



**DENGESİZ VERİ SETLERİNDE
TRAFİK İŞARETLERİNİ TANIMA**

Yıldız AYDIN

**Yüksek Lisans Tezi
Bilgisayar Mühendisliği Anabilim Dalı
Bilgisayar Mühendisliği Bilim Dalı
Gülşah TÜMÜKLÜ ÖZYER**

2016

Her hakkı saklıdır

**ATATÜRK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

YÜKSEK LİSANS TEZİ

**DENGESİZ VERİ SETLERİNDE TRAFİK İŞARETLERİNİ
TANIMA**

Yıldız AYDIN

**BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI
Bilgisayar Mühendisliği Bilim Dalı**

**ERZURUM
2016**

Her hakkı saklıdır



T.C.
ATATÜRK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



TEZ ONAY FORMU

DENGESİZ VERİ SETLERİNDE TRAFİK İŞARETLERİNİ TANIMA

Yrd. Doç. Dr. Gülşah TÜMÜKLÜ ÖZYER danışmanlığında, Yıldız AYDIN tarafından hazırlanan bu çalışma 09/06/2016 tarihinde aşağıdaki jüri tarafından Bilgisayar Mühendisliği Anabilim Dalı – Bilgisayar Mühendisliği Bilim Dalı'nda Yüksek Lisans Tezi olarak **oybirliği/oy çokluğu (.../...)** ile kabul edilmiştir.

Başkan : Doç. Dr. Abdulsamet HAŞILOĞLU

İmza :

Üye : Yrd. Doç. Dr. Gülşah TÜMÜKLÜ ÖZYER

İmza :

Üye : Yrd. Doç. Dr. Ahmet DURLU

İmza :

Yukarıdaki sonuç;

Enstitü Yönetim Kurulunun 16/06/2016 tarih ve 25/28 nolu kararı ile onaylanmıştır.

Prof. Dr. Ertan YILDIRIM
Enstitü Müdürü

Not: Bu tezde kullanılan özgün ve başka kaynaklardan yapılan bildirişlerin, çizelge, şekil ve fotoğrafların kaynak olarak kullanımı, 5846 sayılı Fikir ve Sanat Eserleri Kanunundaki hükümlere tabidir.

ÖZET

Yüksek Lisans Tezi

DENGESİZ VERİ SETLERİNDE TRAFİK İŞARETLERİNİ TANIMA

Yıldız AYDIN

Atatürk Üniversitesi
Fen Bilimleri Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı
Bilgisayar Mühendisliği Bilim Dalı

Danışman: Yrd. Doç. Dr. Gülşah TÜMÜKLÜ ÖZYER

Hızla gelişen teknoloji ile birlikte yol güvenliğine verilen önem büyük ölçüde artmış ve insan kaynaklı sorunlara odaklanılmıştır. Sürücülerin göz problemleri, yavaş refleksleri veya telefon gibi elektronik cihazların kullanımından dolayı dikkatlerinin dağılması daha fazla kazanın gerçekleşmesine sebebiyet vermiştir. Bu nedenle trafik işareti otomatik tanıma sistemi (traffic sign recognition (TSR)) günümüzde üzerinde oldukça durulan bir konu olmuştur. Literatürde, TSR sistemi için geliştirilen çalışmalarda kullanılan standart (German, Belgium vs.) veri setlerinin sınıflarında bulunan görüntü sayıları, işaretlerin kullanım sıklıklarından dolayı orantısızdır. Bu tip veri setlerinin üzerinde gerçekleştirilen uygulamalar, yerel öznitelikler ile birlikte kullanılır ise başarılı sonuçlar vermemektedir. Yerel öznitelikler tüm görüntüyü incelemek yerine belirgin noktalara odaklanmakta ve bu sayede işlem ve zaman maliyetini düşürmektedir. Bu çalışmada, işaret levhalarının renk bakımından dış çevreden farklı olmasından dolayı yerel öznitelikler kullanılmış ve dengesiz veri seti ile bu yerel özniteliklerin kullanımı esnasında ortaya çıkan dengesiz veri seti problemi üzerine odaklanılmıştır. Önerilen TSR sistemi öznitelik çıkarımı ve sınıflandırma adımlarından oluşmaktadır. Öznitelik çıkarım adımında ölçeklemeden bağımsız öznitelik dönüşümü ve hızlandırılmış gürbüz özniteliği kullanılarak yeni iki öznitelik elde edilmiştir. Sınıflandırma adımında ise torbalama temelli topluluk sınıflandırıcısı kullanılmıştır. Ayrıca önerilen sistem literatürde sıklıkla kullanılan yönlü eğimlerin histogramı özniteliği, k-en yakın komşu sınıflandırıcısı, karar ağaçları sınıflandırıcısı ve destek vektör makineleri sınıflandırıcısı ile karşılaştırılmıştır. Deneysel çalışmalarda önerilen yöntem ile yerel özniteliklerin dengesiz veri setleri üzerinde %91 doğru sınıflandırma performansı ile başarılı sonuçlar verdiği gözlemlenmiştir.

2016, 125 Sayfa

Anahtar Kelimeler: Ölçeklemeden bağımsız öznitelik dönüşümü, hızlandırılmış gürbüz özniteliği, trafik işaretlerinin tanınması, dengesiz veri seti.

ABSTRACT

MS Thesis

TRAFFIC SIGN RECOGNITION SYSTEM FOR IMBALANCED DATASET

Yıldız AYDIN

Atatürk University
Graduate School of Natural and Applied Sciences
Department of Computer Engineering

Supervisor: Assist. Prof. Dr. Gülşah TÜMÜKLÜ ÖZYER

The importance given to the road safety has increased with quickly developed technology and directed to concentrate upon human related problems. Drivers vision problems, slow reflexes, distraction due to the electronic devices give rise to more accident. For this reason, Traffic Sign Recognition System (TSR) is a highly emphasize topic. In literature, typically traffic signs datasets (German, Belgium), which used in the development studies for TSR system, are non-proportional due to the image number in dataset classes and frequency of the occurrence of the signs. The applications performed on these datasets don't give successful results if they are used with local features. Local features focuses on specific regions instead of whole image and thus decrease the cost of process and time. In this study, local features were used because of traffic signs differ from its surrounding in terms of color and imbalanced dataset problem that occur when these datasets used with local features was focused. Suggested TSR system consist of feature extraction and classification processes. In feature extraction step three new features are obtained by using Scale invariant feature transform (SIFT), speeded-up robust features (SURF). In classification step bagging-based ensemble (BBE) classifier were used. In addition, suggested system compared with widely used methods such as histogram of gradient (HOG) feature, k-nearest neighbor classifier, decision tree classifier and support vector machine classifier. Experimental studies show that local features with suggested method gives successful results on imbalanced dataset with %91 accuracy rate.

2016, 125 Pages

Keywords: Scale-invariant feature transform, speed-up robust features, traffic sign recognition, imbalanced dataset

TEŞEKKÜR

Araştırmanın uygulama aşamasında bilgi ve tecrübeleriyle beni yönlendiren hocam ve danışmanım Sayın Yrd. Doç. Dr. Gülşah TÜMÜKLÜ ÖZYER başta olmak üzere, Sayın hocam Yrd. Doç. Dr. Durmuş ÖZDEMİR'e, araştırmamın her aşamasında desteklerini esirgemeyen meslektaşlarım Yaşar CEYLAN'a, Osman GÜMÜŞ'e ve amirlerim Suat TUNA ve Davut MUMCU'ya teşekkür ederim.

Ayrıca çalışmalarım esnasında maddi ve manevi olarak her zaman yanımda olan öncelikle annem olmak üzere aileme desteklerinden dolayı teşekkür ederim

Yıldız AYDIN

Mayıs, 2016

İÇİNDEKİLER

ÖZET.....	i
ABSTRACT.....	ii
TEŞEKKÜR.....	iii
SİMGELER ve KISALTMALAR DİZİNİ	vi
ŞEKİLLER DİZİNİ.....	viii
ÇİZELGELER DİZİNİ	xi
1. GİRİŞ.....	1
1.1. Araştırmanın Amacı ve Katkısı.....	2
1.2. Tezin Yapısı	3
2. KAYNAK ÖZETLERİ	5
2.1. Dengesiz Veri Seti.....	6
2.2. Trafik İşaretlerinin Otomatik Tanınması.....	6
2.3. Öznitelikler.....	10
2.4. Kelime Torbası	11
2.5. Sınıflandırıcı.....	12
2.6. Özet	13
3. MATERYAL ve YÖNTEM.....	14
3.1. Öznitelik çıkarımı.....	16
3.1.1. Ölçeklemeden bağımsız öznitelik dönüşümü (SIFT).....	18
3.1.1.a. Uzay ölçekli ekstremumların belirlenmesi	18
3.1.1.b. Kilit noktanın yerini belirleme	20
3.1.1.c. Yönelim atama.....	20
3.1.1.d. Kilit nokta tanımlayıcısı	20
3.1.1. Hızlandırılmış gürbüz özniteliği (SURF)	21
3.1.1.a. İlgi noktası tespiti	21
3.1.1.b. İlgi noktası tanımlayıcısı	23
3.1.2. SURF ile elenen SIFT özniteliği (SSIFT)	25
3.1.3. SIFT ile elenen SURF özniteliği (SSURF)	26
3.1.4. Kelimelerin torbası yöntemi (BoW).....	26

3.1.5. Yönlü eğimlerin histogramı (HOG)	27
3.1.4.a. Eğim hesaplama.....	29
3.1.3.b. Yönlü histogramların hesaplanması	29
3.1.3.c. Blok normalizasyonu	30
3.2. Sınıflandırıcılar.....	30
3.2.1. Destek vektör makineleri.....	31
3.2.1.a. Doğrusal destek vektör makineleri	31
3.2.1.b. Doğrusal olmayan destek vektör makineleri	32
3.2.2. Karar ağaçları	32
3.2.3. K- en yakın komşu algoritması	33
3.2.4. Topluluk öğrenmesi (Ensemble Learning).....	34
3.2.4.a. Topluluk öğrenme algoritması.....	35
3.2.4.b. Torbalama temelli topluluk sınıflandırıcısı	36
3.3. Özet	38
4. ARAŞTIRMA BULGULARI ve TARTIŞMA.....	40
4.1. Dengesiz Veri Setlerinde Trafik İşaretlerini Tanıma Uygulamaları	40
4.2. Belçika Trafik İşareti Tanıma Veri Grubu	42
4.3. Öznitelik Çıkarımı.....	44
4.4. Sınıflandırma	46
4.4.1. Destek vektör makineleri sınıflandırıcı yöntemi sonuçlarının grafiksel gösterimi.....	47
4.4.2. Karar ağaçları sınıflandırıcı yöntemi sonuçlarının grafiksel gösterimi.....	69
4.4.3. KNN sınıflandırıcı yöntemi sonuçlarının grafiksel gösterimi	85
4.4.4. TTT sınıflandırıcı yöntemi sonuçlarının grafiksel gösterimi	101
4.5. Özet	117
5. SONUÇ ve ÖNERİLER.....	120
KAYNAKLAR	122
ÖZGEÇMİŞ	126

SİMGELER ve KISALTMALAR DİZİNİ

Kısaltmalar

BTİT	: Belçika Trafik İşaretleri Tanıma
BoW	: Kelimelerin Çantası Yöntemi
DoG	: Gauss Farkı
DVM	: Öznitelikleri ve Destek Vektör Makineleri Sınıflandırıcısı
FLANN	: Yaklaşık En Yakın Komşular İçin Hızlı Kitaplık
GPS	: Küresel Konumlama Sistemi
HOG	: Yönlü Eğimlerin Histogramı
I	: Gri Ölçek Değeri
INNC	: Iterativ En Yakın Komşu Sınıflandırıcısı
KA	: Karar Ağaçları
KNN	: En Yakın Komşu
PI	: Eğim Yönelimleri Histogramının Piramidi
RBF	: Radyal Temelli Fonksiyon
SIFT	: Ölçeklemeden Bağımsız Öznitelik Dönüşümü
SRC	: Seyrek Temsil Tabanlı Sınıflandırıcı
SURF	: Hızlandırılmış Gürbüz Özniteliği
TSR	: Trafik İşaretleri Otomatik Tanıma (Traffic Sign Recognition)
TTT	: Torbalama Temelli Topluluk

Simgeler

%	: Yüzde
C	: Doğrusal olamayan destek vektör makinelerinin parametresi
γ	: Doğrusal olamayan destek vektör makinelerinin parametresi
x	: Yatay Konum
y	: Düşey Konum
σ	: Ölçek uzayı

$*$	: Konvolüsyon operatörü
θ	: Eğim Yönelimi
$\tan$	: Tanjant
$I_{\Sigma}x$	: İntegral Görüntüsü
π	: Pi Sayısı
d_x	: Yatay Yöndeki Haar Dalgacık Cevabı
d_y	: Düşey Yöndeki Haar Dalgacık Cevabı
$ d_x $	: Yatay Yöndeki Haar Dalgacık Cevabının Mutlak Değeri
$ d_y $	: Düşey Yöndeki Haar Dalgacık Cevabının Mutlak Değeri
G_x	: Yatay Yöndeki Eğim
G_y	: Düşey Yöndeki Eğim
v	: Normalize Edilmemiş Vektör
ε	: Küçük Düzenleme Sabitidir
x_j	: Eğitim Örneği
x_{jf}	: Eğitim Örneğinin Özniteliği
C_n	: Baz modeli

ŞEKİLLER DİZİNİ

Şekil 3.1. Sistemin işlem adımlarının belirtildiği akış diyagramı.....	15
Şekil 3.2. Gerçekleştirilen deneysel çalışmaların akış diyagramı.....	16
Şekil 3.3. İlgili Nokta Tanımlayıcısının ve Özelliklerinin Örnekleri	17
Şekil 3.4. Gauss Piramidinden DoG Hesaplanması.....	19
Şekil 3.5. DoG Görüntüsünde Minimum ve Maksimum Değerlerin Tespiti.....	19
Şekil 3.6. Kilit Nokta Tanımlayıcıların Oluşturulması.....	21
Şekil 3.7. Haar dalga filtrelerinin x ve y yönündeki cevapları	23
Şekil 3.8. Her karenin 2×2 alt bölümleri tanımlayıcının gerçek alanlarına karşılık gelmektedir (sol). Dalgacık cevaplarının toplamı(sağ)	24
Şekil 3.9. Bir alt bölgenin tanımlayıcı girişlerindeki yoğunluğun doğasını temsil etmektedir. Sol: Homojen bir bölgede olması durumunda, tüm değerler nispeten düşüktür. Orta: x yönünde frekansların varlığında $P dx $ yüksek, ama diğerleri düşük kalır	25
Şekil 3.10. SSIFT tanımlayıcısının elde edilmesi için gerçekleştirilen işlem adımları ..	25
Şekil 3.11 SSURF tanımlayıcısının elde edilmesi için gerçekleştirilen işlem adımları .	26
Şekil 3.12. Hog Özniteliği: Soldaki görüntü giriş görüntüsü, sağdaki görüntü eğim yönelimlerini göstermektedir.	28
Şekil 3.13. A,B ve C doğrusal sınıflandırıcılardır. Kalın çizgi ise bu baz sınıflandırıcının çoğunluk oyu ile örneği sınıflandıran topluluktur	35
Şekil 3.14. Torbalama algoritması	37
Şekil 3.15. Torbalama temelli topluluk sınıflandırıcısının işlem akış diyagramı.....	38
Şekil 4.1. Deneyler.....	41
Şekil 4.2. BTİT veri seti sınıflarına ait örnek görüntüler.....	43
Şekil 4.3. (a) Orijinal Görüntü, (b) SIFT anahtar noktaları, (c) SURF anahtar noktaları, (d) HOG özniteliği (Aydın vd. 2016).....	46
Şekil 4.4. Yerel öznitelik ve DVM sınıflandırıcısı yönteminin doğru sınıflandırma performansları.....	48
Şekil 4.5. SIFT özniteliği ve DVM sınıflandırıcısı yöntemine ait konfüzyon matrisi....	49
Şekil 4.6. SURF özniteliği ve DVM sınıflandırıcısı yöntemine ait konfüzyon matrisi ..	50

Şekil 4.7. SSIFT özniteliği ve DVM sınıflandırıcısı yöntemine ait konfüzyon matrisi .	51
Şekil 4.8. SSURF özniteliği ve DVM sınıflandırıcısı yöntemine ait konfüzyon matrisi	52
Şekil 4.9. SIFT+SURF özniteliği ve DVM sınıflandırıcısı yöntemine ait konfüzyon matrisi	53
Şekil 4.10. HOG, HOG+SIFT, HOG+SSIFT, HOG+SSURF ve DVM sınıflandırıcısı yönteminin doğru sınıflandırma performansları	60
Şekil 4.11. HOG özniteliği ve DVM sınıflandırıcısı yöntemine ait konfüzyon matrisi.....	61
Şekil 4.12. HOG+SIFT özniteliği ve DVM sınıflandırıcısı yöntemine ait konfüzyon matrisi.....	62
Şekil 4.13. HOG+SSIFT özniteliği ve DVM sınıflandırıcısı yöntemine ait konfüzyon matrisi.....	63
Şekil 4.14. HOG+SSURF özniteliği ve DVM sınıflandırıcısı yöntemine ait konfüzyon matrisi.....	64
Şekil 4.15. Yerel öznitelik ve KA sınıflandırıcısı yönteminin doğru sınıflandırma performansları	69
Şekil 4.16. SIFT özniteliği ve KA sınıflandırıcısı yöntemine ait konfüzyon matrisi	70
Şekil 4.17. SURF özniteliği ve KA sınıflandırıcısı yöntemine ait konfüzyon matrisi ...	71
Şekil 4.18. SSIFT özniteliği ve KA sınıflandırıcısı yöntemine ait konfüzyon matrisi ...	72
Şekil 4.19. SSURF özniteliği ve KA sınıflandırıcısı yöntemine ait konfüzyon matrisi .	73
Şekil 4.20. SIFT+SURF özniteliği ve KA sınıflandırıcısı yöntemine ait konfüzyon matrisi.....	74
Şekil 4.21. HOG, HOG+SIFT ve KA sınıflandırıcısı yönteminin doğru sınıflandırma performansları	80
Şekil 4.22. HOG özniteliği ve KA sınıflandırıcısı yöntemine ait konfüzyon matrisi.....	81
Şekil 4.23. HOG+SIFT özniteliği ve KA sınıflandırıcısı yöntemine ait konfüzyon matrisi.....	82
Şekil 4.24. Yerel özniteliklerin ve KNN sınıflandırıcısı yönteminin doğru sınıflandırma performansları	85
Şekil 4.25. SIFT özniteliği ve KNN sınıflandırıcısı yöntemine ait konfüzyon matris ...	86
Şekil 4.26. SURF özniteliği ve KNN sınıflandırıcısı yöntemine ait konfüzyon matris..	87

Şekil 4.27. SSIFT özniteliği ve KNN sınıflandırıcısı yöntemine ait konfüzyon matris.....	88
Şekil 4.28. SSURF özniteliği ve KNN sınıflandırıcısı yöntemine ait konfüzyon matris.....	89
Şekil 4.29. SIFT+SURF özniteliği ve KNN sınıflandırıcısı yöntemine ait konfüzyon matris.....	90
Şekil 4.30. HOG özniteliği ve HOG+SIFT özniteliğinin KNN sınıflandırıcısı ile uygulandığı deneylerin doğru sınıflandırma performansları.....	96
Şekil 4.31. HOG özniteliği ve KNN sınıflandırıcısı yöntemine ait konfüzyon matris...	97
Şekil 4.32. HOG+SIFT özniteliği ve KNN sınıflandırıcısı yöntemine ait konfüzyon matris.....	98
Şekil 4.33. Yerel öznitelikler ve TTT sınıflandırıcısı yönteminin doğru sınıflandırma performansları	101
Şekil 4.34. SIFT özniteliği ve TTT sınıflandırıcısı yöntemine ait konfüzyon matris...	102
Şekil 4.35. SURF özniteliği ve TTT sınıflandırıcısı yöntemine ait konfüzyon matris.	103
Şekil 4.36. SSIFT özniteliği ve TTT sınıflandırıcısı yöntemine ait konfüzyon matris.....	104
Şekil 4.37. SSURF özniteliği ve TTT sınıflandırıcısı yöntemine ait konfüzyon matris.....	105
Şekil 4.38. SIFT+SURF özniteliği ve TTT sınıflandırıcısı yöntemine ait konfüzyon matris.....	106
Şekil 4.39. HOG özniteliği, HOG+SIFT özniteliği ve TTT sınıflandırıcısı yönteminin doğru sınıflandırma performansları	112
Şekil 4.40. HOG özniteliği ve TTT sınıflandırıcısı yöntemine ait konfüzyon matris ..	113
Şekil 4.41. HOG+SIFT özniteliği ve TTT sınıflandırıcısı yöntemine ait konfüzyon matris.....	114

ÇİZELGELER DİZİNİ

Çizelge 4.1. BTİT Veri Seti Sınıflarının Örnek Görüntü Sayısı.....	44
Çizelge 4.2. DVM Sınıflandırıcısının ve SIFT Özniteliğinin Sınıf Bazlı Sınıflandırma Performansları	54
Çizelge 4.3. DVM Sınıflandırıcısının ve SURF Özniteliğinin Sınıf Bazlı Sınıflandırma Performansları	55
Çizelge 4.4. DVM Sınıflandırıcısının ve SSIFT Özniteliğinin Sınıf Bazlı Sınıflandırma Performansları	56
Çizelge 4.5. DVM Sınıflandırıcısının ve SSURF Özniteliğinin Sınıf Bazlı Sınıflandırma Performansları	57
Çizelge 4.6. DVM Sınıflandırıcısının ve SIFT+SURF Özniteliğinin Sınıf Bazlı Sınıflandırma Performansları	58
Çizelge 4.7. DVM Sınıflandırıcısının ve HOG Özniteliğinin Sınıf Bazlı Sınıflandırma Performansları	65
Çizelge 4.8. DVM Sınıflandırıcısının ve HOG+SIFT Özniteliğinin Sınıf Bazlı Sınıflandırma Performansları	66
Çizelge 4.9. DVM Sınıflandırıcısının ve HOG+SSIFT Özniteliğinin Sınıf Bazlı Sınıflandırma Performansları	67
Çizelge 4.10. DVM Sınıflandırıcısının ve HOG+SSURF Özniteliğinin Sınıf Bazlı Sınıflandırma Performansları	68
Çizelge 4.11. KA Sınıflandırıcısının ve SIFT Özniteliğinin Sınıf Bazlı Sınıflandırma Performansları	75
Çizelge 4.12. KA Sınıflandırıcısının ve SURF Özniteliğinin Sınıf Bazlı Sınıflandırma Performansları	76
Çizelge 4.13. KA Sınıflandırıcısının ve SSIFT Özniteliğinin Sınıf Bazlı Sınıflandırma Performansları	77
Çizelge 4.14. KA Sınıflandırıcısının ve SSURF Özniteliğinin Sınıf Bazlı Sınıflandırma Performansları	78
Çizelge 4.15. KA Sınıflandırıcısının ve SIFT+SURF Özniteliğinin Sınıf Bazlı Sınıflandırma Performansları	79

Çizelge 4.16. KA Sınıflandırıcısının ve HOG Özniteliğinin Sınıf Bazlı Sınıflandırma Performansları	83
Çizelge 4.17. KA Sınıflandırıcısının ve HOG+SIFT Özniteliğinin Sınıf Bazlı Sınıflandırma Performansları	84
Çizelge 4.18. KNN Sınıflandırıcısının ve SIFT Özniteliğinin Sınıf Bazlı Sınıflandırma Performansları	91
Çizelge 4.19. KNN Sınıflandırıcısının ve SURF Özniteliğinin Sınıf Bazlı Sınıflandırma Performansları	92
Çizelge 4.20. KNN Sınıflandırıcısının ve SSIFT Özniteliğinin Sınıf Bazlı Sınıflandırma Performansları	93
Çizelge 4.21. KNN Sınıflandırıcısının ve SSURF Özniteliğinin Sınıf Bazlı Sınıflandırma Performansları	94
Çizelge 4.22. KNN Sınıflandırıcısının ve SIFT+SURF Özniteliğinin Sınıf Bazlı Sınıflandırma Performansları	95
Çizelge 4.23. KNN Sınıflandırıcısının ve HOG Özniteliğinin Sınıf Bazlı Sınıflandırma Performansları	99
Çizelge 4.24. KNN Sınıflandırıcısının ve HOG+SIFT Özniteliğinin Sınıf Bazlı Sınıflandırma Performansları	100
Çizelge 4.25. TTT Sınıflandırıcısının ve SIFT Özniteliğinin Sınıf Bazlı Sınıflandırma Performansları	107
Çizelge 4.26. TTT Sınıflandırıcısının ve SURF Özniteliğinin Sınıf Bazlı Sınıflandırma Performansları	108
Çizelge 4.27. TTT Sınıflandırıcısının ve SSIFT Özniteliğinin Sınıf Bazlı Sınıflandırma Performansları	109
Çizelge 4.28. TTT Sınıflandırıcısının ve SSURF Özniteliğinin Sınıf Bazlı Sınıflandırma Performansları	110
Çizelge 4.29. TTT Sınıflandırıcısının ve SIFT+SURF Özniteliğinin Sınıf Bazlı Sınıflandırma Performansları	111
Çizelge 4.30. TTT Sınıflandırıcısının ve HOG Özniteliğinin Sınıf Bazlı Sınıflandırma Performansları	115
Çizelge 4.31. TTT Sınıflandırıcısının ve HOG+SIFT Özniteliğinin Sınıf Bazlı Sınıflandırma Performansları	116

Çizelge 4.32. Sınıflandırma Performansları.....	117
--	------------



1. GİRİŞ

Trafik işaretleri otomatik tanıma (traffic sign recognition (TSR)) sistemi makine öğrenmesi, bilgisayarla görme ve örüntü tanıma alanlarında yoğun araştırma yapılan güncel ve sürekli geliştirme ihtiyacı duyan bir problemdir (Hu and Zhu 2010). Bu sistem sürücülere yol durumu ve trafik hakkında bilgi vererek konforlu bir sürüş sağlamaktadır. Ayrıca TSR sistemi, sürücülerin göz ardı ettiği veya bazı sebeplerden dolayı algılayamadığı trafik işaretleri kaynaklı kazaları en aza indirgeyerek, yaya ve sürücü güvenliğini sağlamaktadır. Günümüzde insansız araçlar için kullanılan küresel konumlama sistemi (GPS) tabanlı navigasyon cihazları ile çeşitli trafik yönlendirme işlemleri yapılırsa da bu sistemler sürüş güvenliği ve anlık değişken durumlar (güncel olmayan haritalar, haberleşme problemleri) için tam olarak çözüm üretememektedir. İnsansız araçların değişken durumlara göre karar verip daha güvenli hale gelebilmesi için TSR sisteminin geliştirilmesine yönelik yapılan çalışmalar önem arz etmektedir.

TSR sistemleri, sürücü destek sistemleri içinde yer alan alt bir özelliktir. Bu sistemde karşılaşılan trafik işaretinin önce yeri tespit edilir, sonra işaret tanımlanır. Trafik işaretlerinin tanımlanması bu sistemin yapıtaşı niteliğindedir. Trafik işaretinin tanınması, gerekli çıktının oluşmasını ve sistemin sonuç verebilmesini sağlar. Tanımlama olmadığında, sistem sadece işaretlerin olduğu alanı tanımlar. Fakat sürücüye gerekli geri bildirimi veremez.

TSR sistemi temelde iki aşamadan oluşmaktadır (Mathias *et al.* 2013). İlk adım öznitelik çıkarımı, ikinci adım ise sınıflandırmadır. İlk adımda kullanılan öznitelikler küresel ve yerel öznitelikler olmak üzere 2 tipe ayrılır. Yerel öznitelikler görüntü bölgelerinden çıkartılırken küresel öznitelikler tüm görüntü üzerinden çıkartılmaktadır. Küresel öznitelikler görüntünün arka planının önemli olduğu problemlerde kullanılmaktadır (Özyer 2012). Fakat arka planın göz ardı edildiği durumlarda bu özniteliği kullanmak fazla zaman ve bellek alanı kullanımına yol açmaktadır. Bu dezavantajlar ile birlikte küresel öznitelik kullanımı doğru sınıflandırma performansını da olumsuz yönde etkileyebilmektedir. Bu nedenle yerel öznitelikler arka planın ilgisiz

olduğu ya da amacın ön plandaki nesneyi tanıma olduğu uygulamalarda kullanılmaktadır.

SIFT, SURF gibi yerel öznitelikler, tüm görüntüyü bölümlenmeden ilgili nokta üzerinde odaklanmaktadır. Yerel öznitelikler bu özellikleri sayesinde renk bakımından çevresel etmenlerden farklı olan trafik işaretlerinin tanınması gibi çeşitli bilgisayarla görme problemlerinde başarıyla uygulanabilmektedir. Fakat bu özniteliklerin performansı kullanılan sınıflandırıcı ve veri setine bağlı olarak değişmektedir. Klasik makine sınıflandırıcıları (k-en yakın komşu, destek vektör makineleri) ile birlikte bu öznitelikler kullanılır ise uygulamaların performansı, kullanılan eğitim veri setinin sınıflarındaki görüntü sayılarına bağlı olarak değişmektedir. Eğitim veri seti sınıflarındaki görüntü sayıları arasındaki orantı farkı fazla ise bu özniteliklerin kullanıldığı uygulamalar ile başarılı sonuçlar elde edilememektedir. Çünkü kullanılan eğitim veri seti sınıflarındaki örnek sayısı diğer sınıflardaki örnek sayısından çok fazla veya çok az ise sınıflandırıcılar uygun öğrenme görevini yerine getirememektedir. Bu nedenle dengesiz veri seti problemi ortaya çıkmakta ve klasik makine sınıflandırıcıları çok örnekli sınıfa doğru eğilimli olup az örneğe sahip sınıfları göz ardı etmektedir.

1.1. Araştırmanın Amacı ve Katkısı

Bu çalışmada dengesiz veri seti üzerinde ilgi noktası (interest point detector) temelli yerel özniteliklerin kullanıldığı (interest point detector) bir TSR sistemi önerilmiştir. İlgi noktası temelli yerel öznitelikler, karmaşık sahnelerde görsellik bakımından belirgin olan alanlara odaklanmaktadır. Bu bağlamda yerel özniteliklerin sadece belirgin alandaki objelere yoğunlaşması faydalı bir seçenektir.

Görsel çevre içindeki farklı nesnelerin tanınması gerektiği zaman, ilgi noktası temelli yerel öznitelikler kullanılarak zaman ve hesaplama maliyeti düşürülmektedir. Fakat ilgi noktası tanımlayıcılarından elde edilen, yerel özniteliklerin kullanıldığı sistemlerde doğru sınıflandırma performansı veri seti sınıflarında bulunan görüntü sayısına bağlı olarak değişmektedir. Eğer kullanılan veri seti sınıflarındaki görüntü sayıları arasındaki

oran farkı fazla ise dengesiz veri seti problemi ortaya çıkmaktadır. Bu tarz problemlerde klasik makine sınıflandırıcıları ile başarılı sonuçlar elde edilememektedir.

Bu araştırmanın amacı, renk yönünden çevresel etmenlerden farklı olan trafik işaretlerinin sınıflandırılmasında, ilgi nokta tanımlayıcılarının avantajlarından faydalanılmasını sağlayan yerel öznitelikleri kullanmaktır. Fakat trafik işaret levhalarının bazılarının nadiren, bazılarının sıkça kullanılmasından dolayı trafik işareti veri seti sınıflarına ait görüntü sayıları arasında orantısızlık oluşmakta ve dengesiz veri seti problemi ortaya çıkmaktadır. Çalışmada SIFT ve SURF özniteliklerinin birlikte kullanıldığı iki yeni öznitelik önerilmiş ve TSR sisteminin dengesiz veri seti problemine yönelik katkı sağladığı görülmüştür.

1.2. Tezin Yapısı

Dengesiz veri seti üzerinde yerel özniteliklerin kullanıldığı TSR sistemi için önerilen çalışmanın ikinci bölümünde gerekli altyapının oluşturulması amacıyla trafik işaretlerini otomatik tanıma sistemi için gerçekleştirilen çalışmalar anlatılmıştır. Ayrıca yerel öznitelik tabanlı TSR sisteminde karşılaşılan dengesiz veri seti problemi ve TSR sisteminin işlem adımları ile ilgili literatür araştırması verilmiştir.

Üçüncü bölümde önerilen sistem ve araştırmada kullanılan yöntemler detaylı olarak anlatılmıştır. Araştırmada kullanılan ölçeklemeden bağımsız öznitelik dönüşümü (SIFT), hızlandırılmış gürbüz özniteliği (SURF), kelimelerin çantası yöntemi (BoW), yönlü eğimlerin histogramı özniteliği (HOG), ve destek vektör makineleri (DVM) sınıflandırıcısı, karar ağaçları sınıflandırıcısı (KA), en yakın komşu (KNN) sınıflandırıcısı ve torbalama temelli topluluk (TTT) sınıflandırıcısı yöntemleri tanıtılmıştır.

Dördüncü bölümde kullanılan Belçika Trafik İşareti Tanıma (BTİT) veri seti ve gerçekleştirilen deneysel çalışmalar hakkında bilgiler verilmiş ve deneylerden elde edilen doğru sınıflandırma performansları karşılaştırılmıştır. Elde edilen sonuçlar ve

gelecekte yapılması planlanan çalışmalar beşinci bölümde yer almaktadır.



2. KAYNAK ÖZETLERİ

Trafik işaretleri otomatik tanıma (traffic sign recognition (TSR)) sistemi üzerinde yapılan çalışmalar teknolojinin hızla gelişmesi ile birlikte artmıştır. Özellikle sürücülerden kaynaklanan trafik kazalarındaki artış bu sistemin önemini göstermiştir. Sürüş güvenliğinin yanı sıra akıllı araçlar için bu sistem zorunludur. Akıllı araçlarda bulunan küresel konumlama sistemi (GPS) tabanlı navigasyon cihazları ile trafik işaretleri otomatik tanınması sağlanmıştır. Fakat bu sistemler anlık değişken durumlarda doğru tanıma işlemini gerçekleştirememektedir. Bu nedenle çeşitli sorunlara karşı değişmez TSR sistemine yönelik çalışmalar yapılmıştır.

TSR sisteminden karşılaşılan sorunlardan birisi dengesiz veri seti problemidir. Trafik levhalarının bir kısmı kullanım amaçları doğrultusunda daha fazla, bir kısmı ise daha az konumlandırılmıştır. Kullanım farklılığından dolayı sınıflarda bulunan görüntü sayıları arasında orantısızlık oluşmakta ve dengesiz veri seti problemi ortaya çıkmaktadır. Bu nedenle literatürde kullanılan temel veri setleri dengesizdir. Trafik işaretini otomatik tanıma sistemi uygulamalarında genel olarak aşağıda verilen veri setleri kullanılmaktadır.

- Alman Veri Seti (German TSR Benchmark (GTSRB))
- Belçika Veri Seti (KUL Belgium Traffic Signs Data set (KUL Data set))
- İsveç Veri Seti (Swedish Traffic Signs Data set (STS Data set))
- RUG Veri Seti (RUG Traffic Sign Image Database (RUG Data set))

Aşağıda ilk olarak dengesiz veri seti problemi ile ilgili kaynak özetleri verilmiştir. İkinci bölüm TSR sistemine yönelik geliştirilen çalışmaları içermektedir. Üçüncü bölümde, TSR isteminin ilk adımında genellikle kullanılan öznitelikler, dördüncü bölümde ise yerel özniteliklerin sınıflandırıcılar ile kullanılmasını sağlayan kelimelerin çantası hakkında kaynak özetleri verilmiştir. Son bölümde TSR sisteminin ikinci adımı olan sınıflandırıcılar ile ilgili kaynak özetleri sunulmuştur.

2.1. Dengesiz Veri Seti

Dengesiz veri setleri, özellikle veri madenciliği alanında üzerinde yoğun çalışmalar yapılan zor bir problemdir. Galar *et al.* (2003), torbalama (bagging), artırım (boosting) ve hibrid tabanlı topluluk (hybrid based ensemble) metotlarını farklı dengesiz veri setleri üzerinde kullanmışlardır. Araştırmalarında, SMOTEbagging, RUSBoost yöntemlerinin en iyi sonuç veren yöntemler olduğunu tespit etmişlerdir.

Bu çalışmada, TSR uygulamalarında yaygın olarak kullanılan Belçika Trafik İşaretlerini Tanıma (KUL Belgium Traffic Signs Data Set (BTİT)) veri seti kullanılmıştır. Mathias *et al.* (2003) BTİT veri seti üzerinde yaptıkları çalışmada, öznitelik olarak yönlü eğimlerin histogramı özniteliğini, gri ölçek değeri özniteliğini ve eğim yönelimleri histogramının piramidi özniteliğini kullanmışlardır. Sınıflandırıcı olarak ise en yakın komşu sınıflandırıcısını, seyrek temsil tabanlı sınıflandırıcısını, iterativ en yakın komşu sınıflandırıcısını ve destek vektör makineleri sınıflandırıcısını kullanmışlar ve en yüksek sonucu seyrek temsil tabanlı sınıflandırıcısını kullanarak elde etmişlerdir.

2.2. Trafik İşaretlerinin Otomatik Tanınması

Diğer otomatik tanıma sistemleri gibi trafik işaretlerini otomatik tanıma (traffic sign recognition (TSR)) sistemi de güvenliğimiz ve konforumuz için gerekli bir sistemdir. Özellikle TSR sistemi insansız araçlar için olmazsa olmaz bir parçadır. Bu yüzden TSR sistemi için yapılan araştırmalar son yıllarda oldukça artmıştır.

De la Escalera *et al.* (1997) ,ilk olarak trafik işaretinin olduğu alanı saptamışlardır. Trafik işaretlerinin şeklinin üçgen ya da yuvarlak olmasından dolayı trafik işaretinin olduğu alanı saptama algoritmaları, işaretlere göre farklılık göstermiştir. Bu nedenle, öznitelik çıkarım adımını atlayarak trafik işaretlerinin resimlerini direkt olarak sınır ağlarına giriş örüntüsü olarak vermişlerdir. Farklı sayıdaki katman ve düğümler ile çeşitli ağları eğitip karşılaştırmış ve gerçek zamanlı uygulamalarda tüm algoritmaların başarılı olduğunu gözlemlemişlerdir.

Hu and Zhu (2010) öznitelik olarak ölçeklemeden bağımsız öznitelik, sınıflandırıcı olarak ise destek vektör makineleri sınıflandırıcılarını kullanmışlardır. DVM 'de kernel fonksiyonu olarak radyal temelli fonksiyon (radial basis function (RBF)) seçilmiştir. Kendi oluşturdukları veri seti üzerinde %93 doğru sınıflandırma performansı elde etmişlerdir.

Zhang *et al.* (2014) özellikle geometrik bozulmalara karşı değişmez olan trafik işaretleri tespit etme ve tanıma sistemini önermişlerdir. Tespit etme aşamasında renk bazlı bölümlere uygulayarak arka planı elimine etmişlerdir. Şekil analizi aşamasında ise hızlı fourier dönüşümü rotasyon ve ölçek problemleri için kullanılmıştır. Tanıma aşamasında ise HOG özniteliği ve doğrusal DVM kullanmışlardır. Bu çalışmanın rotasyon, ölçek ve aydınlatma değişikliklerine karşı değişmez olduğu %93 doğru tanıma oranı ile gösterilmiştir.

Perez and Javidi (2002) ölçek değişimlerine, düzlem içi ve düzlem dışı rotasyonlardaki değişikliklere, aydınlanma değişikliklerine, kısmen görünmeyen işaretlere, arka plan gürültüsüne ve hava durumuyla alakalı diğer bozulmalara karşı toleranslı bir doğrusal olmayan kompozit korelasyon filtrelerinin kümeleriyle bir TSR sistemi önermişlerdir.

Soetedjo and Yamada (2003), RGB görüntülerine renk eşikleme uyguladıktan sonra, trafik işaretlerini halka bölümlere metodunu kullanarak sınıflandırmışlardır. Görüntü tanımlayıcıları olarak her bir halkanın normalleştirilmiş bulanık histogramını kullanmışlardır. Kullanılan sistemde test görüntüsü, referans görüntüsü ile test görüntüsü arasındaki fark hesaplanarak sınıflandırılmış ve doğru sınıflandırma oranı %94 olmuştur.

Fang *et al.* (2004), insan tanımlama sürecinin duyuşsal algısal ve kavramsal düzeyinden esinlenen bir TSR sistemi önermişlerdir. Sistemin duyuşsal kısmında HSI renk uzayı, parlaklık değişimlerine karşı sabit olduğundan dolayı kullanılmıştır. Algısal kısmında ise uzay-zamansal dikkat sinir ağı kullanılmıştır. Bu uzay-zamansal dikkat sinir ağı hedef nesnenin bulunabileceği alanlardan alt bölgeleri seçmektedir. Kavramsal seviyede

öznitelikleri elde etmek için heteroilişkisel bellekli sinir ağı kullanılmış ve bu özniteliklere dayalı trafik işaretleri tanınmıştır.

Gao *et al.* (2006), insan görüşü renk görünüm modelini kullanarak işaret özniteliklerini sunmuştur. Uluslararası Aydınlatma Renk Komisyonu tarafından önerilen standart bir renk görünüm modeli olan CIECAM97, renk bilgisi çıkarmaya, trafik işaretlerini bölümlemeye ve sınıflandırmaya uygulanmıştır. Öznitelikler, gerçek görsel sistemin bazı mekanizmalarını taklit eden foveal sistemi tarafından elde edilmiştir. Bu yaklaşımdaki tanıma oranı %95 olmuştur.

Bennallal and Meunier (2003) düşük maliyetli, gerçek zamanlı trafik işareti tanıma sistemi için RGB renk uzayını seçmiştir. Çünkü görüntünün kırmızı, yeşil ve mavi bileşenleri kameralar tarafından herhangi bir dönüşüme gerek olmadan doğrudan desteklenmektedir. Trafik işaret görüntüsünün bölümlendirilmesi esnasında karşılaşılan aydınlanma değişiklikleri kaynaklı renk farkı sorunun üstesinden gelmek için kırmızı pikselleri tüm gün boyunca incelemişlerdir. Kırmızı bileşen ile yeşil bileşen arasındaki farklar ve kırmızı bileşen ile mavi bileşen arasındaki farkların 6:00 pm ve 9:00 pm arasında fazla olduğu sonucuna varmışlardır. Raporda aydınlatma için fazla duyarlı olmayan bu farklılıklar bölümlendirme için uygun bir eşiklendirme ile kolaylıkla kullanılabileceği sonucuna ulaşmışlardır.

Johansson (2002) işaretleri 20 metre mesafeden tanımak için kamera kullanarak gerçek zamanlı bir sistem gerçekleştirmiştir. Çalışmasında eşiklendirme ile renk bölümlemesini kullanmıştır. Kırmızı piksel, kırmızı bileşenin 35'ten yüksek olduğu ve kırmızı ile yeşil ve mavi bileşenlerinin oranının sırasıyla 0,64 ve 0,69 olduğu durumlarda tanımlanmıştır. İşlem süresi yaklaşık 0,2 saniye olmuştur.

Miura *et al.* (2000) sistemlerinde, biri geniş açılı lensli ve diğeri telefoto lensli olmak üzere iki kamera kullanmışlardır. İlk olarak geniş açılı kamerada renk, yoğunluk ve şekil bilgisini kullanarak aday trafik işaretleri tespit edilmiştir. Sonra her bir aday konum, uzak çeken kameradan alınan yüksek boyutlu görüntüde belirlenip

incelenmiştir. Renk ve yoğunluk, çeşitli hava durumu ve yıldırım koşullarında çekilmiş görüntüler üzerinde YUV renk uzayı ile analiz edilmiştir. İşaretler, trafik işareti görüntü veri seti kullanılarak normalleştirilmiş, korelasyon tabanlı örüntü eşleştirme ile tanınmıştır. Fakat işaretlerin sadece %23,5'i başarılı bir şekilde tanınmıştır. Sistem aynı zamanda hız işaretlerinin %97,2'sini tespit etmiş fakat sadece %46,5'ini tanımlayabilmiştir.

Rehrmann *et al.* (1995), bazı üniversitelerin ve Daimler-Benz'in işbirliğiyle gerçekleştirilen Avrupa PROMETHEUS projesi kapsamında geliştirilen bir sistemi tanımlamışlardır. Sistemde klasik örüntü tanıma ile birlikte bulanık mantık tekniklerini içeren renk görüntü analizleri kullanılmıştır. En iyi sonuçlar HSV renk uzayı kullanılarak elde edilmiştir. Renk analizi özel bir altıgen topoloji üzerinde büyüyen bir hiyerarşik bölge üzerinde takip edilmiştir. Başlangıç bölgesi analiz edilmiş, komşu bölge rengi ile benzer olarak belirtildiği durumda büyütülmüştür. Bu bölümlleme işleminden sonra tespit etme ve tanımlama işlemleri gerçekleştirilmiştir. Tespit etme aşamasında, bölgelerden çıkartılan özniteliklerle bulanık mantığı kullanmışlardır. Tanımlama evresinde ise bulunmuş aday trafik işareti alanı içindeki alakasız trafik işareti kenarlarının elenmesi ve tüm pikseller için renk sınıflandırılması işlemleri gerçekleştirilmiştir. Sonra doğru sınıflandırma performansının artırılabilmesi için sinir ağı ve en yakın komşu sınıflandırıcısının olasılık sonuçları birleştirilmiştir. Gerçekleştirilen sistemde, görüntü boyutu 13 ile 17 arasında olan işaretlerin %35'i tespit edilmiştir. Tespit oranı, 18 ile 24 piksel arasındaki işaret boyutları için %78, 25 ve 34 piksel arasındaki işaretler için %92, 34 pikselin üzerindeki için ise %98 olmuştur.

Burschka and Hager (2005) biri sağ kameradan biri sol kameradan gelen ya da tek bir kameradan gelen iki görüntüyü analiz ederek üç boyutlu görüntü hesaplamışlardır. Stereo-tabanlı bu sistemin amacı tüm düzlemsel yapıların iyileştirilmesidir. Bu metotta sağ ve sol görüntüler arasındaki ya da tek bir kameradan peş peşe gelen iki görüntü arasındaki uyumsuzluklar hesaplanmıştır. Bu yaklaşım, uyumsuz görüntünün koordinatları ile üç boyutlu görüntüden gelen eş kartezyen koordinatları arasında bir eşyazımlılık (haritalama ilişkisi) olduğu gerçeğine dayanmıştır. Düzlem nesnesi

düzlemin normal vektörü ile görüntü koordinatının skaler çarpımı hesaplanarak, sonra o konumdaki uyumsuzluk değeri ile karşılaştırılarak tespit edilmiştir. Araştırma, stereo yaklaşımında kameraların ayrılması arttıkça uyumsuzluğun da arttığını göstermiştir.

2.3. Öznitelikler

Öznitelikler görüntü hakkında bilgileri içermektedirler. Öznitelik seçimi araştırmanın amacına bağlı olarak değişmektedir. Öznitelik detektörünün en önemli yönü tekrarlanabilir olmasıdır, yani detektörün aynı kilit noktasını (ilgi noktasını) görüntünün farklı bakış açısından, rotasyonundan ve ölçeklerinden tespit edebilmesidir. Bir nesne her bir görüntü için aynı ölçekte görünmeyebilir, bu nedenle görüntü öznitelikleri farklı ölçeklerdeki nesneler için tespit amacına göre görüntü ölçeklemeye göre sabit olmak zorundadır.

Schmid and Mohr (1997) kilit noktaları bulmak için görüntü tanımlama problemlerinde Harris köşe detektörünü (Harris and Stephens 1988) kullanmışlardır. Harris köşe detektörü, görüntünün farklı ölçeklerindeki aynı kilit noktasını tespit edememektedir. Bu nedenle Harris köşe detektörü ile ölçeğe ve rotasyona karşı değişmeyen bir tanımlayıcının kullanılması gerekmektedir (Azad *et al.* 2009). Görüntü farklı bir kontrast seviyesinde olabilmektedir. Ayrıca obje farklı bir bakış açısından görünüyor olabilmektedir. Bu nedenle görüntü öznitelikleri yüksek doğru tanıma oranı için aydınlatmanın farklı seviyelerine ve üç boyutlu görüntülerdeki farklı bakış açılarına karşı dayanıklı olması gerekmektedir.

Lowe (1999), ayırıcı öznitelikleriyle bilinen ve obje tespiti ile görüntü sınıflandırmasında yaygın olarak kullanılan, ölçekten bağımsız öznitelik dönüşümünü tanıtmıştır. Lowe, ilgi noktası tespitinde ölçek değişmezliği problemini bu öznitelikle çözmüştür. Bu yöntemde, ilgi noktasını tanımlamak için yerel öznitelikler kullanılarak daha fazla ayırt edici öznitelik elde edilmiştir. Ayrıca bu öznitelikler bakış açısına ve aydınlanma değişikliklerine karşı daha fazla değişmez olmuştur.

Bay *et al.* (2009), kilit noktaları tespit etmek ve tanımlamak için hızlandırılmış gürbüz özniteliği (SURF) olarak bilinen, Hessian matrisine dayalı, 64-boyutlu öznitelik vektörlerini çıkaran hızlı bir metot önermiştir. SURF aynı zamanda ölçekten ve rotasyondan bağımsızdır.

Aynı zamanda kilit noktaların tespiti, bir algoritmayı uygulamak yerine yoğun örnekleme ile de hesaplanabilmektedir. Fakat yoğun örneklemede, Harris köşe detektöründe olduğu gibi ölçek ve rotasyondan bağımsız bir tanımlayıcıya ihtiyaç duyulmaktadır. Csurka *et al.* (2004) kilit noktaların tespit edilmesinde yoğun örnekleme ve SIFT tanımlayıcısını kullanan yöntemin en büyük avantajının hesaplama olduğunu iddia etmişlerdir. Yoğun öznitelikler yol, gökyüzü ve dalgasız deniz gibi tek biçimli alanlarda başarılı olduğu için sahne sınıflandırmasında oldukça etkili olmuştur.

Dalal and Triggs (2005) insan tespiti için yönlü eğimlerin histogramını tanıtmışlardır. Bu metotta nesne ilk olarak hücrelere bölünmektedir. Sonra her bir hücre için eğimlerin histogramı hesaplanmaktadır. Son olarak ise histogramlar ayrı ayrı normalleştirilip birleştirilmektedir.

Tüm tanımlayıcıların (SIFT, SURF ve HOG) performansları farklı sahnelerde değişiklik göstermektedir. Fakat bu tanımlayıcıların hepsi ile yeterli doğru tanıma oranı elde edilmektedir. Lowe (2004) SIFT ile karmaşık sahnelerde, Dalal and Triggs (2005) HOG ile insan tespitinde etkili sonuç elde edilebileceğini göstermişlerdir. Bay *et al.* (2009) tanımlama oranı ve hesaplama süresi bakımından SIFT özniteliğinden daha iyi performans gösteren SURF özniteliğini önermişlerdir.

2.4. Kelime Torbası

Görüntü gösteriminin literatürdeki en basit ve etkili metotlarından biri kelime torbası ya da öznitelik torbası olarak bilinmektedir. Bu metot görüntü sınıflandırmada görüntüye sınıf etiketi atamak için kullanılmaktadır. BOW eğitim ve test aşamalarını içeren öğrenmeye dayalı bir metottur. Bu metotta, tüm tanımlayıcılar kümelerine bölünmektedir.

Tanımlayıcılar, küme merkezlerine olan uzaklığa bağlı olarak atanmaktadır. Her küme merkezi görsel kelime ve bu görsel kelimelerden oluşan set ise sözlük olarak adlandırılmaktadır. Öznitelikler, bu küme merkezlerine olan uzaklığa bağlı olarak atanmaktadır. Histogram ise kümelere atanan tanımlayıcıların sayısı ile oluşturulmaktadır.

Muja and Lowe (2009), yaklaşık en yakın komşular için hızlı kitaplık (Fast Library for Approximate Nearest Neighbors (FLANN)) uygulamasını yüksek boyutlu uzaylarda en yakın komşu eşleştirmesi için geliştirmişlerdir. FLANN eşleştirme için en uygun metodu ve parametre değerlerini seçebilmektedir. Sadece istenilen hassaslık derecesi verilen öznitelik uzayı için gerekli olmaktadır. FLANN için hiyerarşik k-ortalamları ağacı ve çoklu rastgele kd-ağaçlarını kullanmışlardır.

Kelime Torbası, PASCAL VOC 2006 (Everingham *et al.* 2006) testinin teknik raporuna göre eşleme tabanlı sınıflandırıcısı (Marszaek and Schmid 2006) ve grafik sinir ağı sınıflandırıcısı (Winn *et al.* 2005) gibi diğer sınıflandırma metotlarına göre daha yüksek doğruluk oranı sağlamıştır.

2.5. Sınıflandırıcı

Sınıflandırıcı, eğitim sırasında sınıfları, verilen sınıf etiketleri ile ayırt etmektedir. Destek vektör makinaları (DVM) (Cortes and Vapnik 1995), bilgisayarla görmede ikili sınıflandırma için iyi bilinen denetimli öğrenim modellerinden birisidir. Verinin doğrusal olarak ayıramadığı durumlarda maksimum-kenarlı hiper düzlemi oluşturmak için çekirdek hilesi uygulanmaktadır. Her bir skaler çarpım, doğrusal olmayan çekirdek fonksiyonuyla değiştirilmektedir.

Destek Vektör Makinalarının doğru tanıma oranı, kullanılan çekirdek parametrelerine bağlı olarak değişmektedir. Gaus radyal temelli fonksiyon (Gaussian radial basis function (RBF)) C ve γ olmak üzere iki parametreden oluşmaktadır. Parametreler verilen aralıkta belirlenip, çapraz doğrulama kullanılarak kontrol edilmektedir. Eğitim

görüntüleri rastgele olarak eşit boyutlu k veri setine bölünmektedir. Her veri seti, diğer veri setlerini doğrulamak için kullanılmaktadır. Doğrulama, her bir veri seti doğrulama verisi olarak kullanılabilece kadar k kez tekrar etmektedir. Son olarak, en yüksek çapraz doğrulama kesinliğine sahip parametreler seçilmektedir.

Csurka *et al.* (2004) , kilit nokta torbasını kullanarak görüntü sınıflandırma için yeni bir metod önermişlerdir. Aynı zamanda DVM'nin, Naive Bayes sınıflandırıcısından daha üstün olduğunu ve doğrusal DVM'nin karesel ve kübik DVM ile karşılaştırıldığında en iyi performansı sergilediğini göstermişlerdir.

Mei *et al.* (2009) gen ekspresyonu verilerinin çoklu sınıflandırılması için verimli bir hibritleştirilmiş k -en yakın komşu (KNN) sınıflandırıcısını ve DVM sınıflandırıcısını önermişlerdir. Araştırmalarında, KNN algoritması ile eğitim verilerini kısaltmış (prunes) ve örnekleri sınıflandırmak için DVM ile birleştirmişlerdir. DVM ve KNN ile kıyaslandığında hibritleştirilmiş k -en yakın komşu (KNN) sınıflandırıcısını ve DVM sınıflandırıcısının sınıflandırma performansının, yanlış sınıflandırma oranının oldukça düşük olduğu tespit edilmiştir.

2.6. Özet

Bu ünite ilk olarak literatürdeki dengesiz veri seti problemi ile ilgili bilgiler verilmiştir. İkinci olarak gerçekleştirilen otomatik trafik işareti tanıma çalışmaları açıklanmıştır. Sonra önerilen TSR sisteminin işlem adımları (öznitelik çıkarımı, kelimelerin torbası, sınıflandırma) açıklanıp kısaca literatür bilgisi verilmiştir.


3. MATERYAL ve YÖNTEM

Bu çalışmanın amacı, dengesiz veri seti üzerinde yerel öznitelikler kullanarak trafik işaretleri otomatik tanıma (traffic sign recognition (TSR)) sistemine yönelik sınıflandırma performansını artırmak için yeni bir öneri geliştirmektir. Araştırma, iki ana konu üzerinde temellendirilerek gerçekleştirilmiştir. Ele alınan ilk konu, çevresel etmenlerden renk yönünden farklı olan trafik işaretlerinin sınıflandırılmasında, ilgili nokta tanımlayıcılarının (interest point detector) avantajlarından faydalanılması için yerel özniteliklerin kullanılmasıdır. Ele alınan ikinci konu ise; dengesiz veri setinin yerel özniteliklerle birlikte kullanıldığı uygulamalar üzerindeki etkisini belirlemektir.

İlk konuda bahsedilen ilgili nokta tanımlayıcıları: Görüntüde bulunan bölgeleri, belirgin veya ilgisiz veri olmasına göre düzenleyerek algılanmasına olanak sağlamaktadır. Bu sayede verilen görüntüde belirgin bölgelere odaklanılarak tüm görüntünün incelenmesine gerek kalmamaktadır. Fakat ilgili nokta temelli yöntem kullanan yerel özniteliklerin kullanıldığı uygulamalarda, klasik makine sınıflandırıcıları (KNN, DVM) dengesiz veri seti üzerinde uygun öğrenme görevini yerine getirememektedir (Kotsiantis *et al.* 2006). Çünkü dengesiz veri setlerinde bir sınıfın örnek sayısı, diğer sınıfların örnek sayılarından çok daha büyüktür. Bu nedenle klasik makine sınıflandırıcıları azınlık sınıflarını göz ardı ederek çok örnekli sınıfa doğru eğilimli olurlar. Bu sorun için algoritma ve veri seviyesinde birçok çözüm hedeflenmiştir (Barandela *et al.* 2003; Wang and Yao 2009; Hido *et al.* 2009). Veri seviyesinde, farklı çözümler için yeni örnekleme formları (yetersiz örnekleme, yüksek hızda örnekleme gibi) vardır. Algoritma düzeyinde çözümler ise ağaç yaprağı olasılık tahminini ayarlama, karar ağaçları eşik değeri ayarlama gibi çeşitli değerlerin ayarlanmasını içermektedir.


Bu çalışmada, temel iki adımda farklı tekniklerle çalışılmış olup en yüksek sınıflandırma performansı için en uygun algoritmanın gerçekleştirilmesi hedeflenmiştir. Araştırmada önerilen TSR sistemi, öznitelik çıkarımı ve sınıflandırma olmak üzere iki bölümden oluşmaktadır. Hedeflenen sisteminin genel çalışma prensibini gösteren akış diyagramı ise Şekil 3.1’de sunulmuştur. İlk olarak, eğitim veri setinde bulunan girdi

görüntülerinden öznitelikler çıkartılıp sınıflandırıcı eğitilmektedir. Daha sonra test görüntülerinden elde edilen öznitelik vektörleri ile test görüntüsü sınıflandırılmaktadır.



Şekil 3.1. Sistemin işlem adımlarının belirtildiği akış diyagramı

Önerilen sistemin ilk adımında SIFT ve SURF tanımlayıcılarından elde edilen SIFT+SURF özniteliği, SIFT ile elenen SURF özniteliği (SSURF) ve SURF ile elenen SIFT(SSIFT) özniteliği olmak üzere üç öznitelik kullanılmıştır. İkinci adımında ise dengesiz veri seti probleminin çözümü için bir topluluk metodu olan torbalama temelli topluluk (TTT) sınıflandırıcısı kullanılmıştır. Çalışmada kullanılan özniteliklerin performansı, TSR problemlerinde temelde kullanılan ve kullanıldığı bu çalışmalarda başarılı sonuçlar elde edilen yönlü eğimlerin histogramı (HOG) özniteliği ile karşılaştırılmıştır (Mathias *et al.* 2013). Önerilen sınıflandırıcının performansı ise temel makine sınıflandırıcıları olan destek vektör makineleri (DVM), karar ağaçları (KA) ve k en yakın komşu (KNN) sınıflandırıcılarının performansları ile karşılaştırılmıştır. Yapılan çalışmalar Şekil 3.2’de gösterilmiştir. Çalışmanın adımları ayrıntılı olarak aşağıda anlatılmıştır.



Şekil 3.2. Gerçekleştirilen deneysel çalışmaların akış diyagramı

3.1. Öznelik çıkarımı

İlk adımda görüntü, öznelik örneklerinin belirlenmesi için piksel dizilerine dönüştürülmektedir. Bu dizilerin her biri tek piksele ya da piksel grubuna göre çok daha fazla bilgi içermektedir. Öznelik seçimi veri türüne bağlıdır. Burada amaç; görüntünün üzerine yayılmış belirgin ve önemli özneliklerin çıkarılmasıdır. Bu belirgin özellikler ilgili nokta ya da diğer adıyla kilit nokta (keypoints) olarak adlandırılmaktadır. Kilit noktalar, temelde köşe çizgi ve lekelenme (çevresinden daha karanlık veya aydınlık olan

bölge ya da nokta) gibi daha fazla bilgi içeren ayırt edici bölgelere yerleştirilmektedir. Ayrıca işlemler tespit edilen öznitelikler kullanılarak yapıldığından, veri azaltarak hesaplama maliyeti düşürülmektedir.



Şekil 3.3. İlgili nokta tanımlayıcısının ve özelliklerinin örnekleri (Juan and Gwun 2009).

Bu çalışmada SIFT, SURF ve HOG öznitelikleri kullanılmıştır. HOG özniteliği plaka tanımlama, araç tanıma gibi farklı sistemlerde kullanılan küresel bir özniteliktir. Eğim yönlerine bakarak bir öznitelik vektörü oluşturur. SIFT özniteliği ile çevresel faktörlere göre değişmeyen öznitelik vektörleri çıkartılmaktadır. Bu öznitelik, nesne tanımlama ve karşılaştırma uygulamalarında sıklıkla kullanılmaktadır. SURF, ilgili nokta etrafında bilgiye dayalı değişmez ve tekrarlanabilir yönelimleri tanımlar. SIFT ile karşılaştırıldığında, ışık değişimine daha az duyarlıdır. Fakat SIFT özniteliğinden daha hızlıdır (Juan and Gwun 2009).

SURF ve SIFT ilgi nokta temelli yerel özniteliklerdir. Bu yöntemlerde, sadece görüntüde bulunan belirgin bölgelere odaklanılarak öznitelik vektörleri çıkartılmaktadır. Bu sayede tüm görüntünün işlenmesi gerekmediği için işlem hesaplama maliyeti düşmektedir. Fakat bu tanımlayıcılar verilen her görüntüde farklı sayıda ilgili nokta çıkartmaktadır. Dolayısıyla sınıflandırma adımında yalnızca eşleştirme algoritması ile kullanılmaktadır. Eşleştirme algoritmasından daha başarılı olan klasik makine sınıflandırıcıları (KNN, DVM vb.) ile bu tanımlayıcıların kullanılabilmesi için tüm görüntü öznitelik vektörlerinin boyutu eşit olmalıdır. Bu tanımlayıcılardan eşit sayıda görüntü özniteliklerinin elde edilebilmesi için ise kelimelerin torbası yönteminin (BoW) kullanılması gerekmektedir. BoW yönteminde tüm tanımlayıcı vektörleri belirlenen

sayıda kümeye bölünür ve küme merkezleri sözlük diye adlandırılır. Böylece tüm özniteliklerin kendilerine ait sözlükleri oluşmaktadır.

Aşağıda bu çalışmada kullanılan öznitelikler detaylı bir şekilde sırasıyla açıklanmıştır.

3.1.1. Ölçeklemeden bağımsız öznitelik dönüşümü (SIFT)

SIFT (Scale-invariant Feature Transform); ölçeklemeden bağımsız öznitelik dönüşümü, görüntülerden belli özellikleri tespit etmek için kullanılan bilgisayarla görme algoritmalarından birisidir. Bu öznitelik ölçek, rotasyon ve çeviri farklılıklarına karşı değişmez olan belirli öznitelikleri saptamaktadır. Aşağıda SIFT özniteliği hesaplamasının başlıca adımları belirtilmiştir.

- Uzak ölçekli ekstremumları belirleme
- Kilit noktanın yerini belirleme
- Yönelim atama
- Kilit nokta tanımlayıcısı belirleme


3.1.1.a. Uzak ölçekli ekstremumların belirlenmesi

SIFT özniteliğinde, ölçek uzayındaki değişmez kilit noktalarının konumlarını tespit etmek için yakın iki ölçeğin farkından hesaplanan Gauss Farkı (difference of Gaussian (DoG)) fonksiyonu kullanılmaktadır. Bu ölçekler, belirlenen bir katsayı (k) ile birbirlerinden ayrılmışlardır. Ölçek uzayı ise verilen görüntünün, $I(x,y)$ ve Gauss fonksiyonunun, $G(x,y,\sigma)$ konvolüsyonu ile hesaplanmaktadır.

$$D(x,y,\sigma) = (G(x,y,k\sigma) - G(x,y,\sigma)) * I(x,y)$$


Gauss piramidinden elde edilen Gauss Farkı fonksiyonunun hesaplanması Şekil 3.4'de gösterilmiştir. Şeklin sol sütununda giriş görüntüsü, farklı Gauss ölçekleri tarafından

piramit haline getirilmiştir. Yakın görüntü ölçekleri, Şekil 3.4'ün sağ sütununda gösterilen DoG görüntülerinin hesaplanması için birbirinden çıkartılmaktadır.



Şekil 3.4. Gauss Piramidinden DoG Hesaplanması (Lowe 2003).

DoG görüntüleri hesaplandığında yerel minimum ve maksimum değerler belirlenmektedir. Şekil 3.5'de gösterildiği gibi ölçek uzayında her bir piksel 26 komşuya sahiptir. Her bir piksel 26 komşusuyla karşılaştırılır; hepsinden büyük ya da hepsinden küçük ise yerel minimum ya da maksimum değer olarak seçilir.



Şekil 3.5. DoG Görüntüsünde Minimum ve Maksimum Değerlerin Tespiti (Lowe 2003).

3.1.1.b. Kilit noktanın yerini belirleme

Kilit noktalar, yönlendirmeye sahip olan dairesel bir görüntü bölgesidir. Potansiyel kilit noktalar, ölçek uzayında piksellerin komşularıyla kıyaslandığı görüntüde bulunabilir. Bu bilgi ile düşük kontrastlı noktalar elimine edilmektedir. Ayrıca, kenarlarda bulunan kilit noktaların kaldırılması gerekebilir. Çünkü kenar noktalar, konumları tam olarak tespit edilemediği için yetersiz kilit noktalardır.

3.1.1.c. Yönelim atama

Bu adımda, her bir kilit noktanın baskın yönelimi hesaplanmaktadır. Her bir kilit nokta için eğim boyutu, $m(x,y)$ ve yönelimi, $\theta(x,y)$ mevcut $L(x,y)$ ölçeği için piksel farkları kullanılarak hesaplanmaktadır:

$$m(x,y) = \sqrt{(L(x+1,y) - L(x-1,y))^2 + (L(x,y+1) - L(x,y-1))^2}$$


$$\theta(x,y) = \tan^{-1}((L(x+1,y) - L(x-1,y))/(L(x,y+1) - L(x,y-1)))$$

Yönelim histogramı, kilit noktaların etrafındaki bölgelerde eğim yönelimi kullanılarak oluşturulmaktadır. Bu histogram, 360 derecelik yönelimleri, 10 derecelik bölgelere ayıran 36 bölümü içermektedir. Her bir örnek, histograma eklenmeden önce eğim büyüklüğüyle ölçülmektedir. Histogramdaki yüksek uçlar, kilit noktanın yönelimi olarak seçilmektedir. Fakat en yüksek ucun %80'i büyüklüğünde başka yerel uçlar tespit edilir ise bu yönelim ile yeni bir kilit nokta oluşturulmaktadır.

3.1.1.d. Kilit nokta tanımlayıcısı

Son adımda, üç boyutlu görüş noktasından ve aydınlatmadaki değişikliklerden etkilenmeyen ve ölçeğe karşı değişmez olan bir bölgesel görüntü tanımlayıcısı oluşturulmaktadır.

Şekil 3.6'da, kilit nokta tanımlayıcılarının nasıl hesaplandığı gösterilmektedir. Kilit nokta etrafındaki bölgelerden, eğim büyüklükleri ve yönelimler hesaplanmaktadır. Eğim büyüklükleri, kilit nokta bölgesinin merkezindeki Gauss'la ağırlandırılmaktadır. Tipik bir uygulamada, pencere 4x4 olmak üzere 16 alt bölgeye bölünür ve her bir alt bölge için bir yönelim histogramı oluşturulur. Tanımlayıcının koordinatları ve eğim doğrusu, doğrunun değişmezliğinin koruması amacıyla kilit noktanın yönelimine yakın olarak konumlandırılmaktadır. 16x16 örnek dizisinden hesaplanan bu 4x4 tanımlayıcılar, toplam 128 boyutludur.



Şekil 3.6. Kilit Nokta Tanımlayıcıların Oluşturulması (Lowe 2003)

3.1.1. Hızlandırılmış gürbüz özneliği (SURF)

SURF (Speed-up Robust Feature); hızlandırılmış gürbüz özneliği, Bay *et al.* (2009) tarafından rotasyondan bağımsız detektör ve tanımlayıcı olarak geliştirilmiş bir yöntemdir. Araştırmalarında, bu tanımlayıcının daha önce önerilen projelerin tekrarlanabilirliğine, farklılığına ve dayanıklılığına göre daha üstün olduğunu ve daha az sayısal zamana ihtiyaç duyduğunu iddia etmişlerdir. SURF tanımlayıcısı, ilgi noktasının tespiti ve ilgi noktası tanımlayıcısının hesaplanması olmak üzere iki temel aşamaya ayrılmıştır. Bu aşamalar aşağıda detaylı olarak anlatılmıştır.

3.1.1.a. İlgi noktası tespiti

SURF özneteliğinde ilgi noktası tespiti, Hessian matrisinin gelişmiş modeli olan Hızlı – Hessian matrisi ile hesaplanmaktadır. Hızlı – Hessian matrisi, hesaplama maliyetini düşürmek için integral görüntülerini $I_{\Sigma}x$, kullanmaktadır. İntegral görüntüsü, $x = (x, y)^T$ konumunda bulunan I giriş görüntüsü içerisindeki merkez ve x tarafından oluşturulan dikdörtgen bir bölgedeki bütün piksellerin toplamı ile hesaplanmaktadır.

$$I_{\Sigma}x = \sum_{i=0}^{i < x} \sum_{j=0}^{j < y} I(i, j)$$

I integral görüntüsünde verilen bir $x = (x, y)$ noktasında ve σ ölçeğinde Hızlı – Hessian matrisi, $H(x, \sigma)$ aşağıdaki gibi hesaplanmaktadır.

$$H(x, \sigma) = \begin{bmatrix} L_{xx}(x, \sigma) & L_{xy}(x, \sigma) \\ L_{xy}(x, \sigma) & L_{yy}(x, \sigma) \end{bmatrix}$$

Görüntünün x noktasındaki gauss ikinci dereceden türevinin konvolüsyonu $L_{xx}(x, \sigma)$ şeklinde gösterilmektedir. Benzer şekilde $L_{xy}(x, \sigma)$, $L_{yy}(x, \sigma)$ Gauss ikinci dereceden türevi temsil etmektedir.

İlgi noktalarının farklı ölçeklerde bulunması gerekmektedir. Ölçek uzayı hesaplanmasındaki temel yol, görüntü piramidinin hesaplanmasıdır. Görüntüler, Gauss ile tekrar tekrar yumuşatılır ve daha sonra piramidin daha yüksek seviyesine ulaşabilmek için alt örneklenir. SURF tanımlayıcısının ölçek uzayı ise filtre boyutunun üst ölçeklenmesi ile hesaplanır. Böylece görüntü boyutu değişmemiş olur. Ölçek uzayı, oktavlara ayrılmıştır. Bir oktav, aynı giriş görüntüsünü artan bir filtre boyutuyla konvol edilerek elde edilen bir dizi filtre yanıt haritalarını gösterir. Her oktav, ölçek seviyelerinin değişmez sayısına bölünür. Ölçekler üzerindeki ilgi noktalarını yerleştirmek için Hessian matrisinin determinantının en uç noktaları tespit edilmektedir.

$$\det(H_{\text{approx}}) = D_{xx} D_{yy} - (wD_{xy})^2$$

ikinci dereceden gauss kısmi türevi D_{xx}, D_{yy}, D_{xy} ve w ise yaklaşık Hessian determinantı için ifadeyi dengelemekte kullanılan filtre cevaplarının ağırlığıdır.

3.1.1.b. İlgi noktası tanımlayıcısı

SURF tanımlayıcısı (Bay *et al.* 2009); ilgi noktası komşuları içindeki yoğunluk içeriğinin dağılımını açıklamaktadır. İlgi noktası tanımlayıcısının hesaplanabilmesi için iki işlem adımının gerçekleştirilmesi gerekmektedir. Bu adımlar yönelim atama ve tanımlayıcının oluşturulmasıdır.


Yönelimin atanması için; x ve y yönündeki Haar dalgacık cevapları (wavelet responses) kullanılmaktadır. Haar dalgacık cevapları ilgi noktası etrafındaki $6s$ yarıçapına sahip yuvarlak komşularından hesaplanmaktadır (Şekil 3.7). Buradaki s ilgi noktasının tespit edildiği ölçeği göstermektedir.



Şekil 3.7. Haar dalga filtrelerinin x ve y yönündeki cevapları (Bay *et al.* 2009)


Dalgacık cevapları hesaplandıktan sonra öznitelik noktasındaki Gauss merkezi ile ağırlandırılmaktadır. Apsis boyunca hesaplanan güçlü yatay cevaplar ve ordinat boyunca hesaplanan güçlü dikey cevaplar uzay içerisinde nokta olarak gösterilmektedir. Baskın yönelim, yatay ve dikey yönde $\frac{\pi}{3}$ boyutundaki kayan yönlenme penceresi içerisindeki tüm yanıtların toplamı hesaplanarak bulunur. Toplanmış bu iki yanıt yerel bir yönlendirme vektörü olarak hesaplanmaktadır. Öznitelik noktasının yönelimi olarak tüm pencereler arasındaki en uzun vektör seçilmektedir (Bay *et al.* 2009).

Yönelim ataması gerçekleştirildikten sonra, Haar dalgacık cevaplarının toplamıyla tanımlayıcı çıkarılmaktadır. Tanımlayıcının çıkarılması için ilk olarak ilgi noktası etrafında yönelime göre yönlendirilmiş olan bir kare bölge inşa edilir. Karenin kenar boyutu için genel seçim $20s$ 'dir (s bulunan ilgi noktasının ölçeğidir). Bölge daha sonra 4×4 alt kare bölgelere ayrılır. Her bir alt bölge; sırasıyla 5×5 düzenli aralıklı örnek noktalar olarak gösterilmektedir. Dalgacık cevabı, her alt bölgenin içinden hesaplanır (Şekil 3.8). Geometrik bozulmalar ve yerleştirme hataları ile ilgili olarak sağlamlık elde etmek için, x ve y yönündeki dx ve dy yanıtları ağırlandırılmaktadır.



Şekil 3.8. Her karenin 2×2 alt bölümleri tanımlayıcının gerçek alanlarına karşılık gelmektedir (sol). Dalgacık cevaplarının toplamı(sağ) (Bay *et al.* 2009).


Daha sonra x ve y yönündeki d_x ve d_y dalgacık cevapları her alt bölge üzerinde toplanır ve öznitelik vektörü girişlerinin ilk setini oluşturur. Yanıtların mutlak değerleri çıkarılarak $|d_x|$ ve $|d_y|$ (Şekil 3.9); yoğunluk değişiklikleri hakkında bilgi elde edilir. Böylelikle her alt bölge, yatay yöndeki Haar dalga cevaplarının toplamı ve mutlak değeri, düşey yöndeki Haar dalga cevaplarının toplamı ve mutlak değeri olmak üzere 4 boyutlu tanımlama vektörüne sahip olur. Sonuç olarak tanımlayıcı vektörün uzunluğu her 4×4 alt bölge için 64 olur. Aydınlatma değişmezliğini sağlamak için, tanımlayıcı bir birim vektörü ile normalize edilir.



Şekil 3.9. Bir alt bölgenin tanımlayıcı girişlerindeki yoğunluğun doğasını temsil etmektedir. Sol: Homojen bir bölgede olması durumunda, tüm değerler nispeten düşüktür. Orta: x yönünde frekansların varlığında $P|dx|$ yüksek, ama diğerleri düşük kalır (Bay *et al.* 2009).

3.1.2. SURF ile elenen SIFT özneliliği (SSIFT)


SIFT ve SURF tanımlayıcıları elde edildikten sonra her bir SIFT tanımlayıcısının merkez konumları (düşey, x ve yatay, y konumları) SURF tanımlayıcılarının merkez konumları ile karşılaştırılır. Karşılaştırma işlemi gerçekleştirilirken ilk olarak görüntüye ait SURF tanımlayıcılarının x ve y değerlerine belirli bir komşuluk k sayısı eklenip, k sayısı çıkartılarak $x+k$, $x-k$, $y+k$, $y-k$ değerleri elde edilir. Karşılaştırılacak olan SIFT tanımlayıcısının x değeri görüntüden elde edilen herhangi bir SURF tanımlayıcısına ait olan $x+k$, $x-k$ değerlerinin arasında ise ve SIFT tanımlayıcısının y değeri herhangi bir SURF tanımlayıcısına ait olan $y+k$, $y-k$ değerlerinin arasında ise bu SIFT tanımlayıcı elenmez. Eğer SIFT tanımlayıcısının merkez konum değerleri verilen bu değerler arasında bulunmaz ise bu SIFT tanımlayıcısı elenir. Sonuç olarak karşılaştırma işleminin ardından elenmeyen SIFT tanımlayıcıları görüntüden elde edilen SSIFT tanımlayıcısı olarak kullanılır. SSIFT tanımlayıcısının çıkarılması için gerekli olan işlem adımları Şekil 3.10' da gösterilmiştir.



Şekil 3.10. SSIFT tanımlayıcısının elde edilmesi için gerçekleştirilen işlem adımları

3.1.3. SIFT ile elenen SURF özniteliği (SSURF)

SSIFT özniteliğinde olduğu gibi SSURF özniteliğinde de ilk olarak görüntüden SIFT ve SURF tanımlayıcıları çıkartılmaktadır. Şekil 3.11’ de görüldüğü gibi elde edilen her bir SURF tanımlayıcısının merkez konumları (düşey, x ve yatay, y konumları) SIFT tanımlayıcılarının merkez konumları ile karşılaştırılmaktadır. SURF tanımlayıcısının k piksel uzaklığında bir SIFT tanımlayıcısı tespit edilemezse bu SURF tanımlayıcısı elenmektedir. Karşılaştırma sonucu elenmeyen SURF tanımlayıcıları ile SSURF özniteliği elde edilmektedir.



Şekil 3.11 SSURF tanımlayıcısının elde edilmesi için gerçekleştirilen işlem adımları

3.1.4. Kelimelerin torbası yöntemi (BoW)

Kelime Torbası (Bag of Words); literatürde ilk olarak metin sınıflandırılması probleminde kullanılmıştır (Quinlan 1993). BoW modelinde, her metin, kelimelerin düzenine bakılmaksızın kelimelerin yalnızca tekrar etme sayılarının dikkate alındığı bir kelime torbası olarak düşünülür. Torbada yani metinde bulunan kelimelerin tekrar etme sayısına bağlı olarak histogram oluşturulur.

Görüntü sınıflandırmada ise ilgi noktası temelli tanımlayıcıların klasik makine sınıflandırıcıları ile sınıflandırılması için BoW modeli kullanılmaktadır. İlgi noktası temelli tanımlayıcıların her görüntüden farklı sayıda çıkartılmasından dolayı klasik makine sınıflandırıcıları ile kullanılamamaktadır. Çünkü bu sınıflandırıcılara girdi olarak verilecek vektörlerin boyutu aynı olmalıdır. BoW modeli ile bu tanımlayıcılar

kullanılarak her görüntü için eşit sayıda olan öznitelik vektörleri oluşturulur ve bu sayede sınıflandırıcılar ile kullanılmasına olanak verilir.

Görüntü sınıflandırmada BoW modeli kullanılırken görüntüler metin olarak düşünülür. Görüntüleri tanımlamak için kullanılan yerel tanımlayıcılar (local descriptors) ise k kod sözcüğü (codeword) olarak kabul edilir.


İlk adımda SIFT ve SURF tanımlayıcıları kullanılarak bir kod kitabı (codebook) inşa edilir. Tüm görüntülerin içerisindeki noktaların tanımlayıcıları bir kümeleme algoritmasına girdi olarak verilir. Ayrıca kod kitabının boyutuna kümeleme algoritmasının yürütülmesinden önce karar verilmelidir. Kümeleme algoritması, daha önce kullanılan tanımlayıcı ile temsil edilen her kelimenin olduğu kelimelerin koleksiyonunu sağlar. Tanımlayıcıların bu koleksiyonu aynı zamanda veri setinin toplam kelimesini temsil etmektedir.

Kod kitabı oluşturulduktan sonra, kümelerin merkezleri eğitici kod sözcüğü olarak kullanılır. Görüntüde bulunan kod sözcükleri eğitici kod sözcüğüne olan uzaklıklarına göre kümelere atanır. Kümelerde bulunan kod sözcüklerinin tekrar etme sayısına bağlı olarak histogram vektörleri oluşturulur ve böylelikle her görüntü, tanımlayıcı sayısı ile değil küme sayısı ile ifade edilebilir. Eşit boyutta öznitelik vektörüne sahip bu görüntüler bir sınıflandırıcı ile kolayca eğitilebilmektedirler.

3.1.5. Yönlü eğimlerin histogramı (HOG)

Yönlü eğimlerin histogramı (Histogram of oriented gradients); bilgisayar vizyonu ve görüntü işleme alanlarında nesneyi algılamak için kullanılan öznitelik tanımlayıcılardır. Bu öznitelik, görüntünün lokalize bölümlerindeki eğim yönlerine bakarak bir öznitelik tanımlayıcısı oluşturur. Bu yüzden plaka tanıma, araç tanıma, nesne tanıma gibi farklı alanlarda kullanılmıştır (Dalal and Triggs 2005; Sashua *et al.* 2004).

Bu öznitelik, kenar yönelim histogramı (Alefs *et al.* 2007) ve ölçeklemeden bağımsız öznitelik dönüşümü özniteliğine (Lowe 2003; Vapnik 1995) benzerlik göstermektedir. Ancak farklı olarak yoğun bir ızgara üzerinde eşit aralıklı hücrelerden hesaplanır ve sınıflandırma doğruluk oranını artırmak için üst üste gelen yerel kontrast normalizasyonu kullanılır (Dalal and Triggs 2005).



Şekil 3.12. Hog Özniteliği: Soldaki görüntü giriş görüntüsünü, sağdaki görüntü eğim yönelimlerini göstermektedir (Bay *et al.* 2009).

HOG tanımlayıcısı, bir görüntü içerisindeki yerel nesnelerin görünümünü ve şekillerini, yoğunluk eğimlerinin veya kenar eğimlerinin dağılımı ile tarif etmektedir. Bu, görüntünün hücre adı verilen, birbiri ile bağlantılı bölgelere ayrılmasıyla sağlanır. Böylece her hücre içerisindeki pikseller için eğim yönelimlerinin histogramı hesaplanabilir. Bu histogramların kombinasyonu bize bütün görüntü için tanımlayıcı verir. Şekil 3.12’de soldaki görüntü giriş görüntüsünü, sağdaki görüntü ise eğim yönelimlerini göstermektedir. Sınıflandırma doğruluk oranını arttırmak için, yerel histogramlar kontrast – normalize edilir. Bu, blok olarak adlandırılan; görüntünün, büyük bir bölgesi boyunca uzanan yoğunluk ölçümünün hesaplanmasıyla gerçekleştirilir. Bloklar 2x2 hücre gruplarıdır. Hücre grupları ise 4x4 veya 8x8 piksel boyutundadır.

Bir görüntüden HOG özelliğinin çıkarılabilmesi için aşağıdaki işlem adımlarının yapılması gerekmektedir:

- Görüntünün eğimlerinin hesaplanması

- Her hücre için yönlü histogramların oluşturulması
- Hücre bloklarındaki histogramların normalize edilmesi

Aşağıda bu adımlar ayrıntılı olarak anlatılmıştır.

3.1.4.a. Eğim hesaplama

HOG özniteliğinde, normalizasyon yapıldığı için birçok diğer özniteliğin ilk adımında gerçekleştirilen görüntü ön işleme yapılmaz. Bu nedenle HOG özniteliği için ilk adım eğim değerlerinin hesaplanmasıdır. I giriş görüntüsünün x ve y yönündeki G_x ve G_y eğimleri aşağıda gösterilen formüllerle elde edilmektedir.

$$G_x = [-1 \ 0 \ 1] * I$$

$$G_y = [-1 \ 0 \ 1]^T * I$$

Burada $*$ olarak ifade edilen simge iki boyutlu konvolüsyon operatörüdür. Eğimler hesaplandıktan sonra eğim yönelimi aşağıda verilen formül ile hesaplanır

$$\theta = \arctan\left(\frac{G_x}{G_y}\right)$$

3.1.3.b. Yönlü histogramların hesaplanması

İkinci adımda hücre histogramları hesaplanmaktadır. Hücre içerisindeki her piksele yönelim histogramının hesaplanması için ağırlık atanır. Bu hücrelerin şekli, kare veya radyal olabilir. Histogram kanalları ise 0 ile 180 derece arasında veya 0 ile 360 derece arasında yayılmıştır. Her hücre için, yönelim oyları toplanılarak eğim histogramı hesaplanır. Oylar eğim büyüklüğüyle ağırlandırılmıştır. Böylece histogram belirli bir noktadaki eğim önemini dikkate almış olur. Bu, bir kenar etrafındaki eğim yöneliminin

bir yakın homojen olmayan bölgedeki bir noktadan daha önemli olduğu gerçeğini açıklar. Her hücre için histogramlar hesaplandığında, tüm histogramları tek bir vektör içerisinde sıralayarak görüntünün tanımlayıcı vektörü inşa edilir.

3.1.3.c. Blok normalizasyonu

Görüntü içinde aydınlatma varyasyonları ve diğer değişkenlikler nedeniyle, hücre histogramlarının normalize edilmesi gerekir. Hücre histogramları, komşu hücre histogramlarının değerlerine göre yerel olarak normalize edilir. Normalizasyon blok diye adlandırılan hücre grupları arasında yapılır.

Blok üzerinden bir normalizasyon faktörü hesaplanır ve bloklar içerisindeki tüm histogramlar bu normalizasyon faktörüne göre hesaplanır. Bu normalizasyon adımı hesaplandıktan sonra, tüm histogramlar tek öznitelik vektörü olarak birleştirilir.

Bir blok üzerinden farklı normalizasyon şemalarının olması mümkündür. Bu şemalar aşağıda gösterilmiştir.

- L1-Norm: $nf = \frac{v}{(|V| + 1 + \epsilon)}$
- L2-Norm: $\frac{v}{(|V| + 1 + \epsilon)}$

Burada v , bir bloktaki tüm histogramları içeren normalize edilmemiş vektör, $|V|_1$ birinci norm ve ϵ küçük düzenleme sabitidir.

3.2. Sınıflandırıcılar

Bu adımda trafik işaretleri görüntülerinden çıkartılan SIFT, SURF, SSIFT, SSURF, ve HOG öznitelikleri, destek vektör makineleri (DVM), karar ağaçları (KA), k-en yakın komşu (KNN) ve torbalama temelli topluluk (TTT) sınıflandırıcılarına girdi olarak

verilmiştir. Bu beş öznitelik ve dört sınıflandırıcı farklı kombinler ile birleştirilerek 20 farklı deney gerçekleştirilip, doğruluk yüzdeleri karşılaştırılmıştır.

Araştırma kapsamında yapılan çalışmada kullanılan destek vektör makineleri, karar ağaçları, k-en yakın komşu ve torbalama temelli topluluk sınıflandırma algoritmaları sırasıyla aşağıda detaylı olarak verilmiştir.

3.2.1. Destek vektör makineleri

Destek vektör makineleri, aktif öğrenme algoritmaları için temel öğrenici olarak kullanılan öğrenme makineleridir. DVM eğitim verisini maksimum kenar boşluğu (kenar boşluğu hiper düzleme en yakın noktanın mesafesi) ile ayıran hiper düzlemi bulur ve öğrenilen bu hiper düzlemi kullanarak yeni örnekleri sınıflandırır. Azami kenar boşluklu hiper düzlem kullanımının temeli yapısal risk minimizasyonuna (Rudnický *et al.* 1988) dayalıdır.

DVM ile doğrusal olarak ayıramayan örnek uzayı, doğrusal olarak ayrılabilceğı farklı örnek uzayına aktarılmaktadır. Doğrusal olarak ayrılabilen örnek uzayları için maksimum sınırının hesaplanması oldukça basittir. Fakat gerçek yaşamda karşılaşılan problemlerin geneli farklı etmenlerden oluşmakta ve doğrusal olarak ayıramamaktadır. Aşağıda DVM çeşitleri belirtilmiştir.

3.2.1.a. Doğrusal destek vektör makineleri

Doğrusal DVM' ler, verilerin doğrusal olarak ayrılabilme ya da ayıramama durumuna göre ikiye ayrılmaktadır. Verilerin doğrusal olarak ayrılabilceğı örnek uzayında sınıfları birbirinden ayıran birden fazla karar düzlemi bulunmaktadır. Destek vektör makineleri bu sınıflar arasındaki mesafeyi en büyük yapan karar düzlemini seçip, bu düzleme yakın vektörleri ise destek vektörleri olarak atamaktadır. Bazı örnek uzaylarının hatasız olarak ayrılması mümkün olmayabilir. Bu durumda, eğitim hatasının sapması kullanılmaktadır.

3.2.1.b. Doğrusal olamayan destek vektör makineleri

Doğrusal olarak ayırlamayan örnek uzayı problemlerinde, çekirdek fonksiyonları kullanılarak örnek uzayı doğrusal olarak ayrılabilceği daha yüksek boyutlu bir uzaya taşınarak çözüm aranmaktadır

3.2.2. Karar ağaçları

Quinlan (1993) tarafından geliştirilen karar ağaçları sınıflandırıcısı, yaygın olarak kullanılan bir makine öğrenme tekniğidir. Bir karar ağacı, karar düğümü ve yaprak düğümlerinden oluşmaktadır. Her karar düğümü giriş görüntüsü, I üzerindeki özniteliğe karşılık gelir. Bu düğümlerin birden çok dalı vardır. Her bir yaprak düğümü ise mevcut sınıflandırma tahminini göstermektedir.

Karar ağacı oluşturma işlemi, basitçe böl ve yönet işlemidir. Eğitim veri seti, S içerisinde bir sınıf var ise S yaprak olmaktadır. Eğer S hiçbir durumu içermiyorsa, S yapraklır ve bu yaprakla ilişkilendiren sınıf, üst düğümün ana sınıfı ile birleştirilir. Eğer S birden fazla sınıfa sahip ise giriş görüntüsünün özniteliklerine bağlı olarak S alt gruplara bölünür ($S_1, S_2, \dots, S_n$). Karar ağacı oluşturmada bu işlem her bir alt grup tek bir sınıfa ait olana kadar tekrarlanır.

Buradaki problem, karar ağacı oluşumu süresince her bir karar düğümü için en uygun özniteliği nasıl seçileceğidir. Kullanılan kriterlerden birisi, kazanç oranı kriteridir (gain ratio criterion). Bu kriterin temel fikri, her ayırıştırma aşamasında normalleştirmeye yanlılığı azaltırken, maksimum bilgi kazancını sağlayan özniteliği seçmektir.

Karar ağacı bir kez oluştuktan sonra, eğitim verisi ile aynı özniteliklere sahip test verilerini sınıflandırmak için kullanılabilir. Karar ağacının kök düğümünden başlayarak test görüntüsünün öznitelikleri, eğitim veri setinde olduğu gibi test görüntüsünün öznitelikleri için gerçekleştirilir. Karar işlemi test edilen özniteliğin değeriyle uyan

durumdaki dalı seçerek gerçekleştirilir. Aynı işlem yaprak düğüme ulaşılan kadar sürekli tekrarlanır.

3.2.3. K- en yakın komşu algoritması

Makine öğrenme teknikleri içerisinde en basit sınıflandırıcılarından birisidir. Test örneğinin en yakın komşusu belirlenir ve bu komşular sorgulanan sınıfı belirlemek için kullanılır.

En yakın komşu algoritmasında, test örnekleri yakın komşularının sınıfları temel alınarak sınıflandırılır. Bu teknikle genellikle birden fazla komşu dikkate alınır. Bu yüzden k, en yakın komşu sınıflandırıcısı diye adlandırılır. Burada bahsedilen k, sınıflandırma aşamasında dikkate alınan örneklerin sayısını göstermektedir. Çalışma zamanında eğitim örneklerinin bellekte bulunması gerektiğinden bellek tabanlı sınıflandırma diye de adlandırılabilir. Ayrıca direk olarak eğitim örnekleri ile ilgili olduğundan örnek-tabanlı sınıflandırma olarak da adlandırılır.

K en yakın komşu algoritması, iki adımdan oluşmaktadır. Bu adımlar; en yakın komşuya karar verme ve bu komşuları kullanarak sınıflandırma işlemi yapmaktır. Test örneği seçilen komşuların ait olduğu sınıflar içerisinde en çok örneğin ait olduğu sınıfa atanmaktadır.

Bilinmeyen bir I örneğinin eğitim örneği, x_i arasındaki uzaklık aşağıdaki formülle hesaplanır.

$$d(I, x_i) = \sum_{f \in F} w_f \delta(I_f, x_{if})$$

Buradaki d eğitim veri setini, F öznelikleri göstermektedir.


3.2.4. Topluluk öğrenmesi (Ensemble Learning)

Tek katmanlı klasik makine sınıflandırıcılar (DVM, KNN, KA vb.), dengesiz veri setlerinde örnek sayısı az olan sınıfları göz ardı etmektedir. Bu nedenle, doğru sınıflandırma performansları düşük çıkmaktadır. Topluluk öğrenmesi, dengesiz veri problemini, karar ağaçları gibi temel makine öğrenmesi modellerinden oluşan birden çok baz modelin kombinasyonunu yaparak çözmektedir.

Bir sınıflandırma probleminde örnek, topluluğun baz modellerine sunulur ve bu modellerin çıktıları çeşitli şekillerde birleştirilerek topluluk tahmini olarak sınıflandırılır. Öğrenme problemindeki amaç Şekil 3.13'te gösterildiği gibi yıldız ('*') ve üçgen ('Δ') örnekleri ayırmaktır.

Şekil 3.13'de üç doğrusal sınıflandırıcı topluluk gösterilmiştir. C doğrusu altındaki örnekleri üçgen, üstündeki örnekleri ise yıldız olarak sınıflandırmıştır. Unutulmamalıdır ki; bu üç doğrunun hiçbirisi yıldız ve üçgen örneklerini mükemmel ayıramamıştır. Hiçbir düz çizgi; üçgen örnekleri, yıldız örneklerinden ayıramaz. Buna rağmen her doğru oy kullandığı üç doğrunun topluluğunu ve tüm örnekleri doğru sınıflandırabilir. Her örnek en az üç çizginin ikisi tarafından doğru sınıflandırılmıştır; Böylelikle çoğunluk genellikle doğru sınıflandırmıştır. Bu performans artışı topluluğun birbirinden oldukça farklı 3 doğrusal sınıflandırıcıya sahip olmasından kaynaklanmaktadır.

Bu örnek yüksek hata korelasyonu olmayan baz modellerine neden ihtiyaç duyulduğunu açıkça göstermektedir. Eğer tüm doğrusal sınıflandırıcılar aynı örnekte hata yapsalardı (örneğin tüm topluluk A doğrusunun kopyasını içerseydi) , sınıflandırıcıların çoğunluk oyu da aynı örneği yanlış sınıflandıracağından performans artışı sağlanamazdı. Topluluk modellerinin daha üstün performanslı olmasının bir diğer açıklaması ise tek bazlı model sınıflandırıcılarından daha fazla ifade gücüne sahip olmalarıdır. Şekilde gösterilen topluluk yıldız ve üçgen örnekleri mükemmel ayıran doğrusal sınıflandırıcıların (koyu çizgi) bir parçasıdır.



Şekil 3.13. A,B ve C doğrusal sınıflandırıcılarıdır. Kalın çizgi ise bu baz sınıflandırıcının çoğunluk oyu ile örneği sınıflandıran topluluktur (Şekil Perez and Javidi 2002'den uyarlanmıştır.)

Topluluk öğrenmesi yanlılık (bias) ve varyans terimleri ile ilgilidir. Baz modellerinin azalması ile korelasyon hatası yapılır. Hatanın korelasyonu, baz modeli azaltılarak ve topluluk hatasının varyansı azaltılarak yapılır

3.2.4.a. Topluluk öğrenme algoritması

Baz modellerinin, giriş uzayının farklı parçaları üzerindeki tüm örnekleri doğru sınıflandırması veya yanlış sınıflandırması beklenmez. Fakat birçok algoritma mümkün olduğunca farklı hatalar yapan baz modellerinin havuzunu üretme girişiminde bulunurlar.

Bu algoritmalara örnek olarak torbalama (Breiman 1996), yükseltgeme (boosting) (Freund and Schapire 1996) ve çapraz-geçerlilik bölümlenmesi (Krogh and Vedelsby 1995; Turner and Ghosh 1996) verilebilir. Bu modeller her bir baz modeli, farklı ağırlık dağılımı veya farklı eğitim alt kümesi ile sunarak çeşitliliği artırır. Hata-düzeltilme çıkış kodları her bir baz modelini aynı eğitim girdilerine farklı etiket vererek sunar. Algoritma rastgele etiket bölümlenme yaparak iki yeni etiketli yapı inşa eder. Yeni etiketli eğitim verileri baz modelini eğitmek için kullanılır. Giriş örneği seyreltme (Oza and Turner 1999; Oza ve Turner 2001) ve Stokastik Nitelik Seçici Kurullar (SASC) (Zheng and Webb 1998) her bir baz modelini giriş özneliklerinin farklı alt kümeleri ile

sunarak çeşitliliği artırır. SASC her bir baz modelini (baz modellerinin sayısı elle belirlenir) öz niteliklerin rastgele alt kümeleri ile sunmaktadır. Giriş örneklerini seyreltme bir çok baz modeli kullanır. Her baz modelinin karşılık gelen sınıfın varlığı ve yokluğu ile maksimum korelasyona sahip öz nitelik alt kümelerini kullanan sınıfları vardır. Ancak SASC ve giriş örneklerini seyreltme tüm eğitim örüntülerini baz modellerini eğitirken eşit ağırlandırır.

Yukarıda baz modellerinin eğitilme yöntemleri anlatılmıştır. Bu metotların baz modellerinin birleştirilme yöntemlerini de ele alırsak çoğunluk oyu, en temel birleştirme yöntemlerinden birisidir ve torbalamada en çok kullanılan yöntemdir. Eğer sınıflandırıcıların olasılık değerleri belirlenirse, basit ortalama çok ilgi alan ve etkili olan birleştirme yöntemidir (Lincoln and Skryzpek 1990). Ağırlıklı ortalama önerilmiş ve sınıflandırıcıların ağırlıklarının hesaplanması için farklı yöntemler incelenmiştir (Lincoln and Skryzpek 1990; Hashem and Schmeiser 1993; Benediktsson *et al.* 1994). Yükseltgeme (Boosting) ağırlıklı ortalama metodunu kullanır. Baz modellerinin ağırlıkları sınıflandırma doğruluğu ile orantılıdır. Şimdiye kadar açıklanan teknikler matematiksel olarak derinlemesine analiz edilen doğrusal birleştirme teknikleridir (Hashem and Schmeiser 1993; Perrone and Cooper 1992; Breiman 1996; Turner and Ghosh 1996). Ayrıca sıralama temelli birleştirme (Al – Ghoneim *et al.* 1995; Ho *et al.* 1994), inanç temelli metot (belief-based methods) (Xu *et al.* 1992; Rogova 1994; Yang and Singh 1994) ve diğer istatistik birleştiricileri kapsayan doğrusal olmayan topluluk teknikleri vardır (Turner and Ghosh 1998). Araştırma kapsamında yapılan çalışmada kullanılan topluluk modeli olan torbalama temelli topluluk bir sonraki adımda açıklanmıştır.

3.2.4.b. Torbalama temelli topluluk sınıflandırıcısı

Torbalama (bootstrap), orijinal eğitim setinden çok sayıda torbalama eğitim kümelerini oluşturur ve her birini topluluğa eklenmek üzere sınıflandırıcı oluşturmak için kullanır. Eğitim setinden N boyutlu bir torbalama eğitim setini oluşturmak için N tane multinomial deney gerçekleştirilir. Her deneyde N örneklerinden bir tanesi çekilir.

Örneklerin deneylerde çekilme olasılığı her deney için $1/N$ olur. Şekil 3.14'te gösterilen ikinci algoritmada seçilen r tane sayıdan N sayısına kadar bu işlem tekrarlanır ve r inci eğitim örneği torbalama, S eğitim setine eklenir. Orijinal eğitim setindeki örneklerden bazıları torbalama eğitim setine katılmak için seçilmezken diğerleri bir ya da daha çok kez seçilebilir. Torbalama için kullanılan algoritma Şekil 3.14'te gösterilmiştir.

Torbalama(T, M)

Her $m = 1, 2 \dots M$.

$T_m = \text{Örnek_Değiştirme}(T, N)$

$h_m = L_b T_m$

Döndür $h_{\text{sonuncu}}(x) = \text{argmax}_{y \in Y} \sum_{m=1}^M I(h_m(x) = y)$

Örnek_Değiştirme(T, N)

$S = \emptyset$

Her $i = 1, 2 \dots N$


$r = \text{rasgele}_{\text{tamsayı}}(1, N)$

$T(r)'$ yi S' e ekle

Döndür S

Şekil 3.14. Torbalama algoritması

Torbalama temelli topluluk öğrenmesinde S torbalama eğitim setleri üretilir ve bunlar kullanılarak sınıflandırıcılar oluşturulur. Torbalama baz modellerini, $C(x)$ kullanarak yeni örnekleri sınıflandırır. Baz modelleri ($C_1, C_2 \dots C_m$) tarafından en çok oy alan y sınıfı, sonuç olarak döndürülür. Bu çalışmada sınıflandırıcı olarak karar ağaçları kullanılmıştır. Şekil 3.15'te bu çalışma için kullanılan torbalama temelli topluluk sınıflandırıcısının işlem adımlarını verilmiştir.



Şekil 3.15. Torbalama temelli topluluk sınıflandırıcısının işlem akış diyagramı

Torbalamada eğitim örnekleri bazı farklara sahip olarak üretilmektedir. Eğer bu farklar baz modelleri arasında gözle görülebilen derecede ise performans tekil baz modellerine göre oldukça artar. Eğitim setinin büyük farklılığa sahip olduğu modeller, dengesiz model olarak tanımlanır (Breiman 1996) Diğer bir deyişle torbalama baz modellerinin varyansını azaltmaktadır.

3.3. Özet

Bu bölümde otomatik trafik işareti tanıma sisteminin yerel özniteliklerin kullanımı esnasında karşılaşılan dengesiz veri seti problemi ele alınmıştır. Önerilen yerel öznitelik tabanlı dengesiz veri seti üzerindeki TSR sisteminin genel yapısı ve ilgili algoritması bu çalışmadaki katkıları üzerinde durularak açıklandı.

İlk olarak TSR problemi için bu çalışmada kullanılan yerel ve küresel öznitelikler tanıtılmıştır: SIFT, SURF SSIFT, SSURF ve HOG. SIFT ve SURF özniteliği ilgi noktası tanımlayıcılarını kullanarak pratik bir yol izlemektedir. HOG özniteliği ise tüm görüntünün bölümlenmesi ile çıkarılmaktadır.

Son olarak ise TSR probleminin ikinci adımı olan sınıflandırmada kullanılan klasik makine sınıflandırıcıları (DVM, KNN, KA) ve yerel özniteliklerin dengesiz veri seti problemi çözümü için önerilen torbalama temelli topluluk sınıflandırıcısı tanıtılmıştır.



4. ARAŞTIRMA BULGULARI ve TARTIŞMA

Çalışmada, dengesiz veri setleri üzerinde trafik işareti otomatik tanıma (traffic sign recognition (TSR)) sistemi Matlab ortamında oluşturulmuştur. Algoritmalar yüksek performanslı hesaplama kabiliyetine sahip sunucular içerisinde çalıştırılmıştır.

Çalışmada önerilen TSR sisteminin gerçekleştirilmesi için Belçika Trafik İşaretleri Tanıma (BTİT) veri seti kullanılmıştır. BTİT, sınıf sayısı ve trafik işareti görüntü sayısı yönünden diğer veri setlerine kıyasla (German, Sweden vs.) daha zengin olduğu için bu çalışmada kullanılmıştır. Fakat BTİT veri seti sınıflarına ait görüntü sayıları arasında büyük dengesizlik vardır. Bu veri setinde bazı sınıflara ait görüntüler diğer sınıflardaki görüntülerden fazla ya da azdır. Sınıflarda bulunan görüntü sayıları arasındaki bu orantısızlıktan dolayı yerel özniteliklerin kullanıldığı çalışmalarda dengesiz veri seti problemi ortaya çıkmaktadır. Yerel öznitelikler, ilgili alanlar üzerinde tanımlayıcı oluşturularak çıkartılmaktadır. Dolayısıyla tüm görüntünün bölünmesi yerine ilgi noktası üzerinde odaklanılan uygulamalarda zaman ve disk alanı gibi kaynaklardan tasarruf edilmesi sağlanmaktadır.

Çalışmanın bu bölümünde, dengesiz veri setindeki trafik işaret görüntüleri için yerel özniteliklerle ilgili nokta tabanlı yerel özniteliklerin avantajları kullanılarak, yeni bir trafik işareti otomatik tanıma sisteminin tasarlanması için yapılan uygulamalar ve kullanılan yöntemlerin sonuçları sunulmuştur. Araştırmada SIFT, SURF, SSIFT, SSURF, SIFT+SURF, HOG, HOG+SIFT, HOG+SSIFT, HOG+SSURF öznitelikleri ve DVM, KA, KNN, TTT sınıflandırıcıları ile yapılan deneysel çalışmalar ve deneylerde kullanılan veri seti hakkında bilgiler verilerek, elde edilen sonuçlar ilgili başlıklar altında sunulmuştur.

4.1. Dengesiz Veri Setlerinde Trafik İşaretlerini Tanıma Uygulamaları

BTİT veri seti üzerinde bu araştırma kapsamında yapılan deneyler, dokuz farklı

özniteliğin ve dört farklı sınıflandırıcının değişik kombinasyonlarda birleştirilmesi ile gerçekleştirilmiştir. Toplamda otuz farklı deney yüksek performanslı hesaplama kabiliyetine sahip sunucular üzerinde çalıştırılmıştır. Uygulanan bu deneyler Şekil 4.1’de sunulmuştur.

SIFT ÖZNİTELİĞİ	• DVM • KNN • TTT • KA
SURF ÖZNİTELİĞİ	• DVM • KNN • TTT • KA
SSIFT ÖZNİTELİĞİ	• DVM • KNN • TTT • KA
SSURF ÖZNİTELİĞİ	• DVM • KNN • TTT • KA
SIFT+SURF ÖZNİTELİĞİ	• DVM • KNN • TTT • KA
HOG ÖZNİTELİĞİ	• DVM • KNN • TTT • KA
HOG+SIFT ÖZNİTELİĞİ	• DVM • KNN • TTT • KA
HOG+SSIFT ÖZNİTELİĞİ	• DVM
HOG+SSURF	• DVM

Şekil 4.1. Deneyler



Şekil 4.1’in sol sütunu araştırmada kullanılan öznitelikleri, sağ sütunu ise kullanılan sınıflandırıcıları göstermektedir. Deneyler sonucunda elde edilen bulgular aşağıda ilgili

başlıklar altında sunulmuştur.

4.2. Belçika Trafik İşareti Tanıma Veri Grubu

BTİT veri seti şekline ve rengine bağlı olarak zorunlu, tehlikeli ve yasaklayıcı olmak üzere üç ana kategoriye ayrılır. Zorunlu kategorisindeki görüntülerin şekli yuvarlak, içi mavi ve sembolleri beyazdır. Tehlike kategorisi üçgen şekline sahip, içi beyaz, kenarları ise kırmızı olan görüntülerden meydana gelmektedir. Son kategori olan yasaklayıcı işaretler ise içi beyaz, kenarları kırmızı olan yuvarlak işaret görüntülerinden oluşmaktadır.

Belçika Flanders bölgesindeki kentsel çevrede çekilen görüntülerden oluşan bu veri seti 62 sınıfa ayrılmıştır. Tüm kategorilerdeki işaret görüntülerinin her biri için farklı kameralardan ve farklı uzaklıklardan çekilen ortalama üç görüntü vardır. Her sınıfa ait örnek görüntüler Şekil 4.2’de verilmiştir. Şekilden de anlaşılabileceği gibi kırpılmış olan bu görüntüler, az da olsa arka plan içermektedir. Bu veri setinde bulunan görüntülerin genişlikleri 26 piksel ile 704 piksel arasında, yükseklikleri ise 21 piksel ile 500 piksel arasında değişmektedir. Bu çalışmada kullanılan görüntüler SIFT ve SURF öznitelikleri için 100x100, HOG özniteliği için ise 28x28 boyutlarında olacak şekilde yeniden boyutlandırılmıştır.

Sınıf	Görüntüler	Sınıf	Görüntüler	Sınıf	Görüntüler	Sınıf	Görüntüler
0		16		32		48	
1		17		33		49	
2		18		34		50	
3		19		35		51	
4		20		36		52	
5		21		37		53	
6		22		38		54	
7		23		39		55	
8		24		40		56	
9		25		41		57	
10		26		42		58	
11		27		43		59	
12		28		44		60	
13		29		45		61	
14		30		46			
15		31		47			

Şekil 4.2. BTİT veri seti sınıflarına ait örnek görüntüler

Şekil 4.2’de görüldüğü gibi tüm kategorilerdeki işaretler tamamen görülebilir veya kısmen kapatılmış, parlak veya mat, açık veya koyu, büyük veya küçük ve önden

görünümlü veya açılı olabilir. Aynı zamanda sahneler ve piksel çözünürlükleri yüksek derecede değişkenlik göstermiştir.

BTİT veri seti 4591 görüntüden oluşan eğitim veri seti ve 2534 görüntüden oluşan test veri seti olmak üzere iki kısma ayrılmıştır. Eğitim veri setinin sınıflara göre dağılımı Çizelge 4.1’de gösterilmiştir.

Çizelge 4.1. BTİT Veri Seti Sınıflarının Örnek Görüntü Sayısı

Sınıf	Görüntü Sayısı	Sınıf	Görüntü Sayısı	Sınıf	Görüntü Sayısı	Sınıf	Görüntü Sayısı	Sınıf	Görüntü Sayısı
0	15	14	43	28	125	42	35	56	95
1	110	15	9	29	33	43	30	57	78
2	13	16	9	30	37	44	48	58	15
3	15	17	79	31	63	45	74	59	42
4	25	18	81	32	316	46	44	60	9
5	11	19	231	33	12	47	147	61	282
6	18	20	42	34	46	48	11		
7	157	21	43	35	60	49	12		
8	27	22	375	36	18	50	15		
9	18	23	15	37	98	51	27		
10	21	24	48	38	285	52	27		
11	7	25	42	39	196	53	199		
12	18	26	6	40	242	54	118		
13	90	27	18	41	148	55	12		

Çizelge 4.1’de verilen BTİT veri seti sınıflarının görüntü sayılarının ortalaması 73,95, standart sapması ise 85,88 değerindedir. Bu değerlerden de anlaşılacağı gibi sınıflara ait görüntü sayıları arasındaki dengesizlik oldukça fazladır.

4.3. Öznitelik Çıkarımı

Bu çalışmada öznitelik olarak SIFT, SURF, HOG kullanılmıştır. Ayrıca daha güçlü öznitelikler elde etmek için altı farklı algoritma gerçekleştirilmiştir. İlk algoritmada SIFT ve SURF özniteliklerinin histogramları birleştirilerek SIFT+SURF özniteliği elde edilmiştir. İkinci güçlü öznitelik çıkarım algoritmasında SURF tanımlayıcıları

kullanılarak bazı SIFT tanımlayıcıları elenmiştir. Üçüncü öznitelik çıkarım algoritmasında SIFT tanımlayıcıları kullanılarak bazı SURF tanımlayıcıları elenmiştir. Dördüncü öznitelik için HOG ve SSIFT öznitelikleri birleştirilerek HOG+SSIFT özniteliği elde edilmiştir. Beşinci öznitelik için HOG ve SSURF öznitelikleri birleştirilerek HOG+SSURF özniteliği elde edilmiştir. Son olarak ise HOG ve SIFT özniteliklerinin birleştirilmesiyle HOG+SIFT özniteliği oluşturulmuştur. SIFT tanımlayıcısı Vlfeat kütüphanesini kullanılarak çıkartılırken SURF tanımlayıcısı ve HOG özniteliği matlab ortamının kütüphaneleri kullanılarak çıkartılmıştır. SIFT özniteliğinin histogramının çıkarılması için gerekli olan kelimelerin çantası yönteminde kümeleme metodu olarak K-means seçilmiştir. BTİT veri setinde bulunan 4585 görüntüden elde edilen 179579 SIFT tanımlayıcısı ve 110562 SURF tanımlayıcısı 1000, 3000, 5000, 8000, 10000 kümeye bölünmüştür. En yüksek doğru sınıflandırma performansı 5000 kümeye bölününce elde edildiğinden bu çalışmada küme sayısı 5000 seçilmiştir. Görüntünün çözünürlüğü ve piksel değeri performansı etkilediğinden tüm görüntüler tüm öznitelik çıkarım adımlarında yeniden boyutlandırılmıştır.

Şekil 4.3'ün ilk sütununda örnek görüntüler, ikinci sütununda SIFT anahtar noktaları, üçüncü sütununda SURF anahtar noktaları, dördüncü sütununda ise hog özniteliğini gösterilmektedir.



Şekil 4.3. (a) Orijinal Görüntü, (b) SIFT anahtar noktaları, (c) SURF anahtar noktaları, (d) HOG özniteliği (Aydın vd. 2016).

Şekil 4.3'ten anlaşıldığı üzere, HOG özniteliği tüm görüntünün bölümlenmesi ile elde edilirken, SIFT ve SURF öznitelikleri ilgi odakları üzerinde yoğunlaşmaktadır. Bu sayede SIFT ve SURF özniteliklerinde arka planda bulunan ilgisiz alanların elemine edilmesi ile avantaj sağlanmaktadır. Ayrıca SIFT ve SURF öznitelikleri birleştirilerek ilgi odağı üzerinde bulunan anahtar nokta sayısının artması, SSIFT ve SSURF özniteliklerinde ise arka plan üzerinde bulunan ilgi noktalarının elimine edilmesi sağlanmıştır. Böylelikle hem SIFT özniteliğinden hem de SURF özniteliğinden daha güçlü üç yerel öznitelik elde edilmiştir

4.4. Sınıflandırma


Bu çalışmada sınıflandırıcı yöntemi olarak DVM, KA, KNN VE TTT sınıflandırıcıları kullanılmıştır. Bu sınıflandırıcılar kullanılırken bazı parametrelerin belirlenmesi gerekmektedir. DVM sınıflandırıcısı yönteminde kernel fonksiyonu, KNN

sınıflandırıcısı yönteminde k parametresi, TTT sınıflandırıcısı yönteminde ise topluluk öğrenme döngü sayısının belirlenmesi gerekmektedir. Araştırmada DVM sınıflandırıcısı kullanılırken en yüksek duyarlılıklı sonuçlar kernel fonksiyonu olarak radyal temelli fonksiyon (RTF) kullanıldığı zaman elde edilmiştir. RTF kullanılırken C ve γ parametreleri 2 olarak belirlenmiştir. KNN sınıflandırıcısı kullanılırken test örneği 3 komşunun yakınlığına bakılarak sınıflandırılmıştır. Son olarak TTT sınıflandırıcısı yönteminde topluluk öğrenme döngü sayısı 200 olarak belirlenmiştir


Aşağıda, araştırma kapsamında BTİT veri seti üzerinde kullanılan sınıflandırıcıların sınıflandırma performanslarının gösterildiği grafikler sınıf bazlı ele alınarak sonuçları tartışılmıştır.

4.4.1. Destek vektör makineleri sınıflandırıcı yöntemi sonuçlarının grafiksel gösterimi

BTİT veri seti kullanılarak geliştirilen bu çalışmada DVM sınıflandırıcısı ve yerel öznitelik (SIFT, SURF, SSIFT, SSURE, SIFT+SURF) yöntemleri ile elde edilen doğru sınıflandırma performansları Şekil 4.4’de, konfüzyon matris grafikleri ise Şekil 4.5, Şekil 4.6, Şekil 4.7, Şekil 4.8, Şekil 4.9’da gösterilmektedir.




Şekil 4.4. Yerel öznitelik ve DVM sınıflandırıcısı yönteminin doğru sınıflandırma performansları




Şekil 4.5. SIFT öz niteliği ve DVM sınıflandırıcısı yöntemine ait konfüzyon matrisi

Şekil 4.6. SURF özneliği ve DVM sınıflandırıcısı yöntemine ait konfüzyon matrisi



Şekil 4.7. SSIFT özneteliği ve DVM sınıflandırıcısı yöntemine ait konfüzyon matrisi



Şekil 4.9. SIFT+SURF öz niteliği ve DVM sınıflandırıcısı yöntemine ait konfüzyon matrisi

DVM sınıflandırıcısı SIFT öz niteliği ile birlikte kullanıldığında %36, SURF öz niteliği ile birlikte kullanıldığında %68, SSIFT öz niteliği ile birlikte kullanıldığında %87, SSURF öz niteliği ile birlikte kullanıldığında %89 ve SIFT+SURF ile birlikte kullanıldığında %81 oranında doğru sınıflandırma performansı elde edilmiştir. Bu yerel öz niteliklerin sınıf bazlı doğru sınıflandırma performansları, Çizelge 4.2, Çizelge 4.3, Çizelge 4.4, Çizelge 4.5 ve Çizelge 4.6’de verilmiştir.

Çizelge 4.2. DVM Sınıflandırıcısının ve SIFT Özniteliğinin Sınıf Bazlı Sınıflandırma Performansları

Sınıf	Doğru Sayısı	Yanlış Sayısı	F değeri	Sınıflandırma Performansı	Sınıf	Doğru Sayısı	Yanlış Sayısı	F değeri	Sınıflandırma Performansı
0	0	6	0	0	31	12	74	0,24	0,13
1	0	27	0	0	32	419	3	0,98	0,99
2	0	7	0	0	33	0	0	0	0
3	0	6	0	0	34	0	9	0	0
4	0	12	0	0	35	0	154	0	0
5	0	3	0	0	36	0	0	0	0
6	0	6	0	0	37	24	7	0,87	0,77
7	39	51	0,60	0,43	38	167	46	0,87	0,78
8	0	12	0	0	39	31	68	0,47	0,31
9	0	0	0	0	40	0	48	0	0
10	0	28	0	0	41	0	11	0	0
11	0	0	0	0	42	0	9	0	0
12	0	3	0	0	43	0	6	0	0
13	0	39	0	0	44	0	3	0	0
14	0	15	0	0	45	0	84	0	0
15	0	0	0	0	46	0	6	0	0
16	0	12	0	0	47	7	24	0,36	0,22
17	0	183	0	0	48	0	0	0	0
18	6	116	0,09	0,04	49	0	3	0	0
19	30	133	0,30	0,18	50	0	0	0	0
20	2	1	0,80	0,66	51	0	6	0	0
21	0	45	0	0	52	0	0	0	0
22	61	0	0,07	1	53	19	5	0,82	0,79
23	0	15	0	0	54	14	34	0,45	0,29
24	0	13	0	0	55	0	15	0	0
25	0	3	0	0	56	10	23	0,46	0,30
26	0	0	0	0	57	1	40	0,047	0,02
27	0	9	0	0	58	0	9	0	0
28	0	51	0	0	59	0	17	0	0
29	0	28	0	0	60	0	11	0	0
30	0	37	0	0	61	66	39	0,76	0,62
Sınıf Bazlı Doğru Sınıflandırma Performansı: %8					Görüntü Sayısı Bazlı Doğru Sınıflandırma Performansı: %36				

Çizelge 4.3. DVM Sınıflandırıcısının ve SURF Özniteliğinin Sınıf Bazlı Sınıflandırma Performansları

Sınıf	Doğru Sayısı	Yanlış Sayısı	F değeri	Sınıflandırma Performansı	Sınıf	Doğru Sayısı	Yanlış Sayısı	F değeri	Sınıflandırma Performansı
0	0	6	0	0	31	74	12	0,95	0,86
1	23	4	0,89	0,85	32	422	0	0,65	1
2	0	7	0	0	33	0	0	0	0
3	0	6	0	0	34	4	5	0,71	0,44
4	0	12	0	0	35	0	154	0	0
5	0	3	0	0	36	0	0	0	0
6	0	6	0	0	37	24	7	0,85	0,77
7	88	2	0,83	0,97	38	204	9	0,80	0,95
8	0	12	0	0	39	94	5	0,98	0,94
9	0	0	0	0	40	48	0	0,44	1
10	0	28	0	0	41	0	11	0,31	0
11	0	0	0	0	42	0	9	0	0
12	0	3	0	0	43	0	6	0	0
13	11	28	0,50	0,28	44	1	2	0,50	0,33
14	0	15	0	0	45	68	16	0,90	0,80
15	0	0	0	0	46	0	6	0	0
16	0	12	0	0	47	30	1	0,90	0,96
17	20	163	0,51	0,10	48	0	0	0	0
18	87	35	0,83	0,71	49	0	3	0	0
19	157	6	0,97	0,96	50	0	0	0	0
20	3	0	1	1	51	0	6	0	0
21	30	15	0,62	0,66	52	0	0	0	0
22	61	0	0,87	1	53	24	0	1	1
23	0	15	0	0	54	42	6	0,97	0,87
24	1	12	0,27	0,07	55	0	15	0	0
25	3	0	1	1	56	32	1	0,94	0,96
26	0	1	0	0	57	21	20	0,78	0,51
27	0	9	0	0	58	0	9	0	0
28	36	15	0,83	0,70	59	2	15	0,30	0,11
29	2	26	0,63	0,07	60	0	11	0	0
30	5	32	0,15	0,13	61	105	0	0,91	1
Sınıf Bazlı Doğru Sınıflandırma Performansı: %21					Görüntü Sayısı Bazlı Doğru Sınıflandırma Performansı: %68				

Çizelge 4.4. DVM Sınıflandırıcısının ve SSIFT Özniteliğinin Sınıf Bazlı Sınıflandırma Performansları

Sınıf	Doğru Sayısı	Yanlış Sayısı	F değeri	Sınıflandırma Performansı	Sınıf	Doğru Sayısı	Yanlış Sayısı	F değeri	Sınıflandırma Performansı
0	2	4	0,50	0,33	31	74	12	0,93	0,86
1	22	5	0,80	0,81	32	418	4	0,99	0,99
2	3	4	0,60	0,42	33	0	0	1	0
3	0	6	0,00	0	34	6	3	0,27	0,66
4	12	0	0,92	1	35	85	69	0,71	0,55
5	3	0	1	1	36	0	0	1	0
6	4	2	0,80	0,66	37	30	1	0,98	0,96
7	86	4	0,98	0,95	38	201	12	0,97	0,94
8	10	2	0,80	0,83	39	95	4	0,98	0,95
9	0	0	1	0	40	40	8	0,43	0,83
10	23	5	0,90	0,821	41	8	3	0,73	0,72
11	0	0	1	0	42	7	2	0,88	0,77
12	2	1	0,80	0,667	43	3	3	0,67	0,50
13	13	26	0,49	0,33	44	2	1	0,80	0,66
14	15	0	0,91	1	45	68	16	0,88	0,80
15	0	0	1	0	46	4	2	0,73	0,66
16	8	4	0,80	0,667	47	31	0	0,97	1
17	168	15	0,95	0,91	48	0	0	1	0
18	116	6	0,97	0,95	49	3	0	0,67	1
19	156	7	0,78	0,95	50	0	0	1	0
20	3	0	1	1	51	3	3	0,67	0,50
21	40	5	0,94	0,88	52	0	0	1	0
22	57	4	0,68	0,93	53	23	1	0,85	0,95
23	9	6	0,75	0,60	54	40	8	0,90	0,83
24	10	3	0,83	0,76	55	7	8	0,64	0,46
25	3	0	1	1	56	31	2	0,95	0,93
26	0	0	1	0	57	29	12	0,83	0,70
27	8	1	0,94	0,88	58	6	3	0,80	0,66
28	28	23	0,53	0,54	59	11	6	0,79	0,64
29	28	0	1	1	60	4	7	0,53	0,36
30	37	0	1	1	61	102	3	0,96	0,97
Sınıf Bazlı Doğru Sınıflandırma Performansı: %41					Görüntü Sayısı Bazlı Doğru Sınıflandırma Performansı: %87				

Çizelge 4.5. DVM Sınıflandırıcısının ve SSURF Özneteliğinin Sınıf Bazlı Sınıflandırma Performansları

Sınıf	Doğru Sayısı	Yanlış Sayısı	F değeri	Sınıflandırma Performansı	Sınıf	Doğru Sayısı	Yanlış Sayısı	F değeri	Sınıflandırma Performansı
0	1	5	0,29	0,16	31	85	1	0,99	0,98
1	26	1	0,81	0,96	32	420	2	1	0,99
2	2	5	0,44	0,28	33	0	0	1	0
3	2	4	0,50	0,33	34	9	0	1	1
4	7	5	0,61	0,58	35	63	91	0,58	0,40
5	2	1	0,80	0,66	36	0	0	1	0
6	4	2	0,73	0,66	37	30	1	0,98	0,96
7	90	0	0,97	1	38	206	7	0,97	0,96
8	6	6	0,55	0,50	39	96	3	0,98	0,96
9	0	0	1	0	40	40	8	0,50	0,83
10	21	7	0,86	0,75	41	7	4	0,45	0,63
11	0	0	1	0	42	7	2	0,82	0,77
12	2	1	0,80	0,66	43	5	1	0,91	0,83
13	25	14	0,71	0,64	44	2	1	0,80	0,66
14	14	1	0,78	0,93	45	72	12	0,91	0,85
15	0	0	0,67	0	46	3	3	0,60	0,50
16	4	8	0,50	0,33	47	31	0	0,91	1
17	177	6	0,97	0,96	48	0	0	1	0
18	114	8	0,96	0,93	49	3	0	0,67	1
19	163	0	0,94	1	50	0	0	1	0
20	3	0	1	1	51	3	3	0,67	0,50
21	41	4	0,95	0,91	52	0	0	1	0
22	61	0	0,72	1	53	22	2	0,96	0,91
23	8	7	0,70	0,53	54	48	0	0,97	1
24	10	3	0,80	0,76	55	8	7	0,70	0,53
25	3	0	1	1	56	33	0	0,94	1
26	0	0	1	0	57	28	13	0,81	0,68
27	5	4	0,71	0,55	58	9	0	1	1
28	39	12	0,58	0,76	59	11	6	0,79	0,64
29	28	0	1	1	60	4	7	0,53	0,36
30	37	0	1	1	61	105	0	0,97	1
Sınıf Bazlı Doğru Sınıflandırma Performansı: %41					Görüntü Sayısı Bazlı Doğru Sınıflandırma Performansı: %89				


Çizelge 4.6. DVM Sınıflandırıcısının ve SIFT+SURF Özniteliğinin Sınıf Bazlı Sınıflandırma Performansları

Sınıf	Doğru Sayısı	Yanlış Sayısı	F değeri	Sınıflandırma Performansı	Sınıf	Doğru Sayısı	Yanlış Sayısı	F değeri	Sınıflandırma Performansı
0	0	6	0	0	31	79	7	0,96	0,91
1	26	1	0,88	0,96	32	421	1	0,96	0,99
2	0	7	0	0	33	0	1	0	0
3	0	6	0	0	34	7	2	0,88	0,77
4	0	12	0	0	35	38	116	0,40	0,24
5	0	3	0	0	36	0	1	0	0
6	0	6	0	0	37	29	2	0,97	0,93
7	90	0	0,96	1	38	203	10	0,93	0,95
8	0	12	0	0	39	96	3	0,98	0,96
9	0	1	0	0	40	46	2	0,20	0,95
10	0	28	0	0	41	6	5	0,71	0,54
11	0	1	0	0	42	0	9	0	0
12	0	3	0	0	43	0	6	0	0
13	15	24	0,55	0,38	44	1	2	0,50	0,33
14	10	5	0,80	0,66	45	71	13	0,90	0,84
15	0	1	0	0	46	3	3	0,67	0,50
16	0	12	0	0	47	31	0	0,95	1
17	139	44	0,86	0,75	48	0	1	0	0
18	113	9	0,96	0,92	49	0	3	0	0
19	162	1	0,94	0,99	50	0	1	0	0
20	3	0	1	1	51	0	6	0	0
21	38	7	0,92	0,84	52	0	1	0	0
22	60	1	0,90	0,98	53	24	0	1	1
23	0	15	0	0	54	46	2	0,98	0,95
24	8	5	0,76	0,61	55	0	15	0	0
25	3	0	1	1	56	33	0	0,99	1
26	0	1	0	0	57	31	10	0,86	0,75
27	0	9	0	0	58	0	9	0	0
28	46	5	0,94	0,90	59	9	8	0,69	0,52
29	23	5	0,90	0,82	60	0	11	0	0
30	25	12	0,81	0,67	61	105	0	0,93	1
Sınıf Bazlı Doğru Sınıflandırma Performansı: %28					Görüntü Sayısı Bazlı Doğru Sınıflandırma Performansı: %81				

Çizelgelerden de görüleceği gibi SIFT özniteliği bu sınıflandırıcı ile kullanıldığında kırk altı sınıf %0, bir sınıf %100 ve diğer sınıflar %0,02 ile %0,99 arasında değişen oranlarda doğru sınıflandırılmıştır. SURF özniteliğinin DVM ile kullanımında otuz iki sınıf %0, yedi sınıf %100 ve diğer sınıflar %0,07 ile %0,97 arasında değişen oranlarda doğru sınıflandırılmıştır. SSIFT özniteliğinin DVM ile kullanımında on sınıf 0%, dokuz sınıf %100 ve diğer sınıflar %33 ile %99 arasında değişen oranlarda doğru sınıflandırılmıştır. SSURF özniteliği ile dokuz sınıf 0%, on dört sınıf %100 ve diğer sınıflar %16 ile %99 arasında değişen oranlarda doğru sınıflandırılmıştır. SIFT+SURF özniteliğinin DVM ile birlikte kullanılması ile yirmi sekiz sınıf %0, yedi sınıf %100 ve diğer sınıflar %0,24 ile %0,99 arasında değişen oranlarda doğru sınıflandırılmıştır.


DVM sınıflandırıcısı SIFT, SURF ve SIFT+SURF öznitelikleri ile birlikte kullanıldığında görüntü sayısının az olduğu sınıfların (azınlık sınıfı) doğru sınıflandırma performansı genellikle %0'dır. Görüntü sayısının çok olduğu sınıfların (çoğunluk sınıfı) performansının azınlık sınıflarının performansına göre daha başarılı olduğu Şekil 4.10'da görülmektedir. Dengesiz veri seti üzerinde SSIFT ve SSURF özniteliklerinin DVM ile birlikte kullanılması ile başarılı sonuçlar elde edilmiştir.

HOG, HOG+SIFT, HOG+SSIFT, HOG+SSURF özniteliklerinin DVM sınıflandırıcısı ile birlikte kullanıldıkları deneylerin doğru sınıflandırma performansları Şekil 4.10'da, konfüzyon matrisleri ise Şekil 4.11, Şekil 4.12, Şekil 4.13 ve Şekil 4.14'de gösterilmiştir. Konfüzyon matrisi, sınıflandırma algoritmasının performansını gösteren özel bir çizelgedir. Bu çizelgedeki her sütun tahmin edilen sınıfı, her satır ise örneğin ait olduğu doğru sınıfı göstermektedir.




Şekil 4.10. HOG, HOG+SIFT, HOG+SSIFT, HOG+SSURF ve DVM sınıflandırıcısı yönteminin doğru sınıflandırma performansları

Şekil 4.11. HOG özneliği ve DVM sınıflandırıcısı yöntemine ait konfüzyon matrisi



Şekil 4.12. HOG+SIFT öz niteliği ve DVM sınıflandırıcısı yöntemine ait konfüzyon matrisi



Şekil 4.14. HOG+SSURF özneteliği ve DVM sınıflandırıcısı yöntemine ait konfüzyon matrisi

DVM sınıflandırıcısı HOG özneteliği ile birlikte kullanıldığında %95, HOG+SIFT, HOG+SSIFT, HOG+SSURF ile birlikte kullanıldığında %96 oranında doğru sınıflandırma performansı elde edilmiştir. Bu özneteliklerin sınıf bazlı doğru sınıflandırma performansları Çizelge 4.7, Çizelge 4.8, Çizelge 4.9 ve Çizelge 4.10'de verilmiştir.

Çizelge 4.7. DVM Sınıflandırıcısının ve HOG Öznitelisinin Sınıf Bazlı Sınıflandırma Performansları

Sınıf	Doğru Sayısı	Yanlış Sayısı	F değeri	Sınıflandırma Performansı	Sınıf	Doğru Sayısı	Yanlış Sayısı	F değeri	Sınıflandırma Performansı
0	4	2	0,80	0,66	31	86	0	1	1
1	27	0	0,96	1	32	421	1	1	0,99
2	3	4	0,60	0,42	33	0	0	1	0
3	5	1	0,91	0,83	34	9	0	1	1
4	8	4	0,67	0,66	35	139	15	0,95	0,90
5	3	0	1	1	36	0	0	1	0
6	4	2	0,73	0,66	37	31	0	1	1
7	87	3	0,95	0,96	38	201	12	0,97	0,94
8	9	3	0,82	0,75	39	99	0	0,99	1
9	0	0	1	0	40	47	1	0,98	0,97
10	25	3	0,94	0,89	41	11	0	0,73	1
11	0	0	1	0	42	8	1	0,84	0,88
12	3	0	1	1	43	4	2	0,80	0,66
13	33	6	0,89	0,84	44	3	0	1	1
14	15	0	0,73	1	45	77	7	0,96	0,91
15	0	0	1	0	46	6	0	1	1
16	6	6	0,67	0,50	47	31	0	0,97	1
17	177	6	0,95	0,96	48	0	0	1	0
18	119	3	0,97	0,97	49	3	0	0,50	1
19	163	0	1	1	50	0	0	0,67	0
20	3	0	1	1	51	3	3	0,67	0,50
21	42	3	0,92	0,93	52	0	0	1	0
22	61	0	0,98	1	53	24	0	0,96	1
23	13	2	0,84	0,86	54	48	0	0,99	1
24	10	3	0,87	0,76	55	15	0	1	1
25	3	0	0,60	1	56	33	0	0,77	1
26	0	0	1	0	57	20	21	0,66	0,48
27	9	0	1	1	58	8	1	0,89	0,88
28	51	0	0,93	1	59	17	0	1	1
29	28	0	1	1	60	11	0	1	1
30	37	0	1	1	61	105	0	1	1
Sınıf Bazlı Doğru Sınıflandırma Performansı: %48					Görüntü Sayısı Bazlı Doğru Sınıflandırma Performansı: %95				

Çizelge 4.8. DVM Sınıflandırıcısının ve HOG+SIFT Özniteliğinin Sınıf Bazlı Sınıflandırma Performansları

Sınıf	Doğru Sayısı	Yanlış Sayısı	F değeri	Sınıflandırma Performansı	Sınıf	Doğru Sayısı	Yanlış Sayısı	F değeri	Sınıflandırma Performansı
0	4	2	0,80	0,66	31	86	0	1	1
1	27	0	0,96	1	32	421	1	1	0,99
2	3	4	0,60	0,42	33	0	0	1	0
3	5	1	0,91	0,83	34	9	0	1	1
4	8	4	0,67	0,66	35	138	16	0,95	0,89
5	3	0	1	1	36	0	0	1	0
6	4	2	0,73	0,66	37	31	0	1	1
7	87	3	0,95	0,96	38	203	10	0,98	0,95
8	9	3	0,82	0,75	39	99	0	1	1
9	0	0	1	0	40	47	1	0,98	0,97
10	25	3	0,94	0,89	41	11	0	0,73	1
11	0	0	1	0	42	8	1	0,84	0,88
12	3	0	1	1	43	4	2	0,80	0,66
13	33	6	0,89	0,84	44	3	0	1	1
14	15	0	0,75	1	45	77	7	0,96	0,91
15	0	0	1	0	46	6	0	1	1
16	6	6	0,67	0,50	47	31	0	0,97	1
17	178	5	0,95	0,97	48	0	0	1	0
18	119	3	0,97	0,97	49	3	0	0,50	1
19	163	0	1	1	50	0	0	0,67	0
20	3	0	1	1	51	3	3	0,67	0,50
21	42	3	0,92	0,93	52	0	0	1	0
22	61	0	0,98	1	53	24	0	0,96	1
23	14	1	0,90	0,93	54	48	0	0,99	1
24	10	3	0,87	0,76	55	15	0	1	1
25	3	0	0,60	1	56	33	0	0,77	1
26	0	0	1	0	57	20	21	0,66	0,48
27	9	0	1	1	58	8	1	0,89	0,88
28	51	0	0,93	1	59	17	0	1	1
29	28	0	1	1	60	11	0	1	1
30	37	0	1	1	61	105	0	1	1
Sınıf Bazlı Doğru Sınıflandırma Performansı: %48					Görüntü Sayısı Bazlı Doğru Sınıflandırma Performansı: %96				

Çizelge 4.9. DVM Sınıflandırıcısının ve HOG+SSIFT Özniteliğinin Sınıf Bazlı Sınıflandırma Performansları

Sınıf	Doğru Sayısı	Yanlış Sayısı	F değeri	Sınıflandırma Performansı	Sınıf	Doğru Sayısı	Yanlış Sayısı	F değeri	Sınıflandırma Performansı
0	4	2	0,80	0,66	31	86	0	1	1
1	27	0	0,96	1	32	421	1	1	0,99
2	3	4	0,60	0,42	33	0	0	1	0
3	5	1	0,91	0,83	34	9	0	1	1
4	8	4	0,64	0,66	35	139	15	0,95	0,90
5	3	0	1	1	36	0	0	1	0
6	5	1	0,91	0,83	37	31	0	1	1
7	89	1	0,96	0,98	38	206	7	0,98	0,96
8	9	3	0,86	0,75	39	99	0	1	1
9	0	0	1	0	40	46	2	0,97	0,95
10	26	2	0,96	0,92	41	11	0	0,73	1
11	0	0	1	0	42	8	1	0,84	0,88
12	3	0	1	1	43	4	2	0,80	0,66
13	33	6	0,89	0,84	44	3	0	1	1
14	15	0	0,77	1	45	77	7	0,95	0,91
15	0	0	1	0	46	5	1	0,91	0,83
16	7	5	0,74	0,58	47	31	0	0,95	1
17	179	4	0,97	0,97	48	0	0	1	0
18	119	3	0,97	0,97	49	3	0	0,50	1
19	163	0	1	1	50	0	0	1	0
20	3	0	1	1	51	3	3	0,67	0,50
21	42	3	0,93	0,93	52	0	0	1	0
22	61	0	0,98	1	53	24	0	0,96	1
23	12	3	0,89	0,80	54	48	0	0,99	1
24	10	3	0,87	0,76	55	15	0	1	1
25	3	0	0,67	1	56	33	0	0,80	1
26	0	0	1	0	57	24	17	0,74	0,58
27	9	0	1	1	58	8	1	0,89	0,88
28	51	0	0,89	1	59	17	0	1	1
29	28	0	1	1	60	11	0	1	1
30	37	0	1	1	61	105	0	1	1
Sınıf Bazlı Doğru Sınıflandırma Performansı: %48					Görüntü Sayısı Bazlı Doğru Sınıflandırma Performansı: %96				

Çizelge 4.10. DVM Sınıflandırıcısının ve HOG+SSURF Özniteliğinin Sınıf Bazlı Sınıflandırma Performansları

Sınıf	Doğru Sayısı	Yanlış Sayısı	F değeri	Sınıflandırma Performansı	Sınıf	Doğru Sayısı	Yanlış Sayısı	F değeri	Sınıflandırma Performansı
0	4	2	0,80	0,66	31	86	0	1	1
1	27	0	0,96	1	32	421	1	1	0,99
2	3	4	0,60	0,42	33	0	0	1	0
3	5	1	0,91	0,83	34	9	0	1	1
4	8	4	0,64	0,66	35	137	17	0,94	0,88
5	3	0	1	1	36	0	0	1	0
6	4	2	0,73	0,66	37	30	1	0,98	0,96
7	89	1	0,96	0,98	38	206	7	0,98	0,96
8	9	3	0,86	0,75	39	99	0	1	1
9	0	0	1	0	40	46	2	0,97	0,95
10	26	2	0,96	0,92	41	11	0	0,71	1
11	0	0	1	0	42	8	1	0,84	0,88
12	3	0	1	1	43	4	2	0,80	0,66
13	33	6	0,89	0,84	44	3	0	1	1
14	15	0	0,77	1	45	77	7	0,95	0,91
15	0	0	1	0	46	5	1	0,91	0,83
16	7	5	0,74	0,58	47	31	0	0,97	1
17	179	4	0,97	0,97	48	0	0	1	0
18	119	3	0,97	0,97	49	3	0	0,50	1
19	163	0	1	1	50	0	0	1	0
20	3	0	1	1	51	3	3	0,67	0,50
21	42	3	0,92	0,93	52	0	0	1	0
22	61	0	0,97	1	53	24	0	0,96	1
23	12	3	0,89	0,80	54	48	0	0,99	1
24	10	3	0,87	0,76	55	15	0	1	1
25	3	0	0,60	1	56	33	0	0,80	1
26	0	0	1	0	57	24	17	0,74	0,58
27	9	0	1	1	58	9	0	0,95	1
28	51	0	0,91	1	59	17	0	1	1
29	28	0	1	1	60	11	0	1	1
30	37	0	1	1	61	105	0	1	1
Sınıf Bazlı Doğru Sınıflandırma Performansı: %48					Görüntü Sayısı Bazlı Doğru Sınıflandırma Performansı: %96				


HOG ve HOG+SIFT öznitelikleri bu sınıflandırıcı ile kullanıldığında dokuz sınıf %0, yirmi sekiz sınıf %100 ve diğer sınıflar %0,42 ile %0,99 arasında değişen oranlarda doğru sınıflandırılmıştır. HOG+SSIFT ve HOG+SSURF özniteliklerinin DVM ile

birlikte kullanımında dokuz sınıf %0, yirmi yedi sınıf %100 ve diğer sınıflar %0,42 ile %0,99 arasında değişen oranlarda doğru sınıflandırılmıştır.

HOG, HOG+SSIFT, HOG+SSURF, HOG+SIFT öznitelikleri DVM sınıflandırıcısı ile birlikte kullanıldığında veri setinden bağımsız performans göstermiştir. Bu öznitelikler ile dengesiz veri seti kaynaklı yanlışlık probleminin oluşmadığı tespit edilmiştir.


4.4.2. Karar ağaçları sınıflandırıcı yöntemi sonuçlarının grafiksel gösterimi

Karar ağaçları sınıflandırıcısı ve yerel öznitelik (SIFT, SURF, SSIFT, SSURF, SIFT+SURF) yöntemleri ile elde edilen doğru sınıflandırma performansları Şekil 4.15'te, konfüzyon matris grafikleri ise Şekil 4.16, Şekil 4.17, Şekil 4.18, Şekil 4.19 ve Şekil 4.20'de gösterilmektedir.




Şekil 4.15. Yerel öznitelik ve KA sınıflandırıcısı yönteminin doğru sınıflandırma performansları

Şekil 4.17. SURF özneteliği ve KA sınıflandırıcısı yöntemine ait konfüzyon matrisi



Şekil 4.19. SSURF özneliği ve KA sınıflandırıcısı yöntemine ait konfüzyon matrisi



Şekil 4.20. SIFT+SURF özniteliği ve KA sınıflandırıcısı yöntemine ait konfüzyon matrisi

KA sınıflandırıcısı SIFT özneteliği ile birlikte kullanıldığında %78, SURF özneteliği ile birlikte kullanıldığında %78, SSIFT özneteliği ile birlikte kullanıldığında %76, SSURF özneteliği ile birlikte kullanıldığında %81 ve SIFT+SURF ile birlikte kullanıldığında %79 oranında doğru sınıflandırma performansı elde edilmiştir. Bu yerel özneteliklerin sınıf bazlı doğru sınıflandırma performansları Çizelge 4.11, Çizelge 4.12, Çizelge 4.13, Çizelge 4.14 ve Çizelge 4.15’de verilmiştir.

Çizelge 4.11. KA Sınıflandırıcısının ve SIFT Özniteliğinin Sınıf Bazlı Sınıflandırma Performansları

Sınıf	Doğru Sayısı	Yanlış Sayısı	F değeri	Sınıflandırma Performansı	Sınıf	Doğru Sayısı	Yanlış Sayısı	F değeri	Sınıflandırma Performansı
0	1	5	0,29	0,16	31	66	20	0,86	0,76
1	17	10	0,58	0,62	32	402	20	0,97	0,95
2	7	0	1	1	33	0	0	1	0
3	1	5	0,17	0,16	34	2	7	0,07	0,22
4	10	2	0,71	0,83	35	75	79	0,63	0,48
5	3	0	1	1	36	0	0	0,50	0
6	4	2	0,80	0,66	37	24	7	0,87	0,77
7	77	13	0,89	0,85	38	189	24	0,90	0,88
8	9	3	0,46	0,75	39	81	18	0,85	0,81
9	0	0	0,50	0	40	29	19	0,29	0,60
10	12	16	0,59	0,42	41	5	6	0,32	0,45
11	0	0	1	0	42	6	3	0,75	0,66
12	1	2	0,29	0,33	43	1	5	0,25	0,16
13	9	30	0,30	0,23	44	2	1	0,80	0,66
14	13	2	0,93	0,86	45	61	23	0,79	0,72
15	0	0	0,50	0	46	4	2	0,50	0,66
16	3	9	0,40	0,25	47	29	2	0,87	0,93
17	148	35	0,87	0,80	48	0	0	0,40	0
18	113	9	0,95	0,92	49	0	3	0	0
19	119	44	0,68	0,73	50	0	0	0,50	0
20	3	0	0,86	1	51	3	3	0,55	0,50
21	39	6	0,91	0,86	52	0	0	0,50	0
22	53	8	0,64	0,86	53	21	3	0,67	0,87
23	5	10	0,48	0,33	54	37	11	0,85	0,77
24	8	5	0,62	0,61	55	7	8	0,64	0,46
25	3	0	0,75	1	56	26	7	0,84	0,78
26	0	0	0,40	0	57	18	23	0,59	0,43
27	4	5	0,57	0,44	58	5	4	0,67	0,55
28	37	14	0,62	0,72	59	13	4	0,72	0,76
29	21	7	0,86	0,75	60	6	5	0,71	0,54
30	37	0	0,93	1	61	93	12	0,89	0,88
Sınıf Bazlı Doğru Sınıflandırma Performansı: %35					Görüntü Sayısı Bazlı Doğru Sınıflandırma Performansı: %78				

Çizelge 4.12. KA Sınıflandırıcısının ve SURF Özniteliğinin Sınıf Bazlı Sınıflandırma Performansları

Sınıf	Doğru Sayısı	Yanlış Sayısı	F değeri	Sınıflandırma Performansı	Sınıf	Doğru Sayısı	Yanlış Sayısı	F değeri	Sınıflandırma Performansı
0	6	0	1	1	31	79	7	0,96	0,91
1	25	2	0,78	0,92	32	400	22	0,96	0,94
2	6	1	0,92	0,85	33	0	0	1	0
3	0	6	0	0	34	8	1	0,94	0,88
4	8	4	0,76	0,66	35	25	129	0,27	0,16
5	2	1	0,80	0,66	36	0	0	1	0
6	5	1	0,91	0,83	37	22	9	0,77	0,70
7	82	8	0,90	0,91	38	166	47	0,84	0,77
8	6	6	0,44	0,50	39	86	13	0,89	0,86
9	0	0	0,50	0	40	20	28	0,42	0,41
10	18	10	0,71	0,64	41	8	3	0,07	0,72
11	0	0	1	0	42	7	2	0,78	0,77
12	2	1	0,50	0,66	43	4	2	0,53	0,66
13	28	11	0,75	0,71	44	2	1	0,50	0,66
14	13	2	0,93	0,86	45	69	15	0,86	0,82
15	0	0	0,50	0	46	1	5	0,15	0,16
16	6	6	0,67	0,50	47	28	3	0,85	0,90
17	157	26	0,89	0,85	48	0	0	1	0
18	109	13	0,92	0,89	49	1	2	0,22	0,33
19	125	38	0,82	0,76	50	0	0	1	0
20	3	0	0,75	1	51	3	3	0,60	0,50
21	38	7	0,88	0,84	52	0	0	0,40	0
22	44	17	0,76	0,72	53	23	1	0,90	0,95
23	11	4	0,76	0,73	54	44	4	0,93	0,91
24	10	3	0,77	0,76	55	5	10	0,48	0,33
25	3	0	0,60	1	56	31	2	0,91	0,93
26	0	0	1	0	57	29	12	0,79	0,70
27	1	8	0,15	0,11	58	5	4	0,71	0,55
28	39	12	0,53	0,76	59	8	9	0,57	0,47
29	26	2	0,96	0,92	60	1	10	0,15	0,09
30	32	5	0,89	0,86	61	95	10	0,86	0,90
Sınıf Bazlı Doğru Sınıflandırma Performansı: %37					Görüntü Sayısı Bazlı Doğru Sınıflandırma Performansı: %78				

Çizelge 4.13. KA Sınıflandırıcısının ve SSIFT Özniteliğinin Sınıf Bazlı Sınıflandırma Performansları

Sınıf	Doğru Sayısı	Yanlış Sayısı	F değeri	Sınıflandırma Performansı	Sınıf	Doğru Sayısı	Yanlış Sayısı	F değeri	Sınıflandırma Performansı
0	1	5	0,25	0,16	31	73	13	0,90	0,84
1	18	9	0,59	0,66	32	394	28	0,96	0,93
2	7	0	0,82	1	33	0	0	1	0
3	0	6	0,00	0	34	7	2	0,25	0,77
4	8	4	0,70	0,66	35	44	110	0,44	0,28
5	2	1	0,67	0,66	36	0	0	0,50	0
6	6	0	0,80	1	37	31	0	1	1
7	82	8	0,93	0,91	38	180	33	0,88	0,84
8	4	8	0,38	0,33	39	83	16	0,86	0,83
9	0	0	1	0	40	29	19	0,26	0,60
10	20	8	0,83	0,71	41	7	4	0,35	0,63
11	0	0	1	0	42	6	3	0,55	0,66
12	2	1	0,67	0,66	43	1	5	0,18	0,16
13	12	27	0,41	0,30	44	2	1	0,67	0,66
14	14	1	0,85	0,93	45	61	23	0,79	0,72
15	0	0	0,67	0	46	2	4	0,33	0,33
16	5	7	0,59	0,41	47	26	5	0,72	0,83
17	149	34	0,87	0,81	48	0	0	1	0
18	114	8	0,96	0,93	49	0	3	0,00	0
19	122	41	0,71	0,74	50	0	0	0,67	0
20	3	0	1	1	51	3	3	0,60	0,50
21	39	6	0,93	0,86	52	0	0	1	0
22	47	14	0,59	0,77	53	21	3	0,48	0,87
23	8	7	0,67	0,53	54	38	10	0,78	0,79
24	8	5	0,57	0,61	55	5	10	0,50	0,33
25	3	0	0,75	1	56	23	10	0,77	0,69
26	0	0	1	0	57	21	20	0,59	0,51
27	9	0	0,90	1	58	7	2	0,88	0,77
28	19	32	0,36	0,37	59	8	9	0,59	0,47
29	25	3	0,94	0,89	60	7	4	0,74	0,63
30	36	1	0,97	0,97	61	83	22	0,79	0,79
Sınıf Bazlı Doğru Sınıflandırma Performansı: %36					Görüntü Sayısı Bazlı Doğru Sınıflandırma Performansı: %76				

Çizelge 4.14. KA Sınıflandırıcısının ve SSURF Özniteliğinin Sınıf Bazlı Sınıflandırma Performansları

Sınıf	Doğru Sayısı	Yanlış Sayısı	F değeri	Sınıflandırma Performansı	Sınıf	Doğru Sayısı	Yanlış Sayısı	F değeri	Sınıflandırma Performansı
0	3	3	0,46	0,50	31	77	9	0,94	0,89
1	22	5	0,67	0,81	32	411	11	0,98	0,97
2	2	5	0,44	0,28	33	0	0	0,67	0
3	2	4	0,50	0,33	34	7	2	0,58	0,77
4	6	6	0,67	0,50	35	53	101	0,51	0,34
5	3	0	1	1	36	0	0	0,67	0
6	4	2	0,62	0,66	37	24	7	0,81	0,77
7	77	13	0,89	0,85	38	177	36	0,89	0,83
8	3	9	0,26	0,25	39	87	12	0,87	0,87
9	0	0	1	0	40	36	12	0,25	0,75
10	18	10	0,75	0,64	41	5	6	0,36	0,45
11	0	0	0,33	0	42	6	3	0,71	0,66
12	2	1	0,80	0,66	43	4	2	0,67	0,66
13	27	12	0,69	0,69	44	3	0	0,67	1
14	12	3	0,80	0,80	45	66	18	0,82	0,78
15	0	0	0,40	0	46	3	3	0,30	0,50
16	8	4	0,80	0,66	47	29	2	0,92	0,93
17	157	26	0,88	0,85	48	0	0	0,67	0
18	116	6	0,95	0,95	49	3	0	0,55	1
19	144	19	0,92	0,88	50	0	0	1	0
20	2	1	0,50	0,66	51	3	3	0,60	0,50
21	39	6	0,93	0,86	52	0	0	1	0
22	57	4	0,88	0,93	53	22	2	0,90	0,91
23	5	10	0,50	0,33	54	39	9	0,87	0,81
24	8	5	0,67	0,61	55	7	8	0,64	0,46
25	1	2	0,09	0,33	56	29	4	0,84	0,87
26	0	0	1	0	57	22	19	0,66	0,53
27	5	4	0,56	0,55	58	7	2	0,88	0,77
28	27	24	0,59	0,52	59	14	3	0,80	0,82
29	25	3	0,91	0,89	60	2	9	0,25	0,18
30	32	5	0,90	0,86	61	92	13	0,87	0,87
Sınıf Bazlı Doğru Sınıflandırma Performansı: %37					Görüntü Sayısı Bazlı Doğru Sınıflandırma Performansı: %81				

Çizelge 4.15. KA Sınıflandırıcısının ve SIFT+SURF Özniteliğinin Sınıf Bazlı Sınıflandırma Performansları


Sınıf	Doğru Sayısı	Yanlış Sayısı	F değeri	Sınıflandırma Performansı	Sınıf	Doğru Sayısı	Yanlış Sayısı	F değeri	Sınıflandırma Performansı
0	5	1	0,91	0,83	31	80	6	0,96	0,93
1	25	2	0,75	0,92	32	407	15	0,97	0,96
2	7	0	1	1	33	0	0	1	0
3	2	4	0,31	0,33	34	8	1	0,30	0,88
4	9	3	0,86	0,75	35	29	125	0,31	0,18
5	3	0	1	1	36	0	0	0,67	0
6	5	1	0,91	0,83	37	26	5	0,91	0,83
7	79	11	0,92	0,87	38	179	34	0,88	0,84
8	9	3	0,49	0,75	39	81	18	0,82	0,81
9	0	0	0,67	0	40	34	14	0,32	0,70
10	16	12	0,71	0,57	41	9	2	0,49	0,81
11	0	0	0,33	0	42	7	2	0,74	0,77
12	2	1	0,67	0,66	43	3	3	0,60	0,50
13	18	21	0,55	0,46	44	2	1	0,80	0,66
14	13	2	0,90	0,86	45	71	13	0,86	0,84
15	0	0	0,29	0	46	4	2	0,62	0,66
16	6	6	0,67	0,50	47	28	3	0,78	0,90
17	150	33	0,87	0,81	48	0	0	0,33	0
18	113	9	0,95	0,92	49	2	1	0,57	0,66
19	125	38	0,79	0,76	50	0	0	0,50	0
20	3	0	0,75	1	51	3	3	0,67	0,50
21	39	6	0,90	0,86	52	0	0	0,67	0
22	54	7	0,65	0,88	53	22	2	0,57	0,91
23	9	6	0,67	0,60	54	40	8	0,89	0,83
24	8	5	0,62	0,61	55	7	8	0,64	0,46
25	3	0	0,50	1	56	26	7	0,83	0,78
26	0	0	1	0	57	17	24	0,57	0,41
27	4	5	0,57	0,44	58	5	4	0,67	0,55
28	41	10	0,75	0,80	59	5	12	0,31	0,29
29	25	3	0,93	0,89	60	7	4	0,78	0,63
30	37	0	1	1	61	89	16	0,86	0,84
Sınıf Bazlı Doğru Sınıflandırma Performansı: %39					Görüntü Sayısı Bazlı Doğru Sınıflandırma Performansı: %79				

Çizelgelerden de görüleceği gibi SIFT özniteliği bu sınıflandırıcı ile kullanıldığında on sınıf %0, beş sınıf %100 ve diğer sınıflar %0,16 ile %0,95 arasında değişen oranlarda doğru sınıflandırılmıştır. SURF özniteliğinin KA ile kullanımında on sınıf %0, üç sınıf

%100 ve diğer sınıflar %0,09 ile %0,95 arasında değişen oranlarda doğru sınıflandırılmıştır. SSIFT özneliliğinin KA ile kullanımında on bir %0, altı sınıf %100 ve diğer sınıflar %0,16 ile %0,97 arasında değişen oranlarda doğru sınıflandırılmıştır. SSURF özneliliğinin KA ile kullanımında dokuz sınıf %0, üç sınıf %100 ve diğer sınıflar %0,18 ile %0,97 arasında değişen oranlarda doğru sınıflandırılmıştır. SIFT+SURF özneliliğinin KA ile birlikte kullanılması ile dokuz sınıf %0, beş sınıf %100 ve diğer sınıflar %0,18 ile %0,96 arasında değişen oranlarda doğru sınıflandırılmıştır.


KA sınıflandırıcısı yöntemi ile yerel öznelilikler birlikte kullanıldığında DVM ve KNN yöntemlerinin aksine yanlışlık sorunun olmadığı görülmektedir.

HOG, HOG+SIFT öznelilikleri ile KA sınıflandırıcısının birlikte kullanıldığı deneylerin doğru sınıflandırma performansları Şekil 4.21’de, konfüzyon matrisleri ise Şekil 4.22 ve Şekil 4.23’de gösterilmiştir.



Şekil 4.21. HOG, HOG+SIFT ve KA sınıflandırıcısı yönteminin doğru sınıflandırma performansları

Şekil 4.22. HOG özniteliği ve KA sınıflandırıcısı yöntemine ait konfüzyon matrisi



Şekil 4.23. HOG+SIFT özneliği ve KA sınıflandırıcısı yöntemine ait konfüzyon matrisi

KA sınıflandırıcısı HOG özneliği ile birlikte kullanıldığında %76, HOG+SIFT özneliği ile birlikte kullanıldığında %77 oranında doğru sınıflandırma performansı elde edilmiştir. Bu özneliklerin sınıf bazlı doğru sınıflandırma performansları Çizelge 4.16 ve Çizelge 4.17’de verilmiştir.

Çizelge 4.16. KA Sınıflandırıcısının ve HOG Özniteliğinin Sınıf Bazlı Sınıflandırma Performansları

Sınıf	Doğru Sayısı	Yanlış Sayısı	F değeri	Sınıflandırma Performansı	Sınıf	Doğru Sayısı	Yanlış Sayısı	F değeri	Sınıflandırma Performansı
0	3	3	0,55	0,50	31	62	24	0,83	0,72
1	27	0	0,95	1	32	396	26	0,94	0,93
2	2	5	0,44	0,28	33	0	0	0,14	0
3	0	6	0	0	34	4	5	0,50	0,44
4	5	7	0,36	0,41	35	74	80	0,63	0,48
5	1	2	0,18	0,33	36	0	0	0,50	0
6	3	3	0,33	0,50	37	23	8	0,52	0,74
7	77	13	0,81	0,85	38	161	52	0,82	0,75
8	8	4	0,53	0,66	39	83	16	0,86	0,83
9	0	0	0,18	0	40	42	6	0,84	0,87
10	5	23	0,26	0,17	41	9	2	0,69	0,81
11	0	0	1	0	42	7	2	0,54	0,77
12	0	3	0	0	43	6	0	0,92	1
13	28	11	0,68	0,71	44	2	1	0,44	0,66
14	15	0	0,71	1	45	52	32	0,69	0,61
15	0	0	0,40	0	46	3	3	0,25	0,50
16	2	10	0,25	0,16	47	24	7	0,80	0,77
17	119	64	0,74	0,65	48	0	0	0,67	0
18	97	25	0,85	0,79	49	2	1	0,09	0,66
19	144	19	0,93	0,88	50	0	1	0	0
20	2	1	0,36	0,66	51	3	3	0,40	0,50
21	32	13	0,80	0,71	52	0	0	0,29	0
22	61	0	0,92	1	53	21	3	0,71	0,87
23	3	12	0,16	0,20	54	44	4	0,87	0,91
24	8	5	0,46	0,61	55	2	13	0,17	0,13
25	1	2	0,10	0,33	56	26	7	0,79	0,78
26	0	0	1	0	57	31	10	0,72	0,75
27	3	6	0,43	0,33	58	3	6	0,38	0,33
28	47	4	0,70	0,92	59	10	7	0,67	0,58
29	15	13	0,70	0,53	60	2	9	0,31	0,18
30	32	5	0,81	0,86	61	96	9	0,88	0,91
Sınıf Bazlı Doğru Sınıflandırma Performansı: %33					Görüntü Sayısı Bazlı Doğru Sınıflandırma Performansı: %76				

Çizelge 4.17. KA Sınıflandırıcısının ve HOG+SIFT Özniteliğinin Sınıf Bazlı Sınıflandırma Performansları


Sınıf	Doğru Sayısı	Yanlış Sayısı	F değeri	Sınıflandırma Performansı	Sınıf	Doğru Sayısı	Yanlış Sayısı	F değeri	Sınıflandırma Performansı
0	3	3	0,67	0,50	31	76	10	0,94	0,88
1	27	0	0,96	1	32	400	22	0,94	0,94
2	0	7	0	0	33	0	0	1	0
3	4	2	0,62	0,66	34	4	5	0,50	0,44
4	2	10	0,12	0,16	35	39	115	0,34	0,25
5	2	1	0,80	0,66	36	0	0	0,67	0
6	5	1	0,22	0,83	37	20	11	0,51	0,64
7	82	8	0,86	0,91	38	157	56	0,83	0,73
8	9	3	0,49	0,75	39	85	14	0,85	0,85
9	0	0	0,25	0	40	43	5	0,88	0,89
10	3	25	0,19	0,10	41	9	2	0,64	0,81
11	0	0	1	0	42	9	0	0,67	1
12	1	2	0,13	0,33	43	6	0	0,75	1
13	19	20	0,38	0,48	44	2	1	0,36	0,66
14	15	0	0,75	1	45	65	19	0,87	0,77
15	0	0	0,20	0	46	3	3	0,32	0,50
16	8	4	0,73	0,66	47	25	6	0,81	0,80
17	120	63	0,77	0,65	48	0	0	1	0
18	109	13	0,94	0,89	49	2	1	0,05	0,66
19	144	19	0,91	0,88	50	0	1	0	0
20	3	0	0,67	1	51	3	3	0,60	0,50
21	34	11	0,84	0,75	52	0	0	0,67	0
22	61	0	0,86	1	53	21	3	0,71	0,87
23	7	8	0,48	0,46	54	45	3	0,90	0,93
24	8	5	0,50	0,61	55	2	13	0,22	0,13
25	3	0	0,67	1	56	26	7	0,84	0,78
26	0	0	1	0	57	23	18	0,71	0,56
27	3	6	0,50	0,33	58	5	4	0,67	0,55
28	48	3	0,78	0,94	59	11	6	0,73	0,64
29	21	7	0,82	0,75	60	2	9	0,31	0,18
30	33	4	0,94	0,89	61	97	8	0,90	0,92
Sınıf Bazlı Doğru Sınıflandırma Performansı: %36					Görüntü Sayısı Bazlı Doğru Sınıflandırma Performansı: %77				

HOG ve HOG+SIFT öznitelikleri bu sınıflandırıcı ile kullanıldığında on bir sınıf %0 dört sınıf %100 ve diğer sınıflar %0,13 ile %0,93 arasında değişen oranlarda doğru sınıflandırılmıştır.


Küresel öznitelik olan HOG özniteliği ve HOG özniteliği ile birleştirilen öznitelikler DVM sınıflandırıcısı ile birlikte kullanıldığında veri setinden bağımsız performans göstermiştir. Bu öznitelikler ile dengesiz veri seti kaynaklı yanlışlık probleminin oluşmadığı tespit edilmiştir.

4.4.3. KNN sınıflandırıcı yöntemi sonuçlarının grafiksel gösterimi


KNN sınıflandırıcısı ve yerel özniteliklerin, birlikte kullanıldığı deneylerden elde edilen sınıf bazlı doğru sınıflandırma performansları Şekil 4.24’de, konfüzyon matrisleri ise Şekil 4.25, Şekil 4.26, Şekil 4.27, Şekil 4.28 ve Şekil 4.29’da gösterilmiştir.




Şekil 4.24. Yerel özniteliklerin ve KNN sınıflandırıcısı yönteminin doğru sınıflandırma performansları




Şekil 4.25. SIFT özneteliği ve KNN sınıflandırıcısı yöntemine ait konfüzyon matrisi




Şekil 4.26. SURF öz niteliği ve KNN sınıflandırıcısı yöntemine ait konfüzyon matrisi



Şekil 4.27. SSIFT özneteliği ve KNN sınıflandırıcısı yöntemine ait konfüzyon matrisi



Şekil 4.28. SSURF özneteliği ve KNN sınıflandırıcısı yöntemine ait konfüzyon matris



Şekil 4.29. SIFT+SURF özniteliği ve KNN sınıflandırıcısı yöntemine ait konfüzyon matris

KNN sınıflandırıcısı, SIFT özniteliği ile birlikte kullanıldığında %63, SURF özniteliği ile birlikte kullanıldığında %30, SSIFT özniteliği ile birlikte kullanıldığında %11, SSURF özniteliği ile birlikte kullanıldığında %14 ve SIFT+SURF ile birlikte kullanıldığında %34 doğru sınıflandırma performansı elde edilmiştir. SIFT, SURF, SSIFT, SSURF ve SIFT+SURF özniteliklerin KNN sınıflandırıcısı ile kullanıldığında elde edilen sınıf bazlı doğru sınıflandırma performansları sırasıyla Çizelge 4.18, Çizelge 4.19, Çizelge 4.20, Çizelge 4.21 ve Çizelge 4.22’te verilmiştir.

Çizelge 4.18. KNN Sınıflandırıcısının ve SIFT Özneteliğinin Sınıf Bazlı Sınıflandırma Performansları

Sınıf	Doğru Sayısı	Yanlış Sayısı	F değeri	Sınıflandırma Performansı	Sınıf	Doğru Sayısı	Yanlış Sayısı	F değeri	Sınıflandırma Performansı
0	1	5	0,29	0,16	31	31	55	0,53	0,36
1	17	10	0,40	0,62	32	410	12	0,96	0,97
2	2	5	0,25	0,28	33	0	0	1	0
3	0	6	0	0	34	1	8	0,05	0,11
4	0	12	0	0	35	60	94	0,55	0,38
5	2	1	0,80	0,66	36	0	0	0,40	0
6	3	3	0,67	0,50	37	30	1	0,98	0,96
7	69	21	0,78	0,76	38	116	97	0,69	0,54
8	5	7	0,48	0,41	39	97	2	0,27	0,97
9	0	0	0,67	0	40	6	42	0,21	0,12
10	21	7	0,78	0,75	41	3	8	0,40	0,27
11	0	0	1	0	42	2	7	0,33	0,22
12	1	2	0,50	0,33	43	0	6	0	0
13	5	34	0,21	0,12	44	0	3	0	0
14	14	1	0,88	0,93	45	15	69	0,30	0,17
15	0	0	0,33	0	46	0	6	0	0
16	3	9	0,38	0,25	47	24	7	0,76	0,77
17	171	12	0,77	0,93	48	0	0	1	0
18	114	8	0,92	0,93	49	0	3	0	0
19	37	126	0,35	0,22	50	0	0	0,67	0
20	3	0	1	1	51	3	3	0,18	0,50
21	41	4	0,89	0,91	52	0	0	1	0
22	27	34	0,60	0,44	53	15	9	0,75	0,62
23	1	14	0,09	0,06	54	14	34	0,42	0,29
24	6	7	0,55	0,46	55	8	7	0,70	0,53
25	1	2	0,50	0,33	56	25	8	0,83	0,75
26	0	0	1	0	57	26	15	0,67	0,63
27	6	3	0,75	0,66	58	3	6	0,50	0,33
28	7	44	0,24	0,13	59	7	10	0,58	0,4
29	15	13	0,64	0,53	60	4	7	0,53	0,36
30	31	6	0,89	0,83	61	78	27	0,71	0,74
Sınıf Bazlı Doğru Sınıflandırma Performansı: %24					Görüntü Sayısı Bazlı Doğru Sınıflandırma Performansı: %63				

Çizelge 4.19. KNN Sınıflandırıcısının ve SURF Özniteliğinin Sınıf Bazlı Sınıflandırma Performansları

Sınıf	Doğru Sayısı	Yanlış Sayısı	F değeri	Sınıflandırma Performansı	Sınıf	Doğru Sayısı	Yanlış Sayısı	F değeri	Sınıflandırma Performansı
0	1	5	0	0,16	31	46	40	0,70	0,53
1	10	17	0,53	0,37	32	121	301	0,45	0,28
2	0	7	0	0	33	0	1	1	0
3	0	6	0	0	34	3	6	0,62	0,33
4	0	12	0	0	35	37	117	0,39	0,24
5	0	3	0	0	36	0	1	1	0
6	0	6	0	0	37	9	22	0,49	0,29
7	17	73	0,31	0,18	38	9	119	0,12	0,07
8	3	9	0,40	0,25	39	24	75	0,39	0,24
9	0	1	1	0	40	7	41	0,24	0,14
10	4	24	0,25	0,14	41	0	11	0	0
11	0	1	1	0	42	2	7	0,33	0,22
12	1	2	0	0,33	43	0	6	0	0
13	6	33	0,27	0,15	44	0	3	0	0
14	1	14	0,24	0,06	45	25	59	0,46	0,29
15	0	1	0,67	0	46	0	6	0	0
16	0	12	0	0	47	8	23	0,41	0,25
17	24	159	0,23	0,13	48	0	0	1	0
18	40	82	0,48	0,32	49	1	2	0,40	0,33
19	162	1	0,15	0,99	50	0	0	0,67	0
20	1	2	0,50	0,33	51	2	4	0,50	0,33
21	31	14	0,83	0,68	52	0	0	0,67	0
22	4	12	0,42	0,25	53	5	19	0,34	0,20
23	0	15	0	0	54	7	41	0,25	0,14
24	5	8	0,44	0,38	55	0	15	0	0
25	2	1	0,86	0,66	56	11	22	0,50	0,33
26	0	0	1	0	57	7	34	0,28	0,17
27	2	7	0,20	0,22	58	3	6	0,50	0,33
28	16	35	0,47	0,31	59	6	11	0,52	0,35
29	13	15	0,63	0,46	60	1	10	0,17	0,09
30	10	27	0,39	0,27	61	17	88	0,27	0,16
Sınıf Bazlı Doğru Sınıflandırma Performansı: %12					Görüntü Sayısı Bazlı Doğru Sınıflandırma Performansı: %30				

Çizelge 4.20. KNN Sınıflandırıcısının ve SSIFT Özneteliğinin Sınıf Bazlı Sınıflandırma Performansları

Sınıf	Doğru Sayısı	Yanlış Sayısı	F değeri	Sınıflandırma Performansı	Sınıf	Doğru Sayısı	Yanlış Sayısı	F değeri	Sınıflandırma Performansı
0	0	6	0	0	31	10	76	0,21	0,11
1	1	26	0,07	0,03	32	135	287	0,48	0,31
2	0	7	0	0	33	0	0	1	0
3	0	6	0	0	34	0	9	0	0
4	0	12	0	0	35	2	152	0,03	0,01
5	0	3	0	0	36	0	0	1	0
6	0	6	0	0	37	18	13	0,73	0,58
7	2	88	0,04	0,02	38	3	210	0,03	0,01
8	0	12	0	0	39	2	97	0,04	0,02
9	0	0	1	0	40	48	0	0,04	1
10	0	28	0	0	41	0	11	0	0
11	0	0	1	0	42	0	9	0	0
12	0	3	0	0	43	0	6	0	0
13	0	39	0	0	44	0	3	0	0
14	0	15	0	0	45	5	79	0,11	0,05
15	0	0	1	0	46	0	6	0	0
16	0	12	0	0	47	0	31	0	0
17	2	181	0,02	0,01	48	0	0	1	0
18	11	111	0,17	0,09	49	0	3	0	0
19	2	161	0,02	0,01	50	0	0	1	0
20	1	2	0,50	0,33	51	0	6	0	0
21	12	33	0,42	0,26	52	0	0	1	0
22	6	55	0,18	0,09	53	2	22	0,15	0,08
23	1	14	0,13	0,06	54	0	48	0	0
24	2	11	0,24	0,15	55	0	15	0	0
25	1	2	0,50	0,33	56	1	32	0,06	0,03
26	0	0	1	0	57	0	41	0	0
27	0	9	0	0	58	0	9	0	0
28	0	51	0	0	59	1	16	0,11	0,05
29	5	23	0,30	0,17	60	0	11	0	0
30	2	35	0,10	0,05	61	0	105	0	0
Sınıf Bazlı Doğru Sınıflandırma Performansı: %4					Görüntü Sayısı Bazlı Doğru Sınıflandırma Performansı: %11				

Çizelge 4.21. KNN Sınıflandırıcısının ve SSURF Özneteliğinin Sınıf Bazlı Sınıflandırma Performansları

Sınıf	Doğru Sayısı	Yanlış Sayısı	F değeri	Sınıflandırma Performansı	Sınıf	Doğru Sayısı	Yanlış Sayısı	F değeri	Sınıflandırma Performansı
0	0	6	0,00	0	31	24	62	0,44	0,27
1	4	23	0,23	0,14	32	111	311	0,42	0,26
2	0	7	0,00	0	33	0	0	1	0
3	0	6	0,00	0	34	1	8	0,20	0,11
4	0	12	0,00	0	35	18	136	0,21	0,11
5	0	3	0,00	0	36	0	0	1	0
6	0	6	0,00	0	37	6	25	0,32	0,19
7	6	84	0,12	0,06	38	0	213	0,00	0
8	0	12	0,00	0	39	6	93	0,11	0,06
9	0	0	1	0	40	48	0	0,04	1
10	0	28	0,00	0	41	0	11	0,00	0
11	0	0	1	0	42	0	9	0,00	0
12	0	3	0,00	0	43	0	6	0,00	0
13	0	39	0,00	0	44	0	3	0,00	0
14	2	13	0,24	0,13	45	9	75	0,19	0,10
15	0	0	1	0	46	0	6	0,00	0
16	1	11	0,15	0,08	47	0	31	0,00	0
17	2	181	0,02	0,01	48	0	0	0,67	0
18	8	114	0,12	0,06	49	0	3	0,00	0
19	16	147	0,18	0,09	50	0	0	1	0
20	0	3	0,00	0	51	3	3	0,67	0,50
21	33	12	0,85	0,73	52	0	0	1	0
22	2	59	0,06	0,03	53	0	24	0,00	0
23	1	14	0,13	0,06	54	5	43	0,19	0,10
24	0	13	0,00	0	55	1	14	0,13	0,06
25	0	3	0,00	0	56	11	22	0,50	0,33
26	0	0	1	0	57	5	36	0,22	0,12
27	0	9	0,00	0	58	1	8	0,20	0,11
28	6	45	0,21	0,11	59	2	15	0,21	0,11
29	17	11	0,76	0,60	60	0	11	0,00	0
30	14	23	0,55	0,37	61	5	100	0,09	0,04
Sınıf Bazlı Doğru Sınıflandırma Performansı: %7					Görüntü Sayısı Bazlı Doğru Sınıflandırma Performansı: %14				

Çizelge 4.22. KNN Sınıflandırıcısının ve SIFT+SURF Özniteliğinin Sınıf Bazlı Sınıflandırma Performansları


Sınıf	Doğru Sayısı	Yanlış Sayısı	F değeri	Sınıflandırma Performansı	Sınıf	Doğru Sayısı	Yanlış Sayısı	F değeri	Sınıflandırma Performansı
0	0	6	0	0	31	42	44	0,66	0,48
1	4	23	0,24	0,14	32	274	148	0,79	0,64
2	0	7	0	0	33	0	0	1	0
3	0	6	0	0	34	4	5	0,62	0,44
4	0	12	0	0	35	33	121	0,35	0,21
5	1	2	0,50	0,33	36	0	0	1	0
6	0	6	0	0	37	21	10	0,81	0,67
7	25	65	0,43	0,27	38	25	188	0,21	0,11
8	3	9	0,40	0,25	39	48	51	0,65	0,48
9	0	0	1	0	40	47	1	0,05	0,97
10	8	20	0,44	0,28	41	0	11	0	0
11	0	0	1	0	42	2	7	0,36	0,22
12	0	3	0	0	43	0	6	0	0
13	2	37	0,10	0,05	44	0	3	0	0
14	5	10	0,50	0,33	45	22	62	0,42	0,26
15	0	0	0,67	0	46	0	6	0	0
16	0	12	0	0	47	8	23	0,41	0,25
17	43	140	0,38	0,23	48	0	0	1	0
18	77	45	0,77	0,63	49	0	3	0	0
19	15	148	0,17	0,09	50	0	0	1	0
20	2	1	0,80	0,66	51	2	4	0,50	0,33
21	35	10	0,88	0,77	52	0	0	0,67	0
22	8	53	0,23	0,13	53	8	16	0,50	0,33
23	1	14	0,13	0,06	54	3	45	0,12	0,06
24	6	7	0,63	0,46	55	0	15	0	0
25	2	1	0,80	0,66	56	13	20	0,57	0,39
26	0	0	1	0	57	6	35	0,24	0,14
27	1	8	0,20	0,11	58	3	6	0,50	0,33
28	4	47	0,15	0,07	59	5	12	0,45	0,29
29	13	15	0,62	0,46	60	1	10	0,17	0,09
30	19	18	0,68	0,51	61	16	89	0,26	0,15
Sınıf Bazlı Doğru Sınıflandırma Performansı: %14					Görüntü Sayısı Bazlı Doğru Sınıflandırma Performansı: %34				

Çizelge 4.18’ da görüldüğü gibi SIFT özniteliği KNN sınıflandırıcısı ile kullanıldığında on beş sınıf %0, bir sınıf %100 ve diğer sınıfları %0,06 ile %0,98 arasında değişen oranlarda doğru sınıflandırılmıştır. SURF özniteliğinin KNN sınıflandırıcısı ile


kullanımında yirmi bir sınıf %0, diğer sınıflar %0,06 ile %0,99 arasında değişen oranlarda doğru sınıflandırılmıştır. SSIFT özneliğinin KNN sınıflandırıcısı ile kullanımında otuz sekiz sınıf %0, bir sınıf %100, diğer sınıflar %0,58 ile %0,01 arasında değişen oranlarda doğru sınıflandırılmıştır. SSURF özneliğinin KNN sınıflandırıcısı ile kullanımında otuz üç sınıf %0, bir sınıf %100, diğer sınıflar %0,06 ile %0,73 arasında değişen oranlarda doğru sınıflandırılmıştır. SIFT+SURF özneliğinin KNN ile birlikte kullanılması ile yirmi iki sınıf %0, diğer sınıflar %0,05 ile %0,98 arasında değişen oranlarda doğru sınıflandırılmıştır.


KNN sınıflandırıcısı yöntemi DVM sınıflandırıcısı yönteminde olduğu gibi yerel özneliliklerle kullanıldığında genelde azınlık sınıflarının doğru sınıflandırılmadığı tespit edilmiştir. Bu sonuç da KNN sınıflandırıcısının dengesiz veri seti üzerinde uygun öğrenme görevini yerine getiremediğini göstermektedir.

KNN sınıflandırıcısının HOG özneliği ve HOG+SIFT özneliği ile kullanımından Şekil 4.30 grafiği ve Şekil 4.31 ve Şekil 4.32 konfüzyon matrisleri elde edilmiştir.



Şekil 4.30. HOG özneliği ve HOG+SIFT özneliğinin KNN sınıflandırıcısı ile uygulandığı deneylerin doğru sınıflandırma performansları





Şekil 4.32. HOG+SIFT özniteliği ve KNN sınıflandırıcısı yöntemine ait konfüzyon matris

KNN sınıflandırıcısı HOG özniteliği ve HOG+SIFT özniteliği ile birlikte kullanıldığında %88 doğru sınıflandırma performansı elde edilmiştir. Elde edilen sonuç, bu özniteliklerin KNN ile birlikte kullanımında doğru sınıflandırma performanslarını değiştirmediyi göstermiştir. Bu özniteliklerin sınıf bazlı doğru sınıflandırma performansları Çizelge 4.23 ve Çizelge 4.24’te verilmiştir.

Çizelge 4.23. KNN Sınıflandırıcısının ve HOG Özniteliğinin Sınıf Bazlı Sınıflandırma Performansları

Sınıf	Doğru Sayısı	Yanlış Sayısı	F değeri	Sınıflandırma Performansı	Sınıf	Doğru Sayısı	Yanlış Sayısı	F değeri	Sınıflandırma Performansı
0	2	4	0,44	0,33	31	86	0	0,99	1
1	27	0	0,95	1	32	420	2	0,99	0,99
2	3	4	0,50	0,42	33	0	0	1	0
3	1	5	0,25	0,16	34	9	0	1	1
4	0	12	0	0	35	129	25	0,91	0,83
5	0	3	0	0	36	0	0	1	0
6	2	4	0,40	0,33	37	30	1	0,98	0,96
7	67	23	0,66	0,74	38	199	14	0,94	0,93
8	3	9	0,19	0,25	39	98	1	0,98	0,98
9	0	0	0,40	0	40	47	1	0,96	0,97
10	19	9	0,68	0,67	41	11	0	0,73	1
11	0	0	0,50	0	42	8	1	0,76	0,88
12	1	2	0,29	0,33	43	2	4	0,50	0,33
13	29	10	0,57	0,74	44	3	0	1	1
14	6	9	0,38	0,40	45	70	14	0,90	0,83
15	0	0	0,10	0	46	5	1	0,53	0,83
16	2	10	0,22	0,16	47	31	0	0,97	1
17	108	75	0,68	0,59	48	0	0	1	0
18	106	16	0,88	0,86	49	3	0	0,50	1
19	163	0	1	1	50	0	0	0,50	0
20	3	0	1	1	51	3	3	0,67	0,50
21	43	2	0,98	0,95	52	0	0	0,67	0
22	61	0	1	1	53	24	0	0,96	1
23	13	2	0,84	0,86	54	47	1	0,99	0,97
24	10	3	0,87	0,76	55	14	1	0,97	0,93
25	3	0	0,60	1	56	26	7	0,64	0,78
26	0	0	1	0	57	21	20	0,61	0,51
27	9	0	1	1	58	9	0	1	1
28	49	2	0,91	0,96	59	15	2	0,94	0,88
29	28	0	0,98	1	60	11	0	1	1
30	37	0	1	1	61	105	0	1	1
Sınıf Bazlı Doğru Sınıflandırma Performansı: %41					Görüntü Sayısı Bazlı Doğru Sınıflandırma Performansı: %88				

Çizelge 4.24. KNN Sınıflandırıcısının ve HOG+SIFT Özniteliğinin Sınıf Bazlı Sınıflandırma Performansları


Sınıf	Doğru Sayısı	Yanlış Sayısı	F değeri	Sınıflandırma Performansı	Sınıf	Doğru Sayısı	Yanlış Sayısı	F değeri	Sınıflandırma Performansı
0	2	4	0,44	0,33	31	86	0	0,99	1
1	27	0	0,95	1	32	420	2	0,99	0,99
2	3	4	0,50	0,42	33	0	0	1	0
3	1	5	0,25	0,16	34	9	0	1	1
4	0	12	0	0	35	129	25	0,91	0,83
5	0	3	0	0	36	0	0	1	0
6	2	4	0,40	0,33	37	30	1	0,98	0,96
7	67	23	0,66	0,74	38	199	14	0,94	0,93
8	3	9	0,19	0,25	39	98	1	0,98	0,98
9	0	0	0,40	0	40	47	1	0,97	0,97
10	19	9	0,68	0,67	41	11	0	0,73	1
11	0	0	0,50	0	42	9	0	0,82	1
12	1	2	0,29	0,33	43	2	4	0,50	0,33
13	29	10	0,57	0,74	44	3	0	1	1
14	6	9	0,38	0,40	45	70	14	0,90	0,83
15	0	0	0,10	0	46	5	1	0,53	0,83
16	2	10	0,22	0,16	47	31	0	0,97	1
17	108	75	0,68	0,59	48	0	0	1	0
18	106	16	0,88	0,86	49	3	0	0,50	1
19	163	0	1	1	50	0	0	0,50	0
20	3	0	1	1	51	3	3	0,67	0,50
21	43	2	0,98	0,95	52	0	0	0,67	0
22	61	0	1	1	53	24	0	0,96	1
23	13	2	0,84	0,86	54	47	1	0,99	0,97
24	10	3	0,87	0,76	55	14	1	0,97	0,93
25	3	0	0,60	1	56	26	7	0,64	0,78
26	0	0	1	0	57	21	20	0,61	0,51
27	9	0	1	1	58	9	0	1	1
28	49	2	0,91	0,96	59	15	2	0,94	0,88
29	28	0	0,98	1	60	11	0	1	1
30	37	0	1	1	61	105	0	1	1
Sınıf Bazlı Doğru Sınıflandırma Performansı: %41					Görüntü Sayısı Bazlı Doğru Sınıflandırma Performansı: %88				

HOG özniteliği bu sınıflandırıcı ile kullanıldığında on bir sınıf %0, on sekiz sınıf %100 ve diğer sınıflar %0,16 ile %0,99 arasında değişen oranlarda doğru sınıflandırıldığı Çizelge 4.23'te verilmiştir. HOG+SIFT özniteliğinin KNN ile birlikte kullanılması ile

on bir sınıf %0, on dokuz sınıf %100 ve diğer sınıflar %0,16 ile %0,99 arasında değişen oranlarda doğru sınıflandırıldığı Çizelge 4.24’te verilmiştir.


4.4.4. TTT sınıflandırıcı yöntemi sonuçlarının grafiksel gösterimi

TTT sınıflandırıcısı ve yerel özniteliklerin kullanıldığı yöntemde dengesiz veri seti olan BTİT veri setinden elde edilen doğruluk yüzdeleri Şekil 4.33, konfüzyon matrisleri ise Şekil 4.34, Şekil 4.35, Şekil 4.36, Şekil 4.37 ve Şekil 4.38’de gösterilmiştir.




Şekil 4.33. Yerel öznitelikler ve TTT sınıflandırıcısı yönteminin doğru sınıflandırma performansları

Şekil 4.34. SIFT özneliği ve TTT sınıflandırıcısı yöntemine ait konfüzyon matris




Şekil 4.35. SURF öz niteliği ve TTT sınıflandırıcısı yöntemine ait konfüzyon matris

Şekil 4.36. SSIFT özneteliği ve TTT sınıflandırıcısı yöntemine ait konfüzyon matris



Şekil 4.37. SSURF öznetiği ve TTT sınıflandırıcısı yöntemine ait konfüzyon matrisi



Şekil 4.38. SIFT+SURF özneliği ve TTT sınıflandırıcısı yöntemine ait konfüzyon matris

TTT sınıflandırıcısı SIFT özneliği ile birlikte kullanıldığında %88, SURF özneliği ile birlikte kullanıldığında %88, SSIFT özneliği ile birlikte kullanıldığında %86, SSURF özneliği ile birlikte kullanıldığında %90 ve SIFT+SURF ile birlikte kullanıldığında %91 doğru sınıflandırma performansı elde edilmiştir. SIFT, SURF, SSIFT, SSURF ve SIFT+SURF özneliklerin KNN sınıflandırıcısı ile kullanıldığında elde edilen sınıf bazlı doğru sınıflandırma performansları sırasıyla Çizelge 4.25, Çizelge 4.26, Çizelge 4.27, Çizelge 4.28 ve Çizelge 4.29’da verilmiştir.

Çizelge 4.25. TTT Sınıflandırıcısının ve SIFT Özniteliğinin Sınıf Bazlı Sınıflandırma Performansları

Sınıf	Doğru Sayısı	Yanlış Sayısı	F değeri	Sınıflandırma Performansı	Sınıf	Doğru Sayısı	Yanlış Sayısı	F değeri	Sınıflandırma Performansı
0	5	1	0,91	0,83	31	79	7	0,96	0,91
1	27	0	0,86	1	32	420	2	0,99	0,99
2	7	0	1	1	33	0	0	1	0
3	0	6	0	0	34	4	5	0,15	0,44
4	10	2	0,87	0,83	35	70	84	0,61	0,45
5	3	0	1	1	36	0	0	1	0
6	6	0	1	1	37	31	0	1	1
7	90	0	0,99	1	38	205	8	0,98	0,96
8	9	3	0,49	0,75	39	99	0	0,99	1
9	0	0	1	0	40	40	8	0,47	0,83
10	21	7	0,86	0,75	41	8	3	0,70	0,72
11	0	0	1	0	42	6	3	0,80	0,66
12	2	1	0,80	0,66	43	0	6	0	0
13	10	29	0,39	0,25	44	3	0	1	1
14	14	1	0,93	0,93	45	70	14	0,89	0,83
15	0	0	1	0	46	3	3	0,55	0,50
16	8	4	0,80	0,66	47	31	0	0,89	1
17	174	9	0,97	0,95	48	0	0	1	0
18	116	6	0,97	0,95	49	0	3	0	0
19	152	11	0,87	0,93	50	0	0	1	0
20	3	0	1	1	51	3	3	0,67	0,50
21	41	4	0,95	0,91	52	0	0	1	0
22	58	3	0,82	0,95	53	24	0	0,58	1
23	7	8	0,64	0,46	54	44	4	0,95	0,91
24	11	2	0,85	0,84	55	13	2	0,90	0,86
25	3	0	1	1	56	31	2	0,97	0,93
26	0	0	1	0	57	23	18	0,70	0,56
27	7	2	0,88	0,77	58	8	1	0,94	0,88
28	38	13	0,79	0,74	59	12	5	0,83	0,70
29	24	4	0,92	0,85	60	8	3	0,84	0,72
30	37	0	1	1	61	102	3	0,94	0,97
Sınıf Bazlı Doğru Sınıflandırma Performansı: %41					Görüntü Sayısı Bazlı Doğru Sınıflandırma Performansı: %88				

Çizelge 4.26. TTT Sınıflandırıcısının ve SURF Özniteliğinin Sınıf Bazlı Sınıflandırma Performansları

Sınıf	Doğru Sayısı	Yanlış Sayısı	F değeri	Sınıflandırma Performansı	Sınıf	Doğru Sayısı	Yanlış Sayısı	F değeri	Sınıflandırma Performansı
0	5	1	0,71	0,83	31	79	7	0,96	0,91
1	27	0	0,86	1	32	419	3	0,99	0,99
2	6	1	1	0,85	33	0	0	1	0
3	1	5	0	0,16	34	5	4	0,15	0,55
4	10	2	0,87	0,83	35	70	84	0,61	0,45
5	3	0	1	1	36	0	0	1	0
6	6	0	1	1	37	31	0	1	1
7	90	0	0,99	1	38	125	3	0,98	0,97
8	9	3	0,49	0,75	39	99	0	0,99	1
9	0	0	1	0	40	40	8	0,47	0,83
10	20	8	0,86	0,71	41	8	3	0,70	0,72
11	0	0	1	0	42	6	3	0,80	0,66
12	2	1	0,80	0,66	43	0	6	0	0
13	11	28	0,39	0,28	44	3	0	1	1
14	14	1	0,93	0,93	45	70	14	0,89	0,83
15	0	0	1	0	46	3	3	0,55	0,50
16	9	3	0,80	0,75	47	31	0	0,89	1
17	174	9	0,97	0,95	48	0	0	1	0
18	116	6	0,97	0,95	49	0	3	0	0
19	152	11	0,87	0,93	50	0	0	1	0
20	3	0	1	1	51	3	3	0,67	0,50
21	41	4	0,95	0,91	52	0	0	1	0
22	12	4	0,81	0,75	53	24	0	0,58	1
23	6	9	0,64	0,40	54	44	4	0,95	0,91
24	11	2	0,85	0,84	55	13	2	0,90	0,86
25	3	0	1	1	56	31	2	0,97	0,93
26	0	0	1	0	57	23	18	0,70	0,56
27	7	2	0,88	0,77	58	8	1	0,94	0,88
28	37	14	0,79	0,72	59	12	5	0,83	0,70
29	24	4	0,92	0,85	60	8	3	0,84	0,72
30	37	0	1	1	61	102	3	0,94	0,97
Sınıf Bazlı Doğru Sınıflandırma Performansı: %41					Görüntü Sayısı Bazlı Doğru Sınıflandırma Performansı: %88				

Çizelge 4.27. TTT Sınıflandırıcısının ve SSIFT Özniteliğinin Sınıf Bazlı Sınıflandırma Performansları

Sınıf	Doğru Sayısı	Yanlış Sayısı	F değeri	Sınıflandırma Performansı	Sınıf	Doğru Sayısı	Yanlış Sayısı	F değeri	Sınıflandırma Performansı
0	2	4	0,50	0,33	31	75	11	0,91	0,87
1	22	5	0,83	0,81	32	417	5	0,99	0,98
2	7	0	1	1	33	0	0	1	0
3	0	6	0	0	34	5	4	0,26	0,55
4	10	2	0,74	0,83	35	60	94	0,56	0,38
5	3	0	1	1	36	0	0	1	0
6	6	0	1	1	37	31	0	1	1
7	89	1	0,99	0,98	38	203	10	0,97	0,95
8	7	5	0,47	0,58	39	96	3	0,98	0,96
9	0	0	1	0	40	34	14	0,43	0,70
10	24	4	0,91	0,85	41	6	5	0,50	0,54
11	0	0	1	0	42	7	2	0,82	0,77
12	3	0	1	1	43	0	6	0	0
13	15	24	0,50	0,38	44	3	0	1	1
14	14	1	0,90	0,93	45	69	15	0,88	0,82
15	0	0	1	0	46	3	3	0,60	0,50
16	7	5	0,74	0,58	47	30	1	0,80	0,96
17	175	8	0,96	0,95	48	0	0	1	0
18	117	5	0,97	0,95	49	0	3	0	0
19	140	23	0,80	0,85	50	0	0	1	0
20	3	0	1	1	51	3	3	0,60	0,50
21	41	4	0,95	0,91	52	0	0	1	0
22	54	7	0,67	0,88	53	23	1	0,49	0,95
23	10	5	0,80	0,66	54	39	9	0,89	0,81
24	13	0	0,93	1	55	9	6	0,75	0,60
25	3	0	1	1	56	31	2	0,94	0,93
26	0	0	1	0	57	19	22	0,60	0,46
27	9	0	1	1	58	7	2	0,88	0,77
28	34	17	0,62	0,66	59	13	4	0,84	0,76
29	28	0	1	1	60	7	4	0,78	0,63
30	37	0	1	1	61	100	5	0,91	0,95
Sınıf Bazlı Doğru Sınıflandırma Performansı: %41					Görüntü Sayısı Bazlı Doğru Sınıflandırma Performansı: %86				

Çizelge 4.28. TTT Sınıflandırıcısının ve SSURF Özneteliğinin Sınıf Bazlı Sınıflandırma Performansları

Sınıf	Doğru Sayısı	Yanlış Sayısı	F değeri	Sınıflandırma Performansı	Sınıf	Doğru Sayısı	Yanlış Sayısı	F değeri	Sınıflandırma Performansı
0	3	3	0,50	0,50	31	86	0	1	1
1	25	2	0,77	0,92	32	420	2	0,99	0,99
2	6	1	0,92	0,85	33	0	0	1	0
3	2	4	0,50	0,33	34	9	0	0,90	1
4	7	5	0,70	0,58	35	65	89	0,59	0,42
5	3	0	1	1	36	0	0	1	0
6	5	1	0,91	0,83	37	27	4	0,93	0,87
7	90	0	0,98	1	38	202	11	0,97	0,94
8	7	5	0,50	0,58	39	96	3	0,97	0,96
9	0	0	1	0	40	47	1	0,76	0,97
10	25	3	0,94	0,89	41	9	2	0,67	0,81
11	0	0	0,67	0	42	8	1	0,89	0,88
12	3	0	0,86	1	43	5	1	0,83	0,83
13	33	6	0,80	0,84	44	3	0	0,86	1
14	15	0	0,73	1	45	71	13	0,89	0,84
15	0	0	0,67	0	46	3	3	0,50	0,50
16	0	12	0,00	0	47	30	1	0,92	0,96
17	178	5	0,97	0,97	48	0	0	1	0
18	119	3	0,96	0,97	49	2	1	0,50	0,66
19	161	2	0,97	0,98	50	0	0	1	0
20	2	1	0,57	0,66	51	3	3	0,67	0,50
21	42	3	0,97	0,93	52	0	0	1	0
22	61	0	0,75	1	53	24	0	0,98	1
23	7	8	0,64	0,46	54	47	1	0,99	0,97
24	10	3	0,83	0,76	55	9	6	0,75	0,60
25	3	0	0,75	1	56	33	0	0,90	1
26	0	0	1	0	57	27	14	0,77	0,65
27	7	2	0,82	0,77	58	8	1	0,94	0,88
28	41	10	0,63	0,80	59	15	2	0,88	0,88
29	28	0	1	1	60	2	9	0,31	0,18
30	37	0	0,97	1	61	104	1	0,94	0,99
Sınıf Bazlı Doğru Sınıflandırma Performansı: %43					Görüntü Sayısı Bazlı Doğru Sınıflandırma Performansı: %90				

Çizelge 4.29. TTT Sınıflandırıcısının ve SIFT+SURF Özniteliğinin Sınıf Bazlı Sınıflandırma Performansları


Sınıf	Doğru Sayısı	Yanlış Sayısı	F değeri	Sınıflandırma Performansı	Sınıf	Doğru Sayısı	Yanlış Sayısı	F değeri	Sınıflandırma Performansı
0	5	1	0,91	0,83	31	84	2	0,99	0,97
1	27	0	0,93	1	32	420	2	1	0,99
2	7	0	1	1	33	0	0	1	0
3	0	6	0	0	34	8	1	0,80	0,88
4	12	0	0,96	1	35	91	63	0,74	0,59
5	3	0	1	1	36	0	0	1	0
6	6	0	1	1	37	31	0	1	1
7	90	0	0,99	1	38	202	11	0,97	0,94
8	11	1	0,56	0,91	39	97	2	0,99	0,97
9	0	0	1	0	40	43	5	0,48	0,89
10	23	5	0,90	0,82	41	9	2	0,82	0,81
11	0	0	1	0	42	9	0	1	1
12	2	1	0,80	0,66	43	5	1	0,91	0,83
13	16	23	0,56	0,41	44	2	1	0,80	0,66
14	15	0	1	1	45	75	9	0,92	0,89
15	0	0	1	0	46	3	3	0,55	0,50
16	8	4	0,80	0,66	47	31	0	0,90	1
17	174	9	0,97	0,95	48	0	0	1	0
18	116	6	0,97	0,95	49	0	3	0	0
19	158	5	0,94	0,96	50	0	0	1	0
20	3	0	1	1	51	3	3	0,67	0,50
21	41	4	0,95	0,91	52	0	0	1	0
22	57	4	0,82	0,93	53	24	0	0,62	1
23	12	3	0,89	0,80	54	47	1	0,98	0,97
24	11	2	0,88	0,84	55	10	5	0,80	0,66
25	3	0	1	1	56	33	0	0,97	1
26	0	0	1	0	57	24	17	0,74	0,58
27	8	1	0,94	0,88	58	8	1	0,94	0,88
28	48	3	0,93	0,94	59	14	3	0,88	0,82
29	28	0	1	1	60	5	6	0,63	0,45
30	37	0	1	1	61	104	1	0,95	0,99
Sınıf Bazlı Doğru Sınıflandırma Performansı: %44					Görüntü Sayısı Bazlı Doğru Sınıflandırma Performansı: %91				

SIFT özniteliği bu sınıflandırıcı ile kullanıldığında on iki sınıf %0, on üç sınıf %100 ve diğer sınıflar %0,25 ile %0,99 arasında değişen oranlarda doğru sınıflandırılmıştır. SURF özniteliğinin TTT ile kullanımında on bir sınıf %0, on iki sınıf %100 ve diğer

sınıflar %0,16 ile %0,99 arasında değişen oranlarda doğru sınıflandırılmıştır. SSIFT özneliğinin TTT ile kullanımında on iki sınıf %0, on iki sınıf %100 ve diğer sınıflar %0,33 ile %0,99 arasında değişen oranlarda doğru sınıflandırılmıştır. SSURF özneliğinin TTT ile kullanımında on sınıf %0, on üç sınıf %100 ve diğer sınıflar %0,18 ile %0,99 arasında değişen oranlarda doğru sınıflandırılmıştır. SIFT+SURF özneliğinin TTT ile birlikte kullanılması ile on bir sınıf %0, on altı sınıf %100 ve diğer sınıflar %0,41 ile %0,99 arasında değişen oranlarda doğru sınıflandırılmıştır.


TTT sınıflandırıcısı, yerel özneliklerin kullanıldığı çalışmalarda azınlık sınıflarını doğru sınıflandırarak yanlışlık sorununu çözmüştür. Şekil 4.33'ten anlaşılabacağı gibi yerel özneliklerden elde edilen sınıflandırma performansı küresel öznelik yöntemi olan HOG özneliği ile elde edilen sınıflandırma performansına oldukça yakındır.

HOG özneliği, HOG+SIFT özneliği ve TTT sınıflandırıcısının birlikte kullanıldığı deneylerin doğru sınıflandırma performansları Şekil 4.39'da, konfüzyon matrisleri ise Şekil 4.40 ve Şekil 4.41'de gösterilmiştir.



Şekil 4.39. HOG özneliği, HOG+SIFT özneliği ve TTT sınıflandırıcısı yönteminin doğru sınıflandırma performansları





Şekil 4.41. HOG+SIFT özneteliği ve TTT sınıflandırıcısı yöntemine ait konfüzyon matris

TTT sınıflandırıcı HOG özneteliği ile birlikte kullanıldığında %94 ve HOG+SIFT özneteliği birlikte kullanıldığında ise %95 doğru sınıflandırma performansı elde edilmiştir. HOG, HOG+SIFT özneteliklerin sınıf bazlı doğru sınıflandırma performansları Çizelge 4.30 ve Çizelge 4.31’de verilmiştir.

Çizelge 4.30. TTT Sınıflandırıcısının ve HOG Özniteliğinin Sınıf Bazlı Sınıflandırma Performansları

Sınıf	Doğru Sayısı	Yanlış Sayısı	F değeri	Sınıflandırma Performansı	Sınıf	Doğru Sayısı	Yanlış Sayısı	F değeri	Sınıflandırma Performansı
0	6	0	1	1	31	85	1	0,99	0,98
1	27	0	0,98	1	32	421	1	0,99	0,99
2	3	4	0,60	0,42	33	0	0	1	0
3	3	3	0,67	0,50	34	9	0	1	1
4	7	5	0,74	0,58	35	127	27	0,90	0,82
5	3	0	1	1	36	0	0	1	0
6	2	4	0,50	0,33	37	30	1	0,95	0,96
7	88	2	0,93	0,97	38	209	4	0,96	0,98
8	12	0	0,96	1	39	99	0	0,99	1
9	0	0	0,67	0	40	45	3	0,95	0,93
10	20	8	0,83	0,71	41	11	0	0,63	1
11	0	0	1	0	42	9	0	1	1
12	2	1	0,80	0,66	43	6	0	1	1
13	36	3	0,92	0,92	44	3	0	1	1
14	15	0	0,63	1	45	77	7	0,94	0,91
15	0	0	1	0	46	3	3	0,67	0,50
16	2	10	0,29	0,16	47	31	0	0,87	1
17	174	9	0,94	0,95	48	0	0	1	0
18	119	3	0,97	0,97	49	3	0	0,67	1
19	163	0	0,98	1	50	0	0	1	0
20	3	0	1	1	51	3	3	0,67	0,50
21	42	3	0,97	0,93	52	0	0	1	0
22	61	0	0,91	1	53	24	0	1	1
23	0	15	0	0	54	48	0	0,99	1
24	10	3	0,87	0,76	55	12	3	0,89	0,80
25	3	0	0,86	1	56	33	0	0,75	1
26	0	0	1	0	57	20	21	0,66	0,48
27	6	3	0,80	0,66	58	6	3	0,80	0,66
28	51	0	0,92	1	59	14	3	0,90	0,82
29	28	0	1	1	60	9	2	0,90	0,81
30	36	1	0,99	0,97	61	105	0	0,99	1
Sınıf Bazlı Doğru Sınıflandırma Performansı: %45					Görüntü Sayısı Bazlı Doğru Sınıflandırma Performansı: %94				

Çizelge 4.31. TTT Sınıflandırıcısının ve HOG+SIFT Özniteliğinin Sınıf Bazlı Sınıflandırma Performansları

Sınıf	Doğru Sayısı	Yanlış Sayısı	F değeri	Sınıflandırma Performansı	Sınıf	Doğru Sayısı	Yanlış Sayısı	F değeri	Sınıflandırma Performansı
0	6	0	1	1	31	85	1	0,99	0,98
1	27	0	0,96	1	32	421	1	0,99	0,99
2	3	4	0,60	0,42	33	0	0	1	0
3	2	4	0,50	0,33	34	9	0	1	1
4	10	2	0,91	0,83	35	128	26	0,91	0,83
5	3	0	1	1	36	0	0	1	0
6	4	2	0,80	0,66	37	31	0	1	1
7	90	0	0,96	1	38	210	3	0,96	0,98
8	11	1	0,88	0,91	39	99	0	0,97	1
9	0	0	1	0	40	45	3	0,95	0,93
10	23	5	0,90	0,82	41	11	0	0,67	1
11	0	0	1	0	42	8	1	0,89	0,88
12	3	0	1	1	43	5	1	0,91	0,83
13	36	3	0,94	0,92	44	3	0	1	1
14	15	0	0,67	1	45	77	7	0,94	0,91
15	0	0	1	0	46	3	3	0,67	0,50
16	0	12	0	0	47	31	0	0,87	1
17	179	4	0,96	0,97	48	0	0	1	0
18	119	3	0,98	0,97	49	3	0	0,67	1
19	163	0	0,99	1	50	0	0	1	0
20	3	0	1	1	51	3	3	0,67	0,50
21	42	3	0,97	0,93	52	0	0	1	0
22	61	0	0,95	1	53	24	0	0,96	1
23	0	15	0	0	54	48	0	1	1
24	10	3	0,87	0,76	55	12	3	0,89	0,80
25	3	0	1	1	56	33	0	0,80	1
26	0	0	1	0	57	26	15	0,78	0,63
27	9	0	1	1	58	6	3	0,80	0,66
28	51	0	0,90	1	59	13	4	0,87	0,76
29	28	0	1	1	60	9	2	0,90	0,81
30	37	0	1	1	61	105	0	0,99	1
Sınıf Bazlı Doğru Sınıflandırma Performansı: %46					Görüntü Sayısı Bazlı Doğru Sınıflandırma Performansı: %95				

HOG özniteliği bu sınıflandırıcı ile kullanıldığında on sınıf %0, yirmi üç sınıf %100 ve diğer sınıflar %0,16 ile %0,99 arasında değişen oranlarda doğru sınıflandırılmıştır. HOG+SIFT özniteliğinin TTT sınıflandırıcısı ile birlikte kullanılması ile on bir sınıf

%0, yirmi beş sınıf %100 ve diğer sınıflar %0,11 ile %0,99 arasında değişen oranlarda doğru sınıflandırılmıştır.

TTT sınıflandırıcısının HOG+SIFT özniteliği ile birlikte kullanıldığı yöntemin doğru sınıflandırma performansının HOG özniteliği ile birlikte kullanıldığı yöntemle kıyasla %1 oranında artış gösterdiği tespit edilmiştir.

4.5. Özet

Bu bölümde geliştirilen dengesiz veri seti üzerinde TSR sisteminin deneysel sonuçları verilmiştir. Önerilen TSR sistemi BTİT veri seti üzerinde test edilmiştir. Bu TSR sisteminin iki ana aşaması vardır: öznitelik çıkarımı ve sınıflandırma. Her aşama detaylı olarak BTİT veri seti üzerinde önerilen algoritma ile analiz edilmiştir. Ayrıca önerilen sistemin literatürdeki TSR sistemleri ile karşılaştırılabilmesi için HOG özniteliği, KNN sınıflandırıcısı, KA sınıflandırıcısı ve DVM sınıflandırıcısı kullanılmıştır.

HOG, SIFT, SURF, SSIFT, SSURF, HOG+SIFT, HOG+SSIFT, HOG+SSURF ve SIFT+SURF öznitelikleri DVM, KNN, KA ve TTT sınıflandırıcıları ile BTİT veri setine uygulanarak geliştirilen çalışmadan elde edilen doğru sınıflandırma performansı Çizelge 4.32’de verilmiştir.

Çizelge 4.32. Sınıflandırma Performansları

Öznitelik	Sınıflandırıcı	Yüzdelik	Sınıf sayısı bazlı yüzdelik oran
DVM	SIFT	0,36	0,8
DVM	SURF	0,68	0,21
DVM	SSIFT	0,87	0,41
DVM	SSURF	0,89	0,41
DVM	SIFT+SURF	0,81	0,28
DVM	HOG	0,95	0,48
DVM	HOG+SIFT	0,96	0,48
DVM	HOG+SSIFT	0,96	0,48
DVM	HOG+SSURF	0,96	0,48

Çizelge 4.32. (devam)

KNN	SIFT	0,63	0,24
KNN	SURF	0,30	0,12
KNN	SSIFT	0,11	0,4
KNN	SSURF	0,14	0,7
KNN	SIFT+SURF	0,34	0,14
KNN	HOG	0,88	0,41
KNN	HOG+SIFT	0,88	0,41
KA	SIFT	0,78	0,35
KA	SURF	0,78	0,37
KA	SSIFT	0,76	0,36
KA	SSURF	0,81	0,37
KA	SIFT+SURF	0,79	0,39
KA	HOG	0,76	0,32
KA	HOG+SIFT	0,77	0,36
TTT	SIFT	0,88	0,41
TTT	SURF	0,88	0,41
TTT	SSIFT	0,86	0,41
TTT	SSURF	0,90	0,43
TTT	SIFT+SURF	0,91	0,44
TTT	HOG	0,94	0,45
TTT	HOG+SIFT	0,95	0,46

Çizelge 4.32 incelendiğinde en düşük doğru sınıflandırma performansının SSIFT özneliliğinin KNN sınıflandırıcısı ile kullanılması sonucu elde edildiği gözlenmiştir. Yerel özneliliklerin kullanıldığı uygulamalarda en yüksek doğru sınıflandırma performans sonucuna SIFT+SURF özneliliği ile TTT sınıflandırıcısının kullanılması ile ulaşılmıştır. Küresel öznelilik olan HOG' un kullanıldığı deneysel çalışmalarda ise en yüksek doğru sınıflandırma performansı HOG+SIFT, HOG+SSIFT, HOG+SSURF öznelilikleri ve DVM sınıflandırıcısı ile elde edilmiştir. Ancak araştırmamızda yerel özneliliklerin dengesiz veri seti kullanımı esnasında ortaya çıkan problemler üzerine odaklanılmıştır.

Deneysel sonuçlara göre SIFT ve SURF öznelilikleri klasik sınıflandırıcılar ile kullanıldığında başarılı sonuçlar elde edilemezken önerilen SSIFT, SSURF öznelilikleri

ile başarılı sonuçlar elde edilmiştir. Ayrıca SIFT ve SURF özniteliklerinin kullanıldığı uygulamaların dengesiz veri seti kaynaklı performans düşüklüğü TTT sınıflandırıcısı sayesinde artırılmıştır.



5. SONUÇ ve ÖNERİLER

Bu çalışmada trafik işareti otomatik tanıma sistemi, dengesiz veri seti olan BTİT veri seti üzerinde iki yerel özniteliğin ve bir küresel özniteliğin farklı kombinasyonlarından elde edilen dokuz öznitelik ile dört farklı sınıflandırıcı yöntemi kullanılarak uygulanmıştır.

BTİT veri seti kullanılarak geliştirilen uygulamaların doğru sınıflandırma performansları karşılaştırıldığında HOG+SSIFT, HOG+SSURF, HOG+SIFT özniteliklerinin ve DVM sınıflandırıcısının en yüksek doğru sınıflandırma performansına sahip olduğu gözlemlenmiştir. Çünkü HOG özniteliği tüm görüntünün bölümlenmesi ile elde edilen küresel bir özniteliktir. Böylelikle veri seti sınıflarındaki örnek dağılımından etkilenmemektedir. Fakat bu çalışmada, ilgi nokta tabanlı tanımlayıcıların avantajlarından faydalanılmasını sağlayan yerel özniteliklerin dengesiz veri seti ile kullanılmasından kaynaklanan probleme odaklanılmıştır. SIFT ve SURF öznitelikleri kullanılarak SSIFT ve SSURF diye adlandırılan iki yeni öznitelik önerilmiştir. Dengesiz veri seti olan BTİT veri seti üzerinde SSIFT özniteliği ve KNN sınıflandırıcısının birlikte kullanıldığı yöntem, en düşük performansa sahip yöntem olmuştur. İkinci en düşük performansa sahip yöntem ise SSURF özniteliği ve KNN sınıflandırıcısının birlikte kullanıldığı yöntem olmuştur. Doğru sınıflandırma performanslarından da anlaşılacağı gibi DVM ve KNN sınıflandırıcıları, yerel öznitelikler ile birlikte kullanıldığı yöntemlerde başarısız olmuştur. Bu sınıflandırıcıların SIFT ve SURF öznitelikleri ile kullanıldığı deneylerde azınlık sınıflarındaki görüntüler çoğunluk sınıfı etiketiyle etiketlenmiştir. Azınlık sınıflarının göz ardı edilmesinden kaynaklanan yanlışlık sorununun çözümü için önerilen SSIFT, SSURF öznitelikleri ve TTT sınıflandırıcısı ile azınlık sınıfları doğru sınıflandırılarak sınıflandırıcı performansının artırılması sağlanmıştır.

Trafik işaretleri otomatik tanıma sistemlerinde araçların hareketli olmasından dolayı yöntemlerin çalışma hızları oldukça önemlidir. SSIFT özniteliği, bazı SIFT tanımlayıcılarının (SURF komşusu olmayan tanımlayıcılar) elenmesinden dolayı SIFT

özniteliğine kıyasla daha hızlı bir öznitelik olmuştur. SSURF özniteliğinde de SSIFT özniteliğinde olduğu gibi bazı tanımlayıcılar (SURF komşusu olmayan tanımlayıcılar) elenmiştir. Bu nedenle SSURF özniteliğinin SURF özniteliğine kıyasla daha hızlı bir öznitelik olduğu tespit edilmiştir. SIFT+SURF özniteliği, SIFT ve SURF öznitelik histogramlarının birleştirilmesinden elde edilmiştir. Birleşmeden kaynaklı daha büyük bir öznitelik histogramına sahip olan SIFT+SURF özniteliğinin SIFT ve SURF özniteliklerine kıyasla daha yavaş bir öznitelik olduğu gözlemlenmiştir. Ayrıca HOG+SIFT, HOG+SURF, HOG+SSIFT ve HOG+SSURF öznitelikleri de öznitelik histogramlarının birleştirilmesi ile elde edildiğinden dolayı HOG, SIFT, SURF, SSIFT ve SSURF özniteliklerine kıyasla daha fazla çalışma zamanına ihtiyaç duymuşlardır.

İleriki çalışmalarda PCA-SIFT, dense SIFT gibi yerel öznitelikler ve farklı algoritmalar kullanılarak yerel öznitelik tabanlı TSR sisteminin daha kapsamlı ve başarılı bir hale getirilmesi planlanmaktadır.

KAYNAKLAR

- Alefs, B., Eschemann, G., Ramoser, H., Beleznaï, C., 2007. Road sign detection from edge orientation histograms. IEEE Intelligent Vehicles Symposium, İstanbul.
- Azad, P., Asfour, T., Dillmann, R., 2009. Combining Harris interest points and the SIFT descriptor for fast scale-invariant object recognition. IEEE RSJ International Conference On Intelligent Robots And Systems, Germany.
- Aydın, Y., Özdemir, D., Özyer, G.T., 2016. Traffic Sign Recognition System For Imbalanced Dataset. 2016 2nd International Conference on Computer and Information Technology (ICCIT 2016), İstanbul.
- Aydın, Y., Özyer, G.T., Özdemir, D., 2016. Ölçeklemeden Bağımsız Öznitelik Dönüşümü Ve Torbalama Temelli Ensemble Kullanarak Trafik İşaretlerinin Tanınması. 24. Sinyal İşleme ve İletişim Uygulamaları Kurultayı, Zonguldak.
- Barandela, R., Valdovinos, R.M., Sanchez, J.S., 2003. New applications of ensembles of classifiers. Pattern Analysis And Applications, 6(3), 245–256.
- Bay, H., Tuytelaars, T., Van Gool, L., 2006. SURF: speeded up robust features, Computer Vision ECCV 2006, Graz, Austria.
- Benediktsson, J.A., Sveinsson, J.R., Ersoy, O.K., Swain, P.H., 1994. Parallel consensual neural networks with optimally weighted outputs. World Congress on Neural Networks, San Diego.
- Bennallal, M., Meunier, J., 2003. Real-time Color Segmentation of Road Signs. 15th IEEE Canadian Conference on Electrical and Computer Engineering, Montreal, Canada.
- Breiman, L., 1996. Bagging predictors. Machine Learning, 24(2), 123-140.
- Burschka, D. and Hager, G., 2005. Vision-Based 3D Scene Analysis for Driver Assistance. International conference on Robotics and Automation, Barcelona, Spain.
- Chavez, A.J., 2012. Image classification with dense SIFT sampling: an exploration of optimal parameters. Doctoral dissertation, Department of Computer Science College of Engineering, Manhattan, Kansas.
- Cortes, C., Vapnik, V., 1995. Support-vector networks. Machine Learning, 20(3), 273 – 297.
- Csurka, G., Dance C., Fan, L., X., Willamowski, J., Bray, C., 2004. Visual categorization with bags of keypoints. Workshop on statistical learning in computer vision, 1(1-22), 1-2.
- Dalal, N., Triggs, B., 2005. Histograms of Oriented Gradients for Human Detection. Conference on Computer Vision and Pattern Recognition, San Diego.
- De la Escalera, A., Moreno, L.E., Salichs, M.A., Armingol, J.M., 1997. Road Traffic Sign Detection and Classification. IEEE Transactions on Industrial Electronics, 44(6), 848 – 859.
- Everingham, M., Van Gool, L., Williams, C., Winn, J., Zisserman, A., 2006. The PASCAL Visual Object Classes Challenge Results. [www.pascal-network.org, http://www.pascal-network.org/challenges/VOC/voc2006/results.pdf](http://www.pascal-network.org/challenges/VOC/voc2006/results.pdf) (15.12.2015).
- Fang, C., Fuh, C., Yen, P., Cheng, S., and Chen, S., 2004. An Automatic Road Sign

- Recognition System Based on a Computational Model of Human Recognition Processing. *Computer Vision and Image Understanding*, (96)2, 237 – 268.
- Freund, Y., Schapire, R., 1996. Experiments with a new boosting algorithm. *International Conference on Machine Learning*, Bari, Italy.
- Galar, M., Fernandez, A., Barrenechea, E., Bustince, H., Herrera, F., 2012. A review on ensembles for the class imbalance problem: bagging-, boosting-, and hybrid-based approaches. *IEEE Transactions on Systems, Man and Cybernetics Part C: Applications and Reviews*, 42 (4), 463-484.
- Gao, X.W., Podladchikova, L., Shaposhnikov, D., Hong, K., Shevtsova, N., 2006. Recognition of traffic signs based on their color and shape features extracted using human vision models, *Journal of Visual Communication and Image Representation*, 17(4), 675 – 685.
- Harris, C., Stephens M., 1988. A combined corner and edge detector. *Fourth Alvey Vision Conference*, United Kingdom.
- Hashem, S., Schmeiser, B., 1993. Approximating a function and its derivatives using MSE-optimal linear combinations of trained feedforward neural networks. *World Congress on Neural Networks*, New Jersey.
- Hido S., Kashima, H., Takahashi, Y., 2009. Roughly balanced bagging for imbalanced data. *Statistical Analysis and Data Mining*, 2(5-6), 412–426.
- Ho, T.K., Hull, J.J., Srihari, S.N., 1994. Decision combination in multiple classifier systems. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 16(1), 66-75.
- Hu, X., Zhu, X., 2010. Traffic sign recognition using Scale invariant feature transform and SVM. *Joint Symposium of ISPRS Commission IV / AutoCarto Annual Conference*, Orlando, Florida.
- Johansson, B., 2002. “Road Sign Recognition from a Moving Vehicle. Master's thesis, Centre for Image Analysis, Uppsala University.
- Juan, L., Gwun, O., 2009. A comparison of sift, pca-sift and surf. *International Journal of Image Processing (IJIP)*, 3(4), 143-152.
- Kotsiantis, S., Kanellopoulos, D., Pintelas, P., 2006. Handling imbalanced datasets: A review. *GESTS International Transactions on Computer Science and Engineering*, 30(1), 25-36.
- Krogh, A., Vedelsby, J., 1995. Neural network ensembles, cross validation and active learning. *Advances in Neural Information Processing Systems-7*, Massachusetts, United States.
- Lincoln, W, Skrzypek, J., 1990. Synergy of clustering multiple back propagation networks. *Advances in Neural Information Processing Systems*, Morgan Kaufmann.
- Lowe, D.G., 2004. Distinctive image features from scale-invariant keypoints. *International Journal of Computer Vision*, 60(2), 91–110.
- Lowe, D.G., 1999. Object recognition from local scale-invariant features. *International Conference on Computer Vision*, Corfu, Greece.
- Marszaek, M., Schmid, C., 2006. Spatial weighting for bag-of-features. *IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'06)*, New York, USA.
- Mathias M., Timofte R., Benenson R., Gool L.V., 2013. Traffic sign recognition - how far are we from the solution?. *IEEE International Joint Conference on Neural*

- Networks, Dallas, USA.
- Mei, Z., Shen, Q., Ye, B., 2009. Hybridized KNN and SVM for gene expression data classification. *Life Science Journal*, 6(1), 61-66.
- Miura, J., Kanda, T., Shirai, Y., 2000. An active Vision System for Real-Time Traffic Recognition. *IEEE Conference on Intelligent Transportation Systems*, Dearborn, USA.
- Muja, M., Lowe, D.G., 2009. Fast approximate nearest neighbors with automatic algorithm configuration 4th International Conference on Computer Vision Theory and Applications, Lisbon, PORTUGAL.
- Oza, N.C., Turner, K., 1999. Dimensionality reduction through classifier ensembles. Technical report NASA-ARC-IC-1999-126, NASA Ames Research Center.
- Oza, N.C., Turner, K., 2001. Input decimation ensembles: Decorrelation through dimensionality reduction. In *Second International Workshop on Multiple Classifier Systems*. Springer-Verlag.
- Özyer, G.T., 2012. Attention-based Image Retrieval. PhD thesis, The graduate school of natural and applied sciences of middle east technical university, Ankara
- Perez, E., Javidi, B., 2002. Nonlinear Distortion-Tolerant Filters for Detection of Road signs in Background Noise. *IEEE Transactions on Vehicular Technology*, 51 (3), 567-576.
- Perrone, M., Cooper, L.N., 1992. When networks disagree: Ensemble methods for hybrid neural networks. *Neural Networks for Speech and Image Processing*, New York.
- Quinlan, J.R., 1993. C4. 5: Program for Machine Learning. Morgan Kaufmann, 299, San Mateo, California.
- Rehrmann, V., Lakmann, R., Priese, L., 1995. A Parallel System for Real-Time Traffic Sign Recognition. *IEEE Intelligent Vehicles '94 Symposium*, Koblenz, Germany.
- Rogova, G., 1994. Combining the results of several neural network classifiers. *Neural Networks*, 7(5), 777-781.
- Rudnick, A.I., Polifroni, J.H., Thayer, E.H., Brennan, R.A., 1988. Interactive problem solving with speech. *Journal of the Acoustical Society of America*, 84(S1), S213-S213.
- Schmid, C., Mohr R., 1997. Local gray value invariants for image retrieval. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 19(5), 530-534.
- Shashua, A., Gdalyahu, Y., Hayun, G., 2004. Pedestrian detection for driving assistance systems: Single-frame classification and system level performance. *IEEE Intelligent Vehicles Symposium*, Parma, Italy.
- Soetedjo, A., Yamada, K., 2003. Traffic Sign Classification Using Ring Partitioned Method. *IEICE Transactions Fundamentals of Electronics Communications And Computer Sciences*, E88A(9), 2419-2426.
- Turner, K., Ghosh, J., 1996. Error correlation and error reduction in ensemble classifiers. *Connection Science*, 8(3-4), 385-404.
- Turner, K., Ghosh, J., 1998. Classifier combining through trimmed means and order statistics. *2nd IEEE World Congress on Computational Intelligence (WCCI 98)*, Anchorage, Alaska.
- Vapnik, V.N., 1995. *The Nature of Statistical Learning Theory*. Springer, 311, New

York.

- Wang, S., Yao, X., 2009. Diversity analysis on imbalanced data sets by using ensemble models IEEE Symposium on Computational Intelligence and Data Mining, Nashville.
- Winn, J., Criminisi, A., Minka, T., 2005. Object categorization by learned universal visual dictionary. 10th IEEE International Conference on Computer Vision (ICCV 2005), Beijing, PEOPLES R CHINA.
- Xu, L., Krzyzak, A., Suen, C.Y., 1992. Methods of combining multiple classifiers and their applications to handwriting recognition. IEEE Transactions on Systems, Man and Cybernetics, 22(3), 418-435.
- Yang, J.B., Singh, M.G., 1994. An evidential reasoning approach for multiple-attribute decision making with uncertainty. IEEE Transactions on Systems, Man, and Cybernetics, 24(1), 1-18.
- Zhang, M., Liang, H.W., Wang, Z.L., Yang, J., 2014. Real-Time Traffic Sign Detection and Recognition for Intelligent Vehicle. 2014 IEEE International Conference On Mechatronics And Automation, Tianjin, China
- Zheng, Z.J., Webb, G.I., 1998. Stochastic attribute selection committees. 11th Australian Joint Conference on Artificial Intelligence (AI 98), Brisbane, Australia

ÖZGEÇMİŞ

Yıldız AYDIN 1988 yılında Erzincan’da doğdu. 2011 yılında Süleyman Demirel Üniversitesinde bilgisayar mühendisliği lisans derecesini aldı. Atatürk Üniversitesi bilgisayar mühendisliği bilim dalında yüksek lisans eğitimine 2013 yılında başladı. Şu anda Erzincan Üniversitesi Bilgi İşlem Daire Başkanlığında uzman olarak görev yapmaktadır.

