflandırma aşamasında Gauss çekirdekli iki DVM kullanılmıştır.

Derin öğrenmeye dayalı yöntemlerde, yüksek doğruluk ürettiği için çoğunlukla trafik işareti tanıma amacıyla ESA mimarisi kullanılmaktadır (Cireşan, Meier, Masci, & Schmidhuber, 2011; Ciregan, Meier, & Schmidhuber, 2012; Wong, Shafiee, & Jules, 2018). (Cireşan, Meier, Masci, & Schmidhuber, 2011)'da, özellik çıkarıcıdan bağımsız olarak çalışabilen, tamamen parametrelili bir algoritma sunulmaktadır. Bu çalışmada ESA ile GPU (Graphics Processing Unit, Grafik İşlemci Birimi) kullanılmıştır.

MicronNet'te (Wong, Shafiee, & Jules, 2018) parametre sayısı azaltılarak mümkün olan en yüksek doğruluğa ulaşılması amaçlanmıştır.

Algılama, iletişim ve bilgi işlem teknolojilerindeki ilerlemeler sebebiyle GSDS'de dünya çapında hızlı bir büyüme görülmüştür. GSDS, günümüz akıllı arabalarının en önemli parçalarındandır. Bu sistemlerin araçlara kazandırdığı işlevlerden biri trafik işaretlerini tanımdır. GSDS, sürücülerin bazı kararlarını makine kararlarıyla değiştirebilmektedir. Bu açıdan GSDS, kaza ile sonuçlanabilecek birçok sürücü hatasını önleyerek daha güvenli ve sorunsuz araç sürüşü sağlar (Piao & Mike, 2008).

Trafiğin karayolu üzerinde sorunsuz akabilmesi, alışlagelmiş yaşam eylemlerinin belirli bir sistem ve düzen çerçevesinde güvenli bir şekilde devam edebilmesi gibi ihtiyaçlar Trafik İşaretleri (Tİ)'nin ortaya çıkmasına neden olmuştur. Tİ'nin tasarımı yapılırken ortamdaki diğer nesnelere göre ayırt edilebilir olmalarına ve konuşulan dilden bağımsız olarak kolayca anlaşılabilir olmalarına dikkat edilir. Bu amaçla, trafik işaretleri üçgen, daire, dikdörtgen veya çokgen gibi düzgün ve basit geometrik şekiller kullanılarak tasarlanır. Tİ'nin renkleri genellikle mavi, sarı, siyah, yeşil, beyaz ve kırmızı gibi temel renklerden seçilir. Tİ, yüksek nitelikli tasarımlar olup her birinin trafik-hukuk düzeni içerisinde özel anlamları mevcuttur (Sermanet & LeCun, 2011).

Tİ, sürüş güvenliği açısından da büyük önem arz etmektedir. Sürüş esnasında Tİ'nin dikkatli bir şekilde takip edilip, bu işaretlere göre gerekli aksiyonların alınması gerekmektedir. Ancak, dikkat dağınıklığı ve diğer çevre etkenleri gibi sebeplerle Tİ'nin fark edilmesi zorlaşabilmektedir. Bu tarz olumsuzlukların ortadan kaldırılabilmesi konusunda akıllı araçların önemi günden güne daha fazla hissedilmektedir (Fu & Huang, 2010). Akıllı araçlar üzerlerinde bulundurdıkları sensörler yardımıyla seyahat ettikleri yol üzerinde gerçek zamanlı olarak veri toplarlar. Topladıkları bu verileri işleyerek Tİ'ni otomatik olarak algılayabilirler (Wali, ve diğerleri, 2019).

Trafik işareti tanıma ile Tİ türleri etkili bir şekilde sınıflandırılır. Bu sınıflandırmadaki en temel zorluk ise farklı çevre koşullarında algılanan verilerin kalitelerinin farklı olmasıdır. Genel olarak görüntü kalitesi birkaç değişkenden etkilenebilmektedir. Bu değişkenler, yol verileri toplanırken kullanılan kameranın çözünürlük kalitesi, çekilen görüntünün çok parlak, çok loş veya spot ışıkları içermesi, görüntünün çekildiği andaki hava koşulları, araç hareketinden kaynaklanan hareket bulanıklığı ve görüntünün çekildiği ortamda Tİ'ni gizleyen nesneler olarak sıralanabilir. Aslında bu zorlukların ana kaynağı kontrol edilemeyen çevre koşullarıdır (Li, Ma, Huang, & Li, 2018).

Derin öğrenme kullanan trafik işareti tanıma algoritmaları, tanıma doğruluğu hususunda yüksek performans sunsalar da bu algoritmalar fazlasıyla karmaşıktırlar ve hesaplama maliyetleri yüksektir. Bu nedenle, çeşitli sınırlamalarla karşı karşıyalardır. Dolayısıyla, trafik işareti tanıma algoritmalarında daha fazla iyileştirmeye gereksinim duyulduğu söylenebilir. Bu noktada, çeşitli görüntü iyileştirme tekniklerinin kullanılması, bahsedilen zorluklara daha iyi performans gösteren bir çözüm olabilir. Böylece, ağ karmaşıklığı basitleştirilirken daha iyi doğruluk elde edilebilir (Shustanov & Yakimov, 2017).

Trafik işareti tanıma için yapılan çalışmalar geleneksel yöntemler ve öğrenme tabanlı yöntemler olmak üzere ikiye ayrılabilir. Geleneksel yöntemlerde şekil, renk gibi özellikler için görüntü işleme tekniklerinin kullanılmasıyla öznelik elde edilerek sınıflandırma gerçekleştirilir. Fakat son zamanlarda, hız ve performans üstünlüğü nedeniyle derin öğrenme tabanlı yaklaşımların ön plana çıktığı görülmektedir. O yüzden bu çalışmada derin öğrenme tabanlı yöntemler incelenmiştir.

Sermanet vd. (2011) GTSRB Yarışması Aşama I'de %98.97'lik doğruluk üreten çok ölçekli bir ConvNets ağı önermişlerdir. Ağ mimarisi 2 aşamalı yapıdan oluşmaktadır. İlk aşamada elde edilen öznelikler 2. aşamayla birlikte sınıflandırma katmanına da beslenir. Böylece daha yüksek doğruluk elde edilmesi hedeflenmiştir. Burada görüntüler 32 x 32 olarak yeniden boyutlandırılmıştır ve YUV renk uzayı kullanılmıştır. Aşama I sonrası ise var olan ağ daha da genişletilerek ve renkli yerine gri görüntüler kullanılarak %99.17 doğruluğa ulaşılmıştır.

Ciregan vd. (2012), Tİ sınıflandırma problemi için önceden işlenmiş veriler üzerinde eğitilmiş farklı derin sinir ağları içeren birçok sütunlu MCDNN (Multi-Column Deep Neural Network, Çok Sütunlu Derin Sinir Ağı) yaklaşımını önermişlerdir. Bu çalışmada GTSRB veri setini kullanılmıştır. Bu veri setinin dezavantajlarını iyileştirmek amacıyla görüntü ayarlama, histogram eşitleme, uyarlanabilir histogram eşitleme ve kontrast normalleştirme gibi ön işleme adımları uygulanmıştır. MCDNN yaklaşımı bütün eğitim görüntülerinin aynı boyutta olmasını gerektirdiğinden, tüm görüntüler 48x48 olarak boyutlandırılmıştır. Beş veri setinin her biri için 5 ağ olmak üzere, toplamda 25 ağ eğitilmiştir. 25 derin sinir ağı sütunu ile önerilen MCDNN, %99.46'lık bir tanıma oranı elde edilmiştir. Ancak, 25 sütunlu MCDNN'yi eğitmek dört GPU'da yaklaşık 37 saat sürmektedir. Bu yaklaşımın performansı kullandığı parametrelerin sayısı nedeniyle zayıftır (38.5 M).

(Jin, Fu, & Zhang, 2014) çalışmasında HLSGD (Hinge Loss Stochastic Gradient Descent) adı verilen bir yöntem önerilmiştir. Orijinal görüntü, histogramla eşitlenmiş görüntü, görüntü yoğunluk değerlerini ayarla ve kontrast sınırlı uyarlanabilir histogramla eşitlenmiş görüntü olmak üzere 4 farklı ön işleme gerçekleştirilmiştir. Bu ön işlemlerin her biri için 5 ESA ağı eğitilmiştir. Topluluk (ensemble) yönteminde ise 4 farklı ön işlem ve her biri için 5 ESA eğitimi olacak şekilde toplam 20 ESA ağı elde edilmiştir. Topluluk yöntemin doğruluğu %99.65 olarak hesaplanmıştır. Tek bir ESA ağında 1,162,284 eğitilebilir parametre bulunan topluluk ağında toplam yaklaşık 23.2 M parametre bulunmaktadır.

Aghdam vd. (2017) yeni bir ConvNets mimarisi sunmuşlardır. Mimaride, başlangıçta verilen evrişim bloğu 2 paralel bloklara ayrılmış ve sonrasında birleştirme yapılmıştır. Ayrıca bu mimariden tam bağlantılı katmanı çıkarılarak kompakt bir versiyonu daha üretilmiştir. Son olarak en az sayıda ConvNets kullanarak daha iyi performans elde edilecek bir topluluk yöntemi önerilmiştir. Önerilen topluluk yöntemle %99.61 doğruluğa ulaşılmıştır.

Arcos-García vd. (2018), GTSRB veri kümesi üzerinde evrişimli katmanlar ve uzamsal dönüştürücü ağırları içeren bir Derin Sinir Ağı kullanan bir Tİ tanıma sistemi önermişlerdir. Bu sistem ile Tİ görüntüleri, ince taneli bir sınıflandırmaya tabi tutulmuştur. 3 uzamsal dönüştürücülü ESA, açık geometrik dönüşümler gerçekleştirerek arka plan ve geometrik gürültüyü kademeli olarak baskılar. Global normalizasyon ve Gauss çekirdekleriyle görüntülerin kenarları iyileştirilmiştir. Bu çalışmadaki ağ, 14.6 M parametreye sahiptir. Önerilen bu ağ mimarisi ile GTSRB ve BTSC veri setlerinde sırasıyla %99.71 ve %98.86'lık bir tanıma performansı elde edilmiştir.

Saha vd. (2018, December) birden fazla veri seti için yüksek başarımlı elde edilen yeni bir mimari önermişlerdir. Mimari içerisinde hiyerarşik olarak genişletilmiş atlama bağlantısına sahip artık ESA ağı kullanılmıştır. Çalışmanın GTSRB ve BTSC veri setleri için performans sonuçları sırasıyla %99.33 ve %99.17 olarak hesaplanmıştır. Mimarinin parametre sayısı 6.256 M'dir.

(Zhang, Wang, Lu, Wang, & Sangaiah, 2020) çalışmasında student (öğrenci) ve teacher (öğretmen) adı verilen 2 hafif derin evrişimsel sinir ağı önerilmiştir. Daha fazla parametre sayısına sahip öğretmen modelden bilgi damıtma yapılarak daha az parametreye sahip öğrenci modelinin performansı ölçülmüştür. Öğrenci modeli 0.8 milyon parametreye sahiptir. GTSRB ve BTSC veri setleri için öğrenci modelin performans sonuçları sırasıyla %99.61 ve %99.13'tür.

Nartey vd. (2020) küçük ve değişken sayıda veri içeren sınıflara sahip veri setleri için yeni bir yarı denetimli yöntem sunmuşlardır. Kendi kendine eğitim ile sözde etiketli örnek oranı %20 seçildiğinde GTSRB veri seti üzerinde 99.27% doğruluğa ulaşılmıştır. Benzer şekilde örnek oranı %40 olduğunda BTSC üzerinde %98.97 doğruluk elde edilmiştir.

Bayoudh vd. (2021) 2D - 3D dönüşümüne sahip transfer öğrenimi kullanan yeni bir model önermişlerdir. Burada, 2D öznetelikleri işleyen derin ağ modeli önceden eğitilmiş ve 3D dönüşümü ile elde edilen öznetelikler daha sık olan bir modele verilmiştir. Bu hibrit

modelle daha az parametre ile hızlı öğrenme yapılması amaçlanmıştır. GTSRB veri seti üzerinde %99.28 doğruluğa ulaşan modelin toplam parametre sayısı 4 M'dir.

Bi vd. (2021) trafik işaretlerini tanıma için geliştirilmiş bir VGG-16 ağı sunmuşlardır. VGG-16 ağında fazla görülen evrişim katmanları tasarlanan ağa dâhil edilmez ve böylece parametre sayısı azaltılmış olur. Ayrıca GAP (Global Average Pooling, Global Ortalama Havuzlama) ve BN (Batch Normalization, Yığın Normalizasyon) katmanı eklenerek daha düşük parametre ile yüksek doğruluğun elde edilmesi planlanmıştır. Bu haliyle ağıdaki toplam parametre sayısı 1.15 milyondur. GTSRB veri setindeki doğruluk değeri ise %99.21 olarak elde edilmiştir. Çalışmanın geçiş testinde, önceden eğitilmiş BTSC veri seti ile %99.02 doğruluk elde edilmiştir. Sonuç olarak yöntem düşük parametre sayısına sahip olmasına rağmen, literatüre göre daha düşük doğruluk değerine ulaşmıştır.

(Haque, Arefin, Shihavuddin, & Hasan, 2021) çalışmasında Deeptin adı verilen ince - tek sıra fakat derin olan yeni bir mimari önerilmiştir. Düşük parametre sayısına sahip modelde, her evrişim katmanı eğitilebilir 50'den az özellik barındırmaktadır. Model giriş görüntüsü için hem RGB, hem gri renk kullanılmıştır. GTSRB veri seti için doğruluk sonuçları renkli ve gri giriş görüntüleri için sırasıyla %99.42 ve %99.40 olarak hesaplanmıştır. Ayrıca gri ve renkli görüntüler için 3'er model birleştirilip eğitilerek topluluk model oluşturulmuştur. 2.69×10^5 parametreye sahip topluluk modelin doğruluk sonucu ise %99.72'dir. Ayrıca, BTSC veri seti için transfer öğrenme ve sıfırdan öğrenme ile model performansı incelenmiştir. Sıfırdan öğrenme ile %98.97 test doğruluğu elde edilirken, transfer öğrenme ile %99.29 doğruluk elde edilmiştir.

Patel vd. trafik işareti tanıma sistemi üzerinde düzenleme işlemlerinin etkisini incelemişlerdir (Patel, Shukla, Shrivastava, & Gyanchandani, 2022). Kullanılan işlemler L1, L2, Dropout, and BN'dir. Sonuçlar incelendiğinde BN ve Dropout'un birlikte kullanılmasıyla GTSRB veri seti üzerinde %99.56 doğruluğa erişildiği görülmektedir.

Zhang ve Huang çalışmasında hızlı ve yüksek doğruluğa sahip trafik işareti tanıma modeli önermişlerdir (Zhang & Huang, 2022). Önerilen model öznetelik çıkarımı aşamasında geliştirilmiş Inception modülü ve çok ölçekli öznetelik birleştirme kullanılmıştır. Model parametre sayısını azaltarak hızlı bir eğitimin yapılması için de GAP ve BN kullanılmıştır. Bu model ile GTSRB veri setinde %99.6 doğruluğa ulaşılmıştır.

Zheng ve Jiang çalışmasında evrişimsel sinir ağı ve dönüştürücülerin trafik işareti tanıma üzerine performans karşılaştırması yapılmıştır (Zheng & Jiang, 2022). Bunun için 7 evrişimsel sinir ağı ve beş görü dönüştürücü model denenmiştir. 3 farklı veri seti üzerinde

yapılan çalışmada evrişimsel sinir ağına kıyasla dönüştürücüler ile daha düşük doğruluk elde edildiği görülmüştür. GTRSB veri seti özelinde dönüştürücülerle en iyi test sonucuna %86.03 ile ulaşılmıştır. Çalışmada en yüksek doğruluk üreten ESA ağı ise %98.84 ile VGG16 olmuştur. Doğruluk metriği üzerinden kıyaslama yapıldığında iki model arasında oldukça yüksek performans farkı olduğu görülmektedir. Kısaca, trafik işareti tanıma özelinde görü dönüştürücüler ESA ağlarına göre daha düşük performans göstermişlerdir.

Fang vd. (2022) MicronNet mimarisi üzerinde BN ve çarpanlara ayırma uygulayarak iyileştirme gerçekleştirmiştir. Böylece GTSRB veri seti üzerinde MicronNet'e göre hem parametre sayısını azaltmış hem de doğruluk değerini artırmıştır. 0.44 M parametre sayısı ile MicronNet-BF modeli GTSRB'de %99.38 doğruluğa ulaşmıştır.

(Youssof, 2022) çalışmasında hem trafik işareti tanıma hem de trafik işareti sınıflandırma için yeni yöntemler önermiştir. Sınıflandırma bölümünde önerilen ESA ağı 0.8 M parametreye sahiptir. ESA ağı ile GTSRB veri setinde %99.20 doğruluk değeri elde edilmiştir.

(Lim, Lee, Lim, & Ong, 2023) çalışmasının birincil amacı, ResNet50, DenseNet121 ve VGG16 gibi önceden eğitilmiş modellerden yararlanmaya odaklanarak, trafik işaretlerinin sınıflandırılmasında evrişimsel sinir ağlarının uygulamasını araştırmaktır. Modelin doğruluğunu ve dayanıklılığını artırmak için yazarlar, çoğunluk oylamasını kullanan bir toplu öğrenme yaklaşımını benimsemiştir. Bu yaklaşım, birden çok ESA'nın çıktılarını toplayarak modelin performansını artırmıştır. Üç farklı veri seti üzerinde yapılan çalışmada topluluk yaklaşımı ile GTSRB'de %98.84, BTSD'de %98.33 ve TSRD'de %94.55 tanıma doğruluğu elde edilmiştir.

Yapılan çalışmalar incelendiğinde çoğunlukla önerilen model, ya tek bir veri setinde yüksek doğruluk elde etmiştir ya da düşük parametre sayısına sahiptir. Farklı veri setleri ile çalışılan çalışmalarda ise daha düşük doğruluk sonuçlarının elde edildiği gözlemlenmiştir. Bizim çalışmamızda ise farklı veri setleri için etkin, güçlü, yüksek doğruluğa sahip bir model önerilmiştir.

1.2. Trafik Işıkları

Trafik ışığı tanıma, gelişmiş bir GSDS ve otonom araçlar için önemli bir role sahiptir. Son zamanlarda, derin öğrenme, yüksek sınıflandırma performansı nedeniyle görme tabanlı

nesne tanıma uygulamalarında giderek daha popüler hale gelmiştir. Bu tez kapsamında da trafik ışıkları tanıma işlemlerine yer verilmiştir.

Ulaşım, insan hayatının önemli bir parçası olduğundan, insan sağlığı, refahı ve güvenliği ile önemli derecede ilişkilidir. Ulaştırma sistemlerinde meydana gelmesi muhtemel birçok yenilik ve gelişme, iletişim, algılama ve işleme teknolojilerinden beklenmektedir (Sussman, 2008; Papadimitratos, Fortelle, Evenssen, Brignolo, & Cosenza, 2009). 21. yüzyılda farklı ihtiyaçlar ve nedenler dolayısıyla karayolu taşımacılığında büyük artışlar yaşanmış ve ülkelerin karayolu ağları meydana gelen bu trafik yükünü gün geçtikçe kaldıramaz hale gelmiştir. Bu nedenle, sürücülerini yönlendirmek ve uyarmak, trafik kurallarını düzenlemek amacıyla Trafik Kontrol Cihazları (TKC) geliştirilmiştir. TKC'ler; kaldırım işaretleri, trafik lambaları ve işaretler gibi sürücülerle iletişim kurarak, sürücüler için verimli ve güvenli ulaşım sağlayan trafik altyapı birimleridir (Jensen, Philipsen, Møgelmoose, Moeslund, & Trivedi, 2016). Bu birimler, karayollarını ortak kullanan herkes için koyulan trafik kurallarını denetleyen pratik sistemlerdir. Ancak, TKC'ler, kurallara uyulmadığında işlevsiz hale gelir ve bu durumun tehlikeli sonuçları olabilir. Örneğin, bir sürücü, kırmızı ışıktaki durma kuralının uygulandığı bir bölgede, kavşakta yanan bir kırmızı ışıktaki durmazsa, can ve mal kaybı ile sonuçlanabilecek bir kazaya neden olabilir. Sürücü hatası kasıtlı olabileceği gibi, dikkat dağınıklığı, stres, hatalı TKC'ler, yanlış anlamalar vb. gibi nedenlerden ötürü kasıtsız da olabilir (Jensen, Philipsen, Møgelmoose, Moeslund, & Trivedi, 2016).

Sürücü yardım sistemleriyle çevre izlemesi yapılarak ve kritik durumlarda sürücü uyarılarak (gerekirse müdahale edilerek) trafik kazaları önlenabilir. Son yıllarda farklı otomotiv şirketleri tarafından birçok GSDS geliştirilmiştir (Kim, Park, & Jung, 2018). Modern GSDS'ler çoğunlukla görüş tabanlıdır, ancak GSDS'lerde ışık algılama, menzil (lidar), radyo algılama, menzil (radar) ve diğer algılama teknolojileri de kullanılmaktadır (Kukkala, Tunnell, Pasricha, & Bradley, 2018).

GSDS'lerin en önemli çalışma alanlarından biri trafik ışıklarıdır. Trafik ışıkları, ulaşım için ortak yolları kullanan yayalar ve araçlar gibi trafik üyelerini geçiş hakkı konusunda bilgilendirerek trafik akışını düzenler (Jensen, Philipsen, Møgelmoose, Moeslund, & Trivedi, 2016). Trafik ışıklarının yapısı birçok ülkede birbirine benzerdir. Genellikle, dikey olarak sıralanmış, yeşil, sarı ve kırmızı renklerde üç dairesel göstergeden oluşurlar (Diaz, Cerri, Pirlo, Ferrer, & Impedovo, 2015). Otonom araçlarda, trafik ışığı tanıma teknolojisi, trafik ışıklarının durumu, rengi ve sayısı ile her bir trafik ışığı tarafından kontrol edilen şeritler

hakkında bilgi edinilmesini sağlar (Charette & Nashashibi, 2009; Fairfield & Urmson, 2011; Possatti, ve diğerleri, 2019). Doğru tanıma yapan bir trafik ışığı tanıma sistemi tasarlanırken, dış ortam koşullarının çeşitliliği ve aracın ego hareketi nedeniyle farklı zorluklarla baş etmek gerekebilmektedir. Bu zorluklardan bazıları şu şekilde sıralanabilir (Liu W. , ve diğerleri, 2016):

1. Sürekli değişen ortam,
2. Sokak lambaları ve reklam panoları gibi ışık kaynaklarından dolayı oluşan engeller,
3. Farklı hava ve aydınlatma koşullarının etkisi,
4. Aracın ego hareketi nedeniyle trafik ışıklarının boyutlarının ve görüş açısının değişmesi,
5. Trafik ışıklarının çeşitli görünüşleri, örneğin bazı trafik ışıklarında geri sayım sayacı bulunmaktadır, bazılarında ise yoktur,
6. Farklı şekillerle farklı anlamlar belirten trafik işaretlerinin varlığı,
7. Akıllı telefonların ve sabit kameraların bulanıklığa veya renk bozulmalarına neden olabilecek otomatik beyaz dengesi ve otomatik odaklama işlevi,
8. Trafik ışığı tanıma algoritmasının gerçek zamanlı olmaması (Gomez, Alencar, Prado, Osório, & Wolf, 2014).

Trafik ışıklarının biçimsel tasarımı kolay olsa da trafik ışıklarının belirlenmesi kolay bir süreç değildir. Bu teknolojinin zorlu trafik koşullarıyla başa çıkabilmesi için sahip olması gereken temel özellikler şunlardır:

- Tanıma sistemi sağlam olmalıdır (Chiang, Ming-Che Ho, Pratama, & Syu, 2011).
- Algoritma çalışması gerçek zamanlı olmalıdır (Greenhalgh & Mirmehdi, 2012).

Trafik ışıklarının tanınması amacıyla literatürde birçok çalışma yapılmıştır. Bu amaç için ilk aşamada, öznitelik tabanlı yaklaşımlar yaygın olarak benimsenmiştir (Diaz-Cabrera, Cerri, & Medici, 2015; Wang & Xiong, 2016; Hosseinyalamdary & Yilmaz, 2017; Saini, Nikhil, Konda, Bharadwaj, & Ganeshan, 2017; Lee S.-H. , Kim, Lim, & Lim, 2018). Örneğin, (Zhang, Xue, Zhang, Zhang, & Zheng, 2014) çalışmasında, trafik ışıklarının olası konumlarını puanlayan bir algoritma geliştirmek amacıyla şekil, renk, yapı ve coğrafi konum bilgileri kullanılmıştır. (Liu W. , ve diğerleri, 2016) çalışmasında, renk bölgelerini çıkarmak için HSV renk uzayında, elipsoit geometride bir eşik modeli oluşturulmuştur. Ayrıca, trafik ışığının aday bölgelerini tanımlamak ve kullanılan iki heterojen özelliği birleştirmek için bir çekirdek fonksiyonu önerilmiştir. (Gomez, Alencar, Prado, Osório, & Wolf, 2014)'de tespit edilen trafik ışığı ile var olan en iyi durum dizisini bulmak amacıyla Viterbi algoritması

uygulanarak tahmin yapılmıştır. (Barnes, Maddern, & Posner, 2015) çalışmasında renk dağılımı kullanılarak, trafik ışığı adayları dikey üç bölgeye ayrılmıştır. (Haltakov, Mayr, Unger, & Ilic, 2015)'te bir ortak güçlendirme sınıflandırıcısı kullanılarak 21 elemanlı özellik vektörü sınıflandırılmıştır.

Trafik ışıklarının tanınması amacıyla yapılan öznelik tabanlı yaklaşımlar, çeşitli hava koşullarında ve çeşitli parlaklıklarda genellikle iyi performans verir. Bu nedenle, trafik ışıklarının sınıflandırılması ve tanınması probleminin çözümü için son yıllarda sinirsel karar vermeyi taklit eden derin öğrenme modelleri önerilmiştir (Jensen, Philipsen, Møgelmoose, Moeslund, & Trivedi, 2016). Sinir ağları kullanımı, dinamik senaryolarda trafik ışığı tanıma işleminin doğruluğunu büyük ölçüde artırmaktadır (John V. , Yoneda, Liu, & Mita, 2015; Chen & Huang, 2016; Bach, Stumper, & Dietmayer, 2018; Lee & Kim, 2019). Bu yöntemlerde, öncelikli amaç, ilgi bölgesi oluşturmaktır. Sinir ağı, trafik ışıklarının durumunu ve rengini belirleyebilmektedir (Wang & Zhou, 2018; Hirabayashi, Sujiwo, Monrroy, Kato, & Edahiro, 2019; Wang, ve diğerleri, 2019). John vd. (2014) çalışmalarında, ilgi bölgelerinin doku, renk ve şekil özelliklerini çıkarmak amacıyla görüntü işleme tekniklerini kullanmışlardır. Sonrasında, trafik ışığı durumunun tanımlanması için, Çok Katmanlı Algılayıcı ve bir Yapay Sinir Ağı (YSA) kullanılmıştır. Bu çalışmalarda ön işleme, hesaplama miktarını azaltmaktadır (Wang, Tang, Zhao, & Zhou, 2022). Referans (Charette & Nashashibi, 2009)'te önerilen uyarlamalı şablon eşleştirme sistemi, öğrenmeye dayalı AdaBoost kademeli Haar özellik sınıflandırıcısıyla karşılaştırılmıştır. (Franke, ve diğerleri, 2013)'de bulunan trafik ışıklarının durumunu belirlemek için bir sinir ağı kullanılmıştır.

Trafik ışıklarının sınıflandırılması için yapılan bazı çalışmalar kademeli sınıflandırıcılara dayanmaktadır. Örneğin, Charette vd. (2009) özelleştirilmiş bir Uyarlanabilir Şablon Eşleştirme yöntemi ile farklı ülkelerden gelen trafik ışıklarının analizini yapmışlardır. İlk olarak yöntem, şehir içi yollarda test edilmiş, sonrasında ise aynı Çin, Fransa ve ABD'den gelen trafik ışıklarına uygulanmıştır (Charette & Nashashibi, 2009). Bu çalışmalarda elde edilen doğruluk oranı %95'tir. Başka bir çalışmada, önerilen GSDS'yi eğitmek için fazla sayıda trafik ışığı görüntü seti kullanılmıştır ve kırmızı, yeşil ışıklar dikkate alınmıştır (Fairfield & Urmson, 2011). HOG özellikleri ve DVM histogramı da bu alanda kullanılan tanıyıcılardır (Diaz, Cerri, Pirlo, Ferrer, & Impedovo, 2015).

Literatürde yapılan çalışmalarda ortak olarak genellikle Bosch Small Traffic Lights Dataset (Kim, Park, & Jung, 2018; Oh, Sim, & Kim, 2020; Nguyen, 2020) ve LISA (Oh, Sim, & Kim, 2020) veri setleri kullanılmıştır.

Kim vd. (2018) tarafından yapılan çalışmada 6 farklı renk uzayı (RGB, normalize edilmiş RGB, Ruta RYG, YCbCr, HSV ve CIE Lab) girilmiştir ve 3 farklı ağ modeli (Daha Hızlı Bölge Tabanlı Evrişimsel Sinir Ağı ve Bölge Tabanlı Tam Evrişimsel Ağ'lara dayanan modeller) ile eğitim yapılmıştır.

Oh vd. (2020) çalışmasında da derin öğrenme algoritmaları kullanılmıştır. Barkod oluşturma yoluyla, trafik ışığı görüntüleri tek boyutlu görüntülere indirgenmiş ve tek boyutlu bir evrişimli sinir ağı kullanılarak sınıflandırma yapılmıştır.

Wang vd. (2022) çalışmasında trafik ışıklarının koordinatlarını ve rengini belirlemek için ESA ve tümleşik kanal öznitelik yakalama (integrated channel feature tracking) kullanılmıştır. Bu çalışma, algılama ve izlemeyi birleştirerek tanıma doğruluğunu ve işleme hızını iyileştirmiştir.

1.3. Yol Şerit

Etkili bir şerit algılama algoritması, sürüş güvenliğini destekleyen önemli bilgiler sağladığından, gelişmiş bir sürücü destek sisteminin temel bir bileşenidir. Şerit algılama ve izleme algoritmasının karşılaştığı zorluklar arasında, şerit işaretlerinin net olmaması, kötü hava koşulları nedeniyle kötü görünürlük, aydınlatma ve ışık yansımaları, gölgeler ve yoğun yol tabanlı talimatlar bulunmaktadır (Lee & Moon, 2018).

Gelişmiş bir şerit algılama modeli, aşağıdaki gibi kritik ve çeşitli koşullarda bile performans gösterebilecek kadar sağlam olmalıdır (Sapkal, Arti, Pawar, & Singh, 2023):

- Yoğun gölgeler veya ıslak yollar nedeniyle zayıf görünürlük,
- Virajlı veya dik yollar,
- Yol renginde veya malzemesinde değişiklik,
- Farklı eğimler,
- Sürekli veya kesikli çizgiler,
- Sis, kar veya yoğun yağış gibi çevresel koşullar,
- Yol işaretlerinin bozulması.

Yol şerit çizgileri algılama işlemleri, akıllı araçlarda güvenli sürüş için önem teşkil etmektedir. Bir kameradan gelen görsel veriler; yüksek bilgi içeriği, düşük maliyeti, çalışma gücü ve gerekirse ultra-sonik sensörleri veya radarı yardımcı sensör olarak kullanabilmesi sayesinde yol şerit çizgilerini algılamak için yaygın olarak kullanılmıştır (Hillel, Lerner, Levi, & Raz, 2014). Yol şerit çizgileri algılama için görmeye dayalı yaklaşımda bir

kameradan çekilen 2 boyutlu görüntü, (şerit bilgilerini almak için genellikle ön camın arkasına monte edilir) görüntü işleme yöntemleri ile analiz edilir.

Şerit algılama yöntemleri, geleneksel ve öğrenme tabanlı olmak üzere iki kategoride incelenebilir (Zakaria, ve diğerleri, 2023). Geleneksel yöntemler, görüntüden şerit işaretleri hakkında bilgi çıkarmak ve ardından çizgi tespiti ve çizgi uydurmak için özellikle eğim, doku, sınırlar, renk vb. bilgileri kullanmaktadır. Bu nedenle, geleneksel şerit algılama modellerinin işlem hattı esas olarak görüntü ön işleme, özellik çıkarma ve model uydurma ve algılanan şerit takibi olmak üzere üç aşamaya bölünmektedir (Sapkal, Arti, Pawar, & Singh, 2023). Lee ve Moon'un (2018) yaptığı çalışmada başlangıç, şerit algılama ve şerit izleme olmak üzere üç adımdan oluşan sağlam ve hızlı bir şerit algılama ve izleme algoritması önerilmiştir.

Mu ve Ma (2014) çalışmasında, karmaşık ortamlar için bir şerit algılama algoritması önerilmiştir. Otsu nesne segmentasyonu ile aday şerit bölgesinin seçilmesi gerçekleştirilmiştir. Ayrıca, aday şerit işaretçileri kenarlardan eşik seçimiyle elde edilmiştir. Sonunda şerit işaretçileri parça parça montajlama ile tespit edilmiştir. Ön işleme aşamasında parça parça lineer dönüşüm, ortamın loş olduğu durumlarda algılama performansını artırmıştır. Özellik tabanlı yöntem genellikle görüntünün yoğunluğundan etkilenmektedir. Bu çalışmada da yoğunluktaki değişiklik nedeniyle yanlış şerit algılama yapılabilmektedir.

Yoo vd. (2017) tarafından yapılan çalışmada ufuk noktası tahminine dayanan sağlam bir şerit algılama yöntemi önerilmiştir. Ancak, karmaşık arka plana sahip bir görüntüde, ufuk noktasını doğru olarak tahmin etmek kolay değildir. Bu nedenle, bir girdi görüntüsünden çıkarılan çizgi parçalarının kesişme noktalarına dayanan olasılıklı bir oylama prosedürü kullanılmıştır. Önerilen oylama işlevi, çıkarılan çizgi parçalarının ilgi düzeyini temsil eden çizgi parçası gücüyle tanımlanmıştır. Daha sonra, şerit için aday çizgi bölümleri, geometrik sınırlamalar göz önüne alınarak seçilmiştir. Son olarak, ana bilgisayar şeridi, aday çizgi bölümlerindeki aykırılıkları gidermek için tasarlanan önerilen puan işlevi kullanılarak tespit edilmiştir. Bu çalışmanın dezavantajı, parametrik ayarlarla şerit tespitinin, yapılandırılmamış yollar için kullanılamamasıdır.

(Shilaskar, ve diğerleri, 2023) çalışmasının amacı, sürücü yorgunluk belirtilerini tespit eden ve kazaları önlemek için araç hızını kontrol eden bir sistemi geliştirmektir. Sürücü uyukulu, bilinci kapalı veya sarhoşsa sistem alarm çalacak ve şerit tespiti ile araç tespitini kullanarak otomobil otomatik olarak yolun köşesinde durdurulacaktır. Şerit tespiti ile araç

tespiti yöntemi, gri renge dönüştürme, Canny fonksiyonu ile kenar algılama, ilgi bölgelerini belirleme ve Hough dönüşümü gibi adımları içermektedir.

Öğrenme tabanlı şerit tespit uygulamaları da gün geçtikçe artmaktadır. Derin öğrenmeye dayalı modeller ek ön işleme gerektirmez ve modeli eğitirken özellikleri örtülü olarak öğrenmektedir (Sapkal, Arti, Pawar, & Singh, 2023).

Ye vd. (2018) çalışmasında evrimsel sinir ağlarına ve yapısal analize dayalı yeni ve etkili bir şerit algılama yöntemi önerilmiştir. Şerit algılama görevini daha kolay ele almak için makine öğrenme yöntemlerinin kullanılmasına yardımcı olan hem eğitim verilerini hem de aday şerit işaretlerini elde etmek için bir yöntem oluşturulmuştur. Değişen veya kavisli şeritlerle ilgili problemlerin üstesinden gelebilmek için yerel dalga formlarının özellikleri kullanılmıştır. Şerit işaretlerini tespit etmek için yol geometrisinin yerel ve küresel özellikleri de analiz edilmiştir.

Yol ortamının karmaşıklığı, şerit algılamayı daha zorlaştırmıştır. Son yıllarda, derin öğrenmenin hızlı gelişimi, bu sorunu çözmeye yönünü işaret etmiştir. Derin öğrenme çevrenin değişimini değil sadece örneklerin çeşitliliğini önemsemektedir. Yeterli sayıda örnek eğitildiği sürece, hedef tespit edilebilmiş ve tanımlanabilmiştir. Buna dayanarak, Liu vd. (2019) tarafından Maske Bölge Tabanlı Evrimsel Sinir Ağını temel alan bir şerit algılama algoritması önerilmiştir. Bu algoritma, TSD-Max veri tabanı toplamı için % 97.9'a kadar doğruluk sağlamış, fakat şeridi hızlı bir şekilde algılama işlemini gerçekleştirememiştir.

Zou vd. ESA ve tekrarlayan sinir ağını (TSA) birleştirerek hibrit bir derin mimari önermiştir (Zou, ve diğerleri, 2019). Spesifik olarak, her çerçevenin bilgisi bir ESA bloğu tarafından soyutlanır ve zaman serisinin özelliğini taşıyan çoklu sürekli çerçevelerin ESA özellikleri daha sonra özellik öğrenme ve şerit tahmini için TSA bloğuna beslenir. İki büyük ölçekli veri seti üzerinde yapılan kapsamlı deneyler, önerilen yöntemin şerit tespitinde iyi performans ürettiğini göstermiştir.

Li vd. (2021) yüksek çözünürlüklü haritalar için Lane-DeepLab modeli geliştirmiştir. Önerilen yöntem temel olarak DeepLabv3+ ağını temel almış ve daha doğru şerit çizgisi tespit sonuçları üretmek için kodlayıcı-kod çözücü yapısı yeniden tasarlanmıştır. Daha fazla özellik elde etmek amacıyla yüksek seviyeli ve düşük seviyeli anlamsal bilgileri birleştirmek için Anlamsal Gömme Dalı (Semantic Embedding Branch - SEB) kullanılmıştır. Ayrıca, değişken hava koşullarının olduğu karmaşık senaryolarda önerilen model, çevre için şerit çizgisini belirlemek üzere bilgileri birleştirmek amacıyla dikkat mekanizmasını ve bağlamsal anlambilimi kullanmıştır.

(Baek, ve diğerleri, 2022) çalışmasında, hafifletilmiş özellik çıkarma modülleri ve kod çözücü modülleri ile şerit tespitine yönelik bir kıyaslama derin öğrenme çerçevesi uygulanmıştır. Bunlar, performansları karşılaştırmak ve gerçek zamanlı performansı ve doğruluğu optimize etmek için bir model seçmek amacıyla gösterge sunmak için kullanılmıştır. Kodlayıcı modül için VGG-16, MobileNet ve ShuffleNet ağları kullanılırken, kod çözücü modül için ön uç genişletme ve UNet kullanılmıştır.


Lee ve Liu (2023), UNet mimarisinden esinlenerek, otonom sürüşte şerit algılama ve yol tahmini (path prediction) için uçtan uca öğrenme amacıyla hafif bir UNet önermiştir. Bu öneri, derinlik tabanlı ayırıcı konvolüsyonlar (depthwise separable convolutions) kullanmaktadır. Ayrıca, evrimsel sinir ağı (ESA) ile bir yol tahmini algoritmasını tasarlayıp entegre ederek, ESA'nın performansını gerçek zamanlı, niteliksel ve niceliksel olarak değerlendirebilecekleri bir simülasyon modeli oluşturmuştur.

1.4. Evrimsel Sinir Ağı ve Modelleri

Yaygın olarak ConvNet olarak bilinen ESA, denetimli yöntem kategorisine giren yaygın YSA türlerinden biridir. Bu yöntem, kalıpları keşfetme ve yorumlama yeteneğiyle bilinir. Bu örüntü tespiti, ESA'nın görüntü analizi için kullanışlılığını ortaya çıkarmaktadır (Jogin, ve diğerleri, 2018). ConvNet, her katmanın bazı benzersiz işlevleri gerçekleştirdiği bir dizi katmandır. Ham veriler, giriş katmanı adı verilen ilk katmanda saklanır. Evrimsel katman, görüntü yaması ile tüm filtreler arasında bir nokta çarpımı gerçekleştirerek ve ardından aktivasyon olarak bilinen başka bir önemli işlevi takip ederek çıktı hacmini hesaplamaktan sorumlu olan ikinci katmandır. Daha sonra matematiksel fonksiyon, evrim katmanının çıktısının her elemanına uygulanır. Bir sonraki katman, önceki katmanın çıktı belleğini verimli hale getirerek hesaplama maliyetlerinin azaltılmasına yardımcı olmak için devreye girer ve havuzlama katmanı olarak bilinir. Son olarak, havuzlama katmanı hesaplaması yapıldıktan sonra, çıktısını son katmana iletecek ve hesaplanan tek boyutlu dizi sınıfı puanının çıktısını alacaktır (Jogin, ve diğerleri, 2018). Temel ESA mimarisi Şekil 8 ile verilmiştir. Derin öğrenme modelini eğitirken iki temel görevin yerine getirilmesi gerekir:

İleri yayılım: Bir sinir ağını eğitmek için önce ona bir girdi sağlanması gerekir, daha sonra bu işlemin sonuçlarının ışığında bir çıktı üretilir.

Geri yayılım: Daha sonra model, sinir ağının ağırlıklarının ileri yayılımda elde edilen hataya yanıt olarak değiştirileceği şekilde geri yayılım tekniğini kullanır (Salehi, ve diğerleri, 2023).




Şekil 8. Temel ESA mimarisi (Saha S. , 2018)

1.4.1. VGG19

VGG ağ mimarisi ilk olarak Simonyan ve Zisserman tarafından önerilmiştir (Simonyan & Zisserman, 2014). 16 katmanlı (VGG16) ve 19 katmanlı (VGG19) VGG ağ mimarisi, Visual Geometry Group (VGG) ekibinin sırasıyla yer belirleme ve sınıflandırma konularında birinci ve ikinci sırayı aldığı ImageNet Challenge 2014 yarışmasının temelini oluşturmuştur (Carvalho, Rezende, Alves, Balieiro, & Sovat, 2017).

VGG-19 ESA mimarisinin ImageNet gibi büyük veri kümeleriyle görüntü işleme yaklaşımlarında yüksek doğruluklar sunduğu bilinmektedir. VGG-19 modelinde yaklaşık 143 M parametre vardır. Bu parametreler, eğitim aşamasında, 1000 farklı nesne kategorisindeki 1.2 M genel nesne görüntüsünü içeren ImageNet veri kümesi dikkate alınarak öğrenilir. VGG-19, evrşimsel ve tamamen bağlı, maksimum havuzlama ve Dropout dâhil olmak üzere 19 eğitilebilir katman içermektedir (Jaworek-Korjakowska, Kleczek, & Gorgon, 2019). VGG19 mimarisi Şekil 9 ile verilmiştir.



Şekil 9. VGG19 ağ mimarisi. Burada “evrş”, evrişimsel katmanı, “TBK” ise, tam bağlantılı katmanı ifade etmektedir.

1.4.2. ResNet-50


ResNet ağları (He, Zhang, Ren, & Sun, 2016), kısayol bağlantıları (shortcut connection) kullanılarak evrişimsel katman bloklarının atlandığı bir derin evrişimsel ağ mimarisine sahiptir. Temel bloklar iki basit tasarım kuralını takip eder:

- Aynı çıktı özellik harita boyutu için katmanlar aynı sayıda süzgece sahiptir
- Özellik eşleme boyutu yarıya düşerse, süzgeç sayısı iki katına çıkar.

Giriş ve çıkış aynı boyutlarda olduğunda, kimlik kısayolu kullanılır. Ağ, softmax aktivasyonlu 1000 tam bağlantılı katmanla sona erer. Eğitilebilir parametre sayısı 23,534,592 ve toplam ağırlıklı katman sayısı 50'dir (Rezende, Ruppert, Carvalho, Ramos, & Geus, 2017).

ResNet-50, gradyan kaybı ve patlamasının yaşandığı geleneksel ESA sorunlarına karşı önerilen bir modeldir. ResNet-50'nin temel fikri, geleneksel ESA'yı iyileştirmek için kısayol bağlantısı düzeninde bağlanmış residual (artıklık) bloklarını kullanmaktır. Doğrusal olmayan aktivasyon fonksiyonu ReLU (Rectified Linear Unit, Doğrultulmuş Doğrusal Birim), eğitim verimliliğini artırmak ve eğimin kaybolmasını önlemek için kullanılmıştır. Artık blok modülü Şekil 10 ile gösterilmektedir. Üst ESA katmanının çıktısı, daha derin ESA katmanlarındaki öğrenme parametrelerinin baskısını etkili bir şekilde hafifleten artık bloklar kullanılarak daha sonraki ESA katmanlarına kısmen kaydedilir. Artık bloklara sahip ResNet-50 ESA modeli, artan ağ derinliğinin neden olduğu gradyan patlaması ve gradyan


kaybolmasının etkilerini etkili bir şekilde azaltmaktadır. ResNet-50 ESA modeli ayrıca orijinal doğrusal olmayan özellikleri, artık bloklardan öğrenilen doğrusal olmayan özelliklerle üst üste bindirerek eğitim sırasında öğrenme için daha fazla bilgi kaydedebilmektedir. ResNet-50, az sayıda ESA parametresi ve üstün ESA performansı sayesinde son yıllarda popüler bir ESA modeli haline gelmiştir (Li, Li, Ren, & Zhang, 2022).



Şekil 10. Resnet-50 artık blok

1.4.3. MobileNet

Bu ağ mimarisi ilk katmanda standart bir evrişim yaklaşımı kullanmaktadır. Diğer tüm katmanlar ise “derinlemesine ayrılabilir” evrişim yapısını dikkate almaktadır. Aslında bu yaklaşım iki farklı evrişim işleminin birleşimidir: Derinlemesine evrişim ve noktasal evrişim (Howard, ve diğerleri, 2017). MobileNet'in yapısı Şekil 11 ile gösterilmiştir. Derinlemesine evrişim filtresi, her bir giriş kanalında tek bir evrişim gerçekleştirir ve nokta evrişim filtresi, derinlemesine evrişimin çıkışını doğrusal olarak 1×1 evrişimlerle birleştirir (Wang, ve diğerleri, 2020).




Şekil 11. MobileNet mimarisi (Wang, ve diğerleri, 2020)

1.4.4. Xception

Xception ağ mimarisi, artık bağlantıları olan derinlemesine ayrılabilir kıvrım katmanlarının doğrusal bir yığınıdır. Bu yaklaşım, mimariyi tanımlamayı ve değiştirmeyi oldukça kolaylaştırmaktadır. Bu ağ mimarisi, özellik çıkarma tabanını oluşturan 36 evrişimsel katmana sahiptir. Bu katmanlar, ilk ve son modül dışında, hepsi doğrusal artık bağlantılara sahip 14 modülle yapılandırılmıştır (Chollet, 2017).

Xception, Inception-v3'ün geliştirilmiş bir versiyonudur. Inception-v3'teki sıradan evrişim işleminin yerine derinlemesine ayrılabilir evrişim kullanılmıştır. Derinlemesine ayrılabilir evrişim, sıradan evrişimi iki sürece ayırmaktadır: ilk olarak, uzamsal evrişim her giriş kanalında bağımsız olarak gerçekleştirilir ve ardından noktasal evrişim, noktadan noktaya evrişim için 1×1 çekirdeği benimser. Xception modelinin mimarisi Şekil 12 ile verilmiştir. Xception modeli 14 bloktan oluşmaktadır. 14 blok toplamda 3 ortak evrişim katmanı ve 33 derinlemesine ayrılabilir evrişim katmanı içermektedir. Tüm bloklar, ilk ve son blokların çevresinde doğrusal artık bağlantıların olmasını beklemektedir (Chen, Liu, Zheng, Zhao, & Shi, 2021).



Şekil 12. Xception model mimarisi (Chen, Liu, Zheng, Zhao, & Shi, 2021)

1.5. Transfer (Aktarmalı) Öğrenme

Transfer öğrenimi, bir modelin başka bir görev için başlangıç noktası olarak hizmet etmeden önce bir problem hakkında bilgi edindiği bir öğrenme yöntemidir. Bu, birincil soruna yakın bir prosedürün zaten mevcut olduğu ve ilgili görevin çok fazla veri gerektirdiği durumlardaki problemler için uygun bir yaklaşımdır. Transfer öğrenimi, önceden eğitilmiş bir modelden özellik çıkarma tekniğini kullanır; bu, geliştiricilerin bir modeli eğitirken baştan başlama ihtiyacını ortadan kaldırır. Bir transfer öğrenme modeli tipik olarak büyük bir veri kümesi (örneğin, ImageNet (ImageNet Large Scale Visual Recognition Challenge (ILSVRC), 2021)) üzerinde eğitilir ve eğitilen modelden elde edilen ilgili parametreler daha sonra herhangi bir ilgili uygulama için özel bir sinir ağı ile kullanılabilir. Bu tür modeller, doğrudan yeni görevlere ilişkin tahminler için veya modelin ilgili diğer uygulama eğitim süreçlerinde kullanılabilir. Örneğin, görüntü sınıflandırma sürecinde, tahmin için kullanılan YSA gibi bir model, köpekler ve kediler gibi belirli bir alanın çok sayıda görüntüsü veya veri seti ile eğitilecek ve öğrenilecektir. Model ağırlıkları sürecin ilk adımı için bir seçenektir. Makinenin şekilleri, desenleri ve çizgileri geri getirme gibi daha kapsamlı bir görev için daha önce ustalaştığı özellikler aynı zamanda farklı hedefler için de faydalıdır. Geleneksel sinir ağlarıyla ilgili göz önünde bulundurulması gereken bir sorun, bu tür modellerin, klinik uygulamada kullanıldığında, modeli eğitirken kullanılmayan verilerden başka bir şey olmayan görünmeyen veriler nedeniyle başarısız olma ihtimalinin yüksek olmasıdır. Bu nedenle daha önce karşılaşılan klinik verilere genelleme kapasitesi, bu algoritmaların hala önemli bir eksikliğidir. Diğer bir eksiklik ise verilerin sınırlı olmasıdır; Derin bir ağın çalışma performansının veri miktarından etkilendiği bilinmektedir. Bu

eksikliğin üstesinden gelmenin bir yolu, daha fazla veri toplamak, özellikle de tam olarak denetlenen verileri aramaktır. Bu nedenle seçim olarak değerlendirilebilecek transfer öğrenme teknikleri vardır. Sıfırdan başlamak yerine, yeni bir ağ yetiştirmek için mevcut bir ağ kullanılabilir; LeNet-5, AlexNet, VGG-16 Net, InceptionNet, ResNet ve DenseNet, görüntülerin sınıflandırılması için önceden eğitilmiş ağlar olarak yaygın şekilde kullanılmaktadır. Tüm bu mimariler, 1000 nesne kategorisi sınıflandırmasından oluşan iyi bilinen veri seti ImageNet üzerinde eğitilmiştir. ImageNet'in eğitim setinde bir milyonun üzerinde, doğrulama setinde elli bin civarında, test setinde ise yüz bin civarında görsel bulunmaktadır (Krizhevsky, Sutskever, & Hinton, 2017). Bu modeller hem eğitim süresini azaltmakta hem de genelleme hatalarını azaltmaktadır. Tablo 2, geleneksel makine öğrenimi ile transfer öğrenimi arasındaki temel farklılıkları göstermektedir (Salehi, ve diğerleri, 2023).

Tablo 2. Geleneksel makine öğrenmesi ve transfer öğreniminin kısa bir açıklaması

Geleneksel makine öğrenmesi	Transfer öğrenme
Yalıtılmış, tek görevle öğrenme.	Yeni aktivitelerin öğrenilmesi daha önce öğrenilenlere bağlıdır.
Bilgi saklanmaz veya biriktirilmez. Öğrenme, diğer görevlerden öğrenilen bilgiler dikkate alınmadan gerçekleştirilir.	Öğrenme süreci daha verimli, daha doğru olabilir veya daha az eğitim veri seti gerektirebilir.

Evrişimsel bir sinir ağını sıfırdan oluşturma, artıları ve eksileri vardır, ancak bu tür bir optimizasyon işlemi için her şeyden önce çok büyük bir veri seti gerekmektedir. Çok ümit verici bir yaklaşım, önceden eğitilmiş VGG-16, VGG-19, ResNet ve benzeri modelleri daha az veri setleri üzerinde kullanmaktır. Bu bağlamda, transfer öğrenme kavramı, mevcut modellerin benzer görevler için kullanılmasına olanak sağlar. Yeni bir küçük boyutlu veri setinden özellik temsillerini çıkarmak için aynı modeli tekrar kullanarak transfer öğrenme gerçekleştirilmesinin stratejisi şudur: Önceden oluşturulan model özellik çıkarıcı olarak seçilir ve böylece tamamen bağlantılı bir sınıflandırıcının eğitilmesinin yeterli olması sağlanır.

Genellikle derin öğrenme kavramında sinir ağı büyük boyutlu veri setleri için eğitilir. Eğitilmiş yapay sinir ağının yeni görev için kullanılması gerektiğinde, ağın ilk katmanları

sabit kalabilir, fakat yeni veri setinin belirli özelliklerini öğretmek için ağıın son katmanların güncellenmesi gerekmektedir (Chahande & Gohokar).

1.6. Çalışmada Kullanılan Metrikler

Yapılan çalışmaların literatürdeki diğer çalışmalarla performans karşılaştırılmasının yapılabilmesi için çeşitli değerlendirme ölçütleri kullanılmıştır. Bunlar; doğruluk, kesinlik, duyarlılık, F1-skor, ROC (Receiver Operating Characteristic) ve AUC (Area Under the Curve) değerleridir.

- Doğruluk (Accuracy):

Doğruluk, bir ikili sınıflandırma testinin bir koşulu doğru olarak ne kadar iyi tanımladığının istatistiksel bir ölçüsü olarak kullanılır. Diğer bir deyişle, doğruluk hem gerçek pozitiflerin hem de gerçek negatiflerin, incelenen toplam vaka sayısına olan oranıdır.

$$\text{Doğruluk} = \frac{DP + DN}{DP + DN + YP + YN} \quad (1)$$

- Duyarlılık (Recall - Sensitivity):

Geri çağırma veya duyarlılık, doğru şekilde tahmin edilen pozitiflerin, tüm gerçek pozitiflere oranını ifade eder. Geri çağırma, aynı zamanda ROC analizinin dayandığı ayaklardan biridir. Doğru pozitif oranı olarak da adlandırılır.

$$\text{Duyarlılık, DPO} = \frac{DP}{DP + YN} \quad (2)$$

- Kesinlik (Precision -Confidence):

Özgüllük veya kesinlik, doğru şekilde tahmin edilen pozitiflerin, tahmin edilen tüm pozitiflere oranını ifade eder. Makine öğrenmesi, veri madenciliği ve bilgi edinme konularında kullanılır, ancak ROC analizinde tamamen göz ardı edilir. Bununla birlikte, benzer şekilde pozitif belirleyicilik değeri olarak da adlandırılabilir.

$$\text{Kesinlik} = \frac{DP}{DP + NP} \quad (3)$$

- F1-Skor:

Performans ölçüsü olan F1 skoru, duyarlılığın (yani sınıflandırıcının tüm pozitif numuneleri bulma yeteneği) ve kesinliğin (yani sınıflandırıcının negatif olan bir numuneyi pozitif olarak etiketlememe yeteneği) ağırlıklı ortalamasıdır. F1 skoru [0, 1] aralığındaki değerleri alır; yüksek değerlerin üretilmesi beklenmektedir (Kollias, 2022). F1 skoru şu şekilde tanımlanır:

$$F1 - Skor = \frac{2 \times Kesinlik \times Duyarlilik}{Kesinlik + Duyarlilik} \quad (4)$$

- ROC ve AUC:

İkili sınıflandırma, makine öğrenimi ve hesaplamalı istatistiklerin kullanıldığı ortak bir görevdir ve alıcı işletim karakteristik eğrisinin (ROC AUC) altındaki alan, çoğu bilimsel alanda ikili sınıflandırmaları değerlendirmek için ortak standart metrik haline gelmiştir. ROC eğrisinin y ekseninde doğru pozitif oranı (duyarlılık veya geri çağırma) ve x ekseninde yanlış pozitif oranı vardır ve ROC AUC değeri 0 (en kötü sonuç) ile 1 (mükemmel sonuç) arasında değişebilir (Chicco & Jurman, 2023).

AUC olarak bilinen alıcı işletim karakteristiği (ROC, receiver operating characteristic) eğrisi altındaki alan, öngörücü dağıtım modellerinin doğruluğunu değerlendirmek için standart yöntem olarak kabul edilir.

$$YPO = \frac{YP}{YP + DN} \quad (5)$$

Burada; DPO: Doğru Pozitif Oran, YPO: Yanlış Pozitif Oran, DP: doğru pozitif (True Positive), DN: doğru negatif (True Negative), YP: yanlış pozitif (False Positive); YN: yanlış negatif (False Negative) ifade etmektedir.

2. YAPILAN ÇALIŞMALAR

Bu tez kapsamında yapılan çalışmalar trafik işareti, trafik ışıkları ve yol şerit çizgileri olmak üzere 3 alt başlıkta incelenmiştir.

2.1. Trafik İşareti

Tez kapsamında trafik işareti konusu, trafik işareti algılama ve 3 farklı trafik işareti sınıflandırma çalışmasından oluşmaktadır.

2.1.1. Trafik İşareti Algılama

Bu çalışmada, önerilen yöntem ön işleme, bölütleme, morfolojik işlemler, özellik çıkarımı ve son olarak trafik işaret algılama olmak üzere 5 aşamadan oluşmaktadır. Bu aşamalar Şekil 13 ile gösterilmiştir.



Şekil 13. Önerilen yöntemdeki ana işlem adımları

Ön İşleme:

Görüntü işleme çalışmalarında daha iyi ve doğru sonuçlar elde edebilmek için ön işleme kullanılmaktadır. Görüntü renk bilgisinin değiştirilmesi, gürültü giderme, ölçeklendirme gibi işlemler bu aşamada gerçekleştirilmektedir.

Bölütleme:

Bölütleme algoritmaları genellikle benzerlik veya bağlantı kriterlerini dikkate alır. Trafik işaretleri genellikle karakteristik renklere sahip olduğu için çevresindeki nesnelerden ayırt edilebilmektedir. Bölütleme, renk kriterlerine dayanan piksel sınıflandırma işlemiyle ele alınmaktadır (Lillo-Castellano, Mora-Jiménez, Figuera-Pozuelo, & Rojo-Álvarez, 2015).

Morfolojik İşlemler:

Morfolojik işlemler, genişletme ve daraltma işlemlerini kapsar. Bir yapı elemanı ile morfolojik işlem, bazen küçük boşlukları ve eksik sınırları doldurmak için, bazen de görüntüye yayılan birçok kıvılcım gürültülerini filtrelemek için renk bölümlendirilmesinden sonra gerçekleştirilir. Morfolojik kapama işlemi, bölümlenmiş nesneler üzerinde ardışık birkaç pikselden küçük boşlukları gidermek için kullanılır. Morfolojik açma işlemi ise tek nokta veya küçük damla şeklindeki aykırı kıvılcım gürültüsünü gidermek için kullanılır. Kısacası morfolojik filtreler görüntü işlemede etkili bir yöntemdir (Abedin, Dhar, & Deb, 2016)

Özellik Çıkarımı:

Bu aşamada görüntüdeki önemli bilgilerin elde edilmesi için şekilsel özelliklerden faydalanılır. Trafik işaretleri üçgen, yuvarlak ve kare olmak üzere belirli şekillere sahiptir. Görüntüden bu şekillere ait özellikler çıkarılarak trafik işaretinin saptanması sağlanmıştır. Şekillerin tanınması için bağlantılı bileşenler özelliği kullanılır. Pikseller arasındaki komşuluk ilişkisini dikkate alarak elde edilen bağlantılı bileşen özellik değerleri üçgen, yuvarlak ve kare şekillerini içerirse, bu şekiller arka plandan ayrıştırılarak özellik çıkarımı gerçekleştirilir.

Trafik İşareti Algılama:

Öznitelikler dikkate alınarak görüntüden çıkarılan trafik işaretleri görüntülenir ve ayrıca görüntüdeki konum bilgisi gösterilir.

2.1.2. Transfer Öğrenme Yoluyla Trafik İşareti Sınıflandırma

Bu çalışmada, ImageNet'te eğitilmiş ağırlıklar ile görüntü sınıflandırma için VGG19, ResNet50, MobileNet ve Xception modelleri kullanılmıştır.

Transfer öğrenmede kullanılan önceden eğitilmiş birkaç model, ESA'ya dayanmaktadır. ESA'ların eğitimi ile ortaya çıkabilecek zorluklardan biri, optimize edilmesi gereken çok sayıda parametre ile ilgilidir, bu da aşırı uydurma sorununa yol açabilmektedir. Bu amaçla, stokastik havuzlama, Dropout ve veri artırma gibi teknikler önerilmiştir. Ayrıca, ESA'lara ön eğitimde, rastgele parametre ayarlamaları yerine, ön ölçüm parametreleriyle başlatılan bir işlem uygulanır. Böylece öğrenme sürecini hızlandırabilir ve ağın genelleme yeteneğini artırabilir (Voulodimos, Doulamis, & Protopapadakis, 2018). ESA'nın çok farklı bilgisayarlı görü problemlerinin çözümünde mükemmel sonuçlar ürettiği gösterilmiştir.

Yüksek performansı ve eğitimdeki kolaylığı, ESA'nın popülerliğini son yıllarda artıran ana faktörlerden ikisidir.

2.1.3. Renk Uzayına Dayalı Trafik İşareti Sınıflandırma

Bu çalışmada trafik işareti tanıma için yüksek doğruluklu ve düşük parametre sayısına sahip yeni bir ESA modeli önerilmiştir. Ön işleme aşamasında girdi görüntü boyutlandırması ve renk uzayları üzerinde farklı denemeler yapılmıştır. Veri kümesindeki sınıf görüntüleri üzerinde denge sağlamak için veri artırma da uygulanmıştır.

Giriş Görüntü Boyutlandırma:

Bir ESA'yı trafik işareti tanıma amacıyla eğitmek için kullanıldığında girdi görüntü boyutu, dikkate alınması gereken önemli bir faktördür (Haque, Arefin, Shihavuddin, & Hasan, 2021). Stallkamp vd. (2012) çalışmasına göre, IJCNN (International Joint Conference on Neural Networks) 2011'deki en iyi performans gösteren ESA modellerinin tanınma oranı, farklı görüntü boyutları üzerinde test edildiğinde değişiklik göstermektedir. Bunun nedeni büyük olasılıkla eğitim görüntülerinin boyut olarak önemli ölçüde değişmesidir (15 x 15 ile 250 x 250 piksel). Bu bulgudan esinlenerek, önerilen ESA mimarilerinin performansları farklı boyutlarda görüntüler kullanarak ayrı ayrı araştırılmıştır.

Renk Uzayları:

Yapılan çalışmalara bakıldığında renk uzaylarının tanıma doğruluğu üzerinde önemli katkısı olduğu görülmektedir. Bu yüzden görmeye dayalı nesne algılama ve sınıflandırma işlemlerinde, nesnenin karakteristiğinin iyi görüldüğü renk uzayını belirlemek gerekmektedir. Bu tezde, farklı renk uzaylarına yer verilmiştir. Bunlar RGB, CIELab, RIQ ve LGI renk uzaylarıdır.

Literatürde farklı tanıma problemleri için uygulanan RIQ renk uzayı, trafik işaret tanıma amacıyla kullanılmıştır (Liu & Liu, 2008). Bu yeni renk uzayı, RGB renk uzayının R bileşeni ve YIQ renk uzayının I ve Q kromatik bileşenlerinin birleştirilmesiyle elde edilmektedir. YIQ renk uzayı ise, RGB renk uzayının doğrusal bir dönüşümü aracılığıyla tanımlanmıştır:

$$\begin{bmatrix} Y \\ I \\ Q \end{bmatrix} = \begin{bmatrix} 0.2990 & 0.5870 & 0.1140 \\ 0.5957 & -0.2745 & -0.3213 \\ 0.2115 & -0.5226 & 0.3111 \end{bmatrix} \begin{bmatrix} R \\ G \\ B \end{bmatrix} \quad (6)$$

Burada Y, I ve Q sırasıyla renkli bir görüntünün parlaklık, renk tonu ve doygunluk özelliklerini tanımlamaktadır. R, G ve B bileşeni görüntülerinin korelasyonu, Y, I ve Q bileşeni görüntülerini birbirini tamamlayıcı hale getirmektedir.

Kullanılan diğer hibrit renk uzayı LGI (Vo & Verma, 2016); $L^*a^*b^*$, RGB ve $I_1I_2I_3$ renk uzaylarından türetilmiştir. Bu renk uzayları, özellik çıkarımı için literatürde yaygın olarak kullanılmaktadır. $L^*a^*b^*$ 'de parlaklık kanalı L, tanıma problemlerinde diğer iki krominans kanalından daha iyi performans göstermektedir (Vo & Verma, 2016). RGB renk uzayında ise en iyi performans yeşil kanal ile elde edilmektedir. $I_1I_2I_3$ 'te birinci kanal, çoğu krominans ve parlaklık bilgisini içerdiğinden diğer iki kanaldan daha iyi performans göstermektedir (Vo & Verma, 2016). Böylece LGI renk uzayı, yukarıda bahsedilen her bir renk uzayındaki en ayırt edici kanallardan oluşmaktadır. 0 ila 100 aralığında parlaklığı temsil eden L kanalı dışında, diğer kanallar 0-255 aralığındadır. Ohta vd. (1980) tarafından önerilen $I_1I_2I_3$ renk uzayı, RGB renk bileşenlerinin korelasyonu ile elde edilir. Bu tezde kullanılan I_1 renk bileşeni, aşağıdaki dönüşümle oluşturulmuştur:

$$I_1 = \frac{R + G + B}{3} \quad (7)$$

Veri artırma:

Veri artırma, mevcut eğitim setinde değişiklik yaparak yeni etiketli veri üretme işlemidir. Çeşitli veri artırma yöntemleri mevcuttur. Bunlardan biri, gerçek veriler üzerinde bazı dönüşümler gerçekleştirilerek yeni veriler üretmektir. Bir diğer yöntem, gerçek verilere yeni nesneler eklenerek gerçekleştirilir (Hassan, Li, & Ren, 2020). Sınıflandırma problemi üzerine yapılan çalışmalarda veri artırma yapılarak modelin eğitilmesi sonucunda elde edilen performans ile işlenmemiş eğitim verileri üzerinde yapılan eğitimin sonuçları karşılaştırıldığında, artırma ile daha yüksek sınıflandırma doğruluğuna ulaşıldığı görülmüştür (Haque, Arefin, Shihavuddin, & Hasan, 2021; Cubuk, Zoph, Mane, Vasudevan, & Le, 2018). Böylece eğitim veri setinin küçük olması durumunda veri miktarı artırılarak eğitimin daha iyi yapılabilmesi sağlanmaktadır. Veri çeşitliliği artırılarak daha iyi öğrenme sağlanmakta ve bu durum ayrıca gerçek dünyadaki farklılıkları daha iyi yansıtmaktadır.

GTSRB veri kümesi, sınıflar arasında eşit olmayan veri dağılımına sahiptir. Veri artırma bu dengesizliğin üstesinden gelmenin en iyi yollarından biridir. Böylece yapay yeni veriler üretilmektedir. Çalışmada kullanılan veri artırma argümanları döndürme, kaydırma,

yakınlaştırma ve kesme işlemleridir. Kullanılan bu argümanların aralık değeri Tablo 3 ile gösterilmektedir.

Tablo 3. Veri artırma argümanları

İşlem	Aralık değeri
Genişlik kaydırma	0.1
Yükseklik kaydırma	0.1
Yakınlaştırma	0.15
Kesme	0.15
Döndürme	10°

Önerilen Yöntem:

Önerilen ESA mimarisi 10 evrişimsel katman, üç maksimum havuzlama katmanı ve ardından üç tam bağlantılı gizli katman içerir. Son katman, 43 sınıf üzerinde bir olasılık dağılımı üretmek için 43 yollu bir softmax'a bağlanır. Önerilen ESA mimarisinin detaylı katman bilgisi Tablo 4 ile verilmektedir.

Tablo 4. Önerilen ESA mimarisinin detaylı katman bilgileri

Katman	Çekirdek	Adım	Kanal
Evrişimsel katman	5 x 5	1	64
Yığın Normalizasyon			
Evrişimsel katman	5 x 5	1	64
Yığın Normalizasyon			
Evrişimsel katman	5 x 5	1	64
Yığın Normalizasyon			
Evrişimsel katman	5 x 5	1	64
Yığın Normalizasyon			
Maksimum Havuzlama	2 x 2	1	
Evrişimsel katman	3 x 3	1	32
Yığın Normalizasyon			
Evrişimsel katman	3 x 3	1	32

Tablo 4'ün devamı

Yığın Normalizasyon			
Evrişimsel katman	3 x 3	1	32
Yığın Normalizasyon			
Evrişimsel katman	3 x 3	1	32
Yığın Normalizasyon			
Maksimum Havuzlama	2 x 2	1	
Evrişimsel katman	3 x 3	1	16
Yığın Normalizasyon			
Evrişimsel katman	3 x 3	1	16
Yığın Normalizasyon			
Maksimum Havuzlama	2 x 2	1	
Düzleşme (Flatten)			
Tam Bağlantılı			512
Aktivasyon (ReLU)			
Yığın Normalizasyon			
Dropout (0.5)			
Tam Bağlantılı			256
Aktivasyon (ReLU)			
Yığın Normalizasyon			
Dropout (0.5)			
Tam Bağlantılı			128
Aktivasyon (ReLU)			
Yığın Normalizasyon			
Dropout (0.5)			
Tam Bağlantılı			43
Aktivasyon (Softmax)			

2.1.4. Topluluk Öğrenme ile Trafik İşareti Sınıflandırma

Bu çalışmada, trafik işareti sınıflandırması için yüksek doğruluk veren derin evrişimsel sinir ağı modeli önerilmiştir. Görüntülerdeki aydınlık, bozulma gibi sorunların önüne

geçebilmek, özneteliklerin daha iyi çıkarılmasını sağlamak için görüntüler ön işlemden geçirilmiştir. Ayrıca farklı boyutlardaki görüntüler 60 x 60 olacak şekilde yeniden boyutlandırılarak daha hızlı sonuç vermesi amaçlanmıştır. Bu çalışmada verilen temel katkılar şöyledir:

- Doğruluk üzerinde aktivasyon fonksiyonunun etkisi araştırılmıştır.
- Doğruluk üzerinde giriş görüntülerinin etkisi araştırılmıştır. Burada görüntüler, farklı ön işleme tabi tutulmuş, ön işlemlerin ayrı ayrı ve birlikte kullanılması adımlarından sonra modele verilmiştir.
- Geleneksel yöntemlerle öznetelik çıkarımı yapılırken derin öğrenme ile daha iyi performans elde edilmesi amaçlanmıştır. Böylece hibrit bir model oluşturulmuştur.
- Veri setindeki sınıflara ait görüntü sayılarındaki eşitsizliği gidermek için veri artırma yapılmıştır.
- Model eğitilirken fazla uydurmanın önüne geçmek ve daha iyi öğrenmenin sağlanabilmesi için öğrenme oranı ayarlaması yapılmıştır.
- Farklı giriş görüntüsü kullanılarak eğitilen modeller birleştirilerek daha iyi performans elde edilmiştir.
- Transfer öğrenme ile önceden eğitilmiş modeller birleştirilmiş ve böylece eğitilebilir parametre sayısı azaltılmıştır.

Önerilen sınıflandırma yaklaşımı, 3 aşamadan oluşmaktadır. Bunlar; veri setindeki görüntüleri daha anlamlı hale getirmek için ön işleme aşaması, veri artırma için veri artırma aşaması ve sınıflandırma için derin öğrenme aşamasıdır.

Ön işleme:

Veri setindeki görüntüler incelendiğinde aydınlanma, parlaklık ve bulanıklık gibi farklı ortamlarda elde edildiği görülmektedir. Bu koşullar altında derin öğrenme modeli oluşturulurken öznetelik çıkarımı için daha fazla sayıda parametreye ihtiyaç duyulacaktır. Daha iyi öğrenmenin sağlanabilmesi ve düşük parametreyle daha yüksek doğrulukta sonucun elde edilebilmesi için veri setine ön işleme ve görüntü iyileştirme yöntemlerinin uygulanması faydalı olacaktır.

Öncelikle bu çalışmada görüntü iyileştirme işlemleri için veri setine kenar algılama ve görüntü keskinleştirme uygulanmıştır. Bunun için 2 farklı çekirdek matrisi kullanılmıştır. Görüntüyü filtrelemek için çekirdek değerleri ile görüntü evrişim işlemine tabi tutulmuştur. Kullanılan çekirdek matrisleri denklem 8 ve 9 ile verilmiştir. *Çekirdek 1* (Kaur, Jindal, & Singh, 2021) ile kenarlar belirgin hale getirilmiştir. Trafik işaretleri şekilleri belirli yapıda

olduklarından kenar bilgileri önemli bilgiler taşımaktadır. Ayrıca sınıflandırma aşamasına katkı sağlaması için *Çekirdek 2* ile görüntü üzerinde keskinleştirme gerçekleştirilmiştir. Veri setinden örnek görüntüler üzerinde yapılan filtreleme sonucundaki görüntüler Şekil 14 ile gösterilmiştir.

$$\text{Çekirdek 1} = \begin{bmatrix} -1 & -1 & -1 \\ -1 & 8 & -1 \\ -1 & -1 & -1 \end{bmatrix} \quad (8)$$

$$\text{Çekirdek 2} = \frac{-1}{256} \times \begin{bmatrix} 1 & 4 & 6 & 4 & 1 \\ 4 & 16 & 24 & 16 & 4 \\ 6 & 24 & -476 & 24 & 6 \\ 1 & 16 & 24 & 16 & 4 \\ 1 & 4 & 6 & 4 & 1 \end{bmatrix} \quad (9)$$



Şekil 14. Sol: GTSRB veri seti özgün örnek görüntüler. Orta: *Çekirdek 1* görüntüleri. Sağ: *Çekirdek 2* görüntüleri

Görüntü boyutlarının model performansına etkilediği literatürce görülmüştür (Yildiz & Dizdaroğlu, 2021; Haque, Arefin, Shihavuddin, & Hasan, 2021). Bu yüzden görüntü

iyileştirme işlemlerinden sonra görüntüler 60x60 olarak yeniden boyutlandırılmıştır. Kullanılan görüntüler RGB renk uzayındadır.

Veri artırma:

Kullanılan veri seti içerisindeki sınıflara ait görüntüler eşit dağılıma sahip değildir. Bunun önüne geçebilmek için veri artırma işlemleri gerçekleştirilmiştir. Böylece eğitimin daha sağlıklı gerçekleştirilmesi planlanmıştır. Kullanılan veri artırma işlemleri ve değerleri Tablo 5 ile verilmiştir.

Tablo 5. Veri artırma işlemi

İşlem	Aralık değeri
Genişlik kaydırma	0.1
Yükseklik kaydırma	0.1
Yakınlaştırma	0.2
Kesme	0.15
Döndürme	10°


Önerilen Derin Öğrenme Modeli:

Bu tezde önerilen ağ mimarisi (Aghdam, Heravi, & Puig, 2017) çalışması temel alınarak tasarlanmıştır. Önerilen ağ mimarisi 7 evrişim bloğundan oluşmaktadır. Evrişim bloklarında sırasıyla evrişim katmanı, yığın normalizasyon katmanı, aktivasyon fonksiyonu ve maksimum havuzlama katmanları bulunmaktadır. İlk blokta evrişim katmanı 3 x 3 çekirdek (kernel) filtre boyutu 100 kanal ve 1 adım parametre değerlerine sahiptir. Daha sonra bu ilk blok 3 ayrı paralel evrişim bloğuna bağlanır ve 2 adet seri ara bloklar oluşturulur. 2'li seri evrişim bloklarında, ilk evrişimde 75 kanal ve 4 x 4 çekirdek filtre, 2. evrişimde ise 250 kanal ve 4 x 4 çekirdek filtre bulunmaktadır. 3 ayrı paralel kod bloğu için aktivasyon fonksiyonları farklı kombinasyonlarla denenmiştir. Kullanılan aktivasyon fonksiyonları ReLU ve Leaky ReLU ve Parametrik ReLU (PReLU)'dur (He, Zhang, Ren, & Sun, 2015). İkişer evrişim bloğuna ait 3 ayrı çıkış daha sonra sıralama (concatenate) katmanı ile birleştirilmiş ve düzleşme (flatten) katmanı ile düzleştirilmiştir. Daha sonra sırasıyla 128 nörona sahip gizli katman, yığın normalizasyon ve Dropout katmanları eklenmiştir. Dropout oranı 0.5'tir. Sınıflandırma için son katman sınıf sayısını ifade eden 43 nörona sahiptir. Tüm bloklar için maksimum havuzlama katman çekirdeği 2 x 2 olarak seçilmiştir. Önerilen

mimarinin detayları ve katman bilgileri Tablo 6 ile verilmiştir. Ayrıca detaylı katman görseli Şekil 15 ile gösterilmiştir.

Tablo 6. Önerilen mimarinin detayları ve katman bilgileri


Katman	Çekirdek	Adım	Kanal	Çıkış boyutu	Parametre sayısı
Evrişimsel Katman	5 x 5	1	100	60 x 60	7600
Yığın Normalizasyon					400
ReLU					
Evrişimsel Katman	5 x 5	1	100	60 x 60	250100
Yığın Normalizasyon					400
ReLU					
Maksimum Havuzlama	2 x 2	2	100	30 x 30	
	7 x 7				367575
Evrişimsel Katman	5 x 5	1	75	30 x 30	187575
	3 x 3				67575
Yığın Normalizasyon					300
Aktivasyon Fonksiyonu					
Maksimum Havuzlama	2 x 2	2	75	15 x 15	
	7 x 7				919000
Evrişimsel Katman	5 x 5	1	250	15 x 15	469000
	3 x 3				169000
Yığın Normalizasyon					1000
Aktivasyon Fonksiyonu					
Maksimum Havuzlama	2 x 2	2	250	7 x 7	
Sıralama (Concatenate)			250	21 x 7	
Düzleşme					
Tam Bağlantılı			128		4704128
Yığın Normalizasyon					512
Dropout (0.5)					
Tam Bağlantılı				43	5547
Aktivasyon (Softmax)					



Şekil 15. Sınıflandırma için önerilen yöntem

Yığınlama Topluluğu:

Yığınlama topluluğu ile farklı modellerin birleştirilmesi yapılabildiği gibi, aynı modelin farklı girişler için birleştirilmesi de gerçekleştirilebilmektedir (Kim, Lee, An, & Lee, 2020). Bu çalışmada ön işleme aşamasında kullanılan iki farklı çekirdek değeri ile filtreleme yapılarak elde edilen model sonuçlarının birleştirilmesiyle topluluk modeli oluşturulmuştur. Başka bir deyişle kullanılan model parametreleri ve hiper parametreler aynıdır, fakat giriş görüntüleri farklıdır. Var olan modeller eklendikten sonra meta-öğrenicinin girişleri yorumlaması için bir ara katman, yığın normalizasyon, Dropout ve sınıflandırma için son çıkış katmanı eklenmiştir. Ara tam bağlantılı katman 300 nörona sahiptir. Dropout oranı ise 0.5 tir. Oluşturulan yığınlama topluluğu modeli Şekil 16 ile verilmiştir. Burada var olan alt modellerdeki parametre değerlerini korumak için tüm katmanlar eğitilemez olarak ayarlanmıştır.



Şekil 16. Yığınlama topluluğu modelin ayrıntıları

2.2. Trafik Işıkları

Bu çalışmada, trafik ışıklarında sınıflandırma için az sayıda parametreye sahip yeni bir evrimsel sinir ağı modeli önerilmiştir. Hiper parametre ayarlama, derin öğrenme ağlarında zorlu bir süreç olduğundan, bu ayarlamayı yapmak için eğitim denemeleri yapılmış ve test doğruluğu sonuçları karşılaştırılmıştır. Ayrıca veri artırma ile eğitim seti örnek sayısı artırılmış ve eğitimin daha verimli bir şekilde yapılmasını sağlanmıştır. Ayrıca modele verilen girdi görüntüsünde model parametreleri dışında değişiklikler yapılmıştır. Bu değişiklikler, girdi görüntü boyutu ve görüntü renk uzayıdır. Sonuç olarak tüm bu parametreler üzerinde eğitim denemeleri yapılmış ve ağ için en iyi performans gösteren model üretilmiştir.

Renk Uzayları:

Renk uzayları önemli bilgiler içermektedir. Özellikle bilgisayarlı görü alanında ayırt edici bir özelliği vardır. Verilen görüntüden anlamlı bilgi çıkarmak için kullanılabilir. Literatürdeki birçok çalışma, renk uzaylarının özellikle tanıma olmak üzere farklı konularda kullanıldığını göstermektedir (Wang, ve diğerleri, 2015; Kasaei, Ghorbani, Schilperoort, & Rest, 2021; Yıldız & Dizdaroğlu, 2021).

Trafik ışığı çalışmalarında birçok renk uzayı kullanılmaktadır. Çalışmalarda en çok tercih edilen renk uzaylarından biri RGB'dir (Behrendt, Novak, & Botros, 2017; Aneesh, Shine, Pradeep, & Sajith, 2019; Chen & Luo, 2021; Golovnin & Yarmov, 2022). Gri tonlamalı renk uzayı da çalışmalara dâhil edilmiştir (Trehard, Pollard, Bradai, & Nashashibi, 2014; Ji, Yang, Lu, & Wang, 2015). John vd. (2015) çalışmasında, CIELab renk uzayının,

algılama için ilgilenilen bölgenin çıkarılmasına katkıda bulunduğunu vurgulanmıştır. (Sooksatra & Kondo, 2014)'de, aydınlatma farklılıklarından daha az etkilendiği için renk uzayı olarak CIELab tercih edilmiştir. (Philipsen, Jensen, Møgelmoose, Moeslund, & Trivedi, 2015) çalışmasının algılama işleminde LUV renk uzayı kullanılmıştır. Spot ışıkları yoğunluk kanalı L aracılığıyla bulunmaktadır. YCrCb renk uzayı, (Kim, Park, & Jung, 2011)'in dedektör aşamasında aday bölgelere erişmek için kullanılmıştır. Burada bölge, Cr ve Cb renk kanallarına eşik uygulanmasıyla elde edilmiştir.

Birden fazla renk uzayının kullanıldığı çalışmalar da mevcuttur. (Gomez, Alencar, Prado, Osório, & Wolf, 2014)'de HSV ve gri tonlamalı; (Du, Li, Guo, & Xiong, 2017)'de gri tonlamalı, RGB, HSV ve LUV renk uzayları kullanılmıştır. Tanıma aşamasında (Kim, Park, & Jung, 2018) çalışması, RGB, normalize RGB, RYG, YCbCr, HSV ve CIELab olmak üzere altı farklı renk uzayını kullanarak modeli test etmiş ve RGB renk uzayıyla en iyi performansı elde etmiştir.

Görüntü Boyutlandırma:

ESA mimarisi, ağ yapısı nedeniyle aynı boyuttaki görüntüleri eğitebilmektedir. Bu koşulu sağlamak için genellikle görüntüye yeniden boyutlandırma işlemi yapılmaktadır (Boltaevich, oğlu, qizi, & oğlu, 2019). Ayrıca sınıflandırma çalışmalarında görüntü boyutlandırma işleminin performansı etkilediği görülmüştür (Yildiz & Dizdaroğlu, 2021). Bu sonuca neden olan durumlardan biri, veri setlerinin ağırlıklı olarak farklı görüntü boyutlarına sahip görüntülerden oluşması olabilir. Tüm bu durumlar göz önünde bulundurularak bu çalışmada en yüksek performansın elde edilmesi için farklı görüntü boyutları ile eğitim ve test süreçleri gerçekleştirilmiştir.

Veri artırma:

Bu çalışmada, eğitim setine genişlik kaydırma, yükseklik kaydırma, yakınlaştırma, kesme ve döndürme işlemleri uygulanarak veri artırma aşaması gerçekleştirilmiştir. Uygulanan işlemler ve aralık değerleri Tablo 7 ile verilmiştir.

Tablo 7. Veri artırma işlemleri


İşlem	Aralık değeri
Genişlik kaydırma	0.1
Yükseklik kaydırma	0.1
Yakınlaştırma	0.15
Kesme	0.15
Döndürme	10°

Katman Bilgileri:

Bu çalışmada, trafik ışığı sınıflandırması için ESA mimarisine dayalı derin ağ modeli önerilmiştir. Bu mimari dört evrişim bloğu içerir. Bloklar sırasıyla evrişim katmanı, yığın normalizasyon ve ReLU aktivasyon katmanını içerir. Yaklaşımımızda, doldurma parametresi “aynı (same)”dır ve adım değeri 1'e ayarlanmıştır. Birinci ve üçüncü evrişim bloklarından sonra maksimum havuzlama katmanı yer almaktadır. Daha sonra bir atlama bağlantısı (skip connection) sağlayacak olan ekleme (add) katmanı uygulanır. Bu katmanda, üçüncü ve dördüncü evrişim bloklarının çıktıları toplanır. Ardından, ağın çıktısı vektörleştirilir ve gizli, tam bağlantılı katmana gönderilir. Bu katman 32 nörona sahiptir. Aşırı öğrenmeyi önlemek için Dropout eklenir. Son olarak, 4 sınıflı veri setini sınıflandırmak için model mimarisi, dört nöronlu son tam bağlantılı katman ve softmax ile tamamlanır. Bu çalışmada kullanılan mimari detayları Tablo 8'de ve görsel olarak Şekil 17'de verilmiştir. Burada giriş görüntü boyutu 32 x 32 ve renk uzayı RGB'dir.

Tablo 8. Önerilen mimarinin detayları ve katman bilgileri


Katman	Çekirdek	Adım	Kanal	Çıkış boyutu	Parametre sayısı
Evrişimsel Katman	5 x 5	1	64	32 x 32	4864
Yığın Normalizasyon					256
ReLU					
Maksimum Havuzlama	2 x 2	1	64	16 x 16	
Evrişimsel Katman	3 x 3	1	64	16 x 16	36928
Yığın Normalizasyon					256
ReLU					
Evrişimsel Katman	5 x 5	1	96	16 x 16	153696
Yığın Normalizasyon					384
ReLU					
Maksimum Havuzlama	2 x 2	1	96	8 x 8	
Evrişimsel Katman	3 x 3	1	96	8 x 8	83040
Yığın Normalizasyon					384
ReLU					
Ekleme (Add)			96	8 x 8	
Düzleşme (Flatten)					
Tam Bağlantılı			32		196640
Yığın Normalizasyon					128
Dropout (0.5)					
Tam Bağlantılı			4		132
Aktivasyon (Softmax)					



Şekil 17. Önerilen ESA mimarisinin detayları

2.3. Yol Şerit

Bu çalışmada, yol şerit tespiti için geleneksel yöntemlere dayalı yeni bir model önerilmiştir. Model, ön-işleme, öznitelik çıkarımı, eğri uydurma ve orijinal görüntü üzerinde şerit renklendirme olmak üzere 4 aşamadan oluşmaktadır. Model için genel mimari Şekil 18 ile verilmiştir.



Şekil 18. Yol şerit tespit modeli

Ön işleme:

Ön işleme aşamasında öncelikle, görüntülerin farklı boyutlarda olması ihtimaline karşın görüntüler yeniden boyutlandırılmıştır. Daha sonra görüntüye perspektif dönüşümü uygulanmıştır. Kameralar, insan gözünün perspektif görünümüne sahip olduğundan şerit çizgileri yolun ilerisinde birleşiyormuş gibi görünebilmektedir. Yukarıdan aşağıya doğru yola odaklanılarak şerite olan bakış açısı değiştirilmiştir. Böylece şerite ait bazı özellikler farklı bakış açısında daha iyi algılanabilmektedir. Perspektif dönüşümünün uygulanması, kamera tarafından çekilen perspektif görüntüsünü yolun "kuş bakışı" görünümüne dönüştürecektir. Böylece görüntü, esas olarak şerit işaretlerine odaklanmaktadır ve bunları birbirine nispeten paralel olarak sunmaktadır.

Son olarak şerit renklerini daha iyi ayırt edebilmek için renk uzayı RGB den HSV renk uzayına dönüştürülmüştür. Ayrıca şerit işaretlemesini izole etmek amacıyla hem sarı hem de beyaz renkli şerit çizgileri için farklı eşik maskelemesi uygulanmıştır.

Öznitelik Çıkarımı:

Şerit çizgilerinin tespit edebilmek için öncelikle yayma (dilation) ve aşındırma (erosion) morfolojik işlemleri sırasıyla uygulanmıştır. Böylece şeritler belirginleştirilmiş ve küçük önemsiz noktalar, görüntüden uzaklaştırılmıştır. Daha sonra, görüntüde bulunabilecek ama şerit olmayan küçük boyutlu nesneler, alanları kontrol edilerek görüntüden çıkarılmıştır. Bu işlemler sonucunda kuş bakışı görünümündeki yol üzerinde şeritler elde edilmiştir.

Eğri Uydurma:

Eğri uydurma işleminden önce görüntüye ters perspektif dönüşümü uygulanmıştır. Böylece var olan orijinal görüntü düzeyinde eğri uydurma gerçekleştirilecektir. Eğri uydurma yöntemi olarak DVR (Destek Vektör Regresyonu) kullanılmıştır. DVR hem doğrusal hem de doğrusal olmayan regresyon türleri için tahmin ve eğri uydurma açısından yaygın olarak kullanılmaktadır. DVR, Temel olarak Destek Vektör Makinesi öğelerine dayanmaktadır. Destek vektörler, veri noktalarını belirgin bir şekilde hiper düzlem etrafında ayırtıran n-boyutlu bir özellik uzayında üretilen hiper düzleme yakın noktalardır (Parbat & Chakraborty, 2020). Eğri uydurma ile var olan şerit çizgileri, yol boyunca uzatılmıştır.

Şerit Belirleme ve Renklendirme:

Yol görüntüleri üzerinde perspektif dönüşümü yapılmasına rağmen birden fazla yol çizgisi bulunabilir. Buna bağlı olarak da birden fazla eğri uydurulabilir. Burada, yolun kesikli çizgilerden oluşması da bir etkidir. Şerit renklendirme için kullanılacak olan şerit çizgilerini belirlemek için konum bilgisinden yararlanılır. Bulunulan şeritin görüntüde orta nokta arasında yer alacağı ve yolun alt kısmından başlayacak şekilde seçilmesi gerektiği bilgisi yöntemine eklenmiştir. Bu işlemler sonucunda, elde edilen çizgiler arası renklendirilmiş ve şerit, belirgin hale getirilmiştir. 2 şerit çizgisi arası yeşil renk ile boyanmıştır.

3. BULGULAR VE TARTIŞMA


Bu bölümde, yapılan çalışmalara ait sonuçlar verilmiş ve incelenmiştir.

3.1. Trafik İşareti


3.1.1. Trafik İşareti Algılama

Bu çalışmada, trafik işareti algılama için aracın ön kısmında bulunan kamera ile çekilen görüntüler kullanılarak trafik işaret algılama gerçekleştirilmiştir. Kullanılan veri seti Samsun ili Atakum ilçesinde farklı yer ve zamanlarda çekilmiş 20 görüntüyü içermektedir. Görüntülerdeki trafik işaretleri; azami hız sınırlaması, yaya geçidi, ileri ve sola mecburi yön, sağa tehlikeli viraj, kasisli yol, dönel kavşak, duraklama ve park etmek yasak gibi tehlike uyarı, trafik tanzim ve park etme işaretlerini içermektedir. Çalışmada kullanılan verilere ait örnek görüntüler Şekil 19 ile gösterilmiştir.

İşlemler, MATLAB 2018b benzetim ortamının Image Processing Toolbox'ı kullanılarak gerçekleştirilmiştir. Program, 2.5 GHz işlemci ve 16 GB belleğe sahip bir bilgisayarda koşulmuştur. Ortalama işlem süresi 0.58 sn'dir.



Şekil 19. Veri seti örnek görüntüler a) Sağa mecburi yön b) Yaya geçidi c) Duraklamak ve park etmek yasaktır d) Okul geçidi



Şekil 20. Önerilen yöntemin işlem adımları

Görüntülere uygulanan işlem aşamaları Şekil 20 ile verilmiştir. İlk olarak giriş görüntülerinin aynı çözünürlüğe sahip olması için görüntü boyutu yeniden düzenlenmiş ve gri seviye görüntüye dönüştürülmüştür. Burada kullanılan girdi görüntüsünün renk uzayı RGB'dir. Trafik işaretlerine bakıldığında neredeyse tümünde renklerin mavi ve kırmızıdan oluştuğu görülmektedir. Gri seviye görüntüye dönüştürülürken kırmızı ve mavi renk bileşenleri ayrı ayrı işlenmiştir. Gürültü giderme işlemi 3 x 3 boyutunda medyan filtre kullanılarak gerçekleştirilmiştir. Bir sonraki aşamada mavi ve kırmızı renk bileşenleri eşiklemeye tabi tutularak tek bir görüntüde birleştirilmiştir. Burada kırmızı, mavi veya her iki renge sahip trafik işaretlerinin saptanabilmesi amaçlanmıştır. Bu aşamalara ait örnek görüntüler Şekil 21'de gösterilmiştir.

Siyah-beyaz görüntü elde edildikten sonra morfolojik açma ve kapama işlemleri gerçekleştirilmiştir. Kapama işlemi ile şekillerde eksik kalan kısımların veya boşlukların doldurulması, açma işlemi ile de trafik işaretlerine ait olmayan küçük gürültü nesnelerinin yok edilmesi sağlanmıştır. Bir sonraki aşamada şekilsel özellikler dikkate alınarak trafik işareti olmayan nesneler görüntüden ayıklanmıştır. Burada trafik işaret şekilleri olarak üçgen, kare ve yuvarlak ele alınmıştır. Nesnelerin bağlantılı bileşenleri göz önüne alınarak bu üç şekil sınıfına girmeyen nesneler elenmiştir. Bağlantılı bileşenler için MATLAB Image Processing Toolbox içerisinde bulunan regionprops metodu kullanılmıştır. Burada nesnelerin geometrik merkez, alan çevre, genişlik ve yükseklik bilgileri elde edilmiştir. Bu bilgiler ile yuvarlak (10), kare (11) ve üçgen (12) metrikleri hesaplanmıştır. Daha sonra

metrik değerleri dikkate alınarak Şekil 22 ile verilen karar ağacı oluşturulmuştur. Karar ağacı sonucunda herhangi 3 şekle ait olmayan nesneler trafik işareti olamayacağı için görüntüden çıkarılmıştır.

$$\text{Yuvarlak metrik} = \frac{\text{Çevre} * 2}{4 * \pi * \text{Alan}} \quad (10)$$

$$\text{Kare metrik} = \begin{cases} \frac{\text{Genişlik}}{\text{Yükseklik}}, \frac{\text{Genişlik}}{\text{Yükseklik}} < 1 \\ \frac{\text{Yükseklik}}{\text{Genişlik}}, d.d. \end{cases} \quad (11)$$

$$\text{Üçgen metrik} = \frac{\text{Alan}}{\text{Genişlik} * \text{Yükseklik}} \quad (12)$$



(a)



(b)




(c)



(d)

Şekil 21. a) Ölçeklenmiş görüntü b) Kırmızı renk bileşenine ait gri seviye görüntü c) Mavi renk bileşenine ait gri seviye görüntü ve d) Kırmızı + mavi renk bileşenlerinin eşikleme sonrası siyah-beyaz görüntü




Şekil 22. Geometrik şekiller için karar ağacı


Nesnelerin alan değerleri dikkate alınarak trafik işaretlerinin çok büyük ve küçük boyutlarda olmayacağı bilgisine bakılmıştır. Piksel bazlı bakıldığında tüm görüntüye oranla %1 - %2 arasındaki nesneler trafik işareti olabilecek boyuttadır. Bunun dışında kalan aykırı nesneler görüntüden elenmiş ve sonuç görüntü elde edilmiştir. Daha sonra trafik işareti görüntüden çıkarılarak algılama işlemi gerçekleştirilmiş olur. Bu aşamaları içeren görüntüler Şekil 23 ile verilmiştir.

Veri setinde bulunan bir diğer görüntüye ait tüm işlem adımları Şekil 24 (a- Ölçeklenmiş görüntü b- Kırmızı renk bileşenine ait gri seviye görüntü c- Mavi renk bileşenine ait gri seviye görüntü d- Kırmızı ve mavi renk bileşenleri eşikleme sonrası siyah-beyaz görüntü e- Açma-Kapama işlemleri sonrası görüntü f- Şekilsel özelliklere uymayan nesnelerden giderilmiş görüntü g- Sonuç görüntüsü ve h- Saptanan trafik işareti) ile gösterilmiştir.

Bir görüntüde birden fazla trafik işaretinin bulunması durumunda renk ve şekil tabanlı yöntemde algılama işlemi tüm işaretlerde gerçekleştirilmiştir. Önerilen yöntem, veri setindeki diğer görüntülere de uygulanmış, işlemler sonucunda, görüntü içerisinde saptanan trafik işaretlerinin doğru şekilde bulunduğu görülmüştür. Bu görüntülerde ilk saptanan trafik işaretleri Şekil 25 (a- Yaya geçidi b- Sağa mecburi yön c- Duraklamak ve park etmek yasaktır d- Okul geçidi e- Yaya geçidi f- Park etmek yasaktır g- Kasisli yol h- Duraklamak ve park etmek yasaktır i- Dönel kavşak j- Dur k- Sağa tehlikeli viraj l- Onarım yaklaşım levhası m- İleri ve sola mecburi yön + dönüş adası ek helvası n- Her iki yandan gidiniz + dönüş adası ek helvası o- Azami hız sınırlaması + ışıklı işaret cihazı p- Tramvay hattı ile oluşan kavşak q- Azami hız sınırlaması ve r- Park etmek yasaktır + kasisli yol) ile verilmiştir.



Şekil 23. a) Açma-Kapama işlemleri sonrası görüntü b) Şekilsel özelliklere uymayan nesnelerden giderilmiş görüntü c) Sonuç görüntüsü ve d) Saptanan trafik işareti



Şekil 24. Örnek görüntüye ait tüm işlem adımları




Şekil 25. Görüntülerde saptanan trafik işaretleri

3.1.2. Transfer Öğrenme Yoluyla Trafik İşareti Sınıflandırma

Bu çalışmada, önceden eğitilmiş modeller kullanılarak GTSRB veri seti içerisinde bulunan 10 sınıfa ait tanıma sonuçları karşılaştırılmıştır. Uygulamanın gerçekleştirilmesinde Keras kütüphanesinden yararlanılmıştır. ImageNet veri seti üzerinde eğitilen ESA modelleri, GTSRB trafik işaretleri veri setinde bulunan 10 sınıfa ait görüntüler üzerinde tam bağlantılı ağ katmanları değiştirilerek tekrar eğitilip test edilmiştir. Sınıflar, trafik uyarı işaretlerine ve tanzim işaretlerine ait görüntüleri içermektedir. Örnek görüntüler Şekil 26'da (a- Kamyonlar


için öndeki taşıtı geçmek yasaktır, b- yol ver, c- dur, d- sola teklisel devamlı virajlar, e- kasisli yol, f- kaygan yol, g- ışıklı işaret cihazı, h- yaya geçidi, i- ileriden sola mecburi yön ve j- ada etrafında dönünüz) verilmiştir. Eğitim kümesi, 7810 ve test kümesi ise 105 trafik işareti görüntüsünü içermektedir. ESA modellerinde ortak hiper parametreler kullanılmıştır. Burada mini-toplu (mini-batch) boyutu 32 ve optimizasyon algoritması RMSprob (ortalama karekök hata olasılığı) olarak seçilmiştir. Bu çalışmada, VGG19, ResNet50, MobileNet ve Xception modelleri üzerinde tam bağlantılı katmanlar hariç transfer öğrenme ile elde edilen ağırlıklar kullanılmıştır. Diğer katmanlar ise güncellenmiş ve 10 sınıfa ait tanıma yapacak şekilde düzenlenmiştir. Tüm modellere ait düzenlenen katmanlara ait değerler Tablo 9 ile verilmiştir. Burada, veri setindeki görüntüler yeniden boyutlandırılmış ve modellerin giriş katmanları da bu değerlere göre güncellenmiştir. Düzenlemeler sonucunda VGG19, ResNet50 ve MobileNet modelleri Google Colab üzerinden 100 epok ile ve Xception modeli ise, 50 epok ile eğitilmiştir. Bazı epok değerlerine ait kayıp ve doğruluk sonuçları, eğitim ve test işlemleri için sırasıyla Tablo 10-13'te verilmiştir. Bu bağlamda, ortak epok değerlerine ek olarak en yüksek doğruluk üreten sonuçlar da ilgili tablolarda belirtilmiştir.



Şekil 26. Trafik işaretleri:

Tüm epok değerlerine göre test verilerinin doğruluk sonuçları ise, MobileNet, VGG19 ve ResNet50 için karşılaştırmalı olarak Şekil 27'de gösterilmiştir. Burada en iyi doğruluk sonucuna MobileNet modeli ile ulaşıldığı görülmektedir. Diğer en iyi sonuç ise Xception modeliyle elde edilmiştir. Fakat bu model, diğerlerine göre daha uzun işlem süresine sahiptir. Şekil 28'de ise, VGG19, MobileNet ve ResNet modellerine ait test kayıp sonuçları karşılaştırılmıştır. Grafiklerdeki dalgalanmalar, optimizasyon algoritmasından kaynaklanabilmektedir. 50 epok ile Xception modeline ait kayıp ve doğruluk sonuçları Şekil 29 ile gösterilmiştir. Doğruluk oranı salınmalar dışında giderek artış göstermiştir. Doğruluk



oranlarına bakıldığında, genel itibari ile başarı sırası MobileNet, Xception, VGG19 ve ResNet50 şeklindedir.



Şekil 27. VGG19, MobileNet ve ResNet50 modellerine ait test doğruluk sonuçları (100 epok için)

Tablo 9. Modellerde yapılan düzenlemeler

Model	Görüntü boyutları	Tam bağlantılı katman nöron sayısı	Aktivasyon fonksiyonu	Dropout oranı
VGG19	48 x 48	2 x 256	ReLU	2 x 0.5
ResNet50	64 x 64	256		-
MobileNet	64 x 64	256		0.5
Xception	75 x 75	25		0.5



Tablo 10. VGG19 için kayıp ve doğruluk sonuçları

Epok	Kayıp (Eğitim)	Doğruluk (Eğitim)	Kayıp (Test)	Doğruluk (Test)
1	5.26	58.84	6.92	40.63
10	0.72	87.22	1.74	64.65
20	0.36	92.84	1.97	68.54
50	0.16	97.9	3.08	69.03
51	0.29	95.75	2.47	72.21
100	0.17	97.84	3.47	66.82

Tablo 11. ResNet50 için kayıp ve doğruluk sonuçları

Epok	Kayıp (Eğitim)	Doğruluk (Eğitim) %	Kayıp (Test)	Doğruluk (Test) %
1	0.33	93.31	6.12	49.4
10	0.099	98.38	4.73	61.93
11	0.16	98.16	4.64	67.82
20	0.05	99.16	4.29	67.29
50	0.04	99.63	5.49	59.06
100	0.037	99.53	5.46	62.75

Tablo 12. MobileNet için kayıp ve doğruluk sonuçları

Epok	Kayıp (Eğitim)	Doğruluk (Eğitim) %	Kayıp (Test)	Doğruluk (Test) %
1	1.15	78.12	1.62	62.84
10	0.43	95.97	1.19	88.22
20	0.14	98.41	0.03	99.06
25	0.298	97.73	1.3488e-07	100
50	0.21	98.53	0.93	94.26
100	0.03	99.78	1.1921e-07	100

Tablo 13. Xception için kayıp ve doğruluk sonuçları

Epok	Kayıp (Eğitim)	Doğruluk (Eğitim) %	Kayıp (Test)	Doğruluk (Test) %
1	1.67	45.22	4.09	20.39
10	1.108	61.34	1.88	24.32
20	0.44	82.19	0.59	73.4
49	0.317	95.19	0.16	94.41
50	0.29	94.69	0.57	92.9

3.1.3. Renk Uzayına Dayalı Trafik İşareti Sınıflandırma

Önerilen ESA modelinin uygulaması:

Önerilen model Google Colab üzerinde 50 epok ile eğitilmiştir. Eğitim ve test aşamalarında TensorFlow platformu ve Keras kütüphanesi kullanılmıştır. Yığın boyutu (batch size) 32, kayıp fonksiyonu olarak kategorik çapraz entropi seçilmiştir. Öğrenme oranı 0.001 olarak seçilmiştir. Optimizasyon algoritması olarak Adam kullanılmıştır. Başlangıçta giriş görüntüsü ağa 32 x 32 giriş boyutunda verilmiştir.


Renk Uzayları:

Bu çalışmada öncelikle farklı renk uzaylarına sahip 32 x 32 giriş görüntüleri kullanılmıştır. 4 farklı renk uzayına ait test sonuçları Tablo 14 ile gösterilmektedir. Sonuçlar incelendiğinde en yüksek doğruluk değerinin RIQ ve LGI giriş görüntülerinin modele verilmesiyle elde edildiği görülmüştür.

Tablo 14. Renk uzaylarına göre test doğruluk sonuçları

Renk Bilgisi	Doğruluk (%)
RIQ	96.21
LGI	96.56
CIELab	94.98
RGB	95.06


Daha sonra renk uzayları arasında ikili kombinasyonlar denenmiştir. 2 giriş görüntüsü girdi olarak birleştirilmiş ve modele verilmiştir. İlk katman bilgilerine ait görüntü Şekil 30 ile gösterilmiştir. 2 giriş görüntüsü alan model üzerinde aynı hiper parametreler kullanılarak ağ eğitilmiş ve test sonuçları karşılaştırılmıştır. Tablo15 ile verilen sonuçlara bakıldığında 2 giriş görüntüsü üzerinde en yüksek doğruluğuna RIQ ve LGI renk uzaylarının birlikte kullanılmasıyla elde edildiği görülmektedir. Sonuçlara ait kayıp ve doğruluk test sonuçları Şekil 31 ile verilmiştir.



Şekil 30. İkili girişlerin modele verilmesi

Tablo 15. 2’li giriş görüntüleri için test doğruluk sonuçları karşılaştırma

Renk Bilgisi	Doğruluk (%)
RIQ + RGB	98.25
RIQ + CIELab	98.24
RGB + CIELab	97.72
RIQ + LGI	98.54




Şekil 31. a) RIQ + RGB b) RIQ + CIELab c) RGB + CIELab d) RIQ + LGI

Giriş Görüntü Boyutlandırma:

32 x 32 olarak kullanılan giriş görüntü boyutlarına ek olarak 45 x 45 ve 60 x 60 görüntü boyutları da kullanılmıştır. Eğitimler, en iyi test doğruluk sonucunu veren RIQ + LGI renk uzayına sahip giriş görüntüleri üzerinde yapılmıştır. Hiper parametreler üzerinde değişiklik yapılmamıştır. Sonuçlar Tablo 16, doğruluk ve kayıplara ait grafikler Şekil 32 ile gösterilmiştir. Sonuçlara bakıldığında 60 x 60 görüntü boyutu ile daha iyi doğruluk ve daha az kayıp elde edildiği görülmektedir.

Tablo 16. Görüntü boyutlarına göre test doğruluk sonuçları


Renk Bilgisi	Görüntü boyutu	Parametre sayısı	Doğruluk (%)
RIQ + LGI	32 x 32	676,811	98.54
	45 x 45	750,539	97.70
	60 x 60	947,147	98.84



Şekil 32. RIQ + LGI giriş görüntüsü ile görüntü boyutlarına göre test doğruluk sonuçları a) 32 x 32 b) 45 x 45 c) 60 x 60

Şekil 32'deki grafikte test eğrisindeki dalgalanmaları önlemek için öğrenme oranı ayarlanmıştır. Bu ayarlama öğrenme oranı düzenleyicisi (learning rate schedule) kullanılarak gerçekleştirilmiştir. Zamanlayıcı fonksiyonu ilk on epok işleminden sonra üstel olarak azalacak şekilde verilmiştir. On epok işleminden sonra öğrenme oranı güncelleme denklemi (13) ile gösterilmiştir. Modele 60 x 60 giriş görüntüsü verildiğinde kayıp ve doğruluk sonuç grafiği Şekil 33 ile verilmiştir. Grafik incelendiğinde zamanlama ile dalgalanmaların önleniği görülmektedir.

$$\text{öğrenme oranı} = \text{öğrenme oranı} * e^{-0.1} \quad (13)$$



Şekil 33. Öğrenme oranı düzenleyicisinden sonra 60 x 60 giriş görüntüsü için test ve eğitim kayıp ve doğruluk sonuçları

Son olarak bu model üzerinde 3 giriş görüntüsüne ait model eğitilmiştir. Daha önceki sonuçlarda 60 x 60 görüntü boyutu ile yüksek doğruluk elde edildiği için bu aşamada sadece bu görüntü boyutu kullanılmıştır. Yüksek doğruluk üreten RIQ + LGI renk uzaylarına 3. renk uzayı olarak sırasıyla RGB ve CIELab renkleri eklenmiştir. Tablo 17 ile verilen test sonuçları RGB ile daha yüksek doğruluğa ulaşıldığını göstermektedir. Ancak 2 giriş görüntüsü verildiğinde elde edilen doğruluk değeri ile karşılaştırıldığında yüksek doğruluk elde edilememektedir.

Tablo 17. 3'lü giriş görüntüleri için test doğruluk sonuçları karşılaştırma

Renk Bilgisi	Görüntü boyutu	Parametre sayısı	Doğruluk (%)
RGB + RIQ + LGI	60 x 60	951,947	98.34
CIELab + RIQ + LGI			98.27

Önerilen yöntem, literatürdeki çeşitli çalışmaların yanı sıra insan performansı ile karşılaştırılmıştır. Performans sonuçları Tablo 18'de sunulmaktadır. Sonuçlar incelendiğinde önerilen yöntemin MCDNN dışındaki diğer ağlara göre daha yüksek doğruluk elde ettiği ancak önerilen yöntemin MCDNN'ye göre 40 kat daha az parametre sayısına sahip olduğu görülmektedir. Ayrıca CDNN ağına kıyasla daha az sayıda parametreye sahiptir.

Tablo 18. GTSRB veri seti üzerinde performans karşılaştırması

Model	Parametre Sayısı	Top-1 Doğruluk
İnsan (Stallkamp J. , Schlipsing, J., & Igel, 2012)	-	98.81 (%)
CDNN (Cireşan, Meier, Masci, & Schmidhuber, 2011)	1.54 M	98.58 (%)
MicronNet ^a (Wong, Shafiee, & Jules, 2018)	0.51 M	98.09 (%)
MCDNN (Ciregan, Meier, & Schmidhuber, 2012)	38.5 M	99.46 (%)
Önerilen Yöntem	0.95 M	98.84 (%)

^a16 bit sabit noktalı top-1 doğruluk

3.1.4. Topluluk Öğrenme ile Trafik İşareti Sınıflandırma

Deneyisel çalışma için Python dili ve Tensorflow kullanılmıştır. İşlemler Google Colab üzerinde gerçekleştirilmiştir. Öncelikle veri seti üzerinde ön işleme uygulanmıştır. Çözünürlüğü 15 x 15'ten 250 x 250'ye kadar değişkenlik gösteren görüntüler içeren veri seti 60 x 60 olarak yeniden boyutlandırılmıştır. Daha sonra kenar algılama ve görüntü iyileştirme uygulanmıştır. Sınıflar arasında görüntü sayısı farkını ortadan kaldırmak için veri artırma uygulanmıştır. Eğitim veri seti, %90 eğitim seti, %10 doğrulama (validation) seti olacak şekilde bölünmüştür.

Derin öğrenme modelimizin eğitimi aşamasında; Adam optimizasyon algoritması kullanılmıştır. Yığın boyutu 32 ve öğrenme oranı 0.001 olarak seçilmiştir. Kayıp fonksiyonu olarak 'categorical_crossentropy' seçilmiştir. Öğrenme oranı azaltma için Keras kütüphanesinde bulunan ReduceLROnPlateau sınıfı kullanılmıştır. Burada kullanılan parametreler, factor=0.02, patience=10, ve min_lr=0.0001 dir. Yani eğitim sırasında 10 epok boyunca doğrulama kayıp (validation loss) azalmayı bıraktığında öğrenme oranı azaltılır. Yeni öğrenme oranı denklem 14 ile belirlenmiştir.

$$yeni_öo = öo * faktör \quad (14)$$

Burada öo var olan öğrenme oranını, yeni_öo ise bundan sonra kullanılacak olan öğrenme oranını ifade eder. Faktör ise kullanılan ReduceLROnPlateau sınıfına ait öğrenme oranı güncelleme oranının parametresini belirtir. Önerilen model için GTSRB veri seti 50 epok için eğitilmiştir. Parametre sayısı 7152312'dir.

Aktivasyon fonksiyonu seçimi:

Öncelikli olarak 3 gizli evrişim katman blokları için farklı aktivasyon fonksiyonlarına göre eğitim ve test denemeleri yapılmıştır. Ön işlem aşamasında Çekirdek 1 kullanılarak elde edilen veri seti üzerinde yapılan eğitim sonucunda elde edilen test doğruluk sonuçları Tablo 19 ile verilmiştir. Sonuçlar incelendiğinde en yüksek test top-1 doğruluk değerinin %99.62 olarak RELU ve 0.1 ile 0.01 parametre değerlerine sahip Leaky ReLU aktivasyon fonksiyonlarının birlikte kullanılması ile elde edildiği görülmüştür.

Tablo 19. Çekirdek 1 kullanılarak elde edilen test doğruluk sonuçları

Blok 1	Blok 2	Blok 3	Doğruluk (%)	F1-Skor	Kesinlik	Duyarlılık
ReLU	ReLU	ReLU	99.43	99.43	99.45	99.43
ReLU	PReLU	LeakyReLU(0.01)	99.52	99.53	99.54	99.52
ReLU	PReLU	LeakyReLU(0.1)	99.47	99.47	99.48	99.47
ReLU	LeakyReLU(0.01)	LeakyReLU(0.1)	99.62	99.62	99.63	99.62

Veri artırma ve Ön işlem Seçimi:

Veri artırma işlemi Keras kütüphanesinde bulunan ImageDataGenerator sınıfı ile gerçekleştirilmiştir. Çekirdek 1 ile ön işlemden geçirilen veri seti, veri artırma işlemi yapılarak, hem de yapılmayarak test sonuçları kıyaslanmıştır. Ayrıca ön işlemenin doğruluk üzerine etkisinin olup olmadığı anlamak için aynı parametrelerle eğitim yapıp sonuçlar incelenmiştir. Ön işleme ve veri artırma durumuna göre test doğruluk sonuçlarına ait karşılaştırmalar Tablo 20 ile verilmiştir. Sonuçlar incelendiğinde veri artırma işlemi ve ön işleme ile doğruluğun arttığı ve böylece daha iyi sınıflandırma yapıldığı görülmektedir. Bir sonra aşamada veri artırma işlemi uygulanarak işlemlere devam edilmiştir.

Tablo 20. Veri artırma ve ön işleme işlemlerine göre GTSRB test sonuçları

Önişlem	Veri artırma	Top-1 Doğruluk (%)	F1-Skor	Kesinlik	Duyarlılık
Var (Çekirdek 1)	Var	99.62	99.62	99.63	99.62
Var (Çekirdek 1)	Yok	99.13	99.13	99.16	99.13
Yok	Var	99.51	99.51	99.52	99.51
Yok	Yok	99.28	99.28	99.30	99.28

Çekirdek Seçimi:

Aktivasyon fonksiyonu ve veri artırma parametreleri seçildikten sonra Çekirdek 2 ile de eğitim gerçekleştirilmiştir. Ayrıca Çekirdek 1 ve Çekirdek 2'nin birlikte kullanılmasıyla

yapılan ön işlemiden sonra eğitim yapılmıştır. Tüm işlemlerden sonra elde edilen test doğruluk sonuçları Tablo 21 ile ayrıca eğitim sırasında elde edilen kayıp (loss) ve doğruluk sonuçları Şekil 34 ile verilmiştir. Grafikler incelendiğinde yaklaşık 10 epok işleminden sonra öğrenmenin azaldığı görülebilmektedir. Grafikte verilen doğruluk değerleri aralık kısıtlı olduğu için görülmese de öğrenme 50 epok işlemine kadar devam etmektedir. Öğrenmenin yavaş olduğu durumlarda öğrenme oranı düşürülerek öğrenmenin hızlı ve etkili bir şekilde devam etmesi sağlanmıştır.


Sonuçlar incelendiğinde en yüksek test doğruluğuna *Çekirdek 2* ile filtreleme yapılarak görüntülerin model girişine verilmesiyle elde edildiği görülmüştür.

Tablo 21. Çekirdekler için test doğruluk sonuçları

Çekirdek	Top-1 Doğruluk (%)	F1-Skor	Kesinlik	Duyarlılık
Çekirdek 1	99.62	99.62	99.63	99.62
Çekirdek 2	99.65	99.65	99.66	99.65
Çekirdek 1 & Çekirdek 2	99.39	99.39	99.41	99.39

Yığınlama Topluluğu (Stacking Ensemble)

Yığınlama topluluğu model ile daha önceden eğitilmiş alt ağların birlikte kullanılmasıyla daha iyi sonuçların elde edilmesi planlanmıştır. Modeldeki toplam parametre sayısı 14,344,867 olmasına rağmen alt modellerdeki parametreler eğitilemez yapıldığından dolayı eğitilebilir parametre sayısı sadece 39,643'dir. Model, 20 epok ile eğitilmiştir. Derleme seçenekleri ise alt modellerdeki ile aynıdır. Buna göre model test doğruluk sonucu % 99.75 olarak elde edilmiştir.



Şekil 34. Eğitim sırasındaki kayıp ve doğruluk sonuçları üst) Çekirdek 1 orta) Çekirdek 2 alt) Çekirdek 1 & Çekirdek

GTSRB veri seti için mevcut sınıflandırma çalışmaları ve bu çalışmada önerilen yöntemin performans ve parametre sayısı karşılaştırmaları Tablo 22 ile verilmiştir. Sonuçlar incelendiğinde önerilen yığınlama topluluğu (stacking ensemble) modeli ile daha yüksek performans elde edildiği görülmektedir. Parametre sayısı düşük olan çalışmalarla kıyaslandığında önerilen modelin doğruluk değerinin daha yüksek olduğu söylenebilir. Ayrıca (Ciregan, Meier, & Schmidhuber, 2012), (Jin, Fu, & Zhang, 2014) ve (Saha, Kamran, & Sabbir, 2018, December) çalışmaları ile önerilen yöntemin tek çekirdek bazında sonuçları karşılaştırıldığında bile hem parametre sayısının daha az, hem de doğruluk değerinin daha yüksek olduğu görülmektedir.

Tablo 22. GTSRB veri setinde performans ve parametre sayısı karşılaştırmaları

Model ismi	Top-1 Doğruluk (%)	Parametre sayısı	F1-Skor	Kesinlik	Duyarlılık
Önerilen (Topluluk)	99.75	14.34 M	99.75	99.76	99.75
DeepThin (Haque, Arefin, Shihavuddin, & Hasan, 2021) (Topluluk)	99.72	2.69×10^5	-	-	-
Student model (Zhang, Wang, Lu, Wang, & Sangaiah, 2020)	99.61	7.32×10^5	-	-	-
(Aghdam, Heravi, & Puig, 2017)*	99.61	5.6 M	99.4	99.37	99.63
Single CNN with 3 STNs (Arcos-García, Álvarez-García, & Soria-Morillo, 2018)	99.71	14.6 M	99.71	99.71	99.71
İnsan (ortalama) (Stallkamp J. , Schlipsing, J., & Igel, 2012)	98.84	-	-	-	-
İnsan (En iyi) (Stallkamp J. , Schlipsing, J., & Igel, 2012)	99.22	-	-	-	-


Tablo 22'nin devamı

MSCNN (Sermanet & LeCun, 2011)	99.17	1.43 M	-	-	-
MCDNN (Ciregan, Meier, & Schmidhuber, 2012)	99.46	38.5 M	-	-	-
DHCNN (Saha, Kamran, & Sabbir, 2018, December)	99.33	6.26 M	-	-	-
(Bi, Yu, Gao, Zhou, & Yao, 2021)	99.21	1.15 M	-	-	-
HLSGD (Jin, Fu, & Zhang, 2014)	99.65	23.2 M	-	-	-
Hybrid-TSR (Bayoudh, Hamdaoui, & Mtibaa, 2021)*	99.28	4 M	99.33	99.24	99.36
(Patel, Shukla, Shrivastava, & Gyanchandani, 2022)	99.56	-	-	-	-
(Zhang & Huang, 2022)	99.60	-	-	-	-
(Zheng & Jiang, 2022)	98.84	-	-	-	-
(Fang, Cao, & Li, 2022)	99.38	0.44 M	-	-	-
(Youssof, 2022)	99.20	0.8 M	-	-	-
(Nartey, Yang, Asare, Asare, & Asare, 2020)	99.27	-	99.94	99.97	99.93
(Lim, Lee, Lim, & Ong, 2023)	98.84	-	98.84	98.84	98.84
Önerilen (Çekirdek 1)	99.62	7.15 M	99.62	99.63	99.62
Önerilen (Çekirdek 2)	99.65	7.15 M	99.65	99.66	99.65


* F1-skor, kesinlik ve duyarlılık değerleri orijinal çalışma tablosundan hesaplanmıştır.

Model sonuçlarını kesinlik ve duyarlılık metrikleri üzerinden değerlendirmek için kesinlik-duyarlılık eğri grafiği Şekil 35-a ile verilmiştir. Ayrıca modelin sınıflandırma performansını değerlendirmek için ROC eğrisi ile de sonuçlar verilmiştir (Şekil 35-b).

Ayrıca GTSRB üzerinde sınıf bazında ROC AUC grafiği Şekil 36 ile gösterilmiştir. ROC AUC ortalama puanı 0,9996'dır.



Şekil 35. a) Kesinlik-duyarlılık eğrisi b) ROC eğrisi




Şekil 36. GTSRB veri seti üzerinde ROC AUC grafiği

Yanlış Sınıflandırılan Görüntüler:


Yığınlama topluluğu modeli ile yanlış sınıflandırılan görüntüler incelenmiştir. 12,630 görüntüden sadece 31 tanesinin doğru sınıfı tahmin edilememiştir. Bu görüntüler Şekil 37 ile gösterilmiş, gerçek ve tahmin edilen sınıf isimleri üst tarafta belirtilmiştir (T: Tahmin, G: Gerçek). Görüntüler incelendiğinde, insan gözüyle dahi ayırt edilemeyecek şekilde bulunan, oldukça bozunmuş, aydınlanma sorunları bulunan görüntüler olduğu görülebilmektedir.

Ek olarak her bir sınıf için test görüntüleri üzerinde F1-skor, kesinlik ve duyarlılık sonuçları hesaplanmıştır. Sonuçlar Ek Tablo 1 ile verilmiştir. Support sütunu ise her bir sınıfa için toplam test görüntü sayısını ifade etmektedir.

Ayrıca karışıklık matrisi ile sonuçları sayısal olarak görmek mümkündür (Şekil 38). Karışıklık matrisine bakıldığında 3 ve 18 etiketli görüntülerin sayıca diğerlerinden daha fazla sayıda yanlış sınıflandırıldığı görülmektedir. Fakat yanlış sınıflandırılan görüntüler yine genelde aynı sınıfa yanlış tahmin edilmiştir. Bunun nedeni tahmin edilen ve gerçek görüntülerin şekil bakımından birbirine benzemesinden kaynaklanmaktadır. Ön işleme ve özellik çıkarma aşamasında şeklin ön plana çıktığı düşünülebilir.



Şekil 37. Yığınlama topluluğu modeli ile GTSRB’de yanlış sınıflandırılan görüntüler



Şekil 38. GTSRB veri seti için önerilen yığılma topluluğu modelinin karışıklık matrisi

Açıklanabilirlik:

ESA'lardaki doğal açıklanabilirlik eksikliğini ortadan kaldırmak için, anlaşılabilirliği artırmayı amaçlayan ESA katmanlarının çıktılarını analiz etmek ve görselleştirmek için post-hoc açıklayıcı yöntemler kullanılmaktadır. Grad-CAM (gradyan ağırlıklı sınıf aktivasyon haritalaması), öngörülen çıktı üzerinde olumlu etkisi olan bölgeleri vurgulayan ısı haritaları oluşturmaktadır. Grad-CAM, tahmin edilen çıktıya katkıda bulunan bölgelerin bulunmasına yardımcı olmak için evrişimli katmanlarda bulunan uzamsal bilgileri kullanır. Bu uzamsal bilgi, düzleştirme katmanından ve tamamen bağlantılı katmanlardan sonra kaybolur. Bu


nedenle, bu önemli bölgeleri tanımlamak için evrişim katmanındaki gradyanlar kullanılmaktadır (Papandrianos, ve diğerleri, 2022). Bu çalışmada, ESA modelinin tahminlerini yorumlama yöntemi olarak Grad-CAM seçilmiştir. Grad-CAM'in etkinliği, önerilen bir model üzerinde test edilmiş ve görselleştirme sonuçları iyileştirilmiştir.

Grad-CAM tarafından oluşturulan görselleştirme sonuçları Şekil 39 ile verilmiştir. Şekil, orijinal görüntüleri, Grad-CAM yöntemiyle oluşturulan ısı haritalarını ve orijinal görüntünün ısı haritasına bindirilmesiyle elde edilen görselleştirme sonuçlarını içermektedir. Sınıflandırma sonuçlarında piksellerin önemi, ESA tabanlı sınıflandırma modelinin her bir piksele verdiği dikkat düzeyini yansıtan farklı renklerle temsil edilmiştir.


Belirsizlik Değerlendirme:

Çeşitli makine öğrenimi problemlerinde, deterministik sinir ağları, etkili tahmin edicilerin öğrenme yeteneklerini göstermiştir. Bununla birlikte, ağ eğitimi sırasında tahmin kaybını en aza indirmeye yönelik geleneksel yaklaşım, modelin tahminlerine olan güvenini gözden kaçırmaktadır. Çalışmamızda, tahmin belirsizliğini ağırlık belirsizlikleri yoluyla dolaylı olarak çıkaran Bayes sinir ağlarının aksine, (Sensoy, Kaplan, & Kandemir, 2018) çalışmasında önerilen öznel mantık teorisini kullanarak tahmin güvenini açıkça modelleyen yöntem kullanılmıştır. Burada, sınıf olasılıklarını temsil etmek için bir Dirichlet dağılımı sunulmuş, sinir ağının tahminlerini öznel görüşler olarak ele alınmıştır. Çok sınıflı sınıflandırma için ortaya çıkan tahmin edici, sinir ağının sürekli çıktısı tarafından belirlenen parametreleri ile başka bir Dirichlet dağılımı ile temsil edilmiştir.

Çalışmamızda, verilen örnek bir sınıf görüntüsü, 10 derece açılarla toplamda 180 derece döndürülmüş ve modelin görüntüyü hangi sınıf olarak tahmin ettiği belirlenmiştir. Burada kullanılan model, görüntü döndürüleceği için girişte tek bir çekirdek verilen modeldir. Sunulan kayıp fonksiyonu ile belirsizlik tahminlerinin yapılması için *Çekirdek 1* ile model yeniden eğitilmiştir. Örnek görüntüler için her açı değişiminde modelin tahmin ettiği sınıf etiketi, olasılık ve belirsizlik değeri Şekil 40 ile verilmiştir. Sonuçlar incelendiğinde döndürmeden kaynaklı yanlış tahmin yapıldığında belirsizlik değerinin arttığı görülmektedir.



Şekil 39. Grad-CAM ile elde edilen örnek görüntü sonuçları




Şekil 40. 0 ile 180 derece arasında farklı açılara göre sonuçlar. Üst: dönme sonucu olasılık ve belirsizlik, Orta: dönme sonucu sınıf tahmini, Alt: Dönmenin örnek görüntüsü

Güvenlik İzleme:

Otonom araçlarda yapay zekâ ve veriye dayalı karar verme sistemlerinin uygulanması hızla artmaktadır. Otonom araçlar dinamik ortamlarda çalıştıklarından, yetersiz eğitim verileri, dağıtım kayması veya siber güvenlik saldırısı nedeniyle bilinmeyen bir gözlemle karşılaşma riskleri nispeten yüksektir. Bu nedenle, yapay zekâ tabanlı algoritmalar, çevreyi daha iyi yorumlamak, otonom sürüş riskini azaltmak ve yıkıcı kazalardan kaçınmak için güvenilir kararlar almalıdır. Aslansefat vd., otonom araç yazılımında makine öğrenimi tabanlı sınıflandırıcıların güvenliğini sağlamak için tasarlanmış bir döngüdeki insan prosedüründe ampirik kümülatif dağılım fonksiyonu (ECDF, Empirical Cumulative Distribution Function) tabanlı istatistiksel mesafe ölçümlerini uygulayan SafeML II adlı bir yaklaşım önermektedir (Aslansefat, Kabir, Abdullatif, Vasudevan, & Papadopoulos, 2021). Yaklaşım, modelden bağımsızdır ve çeşitli makine öğrenimi ve derin öğrenme

sınıflandırıcılarını kapsayabilmektedir. Önerilen yaklaşımın yeteneklerini göstermek için GTSRB kullanılmıştır.

SafeML kavramı, istatistiksel mesafeleri ölçmek ve mevcut etiketlerin yokluğunda model doğruluğunu tahmin etme etrafında dönmektedir. Gerçek zamanlı doğruluk tahminine sahip olmak, güvenlik kaygıları olan uygulamalar için kritik olabilmektedir. Bu bölümde, istatistiksel farklılıklar ele alınmıştır. Bunu yapmak için, gerçek etiketlerin tahmin edilen etiketlerle eşleşmediği test verileri belirlenir. Örneğin, etiket == 3 ile uğraşırken, güvenilir eğitim görüntüleri (gerçekte 3 etiketli ve 3 olarak tahmin edildi) ile etiket 3 olması gerekirken yanlış sınıflandırılan (örneğin; gerçekte 3 etiketli fakat 5 olarak sınıflandırıldı) görüntüler karşılaştırılır. İstatistiksel parametrik haritalama yoluyla, ESA modelin yanlış kararlar vermesine neden olan istatistiksel faktörleri belirlemeye çalışılır. Örnek uygulama Şekil 41 ile verilmiştir. Burada ilk satır, bahsedilen 2 görüntü arasındaki İstatistiksel Parametrik Haritalamayı, 2. satır doğru etiketlenen görüntüyü, 3. satır ise yanlış etiketlenen görüntünün sırasıyla R, G, B renk kanallarını göstermektedir. Son satırda, etiket 3 ile gerçek görüntü için bir Wasserstein mesafesi ölçümü sunulmaktadır. Burada, sonuçların daha güvenilir ve daha az gürültülü olmasını sağlamak için p değeri dikkate alınarak ECDF tabanlı bir mesafe ölçümü kullanılır. İstatistiksel yorumlanabilirlik amacıyla kullanıldığında. SafeML II'nin istatistiksel olarak sağlam bir mesafe gösterimi sergilediği ve arka plan sinyallerini dahil etmeden ön plandaki alanları etkili bir şekilde yakaladığı görülmektedir.



Şekil 41. 1. Satır: İstatistiksel Parametrik Haritalama, 2. satır: doğru etiketlenmiş görüntü
3. satır: yanlış etiketlenmiş görüntü, 4. Satır: Wasserstein mesafesi ölçümü (Sütunlar sırayla R, G, B renk kanallarını ifade eder.)

Geçiş Testi:

Modelin sağlamlığını test etmek için GTSRB veri setine ek olarak literatürde yine sıklıkla kullanılan BTSC (Belgium Traffic Sign Classification) (Mathias, Timofte, Benenson, & Gool, 2013) veri seti ile performans karşılaştırması yapılmıştır.

GTSRB veri seti ile eğitilmiş önerilen yöntem ile transfer öğrenme uygulanarak tekrar eğitim yapılmıştır. Burada, sınıflandırma aşamasına kadar olan katmanlar eğitilemez (non-trainable) yapılarak önceden eğitilmiş ve elde edilmiş ağırlıklar kullanılmıştır. Benzer model ile sınıflandırmayı içeren son 6 katman eğitilmiş ve sadece son sınıf katmanı 62 sınıfı ifade edecek şekilde değiştirilmiştir. Tekli model ile *Çekirdek 1* ve *Çekirdek 2* girişleri için 100 epok ile eğitim yapılmıştır. Diğer parametreler GTSRB veri setinde kullanılan parametrelerle aynı kalmıştır. Daha sonra *Çekirdek 1* ve *Çekirdek 2* ile eğitilen modeller yine

GTSRB'ye benzer şekilde yığınlama topluluğu modeli ile birleştirilerek eğitilmiştir. Yığınlama topluluğu modeli için epok sayısı 50'dir. Tüm test işlemlerine ait sonuçlar ve farklı mimarilerin BTSC veri seti üzerindeki sonuçları Tablo 23 ile gösterilmiştir. Sonuçlar incelendiğinde önerilen yığınlama topluluğu modeli ile %99.33 ile yüksek doğruluğa ulaşıldığı görülmektedir. Böylece önerilen modelin farklı veri setleri ile yüksek performans elde ettiği görülmüş ve sağlamlık testi yapılmıştır.

Tablo 23. BTSC veri setinde performans ve parametre sayısı karşılaştırmaları

Model ismi	Top-1 Doğruluk (%)	Parametre sayısı	F1-Skor	Kesinlik	Duyarlılık
Önerilen (Topluluk)	99.33	14.34 M	99.38	99.48	99.33
DeepThin (Haque, Arefin, Shihavuddin, & Hasan, 2021) (Topluluk)	99.29	2.69×10^5	-	-	-
(Aghdam, Heravi, & Puig, 2017)	92.12	5.6 M	-	-	-
(Arcos-García, Álvarez-García, & Soria-Morillo, 2018)	98.87	14.6 M	98.86	98.95	98.87
(Saha, Kamran, & Sabbir, 2018, December)	99.17	6.26 M	-	-	-
(Zhang, Wang, Lu, Wang, & Sangaiah, 2020)	99.13	0.8 M	-	-	-
(Bi, Yu, Gao, Zhou, & Yao, 2021)	99.02	1.15 M	-	-	-
(Nartey, Yang, Asare, Asare, & Asare, 2020)	98.97	-	-	-	-
Önerilen (Çekirdek 1)	99.21	7.15 M			
Önerilen (Çekirdek 2)	99.17	7.15 M			

BTSC test veri setinde bulunan 2534 görüntüden, topluluk öğrenme yöntemi ile toplam 17 görüntü yanlış sınıflandırılmıştır. Yanlış sınıflandırılan görüntüler Şekil 42 ile verilmiştir. Bu görüntüler incelendiğinde yine benzer şekilde tahmin edilen sınıf ile gerçek etikete sahip sınıf arasında benzer şekil ve görüntüde ufak farklılıkların olduğu

görülmektedir. Örneğin 45-50 arasındaki etikete sahip sınıf görüntüleri çoğunlukla birbirine benzer park durumunu ifade etmektedir.



Şekil 42. BTSC veri setinde yanlış sınıflandırılan görüntüler, G: Gerçek, T: Tahmin

Üretilen Türkiye Veri Seti Üzerinde Sonuçlar:

Üretilen veri setinin %80'i eğitim, %20'si test verisi olacak şekilde bölünmüştür. Eğitim seti üzerinde diğer veri setlerinde olduğu gibi %10 validasyon (doğrulama) seti olarak ayrılmıştır. Eğitim setinde 4220, test setinde 1055 görüntü bulunmaktadır. Tüm görüntüler eğitimden önce 60 x 60 olacak şekilde yeniden boyutlandırılmıştır. Tüm ön işleme ve diğer işlemler GTSRB ve BTSC veri setlerinde uygulandığı şekilde gerçekleştirilmiştir. Eğitimler tek çekirdek için 100 epok, topluluk öğrenme için 50 epok ile gerçekleştirilmiştir. Tüm test sonuçları Tablo 24 ile verilmiştir. Sonuçlar incelendiğinde topluluk öğrenme yoluyla test seti üzerinde en yüksek doğruluğa %99.53 ile erişildiği görülmektedir.

Tablo 24. Türkiye veri setinde performans ve parametre sayısı karşılaştırmaları

Model	Doğruluk (%)	Parametre sayısı	F1-Skor	Kesinlik	Duyarlılık
Çekirdek 1	99.15	7.15 M	99.14	99.19	99.15
Çekirdek 2	98.77	7.15 M	98.77	98.85	98.77
Topluluk	99.53	14.34 M	99.53	99.57	99.53

Üretilen veri seti ile 1055 test görüntüsü üzerinde yapılan tahmin ile yanlış sınıflandırılan görüntü sayısı sadece 5'tir. Yanlış tahmin edilen ve gerçek sınıf etiketleri verilen görüntüler Şekil 43 ile gösterilmiştir. Sonuçlar incelendiğinde çoğunlukla gözle bile ayırt edilemeyen oldukça düşük çözünürlükte olan görüntüler olduğu görülmektedir.



Şekil 43. Türkiye veri setinde yanlış sınıflandırılan görüntüler (G :Gerçek, T: Tahmin)

3.2. Trafik Işıkları

Veri seti:

Önerilen mimariyi eğitmek ve test etmek için Bosch veri seti, Udacity simülasyonu ve Udacity araba veri seti (Fu J. , 2019) kullanılmıştır. Eğitim setinde 9259 TL, test setinde 1030 trafik ışığı görüntüsü bulunmaktadır. Görüntülerin piksel boyutları 32 x 32'dir. Veri seti, kırmızı, yeşil, sarı ve kapalı etiketli dört sınıftan oluşmaktadır.

Hiper parametre ayarı:

ESA ağlarında birçok hiper parametre bulunmaktadır. Bunlar üzerinde hiper parametre ayarı yapmak oldukça zahmetli bir iştir. Her parametrenin değerindeki değişiklik, ağda önemli performans değişikliğine yol açabilmektedir. En iyi performans değerini elde etmek için parametreleri ayarlamak neredeyse imkansızdır. Bu nedenle, bu çalışmada, yüksek

doğrulukta bir model üretebilmek için hiper parametre değişiklikleri yapılarak performans sonuçları karşılaştırılmıştır. Modelin parametre değerlerini belirlemek için eğitim denemeleri yapılmıştır. Parametre değerleri, deneylerden elde edilen yüksek doğruluk değerlerinden seçilmiştir. Bu bölümde tüm denemeler için karşılaştırma tabloları verilecektir.

Çalışmamızda modelin parametrelerinin seçilmesi için eğitim işlemleri gerçekleştirilmiştir. Başlangıç değerleri seçilerek ve diğer parametreler sabit tutularak ilgili birimde doğruluğu en yüksek olan parametre seçilmiştir. Güncelleme yapılarak sırasıyla diğer birimler incelenmiştir. Her bölümdeki parametre değerleri için beş adet eğitim gerçekleştirilmiş ve parametre olarak test sonuçlarında maksimum doğruluğu sağlayan değer seçilmiştir. Bir parametre için en yüksek performans gösteren değer sabit tutulmuş ve diğer parametrede o değer kullanılmıştır. Böylece deneylerimizde sıralı olarak güncellenerek en yüksek doğruluğa sahip modele ulaşılmıştır. Aşağıda, test sonuçlarının doğruluğuna göre parametre değerlerinin seçimi gösterilmiş ve karşılaştırma tabloları verilmiştir. Eğitimlere başlamadan önce ilk olarak seçilen model parametreleri Tablo 25 ile verilmiştir.

Tablo 25. Başlangıçta seçilen model parametreleri


Filtre sayısı	32-32-64-64	Batch boyutu	32
Filtre çekirdek sayısı	5-3-5-3	Optimizasyon algoritması	SGD
Aktivasyon fonksiyonu	ReLU	Öğrenme oranı	0.001
Birleştirme Katmanı	Ekleme (Add)	Epok sayısı	50
Tam Bağlantılı Gizli Katmandaki Nöron Sayısı	32	Giriş görüntü boyutu	32x32
Dropout oranı	0.5	Renk uzayı	RGB

İşlemler Google Colab üzerinde TensorFlow platformu ve Keras kütüphanesi kullanılarak gerçekleştirilmiştir. Kayıp fonksiyonu olarak kategorik çapraz entropi (categorical cross-entropy) kullanılmıştır. Eğitim setinin %10'u doğrulama seti olarak ayrılmıştır.

Bu bölümde parametreler için sırasıyla eğitim denemeleri yapılmış ve test sonuçları verilmiştir.

Filtre sayısı:


Evrişim katmanını oluştururken, performansı önemli ölçüde etkileyecek birkaç parametre vermek gerekmektedir, bunlardan biri filtre boyutlarının sayısıdır. Bu sayının ayarlanması da hiper parametre ayarı için çok önemlidir. Yüksek seçilen filtre sayısı, eğitim aşamasında performansı düşürecektir. Bu çalışmada, modelimize uygun filtre boyutu sayısını belirlemek için farklı sayılarda (16, 32, 64, 96, 128 ve 256) kombinasyonlar denenmiştir. Eğitim sonucunda dört evrişim katmanı için 64-64-96-96 filtreler kullanılarak en yüksek test doğruluğu elde edilmiştir. Modelin evrişimsel filtre sayısına göre test doğruluk sonuçları Şekil 44 ile verilmiştir.



Şekil 44. Modelin filtre sayısına göre test doğruluğu sonuçları

Filtre çekirdek sayısı:

Evrişim katmanının bir diğer kritik parametresi filtre çekirdeği boyutudur. Filtre boyutu, parametre sayısını ve performansı önemli ölçüde etkilemektedir. Bu nedenle çalışmalarda düşük değerler tercih edilmektedir. Çalışmamızda 3 x 3, 5 x 5 ve 7 x 7 filtre çekirdeği boyutu değerleri kullanılmıştır. Filtre sayısında olduğu gibi, dört evrişim katmanı için farklı değerlerde eğitim denemeleri yapılmıştır. Şekil 45, test doğruluğu sonuçlarını göstermektedir. Burada verilen 5-3-5-3 terminolojisi, 4 katman için katmandaki değer örneğin 3, 3 x 3 çekirdek sayısını; 5, 5 x 5 bir çekirdek sayısını temsil etmektedir. Sonuçlar incelendiğinde en yüksek doğruluğa 5-3-5-3 çekirdek sayısı değerleri ile ulaşıldığı görülmektedir.



Şekil 45. Farklı sayıda filtre çekirdeği sayısı kullanarak test doğruluğu sonuçları


Aktivasyon fonksiyonu:

Derin ağlardaki temel hiper parametrelerden biri aktivasyon fonksiyonudur. Bu fonksiyon, öğrenme için gerekli olan doğrusal olmayanlığı üretir. Çalışmamızda kullanılan aktivasyon fonksiyonları ReLU, Leaky ReLU, Parametrik ReLU (PReLU) ve ELU (Üstel Doğrusal Birim, Exponential Linear Unit)'dur. ReLU, literatürde en çok kullanılan aktivasyon fonksiyonudur. ReLU'da tüm negatif değerler 0, pozitif değerler kendi değerlerini döndürmektedir. Gradyan tabanlı yöntemlerde, RELU ile negatif değerler eğitilemez. Bunu önlemek için, düşük değerli negatif değerleri işleyebilen Leaky ReLU aktivasyon fonksiyonu önerilmiştir.

Parametrik ReLU yapı olarak Leaky ReLU'ya benzer ve negatif giriş değerleri küçük bir değerle çarpılır (He, Zhang, Ren, & Sun, 2015). Ancak buradaki durum Leaky ReLU'dan farklıdır. Bu küçük değer, uygun bir fonksiyonla öğrenilebilmektedir.

ELU, Clevert vd. (2015) tarafından ReLU'ya alternatif olarak önerilmiştir. İki fonksiyon pozitif değerler için aynı sonuçları üretirken, ELU negatif değerler için üstel bir çarpma faktörü içermektedir (Rasamoelina, Adjailia, & Sinčák, 2020).


Bu çalışmada aktivasyon fonksiyonu için denemeler yapılmıştır. Her iki fonksiyonun sonuçları yüksek olmasına rağmen (Şekil 46) yaygın olarak kullanılan RELU seçilmiştir. Ayrıca son aşamada Leaky ReLU ile eğitim sonucu da incelenmiş ancak tüm değerlerle modele verildiğinde en yüksek doğruluğa ulaşılamamıştır.



Şekil 46. Modelin farklı aktivasyon fonksiyonlarına göre test doğruluğu sonuçları

Birleştirme katmanı seçimi:


Kaybolan gradyan etkisini azaltmak için, son evrişim ve önceki evrişim katmanı arasında bir birleştirme işlemi gerçekleştirilmiştir. Birleştirme katmanı için Keras kütüphanesindeki Ekleme (Add), Maksimum, Minimum, Sıralama (Concatenate) ve Ortalama katmanları kullanılmıştır. En yüksek doğruluk, Ekleme katmanı ile elde edilmiştir (Şekil 47). Mevcut durumda, atlama bağlantısı yapılmıştır. Bağlantı atlama, önceki katmanlarda elde edilen düşük düzeyli özniteliklerin üst düzey özniteliklere eklenmesiyle sağlanmıştır (Lee & Kim, 2019). Böylece güçlü öznitelikler elde edilerek sınıflandırma performansının artırılması ve kaybolan gradyan etkisinin azaltılması düşünülmektedir (Taghanaki, ve diğerleri, 2019).



Şekil 47. Birleştirme katmanında kullanılan farklı sınıflara göre deneysel sonuçlar

Tam Bağlantılı Gizli Katmandaki Nöron Sayısı:


Bir diğer önemli hiper parametre, tam bağlantılı gizli katmandaki nöronların sayısıdır. Farklı sayıda tam bağlı katman, derin ve sıkı ESA mimarisinde daha iyi sonuçlar verebilmektedir. Veri seti ve mimarisine göre tam bağlantılı katman sayısındaki değişim performansı etkilemektedir (Basha, Dubey, Pulabaigari, & Mukherjee, 2020). Bu çalışmada, tam bağlantılı gizli katmandaki nöronların sayısını belirlemek için eğitim deneyleri yapılmıştır. Tam bağlantılı gizli katmandaki farklı nöron sayılarına göre elde edilen test doğruluk sonuçları Şekil 48'de verilmiştir. Böylece en iyi performans ağı 32 nöron verilerek elde edilmiştir.



Şekil 48. Tam bağlantılı gizli katmandaki nöron sayısına göre model test sonuçları

Dropout Oranı:


Dropout (Srivastava, Hinton, Krizhevsky, Sutskever, & Salakhutdinov, 2014), aşırı öğrenmeyi önlemek için literatürde sıklıkla kullanılan bir katmandır. Katmandaki rastgele seçilen nöronların belirli bir yüzdesi ağdan kaldırılmaktadır. Bu nöronlara giden ve giden tüm bağlantılar yok edilir. Dropout yüzde oranlarına göre en yüksek test doğruluk değerine 0.5 ile erişilmiştir (Şekil 49).



Şekil 49. Dropout oranı seçimi

Yığın boyutu:


Yığın boyutu, bir seferde eğitim için ağa beslenen görüntü sayısını ifade etmektedir. (Kandel & Castelli, 2020) çalışmasında, yüksek yığın boyutu yerine küçük yığın boyutunun ve öğrenme hızının daha iyi performans sağlayacağı belirtilmiştir. Çalışmamızın sonuçları Şekil 50 ile incelendiğinde, 32 yığın boyutu ile diğerlerine kıyasla en yüksek test doğruluğu sonucunun elde edildiği görülmektedir.



Şekil 50. Yığın boyutu değerine dayalı doğruluk sonuçları

Optimizasyon Algoritması:

Optimizasyon algoritmalarındaki farklılığın sonuçlara etkisi de araştırılmıştır. Öğrenme oranı başlangıçta 0.001'dir. Buna göre eğitim yapıldığında SGD (Stochastic Gradient Descent) algoritması ile en yüksek doğruluk elde edilmiştir. Test sonuçları Şekil 51 ile verilmiştir.




Şekil 51. Modelde kullanılan farklı optimizasyon algoritmaları için doğruluk sonuçları

Öğrenme Oranı Seçimi:


Öğrenme oranı en değerli hiper parametrelerden biridir. Ağı eğitimi için ince ayarın yapılması oldukça önemlidir. Öğrenme oranının çok küçük seçilmesi durumunda aşırı

öğrenme gerçekleşebilir. Çok büyük seçilirse minimum hataya ulaşamaz ve eğitim farklılaşarak sapma meydana gelebilmektedir (Smith, 2018).

Çalışmamızda öncelikle sabit bir öğrenme oranı değeri seçilerek eğitim deneyleri yapılmıştır. Buna göre 0.5, 0.01 ve 0.001 ile aynı en yüksek performans elde edilmiştir (Şekil. 52). Bir sonraki adımda bu değerler başlangıç öğrenme oranı olarak seçilmiş ve ağ kosinüs bozunma sınıfı (Loshchilov & Hutter, 2016) ve 100000 bozunma değeri ile yeniden eğitilmiştir. Test sonuçlarına göre 0.5 öğrenme oranı ile en yüksek doğruluk değeri %96.21 olarak elde edilmiştir. Test sonuçları Şekil 53 ile gösterilmiştir.



Şekil 52. Sabit öğrenme oranı seçimi



Şekil 53. Kosinüs bozunumu sınıfını uygulayarak öğrenme oranı seçimi

Epok sayısı:

Epok sayısı belirlenirken, kosinüs bozunumu sınıfı ile kullanılan farklı başlangıç öğrenme hızı değerlerinin test doğruluğuna etkisi de araştırılmıştır. Tablo 26 ile verilen

sonuçlarda, modelde en yüksek test doğruluğuna 0.01 öğrenme oranı ve 100 epok sayısı ile ulaşıldığı görülmektedir. Böylece sonraki aşamalarda öğrenme oranı olarak 0.01 ve epok sayısı olarak 100 seçilmiş ve kullanılmıştır.


Tablo 26. Epok sayısı ve öğrenme oranı kombinasyonlarına göre model test sonuçları (ÖÖ: öğrenme oranı)

ÖÖ / Epok sayısı	50	100	200
0.5	96.21 %	95.73 %	95.63 %
0.01	96.12 %	96.41 %	95.73 %


Giriş Görüntü Boyutu:

Model, girdi görüntü boyutunun performans üzerindeki etkisini araştırmak için eğitilmiş ve test edilmiştir. Görüntü boyutu olarak 32 x 32, 45 x 45, 60 x 60 ve 75 x 75 değerleri seçilmiştir. Test sonuçlarına göre en yüksek doğruluğa başlangıçta alınan 32 x 32 giriş görüntüsü boyutu ile ulaşılmıştır (Şekil 54). Ayrıca, 32 x 32 ile diğer sonuçlar arasında oldukça mesafe vardır, açık ara diğer sonuçlardan üstün olduğu görülmektedir.

Eğitim aşamasındaki doğruluk ve kayıp grafikleri Şekil 55 ile verilmiştir. Grafikler incelendiğinde 32 girişli görüntü boyutunun daha yüksek doğruluk ve daha düşük kayıp değeri ürettiği görülmektedir.



Şekil 54. Farklı giriş görüntüsü boyutuyla model test sonuçları




Şekil 55. Giriş görüntü boyutu için a) eğitim doğruluğu, b) eğitim kaybı grafiği


Renk Uzayları:

Son bölümde, elde edilen tüm parametre değerlerine sahip model, farklı renk uzayları üzerinde eğitilmiştir. Sonuçlar incelendiğinde başlangıçta seçtiğimiz RGB renk uzayı ile daha yüksek doğruluk elde edildiği gözlemlenmiştir. Test doğruluk sonuçları Şekil 56'da verilmiştir.

Ayrıca eğitim doğruluğu ve eğitim kaybı grafiği Şekil 57 ile verilmiştir. Grafik incelendiğinde RGB renk uzayının diğerlerinden önemli ölçüde daha iyi sonuçlar ürettiği görülmektedir.



Şekil 56. Renk uzayına göre test doğruluğu



Şekil 57. Renk uzayları için a) eğitim doğruluğu, b) eğitim kaybı grafiği

Tüm parametre seçimleri yapıldıktan sonra ağın toplam parametre sayısı 476,708 olarak hesaplanmıştır. Test veri setindeki tüm parametre seçimleri nedeniyle elde edilen modele doğruluk dışında başka metrikler de uygulanmıştır. Tüm metrik sonuçları Tablo 27'de verilmektedir. Ayrıca modelin karışıklık matrisi Şekil 58'de gösterilmektedir. Sonuçlar incelendiğinde kırmızı ve yeşil etiketli görüntülerin sarı ve kapalı etiketlere göre daha doğru etiketlendiği görülmektedir. Ek olarak, gerçekte kırmızı ışığın asla yeşil olarak etiketlenmediğine dikkat etmek önemlidir.

Tablo 27. Model için metrik sonuçları

	Kesinlik	Duyarlılık	F1-skor	Support
Kırmızı	0.95	0.98	0.97	384
Sarı	0.89	0.73	0.80	56
Yeşil	0.98	0.99	0.99	511
Kapalı	0.92	0.85	0.88	79
Doğruluk			0.96	1030
Makro ortalama	0.94	0.89	0.91	1030
Ağırlıklı ortalama	0.96	0.96	0.96	1030



Şekil 58. Trafik ışığı sınıflandırmasının karışıklık matrisi

3.3. Yol Şerit

Tezin bu aşamasında, araç içerisinden çekilen görüntülerden yol şerit çizgilerinin bulunması ve şerit renklendirmesi yapılmıştır. Kullanılan veri seti Türkiye’de şehirlerarası yollardan çekilen görüntülerden oluşmaktadır. Ayrıca literatürde yaygın olarak kullanılan KITTI (Fritsch, Kuhn, & Geiger, 2013, October) veri seti görüntülerine de yer verilmektedir. Kullanılan örnek görüntüler Şekil 59 ile verilmiştir. İşlemler, Python dili ve Opencv (Open Computer Vision Library) kütüphanesi kullanılarak gerçekleştirilmiştir.



Şekil 59. Veri seti örnek görüntüler


Görüntüler, farklı veri setlerinde olabileceği ve çekimden kaynaklı nedenlerden dolayı farklı çözünürlüklere sahip olabileceği için, ilk işlem olarak görüntü boyutlandırma yapılmıştır. Daha sonra görüntüye perspektif dönüşümü uygulanmış ve HSV renk uzayına dönüştürülmüştür. Başlangıçta görüntü renk uzayı RGB formatındadır. Üretilen veri

setindeki örnek bir görüntüye ait perspektif ve renk uzayı dönüşümü sonuçları Şekil 60 ile gösterilmiştir.



Şekil 60. Örnek görüntü ön işleme sonuçları

HSV renk uzayı ile belirginleşen şerit çizgileri eşikleme işlemi ile arka plandan ayıştırılmıştır. Eşikleme sonucu şeritlerde oluşan bozulmaların önüne geçebilmek için önce yayma sonra aşındırma morfolojik işlemleri gerçekleştirilmiştir. Görüntüde bulunan fakat şerit olmayan diğer nesneleri ve gürültüleri gidermek için alan bazlı eleme yapılmıştır. Yapılan işlemlere ait örnek sonuçlar Şekil 61 ile verilmiştir.



Şekil 61. Örnek görüntü öznelik çıkarım sonuçları

Şerit çizgileri elde edildikten sonra yol, ters perspektif dönüşümü ile eski görünümüne getirilmiştir. DVR yöntemi ile şerit çizgileri üzerinde eğri uydurma gerçekleştirilmiştir. Yolun orta ve alt kısmından başlayan şeriti ifade edecek şekilde ilgili şerit çizgileri seçilmiş ve renklendirme gerçekleştirilmiştir. Örnek görüntüye ait son aşamalar, Şekil 62 ile verilmiştir.

Ters Perspektif Dönüşümü



DVR ile eğri uydurma



Şerit Renklendirme




Şekil 62. Örnek görüntü yol tespit son aşamalar

Önerilen yöntem, Türkiye’de çekilen ve KITTI veri setine ait görüntüler üzerinde uygulanmıştır. Farklı çekim açılarında ötürü, iki veri seti arasında perspektif dönüşü için farklı parametreler kullanılmıştır. Görüntüler üzerinde son aşamaları ifade eden DVR ile eğri uydurma ve çıkış görüntüsünün sonuçları, Türkiye veri seti için Şekil 63, KITTI veri seti için Şekil 64 ile verilmiştir. Sonuçlar incelendiğinde birden fazla eğri uydurulmasına rağmen, şeritlerin doğru şekilde tespit edildiği görülebilmektedir.



Şekil 63. Örnek Türkiye görüntülerine ait DVR ve sonuç şerit görüntüleri



Şekil 64. Örnek KITTI görüntülerine ait DVR ve sonuç şerit görüntüleri

4. SONUÇLAR

Trafik işareti algılama çalışmasında, trafik işareti algılama için şekil ve renk tabanlı bir yaklaşım önerilmiştir. Türkiye’de trafik işaret renklerinin kırmızı ve mavi renk odaklı olduğundan, bu veriler ön plana çıkarılmıştır. Gürültü giderme, eşikleme ve morfolojik açma-kapama işlemlerinden sonra daha iyi sonuçlar üretecek görüntü elde edilmiştir. Trafik işaret şekillerinin üçgen, yuvarlak ve kare olması da dikkate alındığında, bu şekiller dışındaki nesneler görüntüden ayırıştırılmıştır. Sonuç olarak elde kalan nesnelerle trafik işaret algılama işlemi gerçekleştirilmiştir. Veri setinde bulunan 20 görüntünün tamamı için trafik işareti algılamanın doğru şekilde yapıldığı görülmüştür.

Trafik işaretlerinin görsel görünümündeki büyük değişkenlik, büyük boyutlu veri setlerinde eğitim işlemlerinin zaman alması ve parametre değerlerinin belirlenmesinin zor olması nedeniyle transfer öğrenme, trafik işareti tanıma algoritmalarında önemli bir yöntem olarak karşımıza çıkmaktadır. Transfer öğrenme, yüksek performans ve daha az sürede eğitim işlemleri için oldukça kullanışlıdır. Transfer öğrenme yoluyla trafik işareti sınıflandırma çalışmasında, önceden eğitilmiş ESA modelleri ile GTSRB veri setinde bulunan 10 sınıfa ait görüntülerin sınıflandırılması gerçekleştirilmiştir. Önceden eğitilen modellerde ağıın en son tam bağlantılı katmanları değiştirilmiş ve doğruluk sonuçları karşılaştırılmıştır. Sonuçlar incelendiğinde MobileNet modeli ile daha yüksek doğruluk değerinin elde edildiği görülmüştür.

Renk uzayına dayalı trafik işareti sınıflandırma çalışmasında, düşük parametre sayısına sahip yeni ve etkili bir Evrişimli Sinir Ağı önerilmiştir. Ağıın eğitilmesinden önce kullanılan giriş görüntüsü değiştirilmiştir. Ağ girişine tekli, ikili ve üçlü kombinasyon halinde RGB, CIELab, RIQ ve LGI renk uzayları verilmiştir. Ayrıca giriş görüntü boyutu değiştirilerek eğitimler yapılmıştır. 32 x 32, 45 x 45 ve 60 x 60 görüntü boyutları kullanılmıştır. En yüksek doğruluk, 60 x 60 giriş görüntü boyutu ve RIQ ve LGI renk uzaylarının bir arada kullanılmasıyla elde edilmiştir. Doğruluk değeri %98.84 ve parametre sayısı 0.95 M'dir.

Topluluk öğrenme ile trafik işareti sınıflandırma çalışmasında yeni derin ve geniş bir sinir ağı modeli önerilmiştir. Modele verilen giriş görüntüleri kenar algılama ve görüntü iyileştirme yapılarak ön işlemeye tabi tutulmuştur. Böylece daha az parametre ile daha fazla öznitelik elde edilmiştir. Görüntüler 60 x 60 olarak yeniden boyutlandırılarak daha hızlı

eğitim yapılması amaçlanmıştır. Model içerisinde kullanılan aktivasyon fonksiyonunun doğruluğu artıracak şekilde seçilmesi sağlanmıştır. Ayrıca modelin daha iyi öğrenebilmesi için eğitim sırasında öğrenme oranı düzenlemesi yapılmıştır. Ek olarak giriş görüntüsü farklı ön işleme tabi tutulan görüntülerle eğitilen modeller, yığınlama topluluğu modeli haline getirilerek daha iyi performans elde edilmesi sağlanmıştır. Tek bir ön işleme aşaması gerçekleştirilen veri seti üzerinde eğitilen modelin parametre sayısı 7.15 M'dir. Yığınlama topluluğu modelinde 2 farklı ön işleme aşaması ile elde edilen veri setinde eğitilen modeller birleştirilmiş ve sınıflandırma için ek katmanlar eklenmiştir. Bu modelde toplam parametre sayısı ise 14.34 M'dir. Fakat transfer öğrenimi ile önceden eğitilen modellerdeki parametrelere eğitilebilir olmadığından, topluluk modelde eğitilebilir parametre sayısı sadece 39,643'tür. Yığınlama topluluğu modeli ile GTSRB veri seti üzerinde %99.75 ile oldukça yüksek bir başarımla elde edilmiştir.

Sınıflandırma çalışması için Türkiye trafik işaretlerinden oluşan yeni bir veri seti üretilmiştir. Yığınlama topluluğu modelinin sağlamlık testi için BTSC ve Türkiye'de üretilen yeni veri seti ile modelin performans incelemesi yapılmıştır. BTSC ile %99.33, Türkiye veri seti ile %99.53 ile yüksek doğruluk değerine ulaşılmıştır. Sonuç olarak hem görüntü iyileştirme yöntemlerinin hem de derin öğrenme yaklaşımının kullanımıyla yüksek performans sağlayan yeni hibrit bir ağ tasarlanmıştır.

Trafik ışığı sınıflandırma çalışmasında yeni bir derin sinir ağı önerilmiştir. Sentetik veri üreterek modeldeki veri miktarını artıran ve model performansını etkileyen veri büyütme işlemi uygulanmıştır. Model parametreleri için eğitim denemeleri yapılmıştır. Kullanılan parametreler filtre sayısı, filtre çekirdeği boyutu, aktivasyon fonksiyonu, birleştirme katmanı, tam bağlantılı gizli katmandaki nöron sayısı, Dropout oranı, yığın boyutu, optimizasyon algoritması, öğrenme oranı ve epok sayısıdır. Her parametrenin ve değerlerinin performansa etkisi incelenmiştir. Ayrıca başlangıçta giriş verilen görüntünün boyut ve renk seçimi için farklı değerler kullanılmış ve sonuçlar karşılaştırılmıştır. RGB renk uzayına ve 32 x 32 giriş boyutuna sahip bir modelle elde edilen en yüksek test doğruluğu %96.41'dir. Ayrıca karışıklık matrisi sonuçları incelendiğinde kırmızı ışığın hiçbir görüntüde yeşil olarak etiketlenmediği görülmüştür. Bu durum en yaygın trafik ihlali olan kırmızı ışıkta geçmeyi engeller ve trafik kazalarına neden olmaz.

Yol şerit tespiti için yapılan çalışmada geleneksel yöntemler kullanan ve DVR ile eğri uydurma gerçekleştiren yeni bir model önerilmiştir. Model; ön işleme, öznitelik çıkarımı, DVR ile eğri uydurma, şerit belirleme ve renklendirme aşamalarında oluşmaktadır. Model

iin kullanılan veri seti, Trkiye’de ekilen grntleri ve KITTI veri seti grntlerini iermektedir. Sonular incelendiėinde hem Trkiye hem de KITTI grntlerinde farklı hava koulları, bulanıklık ve znrlk deėerlerine karřın yksek performans ile řerit tespit edildiėi grlmektedir.



5. ÖNERİLER

Doktora tezi olarak sunulan bu çalışmada, trafik işareti algılama, trafik işareti sınıflandırma, trafik ışıkları sınıflandırma ve yol şerit çizgileri tespit etme konuları araştırılmıştır. Bu tez konuları ile çalışma yapmak isteyen araştırmacılara ve uygulayıcılara iletilmek istenen öneriler aşağıdaki gibi belirtilmiştir:

Türkiye’de üretilen trafik işareti veri seti, en çok kullanılan ve görüntüler alınırken en çok rastlanan trafik işaret sınıfları dahil edilerek oluşturulmuştur. Farklı bölgelerden görüntü alınması ile veri seti sınıf sayısının ve görüntü sayısının artırılması gerçekleştirilebilir. Böylece öğrenme çeşitliliğinin ve performansının artırılması sağlanabilir.

Trafik işareti algılama çalışmasında kullanılan veri setini kendimiz ürettiğimiz için, literatürdeki diğer çalışmalarla performans değerlendirmesi yapılamamıştır. İleriki çalışmalarda, önerilen yöntemin diğer veri setleri kullanılarak performans karşılaştırmasının yapılması planlanmaktadır. Ayrıca renk ve şekil esaslı yöntemle elde edilen çıktı görüntülerinin, evrimsel bir YSA veya başka bir makine öğrenme yöntemi kullanılarak algılama işlemi gerçekleştirilebilir.

Trafik işareti sınıflandırma çalışmalarında doğruluk değerini düşürmeden parametre sayısının nasıl azaltılacağına odaklanılabilir. Dikkat ve artık ağ yapısı gibi farklı yeni nesil öğrenme yaklaşımları denenebilir. F1-skor ve doğruluk gibi ölçümler, daha yüksek performansa ulaşmak için güncellenebilir. Ayrıca modelin sağlamlığı farklı veri setleri üzerinde eğitim yapılarak test edilebilir. Farklı hava koşulları ve bozuk görüntüler için daha iyi sonuçlar üretecek ön işleme adımları araştırılabilir.

Trafik ışıkları sınıflandırma çalışmasında karşılaştırma için doğruluk metriği kullanılmıştır. Ayrıca kesinlik, duyarlılık ve F1- skor metrikleri de eklenebilir.

Yol şerit çizgileri için yöntemin güvenilirliğinin test etmek için farklı veri setleri üzerinde denemeler gerçekleştirilebilir. Ayrıca tüm veri seti incelenerek hem nicel hem de nitel açıdan farklı çalışmalarla performans karşılaştırması yapılabilir.

6. KAYNAKLAR

- Abedin, M. Z., Dhar, P., & Deb, K. (2016). Traffic Sign Recognition using SURF: Speeded up robust feature descriptor and artificial neural network classifier. *2016 9th International Conference on Electrical and Computer Engineering (ICECE)* (s. 198-201). Dhaka, Bangladesh: IEEE. doi:10.1109/ICECE.2016.7853890
- Aghdam, H. H., Heravi, E. J., & Puig, D. (2017). A Practical and Highly Optimized Convolutional Neural Network for Classifying Traffic Signs in Real-Time. *International Journal of Computer Vision*, 122(2), 246–269.
- Aneesh, A. N., Shine, L., Pradeep, R., & Sajith, V. (2019). Real-time Traffic Light Detection and Recognition based on Deep RetinaNet for Self Driving Cars. *2019 2nd International Conference on Intelligent Computing, Instrumentation and Control Technologies (ICICT)* (s. 1554-1557). Kannur, India: IEEE. doi:10.1109/ICICT46008.2019.8993293
- Arcos-García, Á., Álvarez-García, J. A., & Soria-Morillo, L. M. (2018). Deep neural network for traffic sign recognition systems: An analysis of spatial transformers and stochastic optimisation methods. *Neural Networks*, 99, 158-165.
- Arifin, N. A., Irawan, B., & Setianingsih, C. (2017). Traffic sign recognition application using speeded-up robust features (SURF) and support vector machine (SVM) based on android. *2017 IEEE Asia Pacific Conference on Wireless and Mobile (APWiMob)* (s. 52-58). Bandung, Indonesia: IEEE. doi:10.1109/APWiMob.2017.8284004
- Aslansefat, K., Kabir, S., Abdullatif, A., Vasudevan, V., & Papadopoulos, Y. (2021). Toward Improving Confidence in Autonomous Vehicle Software: A Study on Traffic Sign Recognition Systems. *Computer*, 54(8), 66 - 76.
- Bach, M., Stumper, D., & Dietmayer, K. (2018). Deep Convolutional Traffic Light Recognition for Automated Driving. *2018 21st International Conference on Intelligent Transportation Systems (ITSC)* (s. 851-858). Maui, HI, USA: IEEE.
- Baek, S.-W., Kim, M.-J., Suddamalla, U., Wong, A., Lee, B.-H., & Kim, J.-H. (2022). Real-time lane detection based on deep learning. *Journal of Electrical Engineering & Technology*, 1-10.
- Bahlmann, C., Zhu, Y., Ramesh, V., Pellkofer, M., & Koehler, T. (2005). A system for traffic sign detection, tracking, and recognition using color, shape, and motion information. *IEEE Proceedings. Intelligent Vehicles Symposium*, 2005. (s. 255-260). IEEE. doi:10.1109/IVS.2005.1505111
- Barnes, D., Maddern, W., & Posner, I. (2015). Exploiting 3D semantic scene priors for online traffic light interpretation. *2015 IEEE Intelligent Vehicles Symposium (IV)* (s. 573-578). Seoul, Korea (South): IEEE. doi:10.1109/IVS.2015.7225746

- Baro, X., Escalera, S., Vitria, J., Pujol, O., & Radeva, P. (2009). Traffic Sign Recognition Using Evolutionary Adaboost Detection and Forest-ECOC Classification. *IEEE Transactions on Intelligent Transportation Systems*, 10(1), 113 - 126. doi:10.1109/TITS.2008.2011702
- Basha, S. S., Dubey, S. R., Pulabaigari, V., & Mukherjee, S. (2020). Impact of fully connected layers on performance of convolutional neural networks for image classification. *Neurocomputing*, 378, 112-119.
- Bay, H., Tuytelaars, T., & Gool, L. V. (2006). SURF: Speeded Up Robust Features. *Computer Vision—ECCV 2006: 9th European Conference on Computer Vision, Graz, Austria, May 7-13, 2006. Proceedings, Part I 9* (s. 404-417). Springer Berlin Heidelberg.
- Bayoudh, K., Hamdaoui, F., & Mtibaa, A. (2021). Transfer learning based hybrid 2D-3D CNN for traffic sign recognition and semantic road detection applied in advanced driver assistance systems. *Applied Intelligence*, 51, 124–142.
- Behrendt, K., Novak, L., & Botros, R. (2017). A deep learning approach to traffic lights: Detection, tracking, and classification. *2017 IEEE International Conference on Robotics and Automation (ICRA)* (s. 1370-1377). Singapore: IEEE. doi:10.1109/ICRA.2017.7989163
- Bi, Z., Yu, L., Gao, H., Zhou, P., & Yao, H. (2021). Improved VGG model-based efficient traffic sign recognition for safe driving in 5G scenarios. *International Journal of Machine Learning and Cybernetics*, 12(11), 3069–3080.
- Boltaevich, M. B., ogli, N. R., qizi, G. N., & ogli, M. S. (2019). Estimation affects of formats and resizing process to the accuracy of convolutional neural network. *2019 International Conference on Information Science and Communications Technologies (ICISCT)* (s. 1-5). Tashkent, Uzbekistan: IEEE.
- Carvalho, T., Rezende, E. R., Alves, M. T., Balieiro, F. K., & Sovat, R. B. (2017). Exposing Computer Generated Images by Eye's Region Classification via Transfer Learning of VGG19 CNN. *2017 16th IEEE International Conference on Machine Learning and Applications (ICMLA)* (s. 866-870). Cancun, Mexico: IEEE.
- Chahande, M., & Gohokar, V. (tarih yok). Transfer Learning Based Traffic Sign Recognition System for Surveillance Application.
- Charette, R. d., & Nashashibi, F. (2009). Real time visual traffic lights recognition based on Spot Light Detection and adaptive traffic lights templates. *2009 IEEE Intelligent Vehicles Symposium* (s. 358-363). Xi'an, China: IEEE. doi:10.1109/IVS.2009.5164304
- Charette, R. d., & Nashashibi, F. (2009). Traffic light recognition using image processing compared to learning processes. *2009 IEEE/RSJ International Conference on Intelligent Robots and Systems* (s. 333-338). St. Louis, MO, USA: IEEE.
- Chen, B., Liu, X., Zheng, Y., Zhao, G., & Shi, Y.-Q. (2021). A Robust GAN-Generated Face Detection Method Based on Dual-Color Spaces and an Improved Xception. *IEEE*

- Transactions on Circuits and Systems for Video Technology*, 32(6), 3527 - 3538. doi:10.1109/TCSVT.2021.3116679
- Chen, X., & Luo, C. (2021). Fast Traffic Light Recognition Using a Lightweight Attention-Enhanced Model. *Proceedings of the 2021 4th International Conference on Machine Learning and Machine Intelligence*, (s. 15-20).
- Chen, Z., & Huang, X. (2016). Accurate and Reliable Detection of Traffic Lights Using Multiclass Learning and Multiobject Tracking. *IEEE Intelligent Transportation Systems Magazine*, 8(4), 28 - 42.
- Chiang, C.-C., Ming-Che Ho, H.-S. L., Pratama, A., & Syu, W.-C. (2011). Detecting and recognizing traffic lights by genetic approximate ellipse detection and spatial texture layouts. *International Journal of Innovative Computing, Information and Control*, 7(12), 6919-6934.
- Chicco, D., & Jurman, G. (2023). The Matthews correlation coefficient (MCC) should replace the ROC AUC as the standard metric for assessing binary classification. *BioData Mining*, 16(1), 1-23.
- Chollet, F. (2017). Xception: Deep Learning With Depthwise Separable Convolutions. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, (s. 1251-1258).
- Ciregan, D., Meier, U., & Schmidhuber, J. (2012). Multi-column deep neural networks for image classification. *2012 IEEE Conference on Computer Vision and Pattern Recognition* (s. 3642-3649). Providence, RI, USA: IEEE. doi:10.1109/CVPR.2012.6248110
- Cireşan, D., Meier, U., Masci, J., & Schmidhuber, J. (2011). A committee of neural networks for traffic sign classification. *The 2011 International Joint Conference on Neural Networks* (s. 1918-1921). San Jose, CA, USA: IEEE. doi:10.1109/IJCNN.2011.6033458
- Clevert, D.-A., Unterthiner, T., & Hochreiter, S. (2015). Fast and Accurate Deep Network Learning by Exponential Linear Units (ELUs). *arXiv preprint arXiv:1511.07289*.
- Convention on Road Signs and Signals*. (2024, 1 3). United Nations Treaty Collection: <https://web.archive.org/web/20210720182737/https://treaties.un.org/doc/Publication/MTDSG/Volume%20I/Chapter%20XI/XI-B-20.en.pdf> adresinden alındı
- Creusen, I., Wijnhoven, R., Herbschleb, E., & With, P. d. (2010, September). Color exploitation in hog-based traffic sign detection. *2010 IEEE International Conference on Image Processing* (s. 2669-2672). Hong Kong, China: IEEE. doi:10.1109/ICIP.2010.5651637
- Cubuk, E. D., Zoph, B., Mane, D., Vasudevan, V., & Le, Q. V. (2018). AutoAugment: Learning Augmentation Policies from Data. *arXiv preprint arXiv:1805.09501*.
- Diaz, M., Cerri, P., Pirlo, G., Ferrer, M. A., & Impedovo, D. (2015). A survey on traffic light detection. *New Trends in Image Analysis and Processing--ICIAP 2015 Workshops*:

ICIAP 2015 International Workshops, BioFor, CTMR, RHEUMA, ISCA, MADiMa, SBMI, and QoEM, Genoa, Italy, September 7-8, 2015, Proceedings 18 (s. 201-208). içinde Springer International Publishing.

- Diaz-Cabrera, M., Cerri, P., & Medici, P. (2015). Robust real-time traffic light detection and distance estimation using a single camera. *Expert Systems with Applications*, 42(8), 3911-3923.
- Du, X., Li, Y., Guo, Y., & Xiong, H. (2017). Vision-Based Traffic Light Detection for Intelligent Vehicles. *2017 4th International Conference on Information Science and Control Engineering (ICISCE)* (s. 1323-1326). Changsha, China: IEEE.
- Escalera, A. d., Moreno, L., Salichs, M., & Armingol, J. (1997). Road traffic sign detection and classification. *IEEE Transactions on Industrial Electronics*, 44(6), 848 - 859. doi:10.1109/41.649946
- Fairfield, N., & Urmson, C. (2011). Traffic light mapping and detection. *2011 IEEE International Conference on Robotics and Automation* (s. 5421-5426). Shanghai, China: IEEE.
- Fang, H.-F., Cao, J., & Li, Z.-Y. (2022). A small network MicronNet-BF of traffic sign classification. *Computational intelligence and neuroscience*, 2022.
- Franke, U., Pfeiffer, D., Rabe, C., Knoeppel, C., Enzweiler, M., Stein, F., & Herrtwich, R. G. (2013). Making Bertha See. *Proceedings of the IEEE International Conference on Computer Vision Workshops*, (s. 214-221).
- Fritsch, J., Kuhn, T., & Geiger, A. (2013, October). A New Performance Measure and Evaluation Benchmark for Road Detection Algorithms. *16th International IEEE Conference on Intelligent Transportation Systems (ITSC 2013)* (s. 1693-1700). The Hague, Netherlands: IEEE. doi:10.1109/ITSC.2013.6728473
- Fu, J. (2019, 10 20). *Traffic light classifier*. 1 4, 2024 tarihinde <https://github.com/JunshengFu/traffic-light-classifier> adresinden alındı
- Fu, M.-Y., & Huang, Y.-S. (2010). A survey of traffic sign recognition. *2010 International Conference on Wavelet Analysis and Pattern Recognition* (s. 119-124). Qingdao, China: IEEE. doi:10.1109/ICWAPR.2010.5576425
- García-Garrido, M. A., Ocaña, M., Llorca, D. F., Arroyo, E., J. P., & Gavilán, M. (2012). Complete Vision-Based Traffic Sign Recognition Supported by an I2V Communication System. *Sensors*, 12(2), 1148-1169.
- García-Garrido, M. Á., Sotelo, M. Á., & Martín-Gorostiza, E. (2005). Fast Road Sign Detection Using Hough Transform for Assisted Driving of Road Vehicles. M. A. García-Garrido, M. Á. Sotelo, & E. Martín-Gorostiza içinde, *Computer Aided Systems Theory – EUROCAST 2005, 10th International Conference on Computer Aided Systems Theory* (s. 543–548). Spain: Springer Berlin Heidelberg.
- Golovnin, O. K., & Yarmov, R. V. (2022). Universal Convolutional Neural Network for Recognition of Traffic Lights and Road Signs in Video Frames. *SMART Automatics*

- and Energy: Proceedings of SMART-ICAE 2021* (s. 459-468). içinde Singapore: Springer Nature.
- Gomez, A. E., Alencar, F. A., Prado, P. V., Osório, F. S., & Wolf, D. F. (2014). Traffic lights detection and state estimation using Hidden Markov Models. *2014 IEEE Intelligent Vehicles Symposium Proceedings* (s. 750-755). Dearborn, MI, USA: IEEE.
- Greenhalgh, J., & Mirmehdi, M. (2012). Real-Time Detection and Recognition of Road Traffic Signs. *IEEE Transactions on Intelligent Transportation Systems*, 13(4), 1498 - 1506.
- Haltakov, V., Mayr, J., Unger, C., & Ilic, S. (2015). Semantic Segmentation Based Traffic Light Detection at Day and at Night. *Pattern Recognition: 37th German Conference, GCPR 2015, Aachen, Germany, October 7-10, 2015, Proceedings 37* (s. 446-457). Springer International Publishing.
- Haque, W. A., Arefin, S., Shihavuddin, A., & Hasan, M. A. (2021). DeepThin: A novel lightweight CNN architecture for traffic sign recognition without GPU requirements. *Expert Systems with Applications*, 168, 114481.
- Hassan, E. T., Li, N., & Ren, L. (2020). Semantic Consistency: The Key to Improve Traffic Light Detection with Data Augmentation. *2020 IEEE Intelligent Vehicles Symposium (IV)* (s. 1734-1739). Las Vegas, NV, USA: IEEE.
- He, K., Zhang, X., Ren, S., & Sun, J. (2015). Delving Deep into Rectifiers: Surpassing Human-Level Performance on ImageNet Classification. *Proceedings of the IEEE International Conference on Computer Vision (ICCV)*, (s. 1026-1034).
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep Residual Learning for Image Recognition. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, (s. 770-778).
- Hillel, A. B., Lerner, R., Levi, D., & Raz, G. (2014). Recent progress in road and lane detection: a survey. *Machine vision and applications*, 25(3), 727–745.
- Hirabayashi, M., Sujiwo, A., Monrroy, A., Kato, S., & Edahiro, M. (2019). Traffic light recognition using high-definition map features. *Robotics and Autonomous Systems*, 111, 62-72.
- Hosseinyalamdary, S., & Yilmaz, A. (2017). A Bayesian approach to traffic light detection and mapping. *ISPRS journal of photogrammetry and remote sensing*, 125, 184-192.
- Houben, S., Stallkamp, J., Salmen, J., Schlipsing, M., & Igel, C. (2013). Detection of traffic signs in real-world images: The German traffic sign detection benchmark. *The 2013 International Joint Conference on Neural Networks (IJCNN)* (s. 1-8). Dallas, TX, USA: IEEE. doi:10.1109/IJCNN.2013.6706807
- Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., . . . Adam, H. (2017). MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications. *arXiv preprint arXiv:1704.04861*.

- ImageNet Large Scale Visual Recognition Challenge (ILSVRC)*. (2021, 3 11). 01 2024, 04 tarihinde <https://www.image-net.org/> adresinden alındı
- Jaworek-Korjakowska, J., Kleczek, P., & Gorgon, M. (2019). Melanoma thickness prediction based on convolutional neural network with VGG-19 model transfer learning. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops*, (s. 0-0).
- Jensen, M. B., Philipsen, M. P., Møgelmoose, A., Moeslund, T. B., & Trivedi, M. M. (2016). Vision for Looking at Traffic Lights: Issues, Survey, and Perspectives. *IEEE Transactions on Intelligent Transportation Systems*, 17(7), 1800 - 1815. doi:10.1109/TITS.2015.2509509
- Ji, Y., Yang, M., Lu, Z., & Wang, C. (2015). Integrating visual selective attention model with HOG features for traffic light detection and recognition. *2015 IEEE Intelligent Vehicles Symposium (IV)* (s. 280-285). Seoul, Korea (South): IEEE.
- Jin, J., Fu, K., & Zhang, C. (2014). Traffic Sign Recognition With Hinge Loss Trained Convolutional Neural Networks. *IEEE Transactions on Intelligent Transportation Systems*, 15(5), 1991 - 2000. doi:10.1109/TITS.2014.2308281
- Jogin, M., Mohana, Madhulika, M. S., Divya, G. D., Meghana, R. K., & Apoorva, S. (2018). Feature Extraction using Convolution Neural Networks (CNN) and Deep Learning. *2018 3rd IEEE International Conference on Recent Trends in Electronics, Information & Communication Technology (RTEICT)* (s. 2319-2323). Bangalore, India: IEEE. doi:10.1109/RTEICT42901.2018.9012507
- John, V., Yoneda, K., Liu, Z., & Mita, S. (2015). Saliency Map Generation by the Convolutional Neural Network for Real-Time Traffic Light Detection Using Template Matching. *IEEE Transactions on Computational Imaging*, 1(3), 159 - 173.
- John, V., Yoneda, K., Qi, B., Liu, Z., & Mita, S. (2014). Traffic light recognition in varying illumination using deep learning and saliency map. *17th International IEEE Conference on Intelligent Transportation Systems (ITSC)* (s. 2286-2291). Qingdao, China: IEEE. doi:10.1109/ITSC.2014.6958056
- Kandel, I., & Castelli, M. (2020). The effect of batch size on the generalizability of the convolutional neural networks on a histopathology dataset. *ICT Express*, 6(4), 312-315.
- Kasaei, S. H., Ghorbani, M., Schilperoort, J., & Rest, W. v. (2021). Investigating the importance of shape features, color constancy, color spaces, and similarity measures in open-ended 3D object recognition. *Intelligent Service Robotics*, 14, 329–344.
- Kaur, K., Jindal, N., & Singh, K. (2021). Fractional derivative based Unsharp masking approach for enhancement of digital images. *Multimedia Tools and Applications*, 80, 3645-3679.
- Kim, H.-K., Park, J. H., & Jung, H.-Y. (2011). Effective traffic lights recognition method for real time driving assistance system in the daytime. *International Journal of Electrical and Computer Engineering*, 5(11), 1429-1432.

- Kim, H.-K., Park, J. H., & Jung, H.-Y. (2018). An efficient color space for deep-learning based traffic light recognition. *Journal of Advanced Transportation*, 2018, 1-12.
- Kim, M., Lee, M., An, M., & Lee, H. (2020). Effective automatic defect classification process based on CNN with stacking ensemble model for TFT-LCD panel. *Journal of Intelligent Manufacturing*, 31, 1165-1174.
- Kollias, D. (2022). ABAW: Valence-Arousal Estimation, Expression Recognition, Action Unit Detection & Multi-Task Learning Challenges. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR) Workshops*, (s. 2328-2336).
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2017). ImageNet classification with deep convolutional neural networks. *Communications of the ACM*, 60(6), 84-90.
- Kukkala, V. K., Tunnell, J., Pasricha, S., & Bradley, T. (2018). Advanced driver-assistance systems: A path toward autonomous vehicles. *IEEE Consumer Electronics Magazine*, 7(5), 18 - 25.
- Kumar, A. D. (2018). Novel Deep Learning Model for Traffic Sign Detection Using Capsule. *arXiv preprint arXiv:1805.04424*.
- Lee, C., & Moon, J.-H. (2018). Robust Lane Detection and Tracking for Real-Time Applications. *IEEE Transactions on Intelligent Transportation Systems*, 19(12), 4043 - 4048. doi:10.1109/TITS.2018.2791572
- Lee, D.-H., & Liu, J.-L. (2023). End-to-end deep learning of lane detection and path prediction for real-time autonomous driving. *Signal, Image and Video Processing*, 17(1), 199–205.
- Lee, E., & Kim, D. (2019). Accurate traffic light detection using deep neural network with focal regression loss. *Image and Vision Computing*, 87, 24-36.
- Lee, H. S., & Kim, K. (2018). Simultaneous Traffic Sign Detection and Boundary Estimation Using Convolutional Neural Network. *IEEE Transactions on Intelligent Transportation Systems*, 19(5), 1652 - 1663.
- Lee, S.-H., Kim, J.-H., Lim, Y.-J., & Lim, J. (2018). Traffic light detection and recognition based on Haar-like features. *2018 International Conference on Electronics, Information, and Communication (ICEIC)* (s. 1-4). Honolulu, HI, USA: IEEE. doi:10.23919/ELINFOCOM.2018.8330598
- Li, J., Jiang, F., Yang, J., Kong, B., Gogate, M., Dashtipour, K., & Hussain, A. (2021). Lane-deeplab: Lane semantic segmentation in automatic driving scenarios for high-definition maps. *Neurocomputing*, 465, 15-25.
- Li, X.-X., Li, D., Ren, W.-X., & Zhang, J.-S. (2022). Loosening Identification of Multi-Bolt Connections Based on Wavelet Transform and ResNet-50 Convolutional Neural Network. *Sensors*, 22(18), 6825.

- Li, Y., Ma, L., Huang, Y., & Li, J. (2018). Segment-Based Traffic Sign Detection from Mobile Laser Scanning Data. *IGARSS 2018 - 2018 IEEE International Geoscience and Remote Sensing Symposium* (s. 4607-4610). Valencia, Spain: IEEE.
- Liang, M., Yuan, M., Hu, X., Li, J., & Liu, H. (2013). Traffic sign detection by ROI extraction and histogram features-based recognition. *The 2013 International Joint Conference on Neural Networks (IJCNN)* (s. 1-8). Dallas, TX, USA: IEEE. doi:10.1109/IJCNN.2013.6706810
- Lillo-Castellano, J., Mora-Jiménez, I., Figuera-Pozuelo, C., & Rojo-Álvarez, J. (2015). Traffic sign segmentation and classification using statistical learning methods. *Neurocomputing*, 153, 286-299.
- Lim, X. R., Lee, C. P., Lim, K. M., & Ong, T. S. (2023). Enhanced Traffic Sign Recognition with Ensemble Learning. *Journal of Sensor and Actuator Networks*, 12(2), 33.
- Lin, C., Li, L., Luo, W., Wang, K. C., & Guo, J. (2019). Transfer Learning Based Traffic Sign Recognition Using Inception-v3 Model. *Periodica Polytechnica Transportation Engineering*, 47(3), 242-250.
- Liu, B., Liu, H., & Yuan, J. (2019). Lane Line Detection based on Mask R-CNN. *Proceedings of the 3rd International Conference on Mechatronics Engineering and Information Technology (ICMEIT 2019)* (s. 696-699). Atlantis Press.
- Liu, C., Li, S., Chang, F., & Wang, Y. (2019). Machine vision based traffic sign detection methods: review, analyses and perspectives. *IEEE Access*, 7, 86578 - 86596. doi:10.1109/ACCESS.2019.2924947
- Liu, W., Li, S., Lv, J., Yu, B., Zhou, T., Yuan, H., & Zhao, H. (2016). Real-time traffic light recognition based on smartphone platforms. *IEEE Transactions on Circuits and Systems for Video Technology*, 27(5), 1118 - 1131.
- Liu, Z., & Liu, C. (2008). A Hybrid Color and Frequency Features Method for Face Recognition. *IEEE Transactions on Image Processing*, 17(10), 1975 - 1980. doi:10.1109/TIP.2008.2002837
- Loshchilov, I., & Hutter, F. (2016). Sgdr: Stochastic gradient descent with warm restarts. *arXiv preprint arXiv:1608.03983*.
- Luo, H., Yang, Y., Tong, B., Wu, F., & Fan, B. (2017). Traffic Sign Recognition Using a Multi-Task Convolutional Neural Networ. *IEEE Transactions on Intelligent Transportation Systems*, 19(4), 1100 - 1111. doi:10.1109/TITS.2017.2714691
- Luo, S., Yu, L., Bi, Z., & Li, Y. (2020). Traffic sign detection and recognition for intelligent transportation systems: A survey. *Journal of Internet Technology*, 21(6), 1773-1784.
- Maldonado-Bascon, S., Lafuente-Arroyo, S., Gil-Jimenez, P., Gomez-Moreno, H., & López-Ferreras, F. (2007). Road-Sign Detection and Recognition Based on Support Vector Machines. *IEEE Transactions on Intelligent Transportation Systems*, 264 - 278. doi:10.1109/TITS.2007.895311

- Mathias, M., Timofte, R., Benenson, R., & Gool, L. V. (2013). Traffic sign recognition — How far are we from the solution? *The 2013 International Joint Conference on Neural Networks (IJCNN)* (s. 1-8). Dallas, TX, USA: IEEE.
- Mogelmoose, A., Trivedi, M. M., & Moeslund, T. B. (2012). Vision-Based Traffic Sign Detection and Analysis for Intelligent Driver Assistance Systems: Perspectives and Survey. *IEEE Transactions on Intelligent Transportation Systems*, 13(4), 1484 - 1497. doi:10.1109/TITS.2012.2209421
- Mu, C., & Ma, X. (2014). Lane detection based on object segmentation and piecewise fitting. *TELKOMNIKA Indonesian Journal of Electrical Engineering*, 12(5), 3491-3500.
- Nartey, O. T., Yang, G., Asare, S. K., Asare, S. K., & Asare, S. K. (2020). Robust Semi-Supervised Traffic Sign Recognition via Self-Training and Weakly-Supervised Learning. *Sensors*, 20(9), 2684.
- Nguyen, H. (2020). A DEEP LEARNING FRAMEWORK FOR SMALL TRAFFIC LIGHT RECOGNITION IN TRAFFIC SCENE IMAGE. *Journal of Theoretical and Applied Information Technology*, 98(16).
- Oh, C., Sim, D., & Kim, H. J. (2020). Traffic light recognition based on one-dimensional convolutional neural network. *2020 IEEE 23rd International Conference on Intelligent Transportation Systems (ITSC)* (s. 1-6). Rhodes, Greece: IEEE. doi:10.1109/ITSC45102.2020.9294734
- Ohta, Y.-I., Kanade, T., & Sakai, T. (1980). Color information for region segmentation. *Computer Graphics and Image Processing*, 13(3), 222-241.
- Papadimitratos, P., Fortelle, A. D., Evenssen, K., Brignolo, R., & Cosenza, S. (2009). Vehicular communication systems: Enabling technologies, applications, and future outlook on intelligent transportation. *IEEE Communications Magazine*, 47(11), 84 - 95.
- Papandrianos, N. I., Feleki, A., Moustakidis, S., Papageorgiou, E. I., Apostolopoulos, I. D., & Apostolopoulos, D. J. (2022). An Explainable Classification Method of SPECT Myocardial Perfusion Images in Nuclear Cardiology Using Deep Learning and Grad-CAM. *Applied Sciences*, 12(15), 7592.
- Parbat, D., & Chakraborty, M. (2020). A python based support vector regression model for prediction of. *Chaos, Solitons and Fractals*, 138.
- Patel, V., Shukla, S., Shrivastava, S., & Gyanchandani, M. (2022). Regularized CNN for Traffic Sign Recognition. *2022 International Conference on Smart Technologies and Systems for Next Generation Computing (ICSTSN)* (s. 1-5). Villupuram, India: IEEE.
- Philipsen, M. P., Jensen, M. B., Møgelmoose, A., Moeslund, T. B., & Trivedi, M. M. (2015). Traffic Light Detection: A Learning Algorithm and Evaluations on Challenging Dataset. *2015 IEEE 18th International Conference on Intelligent Transportation Systems* (s. 2341-2345). Gran Canaria, Spain: IEEE.

- Piao, J., & Mike, M. (2008). Advanced driver assistance systems from autonomous to cooperative approach. *Transport reviews*, 28(5), 659-684.
- Possatti, L. C., Guidolini, R., Cardoso, V. B., Berriel, R. F., Paixão, T. M., Badue, C., . . . Oliveira-Santos, T. (2019). Traffic light recognition using deep learning and prior maps for autonomous cars . *2019 International Joint Conference on Neural Networks (IJCNN)* (s. 1-8). Budapest, Hungary: IEEE.
- Rasamoelina, A. D., Adjailia, F., & Sinčák, P. (2020). A Review of Activation Function for Artificial Neural Network. *2020 IEEE 18th World Symposium on Applied Machine Intelligence and Informatics (SAMI)* (s. 281-286). Herlany, Slovakia: IEEE.
- Ren, F., Huang, J., Jiang, R., & Klette, R. (2009). General traffic sign recognition by feature matching. *2009 24th International Conference Image and Vision Computing New Zealand* (s. 409-414). Wellington, New Zealand: IEEE. doi:10.1109/IVCNZ.2009.5378370
- Rezende, E., Ruppert, G., Carvalho, T., Ramos, F., & Geus, P. d. (2017). Malicious Software Classification Using Transfer Learning of ResNet-50 Deep Neural Network. *2017 16th IEEE International Conference on Machine Learning and Applications (ICMLA)* (s. 1011-1014). Cancun, Mexico: IEEE.
- Saha, S. (2018). A comprehensive guide to convolutional neural networks—the ELI5 way. *Towards data science*, 15, 15.
- Saha, S., Kamran, S. A., & Sabbir, A. S. (2018, December). Total Recall: Understanding Traffic Signs Using Deep Convolutional Neural Network. *2018 21st International Conference of Computer and Information Technology (ICCIT)* (s. 1-6). Dhaka, Bangladesh: IEEE. doi:10.1109/ICCITECHN.2018.8631925
- Saini, S., Nikhil, S., Konda, K. R., Bharadwaj, H. S., & Ganeshan, N. (2017). An efficient vision-based traffic light detection and state recognition for autonomous vehicles. *2017 IEEE Intelligent Vehicles Symposium (IV)* (s. 606-611). Los Angeles, CA, USA: IEEE. doi:10.1109/IVS.2017.7995785
- Salehi, A. W., Khan, S., Gupta, G., Alabdullah, B. I., Almjally, A., Alsolai, H., . . . Mellit, A. (2023). A Study of CNN and Transfer Learning in Medical Imaging: Advantages, Challenges, Future Scope. *Sustainability*, 15(7), 5930.
- Sapkal, A., Arti, Pawar, D., & Singh, P. (2023). Lane detection techniques for self-driving vehicle: comprehensive review. *Multimedia Tools and Applications*, 1-22.
- Sensoy, M., Kaplan, L., & Kandemir, M. (2018). Evidential Deep Learning to Quantify Classification Uncertainty. *Advances in neural information processing systems*, 31.
- Sermanet, P., & LeCun, Y. (2011). Traffic sign recognition with multi-scale Convolutional Networks. *The 2011 International Joint Conference on Neural Networks* (s. 2809-2813). San Jose, CA, USA: IEEE. doi:10.1109/IJCNN.2011.6033589
- Shilaskar, S., Patil, V., Pawar, S., Poke, A., Jambhulkar, R., & Bhatlawande, S. (2023). Driver Safety System using Microcontroller and Image Processing. *2023*

- International Conference on Intelligent Data Communication Technologies and Internet of Things (IDCIoT)* (s. 340-344). Bengaluru, India: IEEE.
- Shustanov, A., & Yakimov, P. (2017). CNN Design for Real-Time Traffic Sign Recognition. *Procedia Engineering*, 201, 718-725.
- Simonyan, K., & Zisserman, A. (2014). Very Deep Convolutional Networks for Large-Scale Image Recognition. *arXiv preprint arXiv:1409.1556*.
- Smith, L. N. (2018). A disciplined approach to neural network hyper-parameters: Part 1 -- learning rate, batch size, momentum, and weight decay. *arXiv preprint arXiv:1803.09820*.
- Sooksatra, S., & Kondo, T. (2014). Red traffic light detection using fast radial symmetry transform. *2014 11th International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology (ECTI-CON)* (s. 1-6). Nakhon Ratchasima, Thailand: IEEE.
- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. (2014). Dropout: A Simple Way to Prevent Neural Networks from. *Journal of Machine Learning Research*, 15(1), 1929-1958.
- Stallkamp, J., Schlipsing, M., J. S., & Igel, C. (2012). Man vs. computer: Benchmarking machine learning algorithms for traffic sign recognition. *Neural Networks*, 32, 323-332.
- Stallkamp, J., Schlipsing, M., Salmen, J., & Igel, C. (2011). The German Traffic Sign Recognition Benchmark: A multi-class classification competition. *The 2011 International Joint Conference on Neural Networks* (s. 1453-1460). San Jose, CA, USA: IEEE. doi:10.1109/IJCNN.2011.6033395
- Sussman, J. S. (2008). *Perspectives on intelligent transportation systems (ITS)*. Springer Science & Business Media.
- Taghanaki, S. A., Bentaieb, A., Sharma, A., Zhou, S. K., Zheng, Y., Georgescu, B., . . . Hamarneh, G. (2019). Select, Attend, and Transfer: Light, Learnable Skip Connections. *Machine Learning in Medical Imaging: 10th International Workshop, MLMI 2019, Held in Conjunction with MICCAI 2019, Shenzhen, China, October 13, 2019, Proceedings 10* (s. 417-425). içinde Springer International Publishing.
- Trehard, G., Pollard, E., Bradai, B., & Nashashibi, F. (2014). Tracking both pose and status of a traffic light via an Interacting Multiple Model filter. *17th International Conference on Information Fusion (FUSION)* (s. 1-7). Salamanca, Spain: IEEE.
- Vo, H. H., & Verma, A. (2016). Discriminant color texture descriptors for diabetic retinopathy recognition. *2016 IEEE 12th International Conference on Intelligent Computer Communication and Processing (ICCP)*, 309-315. doi:10.1109/ICCP.2016.7737165
- Vo, H. H., & Verma, A. (2016). New Deep Neural Nets for Fine-Grained Diabetic Retinopathy Recognition on Hybrid Color Space. *2016 IEEE International*

- Symposium on Multimedia (ISM)* (s. 209-215). San Jose, CA, USA: IEEE. doi:10.1109/ISM.2016.0049
- Voulodimos, A., Doulamis, N. D., & Protopapadakis, E. (2018). Deep Learning for Computer Vision: A Brief Review. *Computational Intelligence and Neuroscience*, 2018.
- Wali, S., Abdullah, M., Hannan, M., Hussain, A., Samad, S., Ker, P., & Mansor, M. (2019). Vision-Based Traffic Sign Detection and Recognition Systems: Current Trends and Challenges. *Sensors*, 19(9), 2093.
- Wang, J.-G., & Zhou, L.-B. (2018). Traffic Light Recognition With High Dynamic Range Imaging and Deep Learning. *IEEE Transactions on Intelligent Transportation Systems*, 20(4), 1341 - 1352.
- Wang, K., & Xiong, Z. (2016). VISUAL ENHANCEMENT METHOD FOR INTELLIGENT VEHICLE'S SAFETY BASED ON BRIGHTNESS GUIDE FILTERING ALGORITHM THINKING OF THE HIGH TRIBOLOGICAL AND ATTENUATION EFFECTS. *Journal of the Balkan Tribological Association*, 22.
- Wang, K., Tang, X., Zhao, S., & Zhou, Y. (2022). Simultaneous detection and tracking using deep learning and integrated channel feature for ambient traffic light recognition. *Journal of Ambient Intelligence and Humanized Computing*, 13, 271–281.
- Wang, K., X. H., J. C., Cao, C., Xiong, Z., & Chen, L. (2019). Forward and Backward Visual Fusion Approach to Motion Estimation with High Robustness and Low Cost. *Remote Sensing*, 11(18), 2139.
- Wang, S.-J., Yan, W.-J., Li, X., Zhao, G., Zhou, C.-G., Fu, X., . . . Tao, J. (2015). Micro-Expression Recognition Using Color Spaces. *IEEE Transactions on Image Processing*, 24(12), 6034 - 6047.
- Wang, W., Li, Y., Zou, T., Wang, X., You, J., & Luo, Y. (2020). A novel image classification approach via dense-MobileNet models. *Mobile Information Systems*, 2020.
- Wang, Y., Shi, M., & Wu, T. (2009, September). A Method of Fast and Robust for Traffic Sign Recognition. *2009 Fifth International Conference on Image and Graphics* (s. 891-895). Xi'an, China: IEEE. doi:10.1109/ICIG.2009.130
- Wong, A., Shafiee, M. J., & Jules, M. S. (2018). MicronNet: A Highly Compact Deep Convolutional Neural Network Architecture for Real-Time Embedded Traffic Sign Classification. *IEEE Access*, 6, 59803-59810. doi:10.1109/ACCESS.2018.2873948
- Wu, Y., Liu, Y., Li, J., Liu, H., & Hu, X. (2013, August). Traffic sign detection based on convolutional neural networks. *The 2013 International Joint Conference on Neural Networks (IJCNN)* (s. 1-7). Dallas, TX, USA: IEEE. doi:10.1109/IJCNN.2013.6706811
- Yao, J., Huang, B., Yang, S., Xiang, X., & Lu, Z. (2023). Traffic sign detection and recognition under low illumination. *Machine Vision and Applications*, 34(5), 75.

- Ye, Y. Y., Hao, X. L., & Chen, H. J. (2018). Lane detection method based on lane structural analysis and CNNs. *IET Intelligent Transport Systems*, 12(6), 513-520.
- Yildiz, G., & Dizdaroğlu, B. (2021). Convolutional Neural Network for Traffic Sign Recognition based on Color Space. *2021 2nd International Informatics and Software Engineering Conference (IISEC)* (s. 1-5). Ankara, Turkey: IEEE.
- Yoo, J. H., Lee, S.-W., Park, S.-K., & Kim, D. H. (2017). A Robust Lane Detection Method Based on Vanishing Point Estimation Using the Relevance of Line Segments. *IEEE Transactions on Intelligent Transportation Systems*, 18(12), 3254 - 3266. doi:10.1109/TITS.2017.2679222
- Youssof, N. (2022). Traffic sign classification using CNN and detection using faster-RCNN and YOLOV4. *Heliyon*, 8(12).
- Yucong, S., & Shuqing, G. (2021). Traffic sign recognition based on HOG feature extraction. *Journal of Measurements in Engineering*, 9(3), 142-155.
- Zakaria, N. J., Shapiai, M. I., Ghani, R. A., Yassin, M. N., Ibrahim, M. Z., & Wahid, N. (2023). Lane Detection in Autonomous Vehicles: A Systematic Review. *IEEE Access*, 11, 3729 - 3765.
- Zhang, J., Wang, W., Lu, C., Wang, J., & Sangaiah, A. K. (2020). Lightweight deep network for traffic sign classification. *Annals of Telecommunications*, 75, 369–379.
- Zhang, X., & Huang, W. (2022). Traffic sign recognition algorithm based on convolutional neural network. *2022 3rd International Conference on Computer Vision, Image and Deep Learning & International Conference on Computer Engineering and Applications (CVIDL & ICCEA)* (s. 1117-1119). Changchun, China: IEEE.
- Zhang, Y., Xue, J., Zhang, G., Zhang, Y., & Zheng, N. (2014). A multi-feature fusion based traffic light recognition algorithm for intelligent vehicles. *Proceedings of the 33rd Chinese Control Conference* (s. 4924-4929)). Nanjing, China: IEEE. doi:10.1109/ChiCC.2014.6895775
- Zheng, Y., & Jiang, W. (2022). Evaluation of Vision Transformers for Traffic Sign Classification. *Wireless Communications and Mobile Computing*, 2022.
- Zhu, Y., Zhang, C., Zhou, D., Wang, X., Bai, X., & Liu, W. (2016). Traffic sign detection and recognition using fully convolutional network guided proposals. *Neurocomputing*, 214, 758-766.
- Zou, Q., Jiang, H., Dai, Q., Yue, Y., Chen, L., & Wang, Q. (2019). Robust lane detection from continuous driving scenes using deep neural networks. *IEEE Transactions on Vehicular Technology*, 69(1), 41 - 54. doi:10.1109/TVT.2019.2949603

7. EKLER

Ek Tablo 1. GTSRB veri seti üzerinde topluluk öğrenme yöntemiyle sınıf bazında test sonuçları

Sınıf ismi	Kesinlik	Duyarlılık	F1-Skor	Support
Speed limit (20km/h)	1.0000	1.0000	1.0000	60
Speed limit (30km/h)	0.9972	1.0000	0.9986	720
Speed limit (50km/h)	0.9987	0.9987	0.9987	750
Speed limit (60km/h)	1.0000	0.9889	0.9944	450
Speed limit (70km/h)	1.0000	0.9970	0.9985	660
Speed limit (80km/h)	0.9890	1.0000	0.9945	630
End of speed limit (80km/h)	1.0000	1.0000	1.0000	150
Speed limit (100km/h)	0.9978	0.9978	0.9978	450
Speed limit (120km/h)	0.9978	0.9933	0.9955	450
No passing	1.0000	1.0000	1.0000	480
No passing for vehicles over 3.5 metric tons	1.0000	1.0000	1.0000	660
Right-of-way at the next intersection	1.0000	1.0000	1.0000	420
Priority road	1.0000	0.9913	0.9956	690
Yield	1.0000	0.9972	0.9986	720
Stop	1.0000	1.0000	1.0000	270
No vehicles	0.9722	1.0000	0.9859	210
Vehicles over 3.5 metric tons prohibited	1.0000	1.0000	1.0000	150
No entry	1.0000	1.0000	1.0000	360
General caution	1.0000	0.9846	0.9922	390
Dangerous curve to the left	1.0000	1.0000	1.0000	60
Dangerous curve to the right	1.0000	1.0000	1.0000	90
Double curve	0.9574	1.0000	0.9783	90

Bumpy road	1.0000	0.9917	0.9958	120
Slippery road	1.0000	1.0000	1.0000	150
Road narrows on the right	1.0000	1.0000	1.0000	90
Road work	0.9959	1.0000	0.9979	480
Traffic signals	0.9890	0.9944	0.9917	180
Pedestrians	1.0000	1.0000	1.0000	60
Children crossing	1.0000	1.0000	1.0000	150
Bicycles crossing	1.0000	1.0000	1.0000	90
Beware of ice/snow	1.0000	1.0000	1.0000	150
Wild animals crossing	1.0000	1.0000	1.0000	270
End of all speed and passing limits	1.0000	1.0000	1.0000	60
Turn right ahead	0.9953	1.0000	0.9976	210
Turn left ahead	1.0000	1.0000	1.0000	120
Ahead only	0.9974	1.0000	0.9987	390
Go straight or right	0.9917	1.0000	0.9959	120
Go straight or left	0.9833	0.9833	0.9833	60
Keep right	1.0000	1.0000	1.0000	690
Keep left	1.0000	1.0000	1.0000	90
Roundabout mandatory	0.9888	0.9778	0.9832	90
End of no passing	1.0000	1.0000	1.0000	60
End of no passing by vehicles over 3.5 metric tons	1.0000	1.0000	1.0000	90
doğruluk			0.9975	12630
makro ortalama	0.9965	0.9976	0.9970	12630
ağırlıklandırılmış ortalama	0.9976	0.9975	0.9975	12630

ÖZGEÇMİŞ

Gülcan YILDIZ, ilk öğrenimini Ünlüpinar İlköğretim Okulu, orta öğrenimini Kaymakam Nuri Okutan İlköğretim Okulu, lise öğrenimini Kelkit Anadolu Lisesi'nde tamamladı. 2009 yılında Ondokuz Mayıs Üniversitesi (OMÜ) Mühendislik Fakültesi Bilgisayar Mühendisliği Bölümü'nde lisans eğitimine başladı ve 2013 yılında mezun oldu. 2013 yılı bahar döneminde OMÜ Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı'nda yüksek lisans eğitimine başladı. 2014 yılında OMÜ Bilgisayar Mühendisliği bölümünde araştırma görevlisi olarak çalışmaya başladı. 2017 yılı ocak ayında yüksek lisans eğitimini tamamladı ve KTÜ Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı'nda doktora eğitimine başladı. Halen OMÜ Bilgisayar Mühendisliği bölümünde araştırma görevlisi olarak çalışmaktadır. Tezden üretilen akademik çalışmaları ve yayınları aşağıdadır.

SCI, SSCI, AHCI İndekslerine Giren Dergilerde Yayımlanan Makaleler

Yildiz, G., Ulu, A., Dizdaroğlu, B., & Yildiz, D. (2023). Hybrid Image Improving and CNN (HIICNN) Stacking Ensemble Method for Traffic Sign Recognition. *IEEE Access*.

Hakemli Kongre / Sempozyumların Bildiri Kitaplarında Yer Alan Yayınlar

Yıldız, G., & Dizdaroğlu, B. (2019, November). Traffic sign detection via color and shape-based approach. In *2019 1st International Informatics and Software Engineering Conference (UBMYK)* (pp. 1-5). IEEE.

Yıldız, G., & Dizdaroğlu, B. (2020, October). Traffic Sign Recognition via Transfer Learning using Convolutional Neural Network Models. In *2020 28th Signal Processing and Communications Applications Conference (SIU)* (pp. 1-4). IEEE.

Yildiz, G., & Dizdaroğlu, B. (2021, December). Convolutional neural network for traffic sign recognition based on color space. In *2021 2nd International Informatics and Software Engineering Conference (IISEC)* (pp. 1-5). IEEE.

Yıldız, G., Dizdaroğlu, B., Yıldız, D. (2022). Deep Learning-Based Traffic Light Classification with Hyperparameter Selection. 4th International Conference on Artificial Intelligence and Applied Mathematics in Engineering. ICAIAME 2022.

Yıldız, G., Dizdaroğlu, B., Yıldız, D. (2022). Traffic Light Classification with Attention Mechanism Under Harsh Conditions. 4th International Conference on Artificial Intelligence and Applied Mathematics in Engineering. ICAIAME 2022.

Uluslararası Kitaplarda Yayınlanan Kitap Bölümü

Yıldız, G., Dizdaroğlu, B., Yıldız, D. (2023). Deep Learning-Based Traffic Light Classification with Model Parameter Selection. In: Hemanth, D.J., Yigit, T., Kose, U., Guvenc, U. (eds) 4th International Conference on Artificial Intelligence and Applied Mathematics in Engineering. ICAIAME 2022. Engineering Cyber-Physical Systems and Critical Infrastructures, vol 7. Springer, Cham. https://doi.org/10.1007/978-3-031-31956-3_17