

**HEDEF TANIMA ALGORİTMALARI VE
BİR DSP KARTI ÜZERİNDE
GERÇEKLENMESİ**

Çağlar KILIKÇIER



T.C.
ULUDAĞ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

HEDEF TANIMA ALGORİTMALARI VE BİR DSP KARTI ÜZERİNDE
GERÇEKLENMESİ

Çağlar KILIKÇIER

Yrd. Doç. Dr. Ersen YILMAZ
(Danışman)

YÜKSE LİSANS TEZİ
ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

BURSA-2012

Her Hakkı Saklıdır

TEZ ONAYI

ÇAĞLAR KILIKÇIER tarafından hazırlanan “HEDEF TANIMA ALGORİTMALARI VE BİR DSP KARTI ÜZERİNDE GERÇEKLENMESİ” adlı tez çalışması aşağıdaki jüri tarafından oy birliği ile Uludağ Üniversitesi Fen Bilimleri Enstitüsü Elektronik Mühendisliği Anabilim Dalı’nda **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Danışman : Yrd. Doç. Dr. Ersen YILMAZ

Başkan: Yrd. Doç. Dr. Ersen YILMAZ İmza
Uludağ Üniversitesi, Mühendislik-Mimarlık
Fakültesi, Elektronik Mühendisliği Anabilim Dalı

Üye: Prof.Dr. Erdoğan DİLAVEROĞLU İmza
Uludağ Üniversitesi, Mühendislik-Mimarlık
Fakültesi, Elektronik Mühendisliği Anabilim Dalı

Üye: Yrd. Doç. Dr. Fatih KARPAT İmza
Uludağ Üniversitesi, Mühendislik-Mimarlık
Fakültesi, Makina Mühendisliği Anabilim Dalı

Yukarıdaki sonucu onaylarım / ONAY

Prof. Dr. Kadri ARSLAN
Enstitü Müdürü
... / ... / 2012

U.Ü. Fen Bilimleri Enstitüsü, tez yazım kurallarına uygun olarak hazırladığım bu tez çalışmada;

- tez içindeki bütün bilgi ve belgeleri akademik kurallar çerçevesinde elde ettiğimi,
- görsel, işitsel ve yazılı tüm bilgi ve sonuçları bilimsel ahlak kurallarına uygun olarak sunduğumu,
- başkalarının eserlerinden yararlanılması durumunda ilgili eserlere bilimsel normlara uygun olarak atıfta bulunduğumu,
- atıfta bulunduğum eserlerin tümünü kaynak olarak gösterdiğimi,
- kullanılan verilerde herhangi bir tahrifat yapmadığımı,
- ve bu tezin herhangi bir bölümünü bu üniversite veya başka bir üniversitede başka bir tez çalışması olarak sunmadığımı

beyan ederim.

17/ 12 /2012

İmza

Çağlar KILIKÇIER

ÖZET

Yüksek Lisans Tezi

HEDEF TANIMA ALGORİTMALARI VE BİR DSP KARTI ÜZERİNDE
GERÇEKLENMESİ

Çağlar KILIKÇIER

Uludağ Üniversitesi
Fen Bilimleri Enstitüsü
Elektronik Mühendisliği Anabilim Dalı

Danışman: Yrd. Doç.Dr. Ersen YILMAZ

Bu tez çalışmasında hedef tanıma problemi ele alınmıştır. Literatürde yer alan güncel hedef tanıma yöntemleri incelenmiş ve örnek bir hedef tanıma probleminin çözümü sunulmuştur. Örnek hedef tanıma problemi olarak araç içi kamera tarafından alınan görüntülerdeki trafik ışıklarının tanınması problemi seçilmiş ve DVM aracılığı ile çözümü gerçekleştirilmiştir.

Anahtar Kelimeler: Hedef tanıma, DVM, İmge eşikleme, PSO.

2012, vi + 47 sayfa.

ABSTRACT

Master Thesis

**TARGET RECOGNITION ALGORITHMS AND THEIR IMPLEMENTATIONS ON
A DSP CARD**

Çağlar KILIKÇIER

Uludag University
Graduate School of Natural and Applied Sciences
Department of Electronic Engineering

Supervisor: Asst. Prof. Dr. Ersen YILMAZ

In this thesis, target recognition problem is discussed. Current methods in the literature for the target recognition were investigated and a solution of an example problem in target recognition is presented. Traffic light recognition from the in-car cam images is chosen as an example problem and a solution of this problem is realized with SVM.

Key words: Target recognition, SVM, Image thresholding, PSO.

2012, vi + 47 pages.

TEŐEKKÜR

Öncelikle bana alıőmalarımnda laboratuvar ortamı sađlayan bölüm başkanımız sayın Prof. Dr. Erdoğan Dilaverođlu hocama, alıőmalarım boyunca sađladıđı katkılardan ve verdiđi destekten ötürü danıőman hocam sayın Yrd. Do. Dr. Ersen Yılmaz'a ve beni yetiőtiren deđerli hocalarıma teőekkürü bir bor bilirim.

Beni yetiőtiren, bu günlere getiren, her zaman yanımda olan ve bana her konuda destek olan aileme de minnettarım.

ađlar KILIKIER
17/12/ 2012

İÇİNDEKİLER

	Sayfa
ÖZET	i
ABSTRACT	ii
TEŞEKKÜR	iii
SİMGELER ve KISALTMALAR DİZİNİ	v
ŞEKİLLER DİZİNİ	vi
1. GİRİŞ.....	1
1.1. Hedef Tanıma Problemi.....	1
1.2. Tezin Amaç ve Kapsamı	2
1.3. Tezin Katkıları.....	2
2. KAYNAK ARAŞTIRMASI.....	3
2.1. Ön işlem ve İmge iyileştirme Metotları.....	3
2.1.1. Pencere üzerinden yapılan işlemler	5
2.1.2. İmge üzerinde global olarak yapılan işlemler	10
2.2. İmgede İlgi Duyulan Alanı Bulma Metotları.....	11
2.2.1. Eşikleme temelli metotlar.....	12
2.2.2. Bağlı bileşen bölütleme metotları	14
2.2.3. Hibrit metotlar	15
2.3. İmge Sınıflandırma Algoritmaları	17
3. MATERYAL VE YÖNTEM.....	20
3.1. Veri Seti.....	20
3.2. Tekrarsız Ayırık İkili Parçacık Sürüsü Yaklaşımli Çok Seviyeli Eşikleme.....	22
3.2.1. Otsu Kriteri ile Çok Seviyeli Eşikleme	24
3.2.2. Tekrarsız İkili Ayırık Parçacık Sürüsü Optimizasyonu	26
3.3. Çok Seviyeli Bağlı Bileşen Analizi ile Etiketleme.....	28
3.4. Bölüt Seçme	30
3.5. En küçük kareler destek vektör makinesi	31
3.6. TMS 320C6416 DSP	32
4. BULGULAR VE TARTIŞMA	33
5. SONUÇ.....	43
Kaynakça.....	44
ÖZGEÇMİŞ.....	47

SİMGELER ve KISALTMALAR DİZİNİ

Simgeler

Simgeler	Açıklama
\oplus	Morfolojik genişletme işlemi
\ominus	Morfolojik daraltma işlemi
\circ	Morfolojik açma işlemi
\bullet	Morfolojik kapama işlemi
k	Eşik sayısı
L	Gri İmgedeki en koyu değer
p_i	Sınıflandırılmak istenen örnek
x	Sınıflandırılmak istenen örnek
x_i	Eğitim için kullanılan örnek
N	Örnek sayısı
σ^2	Gauss çekirdek fonksiyonunun varyansı
α_i	DVM modelinin Lagrange katsayıları
c	DVM modelinin hata tolerans parametresi
I	Birim Matris

Kısaltmalar

Kısaltmalar	Açıklama
ART	Otomatik Hedef Tanıma
CCS	Code Composer Studio
DSP	Sayısal İşaret İşleme
DVM	Destek Vektör Makinaları
FLIR	İleri bakan kızılötesi
IR	Kızılötesi
HRR	Yüksek çözünürlüklü radar
LS SVM	En küçük kareler Destek Vektör Makinaları
PSO	Parçacık Sürüsü Optimizasyonu
RGB	Kırmızı Yeşil Mavi
SAR	Sentetik açıklıklı radar
TLR	Trafik ışığı tanıma

ŞEKİLLER DİZİNİ

	Sayfa
Şekil 3.1. Karmaşık arka plan ve fren lambaları	21
Şekil 3.2. Karmaşık arka plan ve trafik ışıklarına benzer farklı ışıklar	21
Şekil 3.3. Bulanık çıkmış trafik ışıkları	22
Şekil 3.4. TMS 320c6416 DSK kartı.....	32
Şekil 4.1. Veri setinden örnek olarak alınan 007080 numaralı imge	33
Şekil 4.2. Kenar tespit için RCMG metodu ile işlenmiş 007080 numaralı imge.....	34
Şekil 4.3. 007080 numaralı imgenin (60,20) Epsilon delta komşuluğu ile etiketlenmiş hali	35
Şekil 4.4. Tek eşik seviyesi ile eşiklenmiş imge eşik seviyesi 113	36
Şekil 4.5. İkinci eşik seviyesi eklenmiş hali, eşik seviyeleri 113 ve 180	37
Şekil 4.6. Üçüncü eşik seviyesi eklenmiş hali, eşik seviyeleri 113, 180 ve 71.....	38
Şekil 4.7. Dördüncü eşik seviyesi eklenmiş hali, eşik seviyeleri 113, 180, 71 ve 146 ..	38
Şekil 4.8. Beşinci eşik seviyesi eklenmiş hali, eşik seviyeleri 113, 180, 71, 146 ve 220	39
Şekil 4.9. İmgenin çoklu eşiklemeden sonra etiketlenerek bölütlenmiş hali.....	40
Şekil 4.10. İmgenin bölütleri seçilmiş hali	41
Şekil 4.11. İmgenin DVM ile sınıflandırma işlemi sonucu	42

1. GİRİŞ

1.1. Hedef Tanıma Problemi

Hedef tanıma uygulamaları gündelik hayatımızın içine girmiş bulunmaktadır. Diz üstü bilgisayarlardaki parmak izi tanımadan, telefonlardaki ses tanımaya, sayısal kameralardaki görüntüler ile nesne tanımadan, biyomedikal cihazlardan alınan veriler yardımıyla hastalık teşhisine kadar tüm bu uygulamalar birer hedef tanıma problemi ve çözümü hedef tanıma algoritmaları ile gerçekleştirilmektedir. Hedef tanıma problemi bir nesneyi veya olayı yani belirlenen bir hedefi tanımlanması problemi.

Hedef tanıma konusundaki araştırmalar popüler uygulama ve problemlere sahiptir. Hedef tanıma dendiği zaman akla ilk olarak askeri savunma sistemlerinde kullanılan ATR uygulaması akla gelmektedir fakat sivil amaçlı olarak biyometrik tanıma, otomatik karakter tanıma, ses tanıma ve nesne tanıma gibi uygulamaları da bulunmaktadır. Bu uygulamaların girişinde kullanılan veriler genellikle ses veya imgelerden oluşmaktadır.

Literatür incelendiğinde de araştırmaların ses ve imgeler üzerinde ağırlık kazandığı görülmektedir. İmge üzerine yapılan hedef tanıma çalışmalarında ise çoğunlukla ATR sistemleri üzerine çalışılmıştır.

ATR, genellikle gerçek zamanlı olarak hedef tanıma ve sınıflandırma işleminin yapıldığı algılayıcılar, algoritma, hedef veri kümesi ve donanımı içeren bir sistemi ifade eder (Fuller 2008). Literatürde imge tabanlı ATR sistemleri için genelde SAR (Sentetik açıklıklı radar), FLIR (İleri bakan kızılötesi), HRR (Yüksek çözünürlüklü radar), çeşitli sayısal kameralar ve uydu görüntüleri gibi kaynaklar algılayıcı olarak kullanılmıştır. Bu konularda yapılan çalışmalarda genellikle ATR sistemi bir bütün olarak ele alınmamış ve sistemin belli bir bölümü veya sınıflandırma algoritmaları üzerinde durulmuştur.

Yerel literatürde hedef tanıma problemi için yazılmış IR, yüksek çözünürlüklü uydu ve radar imgelerini kullanan çeşitli tez çalışmaları bulunmaktadır. İmgeden hedef tanıma problemlerinde imgelerin çözünürlüğü arttıkça hedefin bölütlenmesi ve sınıflandırılması işlemi kolaylaşmaktadır.

1.2. Tezin Amaç ve Kapsamı

Bu tezde yüksek çözünürlüğe sahip olmayan sayısal kameralardan elde edilmiş imgeler ile hedef tanıma probleminin çözülmesi amaçlanmıştır. Hedef tanıma problemi olarak imgelerden trafik ışıklarının tespiti seçilmiştir. Trafik ışıklarının tespiti için altı yüz kırka dört yüz seksen çözünürlüğe sahip kalabalık şehir trafiğine ait imgelerden oluşan bir veri kümesi kullanılmıştır. Tez kapsamında, öncelikle imge ile hedef tanıma problemleri için literatürde önerilen ön işlem, bölütleme ve sınıflandırma algoritmaları incelenmiş ve belirlenen problemin çözümü doğrultusunda düşük çözünürlüğe sahip hedeflerin tanınmasını sağlayan bir algoritma farklı ortamlarda gerçekleştirilmiştir.

Tezin ileriki bölümlerinde sırasıyla; ikinci bölümde literatürdeki güncel imge iyileştirme, ilgili alan bulma ve sınıflandırma metotları verilmiştir. Üçüncü bölümde seçtiğimiz hedef tanıma probleminde kullanılan metotlardan ve veri setinden bahsedilmiş. Önerilen hedef tanıma algoritmasında kullanılan metotlar anlatılmış. Seçilen DSP kartından kısaca bahsedilmiştir. Dördüncü bölümde varılan bulgulardan bahsedilmiş ve beşinci bölümde ise sonuçlar verilmiştir.

1.3. Tezin Katkıları

Bu tez çalışması kapsamında en küçük kareler Destek vektör makinası (DVM) yönteminin ve ikili ağaç yapısının kullanıldığı çok sınıflı bir DVM çalışması (Kılıkçier ve Yılmaz 2011) yapılmıştır. Ayrıca Otsu kriterlerine göre PSO kullanan eşikleme algoritmaları için daha gelişmiş bir arama algoritması önerilmiştir (Kılıkçier ve Yılmaz 2012). Bağlı bileşen metodunda çok seviyeli eşikleme sonucunda oluşan seviyelere göre etiketleme yapan bir algoritma önerilmiştir.

2. KAYNAK ARAŞTIRMASI

İmge kullanılan hedef tanıma algoritmalarında hedefin tanınması için sınıflandırıcı algoritmalar kullanılmaktadır. Sınıflandırma algoritmalarının girişinde ise imgede hedefin bulunma olasılığı olan ilgili bölümler ve bu ilgili bölümlerden çıkartılan öznelikler kullanılmaktadır. İlgi duyulan bu bölümlerin çıkartılabilmesi içinse çeşitli ön işlemler ve metotlar bulunmaktadır.

İlgi duyulan bu bölümlerin doğru bir şekilde çıkartılabilmeleri için çoğu zaman imge geometrik dönüşümler gibi ön işlemlerden geçirilmelidir. Daha sonra ise filtreleme gibi bazı iyileştirme işlemlerinden geçmesi gerekmektedir. Özetle hedef tanıma problemi temelde üç alt problemden oluşmaktadır. İmgenin ön işlemde geçirilip iyileştirilmesi, imgede ilgi duyulan alanın belirlenmesi ve bu alanın sınıflandırılarak hedefin tanınmasıdır.

2.1. Ön İşlem ve İmge İyileştirme Metotları

Hedef tanıma sistemlerinin başarı oranını sınıflandırıcıların performansından çok kaynak algılayıcılar ondan sonra ise imge işleme algoritmaları etkilemektedir. İmge algılayıcıların bilinen eksiklikleri ve kusurları imge işleme algoritmaları ile giderilmeye çalışılmaktadır. Sınıflandırma aşamasında öz nitelik çıkarmada bu iyileştirilmiş imgelerden yararlanılmaktadır.

Hedef tanıma problemlerinde kullanılan imgeler çoğu zaman ideal özelliklere sahip değildir ve iyileştirilmesi gerekmektedir. İmgelerde istenmeyen bu durumları düzeltmek için belirli çözüm metotları bulunmaktadır. Fakat imgedeki bozulmaların neler olduğu ve kaynaklarının bilinmediği durumlarda iyileştirme metodunun nasıl seçileceğini belirten genel bir yol yoktur. Bazı durumlarda imgeler üzerinde iyileştirmeler yapılmadan ilgili alan bulma işlemleri yüksek başarı ile gerçekleştirilebilse de çoğu zaman bu imge üzerindeki olası hedef alanlarının doğru bir şekilde bulunması olasılığını azaltmaktadır.

Bu nedenle imgeler üzerinde gürültü azaltma, iyileştirme, çözünürlüğünün değiştirilmesi veya geometrik dönüşümler gibi matematiksel ön işlemler yapılmaktadır. Bozucu etkilerin bilinmediği durumlarda imgelerin iyileştirilmesi için genellikle gri seviye dönüşümü, histogram eşleme, morfolojik işlemler veya filtreler uygulanmaktadır.

Bahsedilen işlemlerin önceliği olabilmekte ve uygulama sırası sonucu değiştirebilmektedir. Öncelik sırasının doğru bir şekilde kararlaştırılabilmesi için, ön işlem ve iyileştirme algoritmaların sınıflandırılması gerekmektedir. İmge gürültü azaltma ve iyileştirme algoritmalarının sınıflandırılması hakkında literatürde farklı görüşler bulunmaktadır. Bu konu hedef tanıma sistemlerinin algoritmalarının seçiminde ve kullanımında önemli bir yer tutmaktadır.

Literatürde önerilen çeşitli sınıflandırmalar vardır. Shih (2010) kitabında “İmge iyileştirme işlemlerini genel olarak üç sınıfa ayırabilir bunlar, noktalar üzerinde yapılan işlemler, pencere üzerinden yapılan işlemler ve tüm imgeyi içeren genel işlemler” demektedir. Shih’in önerdiği şekildeki bir sınıflandırma ile yapılan işlemin ardışık mı yoksa paralel olarak mı çalıştırılabileceği kolayca belirlenebilir. Uygulanacak işlemlerin uygulanma sırası ve birleştirilebilir olup olmadığı anlaşılabilir. Bu sayede hedef tanıma sistemleri için donanım ve algoritma seçimi kolaylaşmaktadır.

Günümüzde imge algılayıcıları üzerinde otonom olarak odaklama, yakınlaştırma, kazanç ve benzeri işlemler gerçekleştirilebilmektedir. Fakat hedef tanıma problemi için bu işlemler her zaman yeterli olmayabilmektedir. Ratches’inde (1997) belirttiği gibi ilgi duyulan alan bulma ve sınıflandırmanın iyileştirilebilmesi için imge üzerinde Histogram eşleme, renklendirme, filtreleme, keskinleştirme gibi işlemler yapılması gerekmektedir.

İmgelerde ilgili alanı bulmaya yardımcı olabilecek imge iyileştirme işlemlerinin başlıca morfolojik işlemler ve filtreleme olduğu söylenebilir. Morfolojik işlemler ve süzgeçler pencere üzerinden yapılan işlemler iken histogram eşitleme gibi işlemler imgenin tamamını içeren genel işlemlerdir. Bu bölümde global ve pencere üzerinden yapılan işlemlerden bahsedeceğiz.

2.1.1. Pencere üzerinden yapılan işlemler

Morfolojik işlemler farklı uygulamalarda kullanım alanları bulmuştur. Bu alanlardan biride imge işleme alanıdır. Bu işlemler bir pencere üzerinden yapılırlar. İmge üzerinde gerçekleştirilen bu işlemler paralel hesaplamaya olanak verirler fakat birden fazla işlem aynı imge üzerinde eş zamanlı paralel olarak hesaplanamazlar. İşlem sırasının önemi vardır.

Morfolojik işlemlerin ikili sayı sistemiyle imge iyileştirmeden, kenar bulmaya farklı bir sürü kullanım alanı bulunmaktadır. Haralick'e (1987) göre morfolojik işlemlerin "İmge işlemede aritmetik morfolojik işlemlerin şekil temelli işlemlerinden yararlanılmaktadır. Uygun şekilde kullanıldığında imgelerin şekillerinin karakteristik özelliklerini koruyup istenmeyen gürültüleri yok etme işini kolaylaştırırlar." Haralick ayrıca nesnelere tanınması, nesne öz niteliklerine ve şekline bağlı olduğundan aritmetik morfolojik işlemlerin nesne tanımada doğal olarak akla gelen ilk yöntem olduğunu belirtmiştir. Morfolojik işlemlerden genişletme, daraltma, açma ve kapama temel morfolojik işlemlerdir bunların dışında süzgeç görevi gören çeşitli morfolojik işlemlerde bulunmaktadır

Morfolojik genişletme işlemi bir küme elemanını kendi kümesinin sınırları dâhilinde kalmak şartıyla başka bir kümenin elemanlarıyla genişletmektir. Genişletme işlemi Minkowski toplamı olarak da isimlendirilmektedir. İkili genişletme matematiksel olarak iki kümeyi vektör toplamını kullanarak birleştirir (Shih 2010).

Örneğin A ve B , N boyutlu uzayda tanımlı olsunlar.

$$A = \{(0,0), (1,1), (2,2), (3,3), (4,4)\}$$

$$B = \{(0,1), (-1, -1)\}$$

Olmak üzere;

$$A \oplus B = \{(0,1), (1,2), (2,3), (3,4), (0,0), (1,1), (2,2), (3,3)\}$$

olur. Genişletme işlemi (2.1) denklemindeki şekilde tanımlanabilir (Shih 2010).

$$(A \oplus_b B)_{(i,j)} = OR_{m,n}[AND(B_{(m,n)}, A_{(i-m,j-n)})] \quad (2.1)$$

Genişletme işlemine ait matris örnekleri aşağıda verilmiştir.

$$A = \begin{matrix} 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \end{matrix}, B = \begin{matrix} 0 & 1 \end{matrix} \rightarrow (A \oplus_b B) = \begin{matrix} 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \end{matrix}$$

$$A = \begin{matrix} 0 & 1 & 0 & 1 \\ 0 & 0 & 1 & 0 \\ 0 & 1 & 0 & 0 \\ 1 & 0 & 0 & 1 \end{matrix}, B = \begin{matrix} 0 & 1 \end{matrix} \rightarrow (A \oplus_b B) = \begin{matrix} 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \\ 0 & 0 & 1 & 0 \\ 0 & 1 & 0 & 0 \end{matrix}$$

$$A = \begin{matrix} 0 & 1 & 0 & 1 \\ 0 & 0 & 1 & 0 \\ 0 & 1 & 0 & 0 \\ 1 & 0 & 0 & 1 \end{matrix}, B = \begin{matrix} 0 & 1 \\ 1 & 0 \end{matrix} \rightarrow (A \oplus_b B) = \begin{matrix} 0 & 0 & 1 & 0 \\ 0 & 1 & 0 & 1 \\ 0 & 0 & 1 & 0 \\ 0 & 1 & 0 & 0 \end{matrix}$$

$$A = \begin{matrix} 0 & 1 & 0 & 1 \\ 0 & 0 & 1 & 0 \\ 0 & 1 & 0 & 0 \\ 1 & 0 & 0 & 1 \end{matrix}, B = \begin{matrix} 0 & 1 \\ 1 & 0 \\ 0 & 1 \end{matrix} \rightarrow (A \oplus_b B) = \begin{matrix} 0 & 0 & 1 & 0 \\ 0 & 1 & 0 & 1 \\ 0 & 0 & 1 & 0 \\ 0 & 1 & 0 & 1 \end{matrix}$$

Yukarıda örneklerden de anlaşılacağı gibi yapılan işlem A matrisinin elemanlarının 1 aldığı yerlerde B matrisini oraya eklemektir. Bu işlem yapılırken B'nin kopyalanması ile daha önceden 1 değerini almış olan bir yer sıfırlanmaz.

Daraltma işlemi, genişleme işleminin ikilemidir. Minkowski toplama işlemi genişletme işlemine denk düşmektedir fakat Minkowski çıkarma işlemi veya vektörel çıkarma daraltma işlemine karşılık gelmemektedir (Haralick 1987). Daraltma işleminin çeşitli matematiksel tanımlamaları bulunmaktadır.

Shih (2010) daraltma işlemi tanımını için (2.2) eşitliğini kullanırken, diğer bir tanımlama (Haralick 1987) ise (2.3) eşitliği şeklindedir.

$$(A \ominus_b B)_{(i,j)} = AND_{m,n}[OR(A_{(i+m,j+n)}, \bar{B}_{(m,n)})] \quad (2.2)$$

$$(A \ominus_b B) = \{x \in E^N | x + b \in A \forall b \in B\} \quad (2.3)$$

Aşağıda (2.2) eşitliği için daraltma işlemi örnekleri verilmiştir.

$$A = \begin{matrix} 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \end{matrix}, B = \begin{matrix} 0 & 1 \end{matrix} \rightarrow (A \ominus_b B) = \begin{matrix} 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \end{matrix}$$

$$A = \begin{matrix} 0 & 1 & 0 & 1 \\ 0 & 0 & 1 & 0 \\ 0 & 1 & 0 & 0 \\ 1 & 0 & 0 & 1 \end{matrix}, B = \begin{matrix} 0 & 1 \end{matrix} \rightarrow (A \ominus_b B) = \begin{matrix} 1 & 0 & 1 & 0 \\ 0 & 1 & 0 & 0 \\ 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 \end{matrix}$$

$$A = \begin{matrix} 0 & 1 & 0 & 1 \\ 0 & 0 & 1 & 0 \\ 0 & 1 & 0 & 0 \\ 1 & 0 & 0 & 1 \end{matrix}, B = \begin{matrix} 0 & 1 \\ 1 & 0 \end{matrix} \rightarrow (A \ominus_b B) = \begin{matrix} 0 & 0 & 1 & 0 \\ 0 & 1 & 0 & 0 \\ 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \end{matrix}$$

$$A = \begin{matrix} 0 & 1 & 0 & 1 \\ 0 & 0 & 1 & 0 \\ 0 & 1 & 0 & 0 \\ 1 & 0 & 0 & 1 \end{matrix}, B = \begin{matrix} 0 & 1 \\ 1 & 0 \\ 0 & 1 \end{matrix} \rightarrow (A \ominus_b B) = \begin{matrix} 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \end{matrix}$$

Verilmiş olan örneklerde yapılan işlem, A matrisinin içinde B matrisi dolaştırılarak A'nın B'yi kapsadığı noktalara 1 değeri verilmesi diğer noktalara ise sıfır değerinin atanmasıdır.

Açma işlemi ise daraltma ve genişletme işlemlerinin sırasıyla daraltma ve sonra genişletme işleminin gerçekleştirilmesinden oluşur. Açma işlemi $A \circ B = (A \ominus B) \oplus B$ olarak ifade edilir. İmge üzerinde parçalanmış olan küçük alanları yok etmeye yarar. Örnek verilecek olursa,

$$A = \begin{pmatrix} 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 1 & 1 & 0 \\ 0 & 0 & 0 & 0 \end{pmatrix}, B = \begin{pmatrix} 0 & 1 \\ 1 & 0 \end{pmatrix} \rightarrow (A \circ B) = \begin{pmatrix} 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 \end{pmatrix}$$

$$A = \begin{pmatrix} 0 & 1 & 0 & 1 \\ 0 & 0 & 1 & 0 \\ 0 & 1 & 0 & 0 \\ 1 & 0 & 0 & 1 \end{pmatrix}, B = \begin{pmatrix} 0 & 1 \\ 1 & 0 \end{pmatrix} \rightarrow (A \circ B) = \begin{pmatrix} 0 & 0 & 0 & 1 \\ 0 & 0 & 1 & 0 \\ 0 & 1 & 0 & 0 \\ 1 & 0 & 0 & 0 \end{pmatrix}$$

$$A = \begin{pmatrix} 0 & 1 & 0 & 1 \\ 0 & 0 & 1 & 0 \\ 0 & 1 & 0 & 1 \\ 1 & 0 & 1 & 1 \end{pmatrix}, B = \begin{pmatrix} 0 & 1 \\ 1 & 0 \\ 0 & 1 \end{pmatrix} \rightarrow (A \circ B) = \begin{pmatrix} 0 & 0 & 0 & 1 \\ 0 & 0 & 1 & 0 \\ 0 & 1 & 0 & 1 \\ 0 & 0 & 1 & 0 \end{pmatrix}$$

Kapama işlemi $A \bullet B = (A \oplus B) \ominus B$ olarak gösterilir ve açma işleminin tersidir. İmge üzerindeki parçalanmış alanları birleştirmeye yarar

$$A = \begin{pmatrix} 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 1 & 1 & 0 \\ 0 & 0 & 0 & 0 \end{pmatrix}, B = \begin{pmatrix} 1 \\ 1 \end{pmatrix} \rightarrow (A \bullet B) = \begin{pmatrix} 0 & 1 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 1 & 1 & 0 \\ 0 & 0 & 0 & 0 \end{pmatrix}$$

$$A = \begin{pmatrix} 1 & 0 & 1 & 0 \\ 0 & 1 & 0 & 0 \\ 1 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 \end{pmatrix}, B = \begin{pmatrix} 1 & 1 \\ 1 & 0 \end{pmatrix} \rightarrow (A \bullet B) = \begin{pmatrix} 1 & 1 & 1 & 0 \\ 1 & 1 & 0 & 0 \\ 1 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 \end{pmatrix}$$

$$A = \begin{pmatrix} 1 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 \\ 1 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 \end{pmatrix}, B = \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix} \rightarrow (A \bullet B) = \begin{pmatrix} 1 & 0 & 1 & 0 \\ 0 & 1 & 0 & 0 \\ 1 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 \end{pmatrix}$$

Geniřletme daraltma, açma, kapama ve benzeri iřlemler imge iřlemede kullanılırken imgeler genellikle ikili olarak deęil gri renk yelpazesinde kullanılmaktadır. Morfolojik iřlemlerin nasıl yapıldığına örnek verecek olursak geniřletme ve daraltma ařağıdaki gibi olur.

$$A = \begin{matrix} 1 & 2 & 3 \\ 4 & 5 & 6 \end{matrix}, B = \begin{matrix} 1 & 2 \\ -2 & -1 \end{matrix}$$

$$A \oplus B = \begin{matrix} (1 + 1) & (1 + 2, 2 + 1) & (2 + 2, 3 + 1) \\ (1 - 2, 4 + 1) & (1 - 1, 2 - 2, 5 + 1, 4 + 2) & (2 - 1, 3 - 2, 5 + 2, 6 + 1) \end{matrix}$$

$$A \oplus B = \begin{matrix} 2 & 3 & 4 \\ 5 & 6 & 7 \end{matrix}$$

$$A \ominus B = \begin{matrix} (1 - 1, 2 - 2, 4 + 2, 5 + 1) & (2 - 1, 3 - 2, 5 + 2, 6 + 1) & (3 - 1, 6 + 2) \\ (4 - 1, 5 - 2) & (5 - 1, 6 - 2) & (6 - 1) \end{matrix}$$

$$A \ominus B = \begin{matrix} 0 & 1 & 2 \\ 3 & 4 & 5 \end{matrix}$$

Geniřletme, daraltma, açma ve kapama morfolojik iřlemlerinin dıřında bu dört temel iřlemin farklı kombinasyonlarını kullanan çeřitli morfolojik iřlem bulunmaktadır. Renkli imgelerin gri skalada morfolojik olarak iřlenmesi için Karasik'in (1999) önerdiği boyut indirgeme metodu ve Evans'ın (2006) kenar bulma için kullandığı morfolojik gradyan operatörü kullanılabilir. Bunların dıřında sınır çıkarma, alan doldurma, iskelet çıkarma, bölütleme, inceltme, kalınlařtırma iřlemi yapan morfolojik iřlemlerde bulunmaktadır.

Süzgeçler morfolojik iřlemlerden farklı olarak imge üzerinde aritmetik iřlemler kullanarak konvolüsyon yardımıyla gerçeleştirilirler. Keskinleřtirme, yumuřatma ve kenar belirginleřtirme gibi farklı amaçlı süzgeçler bulunmaktadır.

2.1.2. İmge üzerinde global olarak yapılan işlemler

İmge üzerinde yapılan global işlemlerde işlem imgenin bütünü üzerinde aynı anda gerçekleştirilir. Frekans ortamında yapılan tüm işlemler bu kapsama girmektedir. Benzer şekilde histogram eşleme metodunda imge üzerindeki yapılan global işlemlere bir örnektir.

Histogram eşleme metodu renk yoğunluk oranı doğrusal olarak dağılmayan imgelerin karşıtlık oranını yayarak her rengin eşit oranda dağılmasını sağlamaya çalışır. Bu metot tüm imgeyi içeren genel bir işlemdir ve sayesinde imgedeki detaylar iyileştirilebilir fakat detaylarla beraber gürültüde artmaktadır. Bu işlem (2.4) denklemine göre yapılır. Denklemdaki s_k yeni, r_k eski yoğunluk değeri, n_G toplam yoğunluk seviyesi sayısı, n imgedeki toplam piksel sayısı olup, n_{r_i}, r_i yoğunluğuna sahip piksel sayısıdır (Shih 2010).

$$s_k = T(r_k) = \frac{(n_G - 1)}{n} \sum_{i=0}^k n_{r_i} \quad (2.4)$$

T bir haritalama dönüşümü olup imgedeki noktaların yeni değerini verir. Bu dönüşüm sonucunda histogram homojen bir yapı alır. Sayısal imgelerde yeni yoğunluk değerleri tam sayı değilse en yakın tam sayıya çevrilir. Histogram eşleme işlemi ne kadar tekrarlanırsa tekrarlanırsın yuvarlatma hataları dışında hep aynı sonucu verir.

Histogram eşleme yöntemine sayısal bir örnek verilme istenirse.

5	7	6	7	4
7	5	7	6	7
6	7	5	7	6
7	6	7	5	7
4	7	6	7	5

n_G sıfırdan yediye kadar sekiz, n ise yirmi beştir. $s_k = T(r_k) = \frac{7}{25} \sum_{i=0}^k n_{r_i}$ işlemi sonucunda $4 \rightarrow 1, 5 \rightarrow 2, 6 \rightarrow 3, 7 \rightarrow 7$ olur.

2	7	3	7	1
7	2	7	3	7
3	7	2	7	3
7	3	7	2	7
1	7	3	7	2

Verilen örneğin histogramı eşlenmiş şekli yukarıdaki gibidir.

2.2. İmgede İlgi Duyulan Alanı Bulma Metotları

İmge bölütleme hedef tanıma algoritmalarının başarımlarını etkileyen önemli bir aşamadır. İmge üzerinde gerekli iyileştirmeler yapıldıktan sonra sıra bölütleme yani ilgi duyulan alanı bulma işlemine gelir. İmgeleri bölütlemek için farklı metotlar önerilmiştir

Uygun olmayan bölütleme metotları, sınıflandırma algoritması adımına gelmeden yanlış karar verilmesine yol açmaktadır. Bu nedenle imgelerde uygulanan bölütleme işlemleri genellikle kullanıldıkları yere bağlı olarak sezgiye ve tecrübeye dayanarak seçilmektedir. Her hedef tanıma probleminde tüm imgeler için geçerli ortak bir optimum bölütleme algoritması bulunması mümkün olmayabilmektedir.

Bölütleme algoritmaları kullanım amaçlarına göre farklı şekillerde sınıflandırılabilir. Bankman'a (2000) göre bölütleme, manüel, yarı otonom veya otonom olarak, piksel tabanlı veya alan tabanlı olarak, klasik, istatistiksel, bulanık ve sinir ağları olarak ya da manüel, düşük seviyeli bölütleme(imgeyi piksel tabanlı inceleyen) ve model tabanlı bölütleme(nesne yapısı, şekil ve semantiğini kullanan metotlar) olarak sınıflandırılabilir.

Shih'e (2010) göre ise temel olarak dört tip bölütleme tekniği vardır. Bu teknikler eşikleme, sınır tabanlı, alan tabanlı ve bunların kombinasyonu olmak üzere dört ana sınıfta toplanabilir (Shih 2010). İmgelerde alan veya sınır bulunması işleminden sonra bu bölgelerin etiketlenmesi gerekmektedir. Bu işlem için genellikle bağlı bileşen etiketleme kullanılmaktadır. Bağlı bileşen etiketleme ve bağlı bileşen bölütleme metotları farklı olup. Bağlı bileşen bölütleme ile imgede kendi içinde tutarlı alanlar bulunmaya çalışılmaktadır.

Son zamanlarda literatürde hibrit yapılara sıkça rastlanmaktadır. Bunlar, eşikleme, öbekleme, optimizasyon, morfolojik işlemler ve sınıflandırma gibi metotların birleşimi ile ortaya koyulmuştur. Bu bölümde yüzeysel olarak eşikleme,bağlı bileşen ve hibrit yapılara sahip metotlardan bahsedeceğiz.

2.2.1. Eşikleme temelli metotlar

İmge eşikleme için kullanılan kriterlere göre farklı eşikleme metotları bulunmaktadır. Varolan metotlar arasında en çok kullanılan ve atıf alan metot Otsu'nun önerdiği metottur (Otsu 1979). Otsu'nun önerdiği metotta eşik seviyelerinin seçimi için aynı seviye aralığındaki piksellerin varyanslarının toplamının tüm seviye aralıklarındaki ağırlıklı ortalamasını minimize eden eşikler aranmaktadır. Otsu metodunun uygulanması hakkında ayrıntılı açıklama üçüncü bölümde verilecektir.

Literatürdeki çoğu metodun ayrıntılı olarak incelendiği bir tarama çalışması Sezgin (Sezgin 2002) tarafından yapılmıştır. Mehmet Sezgin, doktora tezinde eşikleme metotlarını kullanılan kriterlere göre şu şekilde kategorilendirmiştir; histogram şekline dayanan metotlar, öbeklenmeye dayanan metotlar, entropiye dayanan metotlar, nesne özelliklerine dayanan metotlar, uzamsal bilgilere dayanan metotlar ve yerel uyarlamalı metotlar. Bu metotların özet açıklamaları ve kullandıkları eşikleme fonksiyonları (Sezgin ve Sankur 2004) tarama makalesinde bulunmaktadır. Burada yer almayan fakat dikkate değer yeni yaklaşımlardan bazıları Ying ve arkadaşları (2011) ve de Arora ve arkadaşları (2008) tarafından önerilmiştir.

Ying ve arkadaşları çalışmalarında (Ying, et al. 2011) Bernsen algoritmasının gelişmiş bir halini önermişlerdir. Bernsen algoritmasının kullanım amacı imge üzerindeki dengesiz ışıklandırma problemini gidermektir. Bu işlemi imge üzerinde ufak bir pencere kullanarak ortalama eşik değerleri bulup bu eşik değerlerine göre ikili bir imge yaratarak gerçekleştirir.

Normal Bernsen algoritmasında x ve y imgedeki bir noktanın yerini belirtmek üzere; $f(x,y)$ o noktadaki sayısal değeri, w pencere boyutunu ve $T(x,y)$ eşik değeri fonksiyonu belirtir. Yeni ikili imgenin x ve y noktasındaki sayısal değerler $b(x,y)$ (2.5) denkleminde bulunur. Bu algoritmanın geliştirilmiş bir şekli olan (2.6) Ying ve arkadaşları (2011) tarafından önerilmiştir. Önerdikleri metotta ikinci bir $T(x,y)$ fonksiyonu kullanmış ve ağırlıklı ortalamalarında yararlanmıştır. İkinci $T(x,y)$ fonksiyonundaki $\hat{f}(x,y)$ bir gauss süzgecidir. σ süzgecin ölçeğidir. α ve β ağırlık katsayılarıdır, yapılan işleme ve imgeye göre tecrübe ya da deneme yanılma yoluyla seçilir.

$$T(x,y) = \frac{\max_{-w \leq k, l \leq w} f(x+l, y+k) + \min_{-w \leq k, l \leq w} f(x+l, y+k)}{2} \quad (2.5)$$

$$b(x,y) = \begin{cases} 0, & \text{eğer } f(x,y) < T(x,y) \\ 1, & \text{diğer tüm durumlar} \end{cases}$$

$$\hat{f}(x,y) = \frac{1}{(2w+1)^2} \sum_{-w \leq k, l \leq w} f(x+l, y+k) * \exp\left\{-\frac{1}{2}\left[\left(\frac{x}{\sigma}\right)^2 + \left(\frac{y}{\sigma}\right)^2\right]\right\}$$

$$T_2(x,y) = \frac{\max_{-w \leq k, l \leq w} \hat{f}(x+l, y+k) + \min_{-w \leq k, l \leq w} \hat{f}(x+l, y+k)}{2} \quad (2.6)$$

$$b(x,y) = \begin{cases} 0, & \text{eğer } f(x,y) < \beta((1-\alpha)T(x,y) + \alpha T_2(x,y)); \beta \in (0,1) \\ 1, & \text{diğer tüm durumlar} \end{cases}$$

Bu işlemde dikkat edilmesi gereken önemli nokta seçilen pencerenin boyutudur. Çünkü kullanılan pencere imgede yüksek geçiren bir süzgeç görevi görmektedir. İmgede bulunmak istenen hedefe uygun boyutlarda bir pencere ve parametreler seçilmesi gerekmektedir.

İlgi çekici olan diğerk bir metot ise Arora ve arkadaşları (2008) tarafından önerilmiştir. Önerilen eşikleme metodunda eşik değerkleri imgedeki varyanslar olarak alınmaktadır. Çoklu eşikleme içinse varyans değerkleri arasında tekrar yeni varyanslar bulunarak eşikleme işlemleri yapılmaktadır. Ayrıca histogramdaki dengesiz dağılımlarla baş edebilmek için varyans hesabında kullanılan bölgenin alt ve üst sınırlarını kontrol eden iki adet kontrol parametresi bulunmaktadır.

İkili eşikleme için kullanılan metotların çoğuk çoklu eşikleme için kullanılabilir. Fakat çoklu eşiklemenin iki önemli dezavantajı bulunmaktadır. Bunlar kaç adet seviyenin kullanılması gerektiğiki ve eşiklerin hesaplanması için gereken işlem sayısıdır. Bu iki problemin çözümleri için önerilmiş hibrit yapıda eşikleme metotları bulunmaktadır. Tez çalışması kapsamında (Chander, Chatterjee ve Siarry 2011) metodunun farklı bir yaklaşımı önerilmiştir.

2.2.2. Bağlı bileşen bölütleme metotları

Bağlı bileşen ile ilgili çeşitli metotlar bulunmaktadır. Bu çeşitlilik bağıllık ölçütünün seçiminden kaynaklanmaktadır. İmge üzerinde bağılı bileşen ile ilgili ilk temel makalelerden biri Rosenfeld'in (1966) bağıllık ve yakınlıktan bahsettiğiki çalışmasıdır. Bu çalışmasında bağıllık kontrolü için kullanılan imgeler ikili olduğundan komşuluk kuralları basittir. Renkli imgeler ile ilgili kurallar üçüncü bölümde verilmiştir. Gri ve renkli imgeler için bağılı bileşen analizi metotları alfa veya epsilon delta bağılı bileşenleri adı altında farklı komşuluk kontrolü ölçütleri için sunulmuştur. Gri imgeler için Wang'ın (1995) önerdiğiki epsilon delta bileşenleri ölçütünde epsilon bağılı bir grubun elemanları arasındaki fark epsilon'dan büyük olamaz. Benzer şekilde bağılı grubun birbirine komşu elemanları arasındaki farkta deltadan büyük olamaz. Renkli imgeler için önerilen epsilon delta metoduna örnek olarak Westman ve arkadaşlarının (1990) kullandığı hiyerarşik bağılı bileşen analizi verilebilir.

Westman ve arkadaşlarının (1990) önerdiğiki metotta imgedeki pikseller arasındaki mesafe RGB uzayındaki Öklid mesafesi olarak alınır. Alfa bağılı bileşen metotlarına örnek olarak ise alfa omega bağılı bileşen (Soille 2008) metodu verilebilir. Soille'nin önerdiğiki metotta alfa değeri epsilon delta yöntemindeki delta değeri karşılıklı

düşmektedir. Deltadan farklı olarak alfa bir üst sınır olarak kullanılmakta ve bağlı bölge için rasgele olarak alfadan küçük bir değer delta gibi kullanılmaktadır. Omega değeri ise epsilon ile aynı işlevi görmektedir.

2.2.3. Hibrit metotlar

Literatürde yeni önerilen bölütleme metotlarında otomatik hedef tanıma algoritmalarının ihtiyaçlarını göz önüne alan hibrit yapılar kullanılmaktadır. Destek vektör makinaları ve öbikleme metotlarının birleşimi ile çalışan hibrit metotlar ise gelecek vaat etmektedir. DVM kullanan metotlara örnek olarak (Wang, Wang ve Bu 2011), (X.-Y. Wang, Q.-Y. Wang, et al. 2011), (Yu, Wong ve Wen 2011) verilebilir.

Yu ve arkadaşlarının önerdiği metotta (Yu, Wong ve Wen 2011) bölütleme için ölçüt olarak sınıflandırma algoritması olan DVM kullanılmıştır. DVM iki sınıfı birbirinden ayırmak için ideal bir yöntem olmakla beraber eğitici kullanan bir yöntemdir. Bu yüzden bölütleme yapmadan önce eğitici kümesi elle herhangi bir metot kullanılmadan seçilmiş ve sınıflandırma sonuçlarına göre bölütleme işlemi yapılmıştır. Bu yöntemle başarılı sonuçlar alınabilse de bazı kısıtlamaları bulunmaktadır.

Yüksek başarı için öncelikli olarak hedefin piksellerinin öz ilintisinin yüksek olması ve arka planla arasındaki ilintininse düşük olması gerekmektedir. Bunlar bazı durumlarda eğitim kümesinin dikkatli seçimi ile aşılabilecek kısıtlamalardır. Fakat eğitim örneklerinin otomatik olarak seçilmesi işlemi çözülmesi gereken bir problemdir.

Wang ve arkadaşları (X.-Y. Wang, Q.-Y. Wang, et al. 2011) ve (Wang, Wang ve Bu 2011) eğitim örneklerinin otomatik olarak seçilmesini sağlayan bulanık c ortalamalı topaklanma algoritmasının kullanılmasını önermişlerdir. Önerdikleri metotlar ile hedef ve arka plan arasındaki ilintisi düşük olan imgeler için başarılı bölütleme sonuçları alındığı görülmektedir. Fakat bu metotta doğru bölütleme yapabilmek için bulanık c ortalaması algoritmasındaki topak sayısının doğru bir şekilde seçilmesi gerekmektedir.

Bu problemin çözümü için topak sayısının otomatik olarak bulunulduğu topaklanma algoritmaları kullanılabilir, fakat bu şekildeki bir topaklanma düşük öz ilintili hedeflerin farklı öbeklere ayrılması problemini de beraberinde getirmektedir. Kim ve arkadaşlarının önerdiği adaptif topaklanma metoduyla (Kim ve Kang 2012) bu probleme bir çözüm getirilmeye çalışılmıştır.

Kim ve Kang'ın önerdikleri metotta aşırı bölütlenme ve bölüt sayısı dolaylı yoldan iki parametre yardımı ile kontrol edilmektedir. Fakat bu parametrelere otomatik olarak değerler atanmamaktadır. Başarılı sonuçlar alınabilmesi için bölütlenmeyi kontrol eden parametrelerin seçiminde imgeler hakkında ön bilgi gerekmektedir.

Diğer bir metot ise Lezoray'ın (2009) önerdiği otomatik ölçeklemeli morfolojik öbikleme metodudur. Bu metotta öbikleme katsayısının tayini için bir enerji fonksiyonu kullanılmaktadır. Bölütlenme sonucu bir enerji fonksiyonu ile kontrol edilerek en az enerjiyi veren bölütlenme en iyi sonuç olarak seçilir. Önerilen metotta bölütlenmeyi kontrol eden parametre enerji fonksiyonu yardımıyla otomatik olarak seçilmekle beraber enerji fonksiyonun seçimi ayrı bir konudur.

Öbikleme algoritmalarının kullanıldığı diğer hibrit yöntemlerde de benzer problemler görülmektedir. Bu problem sadece DVM ve öbikleme metotlarında değil diğer bölütlenme metotlarında da görülmektedir. Örneğin (Mushrif ve Ray 2009) çalışmasında sezgisel bulanık küme yardımıyla üç renk bandında ayrı ayrı histogramlardaki değişikliklerin oranına bakarak eşikleme yapmıştır. Bu metottada düşük öz ilintili hedefler için benzer aşırı bölütlenme problemleri ortaya çıkabilmektedir.

Soille ve arkadaşlarının (2010) önerdiği aşırı bölütlenme problemine yeni bir bakış açısı getiren hibrit metot, aşırı bölütlenmiş imgelerden anlamlı gruplar çıkarmaya çalışır. Morfolojik işlemler ile bağlı bileşen analizinin birleşiminden oluşan ve spektral uydu görüntülerinin bölünmesinde kullanılan bu metot ile aşırı bölütlenme probleminin çözümünde kullanılacak Lezoray'ın yöntemine benzer çok ölçekli bölütlemeye dayalı bir çözüm elde edilmeye çalışılabilir.

2.3. İmge Sınıflandırma Algoritmaları

Çok basit görünen, ön işlem ve bölütleme gerektirmeyen bir hedef tanıma sisteminde dahi her zaman karar mekanizması için bir sınıflandırıcıya ihtiyaç vardır. İmgeler sınıflandırılırken genellikle nesne tanıma ve veri madenciliği için kullanılan sınıflandırma algoritmaları kullanılmaktadır.

IEEE uluslararası veri madenciliği konferansında (ICDM) Wu ve arkadaşları (2008) tarafından son zamanlarda ki en çok kullanılan metotlar belirlenmiştir. Konferansta belirlenen tanınmış en iyi on veri madenciliği metotlarının anlatıldığı tarama makalesindeki, C4.5, K merkezli öbekleme, Destek vektör makinaları (DVM), AdaBoost, en yakın K komşu kestirimi ve Bayesçi kestirim metotları imge sınıflandırmada da rahatlıkla kullanılabilirlerdir.

Bu metotların dışında imgelerin sınıflandırılabilmesi için yapay sinir ağları, şablon eşleme (template matching), pekiştirmeli öğrenme (reinforced learning), gizli Markov modelleri ve adaptif rezonans teorisi de kullanılmaktadır. Bahsettiğimiz bu metotların içinde DVM imge sınıflandırmada popüler olarak kullanılmaktadır.

Destek vektör makinaları ikili sınıflandırma işlemi yapan bir metottur. Vapnik tarafından yetmişlerde önerilmiş ve doksanlarda farklı uygulama alanları olan popüler bir metot haline gelmiştir (Burges 1998). DVM sınıflandırma işlemi sınıfı bilinmeyen örneği çekirdek adı verilen bir fonksiyona, sınıfları bilinen örneklerle beraber sokarak bu fonksiyonların sonucuna göre karar vermektedir.

DVM metodu farklı sınıfa ait örnekler arasında sınıf tespiti için en uygun karar verme modelini oluşturmaya çalışan bir sınıflandırıcıdır. DVM modelini belirleyen iki ana etmen vardır. Bunlar modeli oluştururken kullanacağımız örnekler ve çekirdek fonksiyonumuzdur. Çekirdek fonksiyonu sınıfı bilinmeyen bir örneğin sınıfı bilinen bir örneğe ne kadar benzediğini belirtmeye yarayan bir ölçüt olarak kullanılır.

Çekirdek fonksiyonu $K(x, x_i)$ kullanılan örneklere ait uzayda tanımlıdır. Sınıflanacak örnek x ile ve eğitim örneğide x_i ile gösterilir. Çekirdek fonksiyonu sınıflandırma problemini $K(x, x_i) = \Phi(x)^T \Phi(x_i)$ fonksiyonları yardımıyla farklı boyutlardaki uzaylarda da çözmektedir.

Çekirdek fonksiyonunu oluşturan $\Phi()$ fonksiyonunun tanımlandığı uzayın boyut sayısı örneklerin tanımlandığı uzaydan büyük, küçük veya sonsuz olabilir. Hesaplama açısından bu bir problem gibi gözükse de çekirdek fonksiyonu kullanılırken $\Phi()$ fonksiyonu kullanılmamakta ve Mercer koşullarını sağlayan fonksiyonlar çekirdek fonksiyonları olarak seçilmektedir (Burges 1998). Çekirdek fonksiyonu genelde Mercer koşulunu sağlayan lineer, polinom ve radyal baz fonksiyonları içinden seçilir.

Lineer çekirdek fonksiyonu $K(x, x_i) = x * x_i$ şeklinde ifade edilir. İsminden de anlaşılacağı gibi lineer sınıflandırma problemlerinde kullanılmaktadır. Çözüm uzayını doğrusal olarak iki parçaya böler.

Polinom çekirdek fonksiyonu $K(x, x_i) = ((x \cdot x_i) + 1)^d$ şeklinde tanımlanmıştır. Çözülme istenen probleme göre farklı üstel kuvvetler kullanılmaktadır.

DVM için en çok tercih edilen çekirdek fonksiyonları radyal baz fonksiyonlarıdır. Bu çekirdek fonksiyonu $K(x, x_i) = \exp\left(-\frac{(x-x_i)^2}{2\sigma^2}\right)$ olarak tanımlanmıştır. Literatürdeki çalışmalar incelendiğinde de en çok Gauss radyal baz fonksiyonunun kullanıldığı görülmektedir. Çok tercih edilmesinin sebebi Gauss radyal baz fonksiyonunun çözüm kümesi üzerindeki birbirinden ayrık çok sayıdaki alanı aynı sınıf içinde tanımlayabilme yeteneğidir. Diğer baz fonksiyonları ile bu tür sınıflandırma işlemleri gerçekleştirilememektedir.

Bazı durumlarda bilinen bu çekirdek fonksiyonları yetersiz kalmakta ve farklı fonksiyonların birleşiminden hibrit çekirdek fonksiyonları elde edilmektedir. Bu yaklaşım çekirdek fonksiyonları Mercer koşulları sağlandığı sürece geçerlidir.

Çekirdek fonksiyonunu kullanan DVM karar verme mekanizmasını denklem (2.7)'den inceleyecek olursak DVM'in sadece iki sonuçtan birini verebileceğini görürüz. Sınıflandırma işlemine, sonucun eksi veya artı bir olmasına göre karar verilir.

$$f(x) = \text{sign}\left[\sum_{i=1}^N \alpha_i y_i K(x, x_i) + b\right] \quad (2.7)$$

Denklem (2.7)'de tanımlı olan y_i , x_i için sınıf bilgisi içermektedir. N eğitim örneği sayısıdır. Lagrange katsayıları olarak ifade edilen α_i katsayıları çözüm uzayındaki sınıflamanın sınırlarını belirlemeye yardımcı olan parametredir. Sınırın ötelenmesi işlemi ise b katsayısı ile gerçekleşmektedir. Çekirdek fonksiyonları denklem (2.7)'de yerine konarak DVM ile karar verme işlemi gerçekleştirilir.

DVM modelinin oluşturulması için Lagrange katsayılarının bulunması gereklidir. Bu işlem bir konveks optimizasyon problemidir ve çözümü için farklı metotlar kullanılabilir. DVM modelinin oluşturulması için (2.8) denklemini maksimum yapan ve (2.9)'daki koşullara uyan α_i katsayıları bulunmalıdır.

$$\text{maks}_{\alpha_i} = \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i,j=1}^N \alpha_i \alpha_j y_i y_j K(x_i, x_j) \quad (2.8)$$

$$\sum_{i=1}^N \alpha_i y_i = 0, 0 \leq \alpha_i \leq c \quad (2.9)$$

Denklem (2.9)'daki c katsayısı eğitim hatasını sınırlamaya yararmakta olup. Oluşturulan DVM modelinin sınır hatlarının yumuşatılmasına yarar.

Suyken (1999) (2.8) denklemini çözmek yerine bu problemi en küçük kareler yöntemi ile lineer bir denklem takımı çözmeye indirgemeyi önermiştir. En küçük kareler yöntemi ile lagrange katsayılarının bulunması bölüm üçte detaylı olarak verilecektir.

3. MATERYAL VE YÖNTEM

Bu kısımda, kullanılan veri setinden ve uygulanan metotlardan bahsedilecektir. Trafik ışıklarının tanınması probleminin çözümü için izlenen yol öncelikle imgelerin probleme uygun bulunan çoklu eşikleme metodu ile bölütlenmesi arkasından bölütler içerisinde seçme işlemi yapılması ve son olarak da seçilen bu bölütlerin sınıflandırılmasıdır.

3.1. Veri Seti

Hedef tanıma algoritmamızın denemesi için Robotics Centre of Mines ParisTech' te yayınlanan Traffic Lights Recognition (TLR) (CHARETTE 2009) veri seti seçilmiştir. Bu veri seti herkese açık olan bir veri setidir. Hedef tanıma problemi için seçtiğimiz veri seti dikiz aynasına yerleştirilmiş, Marling F-046C kamera sensörü ile alınmış imgelerden oluşmaktadır.

İmgeler, altı yüz kırka dört yüz seksen çözünürlükteki RGB sekiz bitlik görüntüler olarak kaydedilmiştir. Kayıt Paris'te gündüz vakti saatte elli kilometrelik hızın altındaki bir sürüşte elde edilmiştir. İmgeler bölütleme ve sınıflandırma işleminin kolay olmadığı bir alanda kalabalık şehir caddelerinde çekilmiştir. İmgelerde çoğu zaman fren lambaları yanan araçlar, reklam tabelaları, park halindeki araçlar, yayalar, farklı ışık kaynakları, ağaçlar ve trafik işaretleri bulunmaktadır.

Trafik ışıklarının bulunması için kullanılan bu veri setinin sınıflandırılmasını zor kılan sebep şekil 3.1 ve şekil 3.2'deki gibi sadece karmaşık arka plan değil şekil 3.3'deki gibi trafik ışıklarının bulanık çıkmış, yansımış, çok ufak veya yanlış şekillerde bulunabilmesidir. Veri setinin yanında ayrıca imgelerin oluşturulduğu GPS konum bilgilerini içeren ek veri setleri de sunulmaktadır.



Şekil 3.1. Karmaşık arka plan ve fren lambaları



Şekil 3.2. Karmaşık arka plan ve trafik ışıklarına benzer farklı ışıklar



Şekil 3.3. Bulanık çıkmış trafik ışıkları

3.2. Tekrarsız Ayrık İkili Parçacık Sürüsü Yaklaşımli Çok Seviyeli Eşikleme

Hedefin tanınması istenilen imgede arka plan karmaşık veya farklı nesnelere oluşuyorsa tek seviyeli eşikleme iyi sonuçlar verememektedir. Bu tür karmaşık arka plana sahip imgelerde çok seviyeli imge eşikleme kullanılmaktadır. Seçilen çok seviyeli eşikleme metodu için, eşik seviyelerinin belirlenmesinde tüm eşik seviyeleri denenmemekte. Tek tek seviyeleri denemek yerine eşik seviyeleri tahmin edilmeye çalışılmaktadır. Bu tahmin işi içinde eşikleme kriterlerini kullanan optimizasyon algoritmalarından yararlanılmaktadır. Çok seviyeli eşikleme kriterleri ikili eşikleme kriterleri üzerinde ufak algoritma değişiklikleri yapılarak elde edilebilmekte. Çok seviyeli eşikleme yöntemlerinin 2004 yılına kadar olan literatür taramasını Mehmet Sezginin doktora tezinde görmekteyiz (Sezgin, 2002).

Çoklu Eşikleme problemi için çeşitli metotlar ortaya atılmıştır. Bu metotlardan literatürde güncel olarak en çok kullanılanı Otsu metodudur. Bu metot eğiticiye ihtiyaç

duymaz ve parametrik değildir Otsu metodundaki ölçüt imge üzerindeki nesnelere ayırmayı garantilememektedir. Ancak bu ölçüt, imgede farklı eşik seviyelerinde kalan kısımların ayırt edilebilirliğini arttırmayı başarılı bir şekilde yapabilmektedir (Otsu 1979).

Düşük çözünürlüklü hedeflerin tanınması probleminde çok seviyeli otsu kriteri kullanılmıştır. Çok seviyeli eşikleme probleminde eşik seviyelerinin daha hızlı tayini için çeşitli metotlar ortaya atılmıştır. Bu metotlardan en çok kullanılanı PSO metodudur. Literatürde çok seviyeli eşikleme için ideal eşik seviyesinin bulunmasına yarayan PSO kullanan çeşitli metotlar önerilmiştir bunlara (Djerou, et al. 2009), (Maitra ve Chatterjee 2008), (Gao, et al. 2010), (Nabizadeh, et al. 2010) ve (Chander, Chatterjee ve Siarry 2011) örnek olarak verilebilir.

Chander'in önerdiği metotta (Chander, Chatterjee ve Siarry 2011) eşik seviyesi aranırken her seferinde bir tek eşik seviyesi daha önceden bulunan eşik seviyeleri göz önüne alınarak aranmaktadır. Eşik seviyeleri bulunduktan sonra farklı sayıda seviyelere sahip olan çok seviyeli eşikleme grupları içerisinde en iyisi seçilir. Bu metot sayesinde gereken işlem basamakları önemli ölçüde azalmaktadır. Fakat bulunan her eşik seviyesi daha önceki bulunan eşik seviyeleri dikkate alınarak arandığından yani tüm eşik seviyeleri aynı anda dikkate alınarak bir arama yapılmadığından en iyi eşik seviyelerinin bulunduğu garantilenememektedir.

Kısaca bir örnek verirsek önerilen metotla üç seviyeli bir eşikleme için iki yüz elli beş artı iki yüz elli dört artı iki yüz elli üç deneme yani yedi yüz altmış iki olasılık denenmektedir. Üç eşik seviyesi aynı anda dikkate alındığında ise iki yüz elli beş çarpı iki yüz elli dört çarpı iki yüz elli üç yani on altı milyon üç yüz seksen altı bin sekiz yüz on olasılık denenmesi gerekmektedir.

Chander'in önerdiği bu metotta diğer bir önemli eksiklik ise PSO algoritmasını kullanırken önerdiği parçacık sayısı ve iterasyonun yarattığı işlem yükünün önerdiği metoda göre denenebilecek olası tüm eşik değerlerinin hesabından daha fazla olmasıdır.

Bu sebeple daha az iterasyon ve parçacık ile daha fazla çözüm uzayının tarandığı Parçacık Tekrarsız Ayrık İkili PSO Temelli Yeni Bir Yaklaşım önerilmiştir (Kılıkçier ve Yılmaz 2012). Tez çalışması kapsamında imgelerden hedef bulunması aşamasında Otsu'nun çok seviyeli eşikleme kriterini kullanan Chander'in önerdiği metottakine benzer, seviye sayısı üst sınırı beş olan Parçacık Tekrarsız Ayrık İkili PSO ile çalışan bir metot kullanılmıştır.

3.2.1. Otsu Kriteri ile Çok Seviyeli Eşikleme

Otsu kriterlerinin nesne tanımadaki ön işlemlerde ve imge filtreleme işlemlerinde geniş bir kullanım alanı vardır. Tek eşik seviyesine sahip Otsu metodu için imgenin histogramının ortalaması, olasılıkları ve varyansları denklem takımı (3.1)'deki gibi hesaplanır. Denklem takımı (3.1)'de k eşik değeri, L en büyük gri ton seviyesi, p_i bir pikselin i seviyesinde olma olasılığı ve ω_i i . grupta olma olasılığıdır. Denklem takımı (3.2) kullanılarak da PSO için kullandığımız uygunluk değeri ölçütü olan λ bulunur (Otsu 1979).

$$\mu_0 = \sum_{i=1}^k \frac{ip_i}{\omega_0} \quad \mu_1 = \sum_{i=k+1}^L \frac{ip_i}{\omega_1} \quad \mu_T = \sum_{i=1}^L ip_i \quad (3.1)$$

$$\sigma_0^2 = \sum_{i=1}^k \frac{(i-\mu_0)^2 p_i}{\omega_0} \quad \sigma_1^2 = \sum_{i=k+1}^L (i-\mu_1)^2 p_i / \omega_1$$

$$\sigma_w^2 = \omega_0 \sigma_0^2 + \omega_1 \sigma_1^2$$

$$\sigma_B^2 = \omega_0 (\mu_0 - \mu_T)^2 + \omega_1 (\mu_1 - \mu_T)^2 \quad (3.2)$$

$$\lambda = \sigma_w^2 / \sigma_B^2$$

Çok seviyeli eşikleme için denklem (3.1) deki ortalama değerler ve varyanslar iki seviye yerine tüm seviyeler için hesaplanır. Benzer şekilde (3.1) ve (3.2) denklem takımları (3.3) ve (3.4) şeklinde değişirler.

Ortalama değerleri hesapladığımız (3.1) denklem takımı tüm eşik aralıklarının ortalamasının hesaplandığı (3.3) denklem takımına dönüşür. Eşik seviye sayımız k ise ilk seviye aralığının ortalaması μ_0 ve son eşik seviyesi k için $\mu_{son\ eşik\ seviyesi}$ denklemi kullanılır.

Bu seviyeler dışında kalan bir ve k eksi bir aralığı içerisindeki seviye aralıkları için ise μ_n denkleminde yararlanılmaktadır. Tüm imgenin ortalamasını hesapladığımız μ_T denklemi ise değişmemektedir. Uygunluk değerini hesapladığımız denklem takımı (3.2) ise (3.4) şeklinde değişmektedir. Yeni denklem takımı (3.4)'te σ_w^2 ve σ_B^2 hesaplanırken tüm seviye aralıkları dikkate alınmakta ve uygunluk değeri ölçütü olan λ için yine σ_w^2 ve σ_B^2 oranları dikkate alınmaktadır. En uygun eşik seviyeleri olarak en büyük λ değerini veren eşik seviyeleri seçilir.

$$\begin{aligned}
\mu_0 &= \sum_{i=0}^{1.eşik\ seviyesi-1} \frac{ip_i}{\omega_0} \\
\mu_n &= \sum_{i=n.eşik\ seviyesi}^{n+1.eşik\ seviyesi-1} \frac{ip_i}{\omega_n} \\
\mu_{son\ eşik\ seviyesi} &= \sum_{i=son\ eşik\ seviyesi}^L \frac{ip_i}{\omega_{son\ eşik\ seviyesi}} \\
\mu_T &= \sum_{i=1}^L ip_i \\
\sigma_0^2 &= \sum_{i=0}^{1.eşik\ seviyesi} \frac{(i-\mu_0)^2 p_i}{\omega_0} \\
\sigma_n^2 &= \sum_{i=n.eşik\ seviyesi}^{n.eşik\ seviyesi-1} \frac{(i-\mu_n)^2 p_i}{\omega_n} \\
\sigma_{son\ eşik\ seviyesi}^2 &= \sum_{i=son\ eşik\ seviyesi}^L \frac{(i-\mu_{son\ eşik\ seviyesi})^2 p_i}{\omega_{son\ eşik\ seviyesi}}
\end{aligned} \tag{3.3}$$

$$\begin{aligned}
\sigma_w^2 &= \omega_0 \sigma_0^2 + \omega_1 \sigma_1^2 + \omega_2 \sigma_2^2 + \dots \\
&\quad + \omega_{son \text{ eşik seviyesi}} \sigma_{son \text{ eşik seviyesi}}^2 \\
\sigma_B^2 &= \omega_0 (\mu_0 - \mu_T)^2 + \omega_1 (\mu_1 - \mu_T)^2 + \omega_2 (\mu_2 - \mu_T)^2 \dots \\
&\quad + \omega_{son \text{ eşik seviyesi}} (\mu_{son \text{ eşik seviyesi}} - \mu_T)^2 \\
\lambda &= \sigma_w^2 / \sigma_B^2
\end{aligned} \tag{3.4}$$

3.2.2. Tekrarsız İkili Ayrık Parçacık Sürüsü Optimizasyonu

Parçacık sürüsü algoritması (PSO) Eberhart ve Kennedy tarafından gerçel sayılar uzayında bir optimizasyon tekniği olarak tanıtılmıştır (Kennedy ve Eberhart 1997). Başlangıçta çözüm uzayında rasgele dağılımlı olarak atanan parçacıklar her adımda kendisinin ve sürünün tecrübelerine dayanarak optimize edilmek istenen fonksiyonda en iyi sonucu veren noktaya doğru ilerlemektedir. PSO algoritmasında parçacıkların bu ilerleme hareketi iki denklem yardımıyla tanımlanmıştır. Parçacıkların hızını veren (3.5) denklemdir ve bu hıza göre yer değiştirmeyi sağlayan (3.6) denklemdir.

$$v_i^t = v_i^{t-1} + c_1 * rand * (p_i - x_i) + c_2 * rand * (p_g - x_i) \tag{3.5}$$

$$x_i^t = x_i^{t-1} + v_i^t \tag{3.6}$$

Parçacığın hızı hesaplanırken (3.5) numaralı denklemde kullanılan c_1 katsayısı yerel veya bireysel olarak adlandırılan öğrenme katsayısıdır. Bu katsayı p_i parçacığının daha önceki kendi en iyi konumundan elde edeceği tecrübelerinden ne ölçüde faydalanacağını belirler. Global uygun değer olarak adlandırılan p_g ise optimize edilmek istenen fonksiyonda en iyi sonucu veren konum bilgisidir. Bu konumun parçacıkların hızına katkısı c_2 katsayısı ile ayarlanır. Herhangi bir parçacığın yeni hızı hesaplanırken o parçacığın eski hızı da hesaba katılarak (3.5) numaralı denklemde

kullanılır. Parçacıkların hızında hangi bilginin hangi ağırlıkta kullanılacağı ise c_1 katsayısının c_2 katsayısına oranına göre belirlenir. c_1 katsayısından daha büyük c_2 katsayısı hareketin sürüdeki en iyi parçacığa doğru olmasına neden olurken tersi durumda parçacığın kendi eski en iyi konumuna doğru gitmesine neden olur. Denklemdaki *rand* isimli sıfır, bir aralığındaki rasgele değişkenler kullanılarak da parçacıkların konumlarındaki değişimlerde en iyi sonuca doğru rasgele bir hızla ilerlemeleri sağlanmış olur. Parçacığın hızı v_i^t hesaplandıktan sonra denklem (3.6)'de parçacığın eski konumu olan x_i^{t-1} ile toplanarak parçacığın yeni konumu hesaplanır. Bu işlemler belli bir döngü boyunca veya optimize edilmek istenen fonksiyonda parçacıkların iyileşmesi son bulana kadar tekrarlanır. İşlemler sonlanınca p_g bize aranan en uygun değeri verir.

Çözülmesi gereken problemin süreksiz çözüm uzayına sahip olduğu durumlarda klasik PSO algoritmasının ayrık çözüm uzayında çalışabilen Ayrık İkili Parçacık Sürüsü Optimizasyonu (DB-PSO) önerilmiştir (Kennedy ve Eberhart 1997). Yapı olarak klasik PSO ile benzer bir hız denklemine (3.7) sahiptir. Ancak hesaplama şekli değişiklik göstermektedir. Parçacık yer yenileme denklemi (3.8) ise tamamen farklıdır. Parçacığın hızı hesaplanırken her bir parçacık ayrı ayrı bitlerin toplamı olarak ifade edilip (3.7) numaralı denklemde teker teker hesaplanmaktadır. Bulunan hızlar bir sigmoid fonksiyonundan geçirilerek aldığı hız değerlerinin sıfır, bir aralığında kalması sağlanır. Bu sayede sigmoid fonksiyonundan (3.9) geçirilen v_{id} sıfır, bir aralığında olan rasgele bir *rand* değişkeniyle karşılaştırılarak bitlerin bir veya sıfır değerini alması sağlanır. Daha sonra bu bitlerin birleştirilmesiyle parçacığın gittiği yeni yer hesaplanır.

$$v_{id}^t = v_{id}^{t-1} + c_1 * rand * (p_{id} - x_{id}) + c_2 * rand * (p_{gd} - x_{id}) \quad (3.7)$$

$$x_{id} = \begin{cases} rand < s(v_{id}) \rightarrow x_{id} = 1 \\ diğ\er \rightarrow x_{id} = 0 \end{cases} \quad (3.8)$$

$$s(v_{id}) = \frac{1}{1 - e^{-v_{id}}} \quad (3.9)$$

Sürekli çözüm uzayları için PSO algoritmasında parçacıkların daha önceden aldıkları değerleri tekrarlayıp tekrarlamadıklarının bakılmamaktadır. Parçacıklar her adımda yeni bir sayısal değer almaktadır. Yerel optimumları takıldığında ise arama yeteneği azalmakta yeni değerler eski değerlere yaklaşmaktadır.

Benzer durum ayrık çözüm uzayları için geçerli değildir. Ayrık seviye veya noktaların bulunduğu durumlarda parçacıkların hızı hareket etmeleri için yetersiz kalabilmekte veya daha önceden her hangi bir parçacık tarafından denenmiş olan bir duruma tekrar gidebilmektedir. Bu durum işlem yükünü gereksiz arttırır ve çözüm uzayının taranma kapasitesinin azalmasına sebep olur. Tekrarsız ayrık ikili parçacık sürüsü optimizasyonu yöntemi ile çok seviyeli eşik ararken parçacık değerlerinin daha önceden denenmiş eşik değerleri tekrarlamasını engelleyen bir yaklaşımdır (Kılıkçier ve Yılmaz 2012).

Önerilen yaklaşımda daha önceden denenmiş parçacık değerleri hafızada saklanır ve yeni önerilen parçacık değerleri daha önce denendi ise değiştirilmesi sağlanır. Bu sayede tekrarlar önlenmiş olur ve parçacıklar yerel optimumlardan çıkmaya zorlanır.

3.3. Çok Seviyeli Bağlı Bileşen Analizi ile Etiketleme

İmgeler kenar bulma süzgeçleri, morfolojik işlemler ve benzeri işlemlerden geçirildikten oluşan sonuçlar bölütlerin kullanılabilir hale gelebilmesi için yeterli değildir. Bölütlerin hedef tanıma işleminde anlamlandırılabilmesi için kullanılan algoritmalar için öncelikle bulunan parçaların etiketlenmesi gerekmektedir. Etiketleme işlemi için genellikle bağlı bileşen etiketleme metodu kullanılmaktadır.

Bağlı bileşen analizi diğer bir adıyla bağlı bileşen etiketlemesi hakkındaki temel kaynaklardan biri, Rosenfeld (1966) tarafından yazılmıştır. Önerdiği metot ile ikili bir imgede yer alan bir piksel bağlı olduğu komşu pikselleri ile aynı olacak şekilde

etiketlenmektedir. Bu işlem sonucunda imge içerisinde komşuluk kurallarına göre ayrık bulunan tüm nesnelere farklı bir etiketle belirlenmiş olur ki bölütlemenin asıl amacı da bu etiketlenmiş alanları bulmaktır.

Rosenfeld'in (1966) önerdiği komşuluk kuralına göre bağlı bileşen etiketleme yapılacak olduğunda imgedeki pikseller i satır, j sütun olmak üzere $a_{i,j}$ olarak adlandırılırlar. Etiketlere v_k denilip etiketlenme işleminden geçmiş pikseller de $a'_{i,j}$ ile gösterilir. Eğer $a_{i,j}=1$ ise $a'_{i,j}=1$, eğer $a_{i,j}=0$ ve $a'_{i-1,j-1}=a'_{i-1,j}=a'_{i-1,j+1}=a'_{i,j-1}=1$ ise $a'_{i,j}=v_k$, v_k yeni kullanılmamış etiket olmak üzere, eğer $a_{i,j}=0$ ve $a'_{i-1,j-1}, a'_{i-1,j}, a'_{i-1,j+1}, a'_{i,j-1}$ bir veya herhangi bir v_k ise $a'_{i,j}$ en küçük v_k 'nin değerine eşit olur. Bu işlemden sonra birbirine komşu olan v_k etiketleri en küçük etikete göre tekrar etiketlenip sonuca ulaşılır.

Bağlı bileşen etiketlemeye sayısal bir örnek verilecek olursa;

$$A = \begin{bmatrix} 0 & 5 & 1 & 5 & 7 \\ 4 & 6 & 1 & 2 & 6 \\ 0 & 6 & 1 & 0 & 1 \\ 0 & 3 & 5 & 1 & 2 \\ 5 & 3 & 1 & 2 & 5 \end{bmatrix}$$

Sekiz renkli $[0,1 \dots, 7]$, A imgesi eşik sınırı dört olmak üzere basit bir eşikleme işleminden sonra aşağıdaki hale dönüşür,

$$A = \begin{bmatrix} 0 & 1 & 0 & 1 & 1 \\ 1 & 1 & 0 & 0 & 1 \\ 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 \\ 1 & 0 & 0 & 0 & 1 \end{bmatrix}$$

Yeni A ikili imgesi için bir değerine sahip pikseller etiketlenirse aşağıdaki A' etiketlenmiş imgesi oluşur.

$$A' = \begin{bmatrix} 0 & a & 0 & b & b \\ a & a & 0 & 0 & b \\ 0 & a & 0 & 0 & 0 \\ 0 & 0 & a & 0 & 0 \\ c & 0 & 0 & 0 & d \end{bmatrix}$$

Rosenfeld'in metodu ile imgedeki sıfır değerine sahip alanlar bölümlenmekle kalmayıp etiketlenmektedir. Bu metodun avantajı kenarları bulup alanları da bu sınırlardan çıkarmak yerine, komşuluk tanımına göre direk olarak alanları bulmasıdır. Ayrıca bu metod kullanıldığında etiket sayısı bize imge üzerindeki bölge sayısını da vermektedir.

Bağlı bileşen analizinin zayıf kaldığı alan ise komşuluk tanımıdır. Çünkü komşuluk tanımı gereği ikili sisteme göre karar vermektedir. Bu yüzden her zaman belli bir kuantalama hatası meydana gelmektedir. Etiketleme için ikili veya çok seviyeli imgeler kullanılabilir (Sonka, Hlavac ve Boyle 2008). İmge türüne ve aranılan nesneye uygun bir şekilde komşuluk kuralları ve eşikleme metodu seçimi yapılarak bölümlenme iyileştirilebilir.

Bağlı bileşen etiketleme işlemi için kullanılabilir olan bazı komşuluk kurallarından bazıları, (Westman, et al. 1990), (Wang ve Bhattacharya 1995) ve (Soille 2008) ikinci bölümde kaynak araştırması kısmında verilmiştir.

Tez kapsamındaki imge bölümlenme probleminin çözümü için bir önceki bölümde bahsedilen çoklu eşikleme metodu seçilmiştir. Bulunan eşik seviyeleri arasında kalan alanlar teker teker değerlendirilmiştir. Alt ve üst sınırlarda dikkate alınarak tüm eşik seviyeleri arasında kalan alanlar, değerlendirilen aralık ve arka plan olarak ikili sistemde etiketleme yapılmıştır.

3.4. Bölüt Seçme

Bölüt seçimi için boyut, şekil, doluluk oranı gibi farklı ölçütler bulunmakta ve her problem için farklı ölçütler kullanılmaktadır. Raoul ve arkadaşları (2009) trafik lambalarının tanınması ile ilgili yaptıkları çalışmalarında bölüt olarak en boy oranını, bölütün içinde boşluk olup olmadığı ve bölütün dış bükey olup olmadığını ölçüt olarak almışlardır.

Tez çalışması kapsamındaki benzer problemimiz için üç farklı bölüt seçme ölçütü kullanılmıştır. Bu ölçütler bölütün boyutu, oranı ve pencere boyutuna göre kapladığı

alanıdır. Bölütler seçilirken genişliği en ve boy olarak en az dört piksel ve en fazla on dokuz piksel olan bölütler seçilmiştir. En boy oranı sıfır nokta sekiz ile bir nokta iki aralığı dışındaki bölütler elenmiştir. En son olarak da bölütün kapladığı pencere alanının boyutuna göre oranının yüzde elliden fazla olması şartı aranmıştır.

Bu sayede trafik ışığı olma olasılığı yüksek olan bölütler sınıflandırma algoritmasına iletilirken, trafik ışığı olmayan bölütlerin sınıflandırılma algoritması tarafından gereksiz olarak denemesi olasılığı azaltılmıştır

3.5. En küçük kareler destek vektör makinesi

En küçük kareler yöntemini kullanan DVM (LS SVM), Suyken (1999) tarafından önerilmiştir. Normal DVM'den farklı olarak lagrange katsayıları hesaplanırken en küçük kareler yöntemi kullanılmaktadır. Bu sayede lagrange katsayılarının hesaplanması daha az işlem ile gerçekleştirilebilmiştir. En küçük kareler DVM yöntemi ile lagrange katsayıları lineer bir denklem takımı yardımıyla çözülmektedir. Lagrange katsayıları (3.10) denklemi yardımıyla elde edilmektedir (Suykens ve Vandewalle 1999).

$$\begin{bmatrix} 0 & Y^T \\ Y & y_i y_j K(x_i, x_j) + c^{-1} I \end{bmatrix} \begin{bmatrix} b \\ \alpha \end{bmatrix} = \begin{bmatrix} 0 \\ \vec{1} \end{bmatrix} \quad (3.10)$$

DVM'in sınıflandırma yeteneği sadece seçilen çekirdek fonksiyonu ve eğitim örneklerine bağlı değildir. Çekirdek fonksiyonunun parametrelerinin ve c hata katsayısının doğru bir şekilde seçilmesi gereklidir.

Parametrelerin seçimi için genellikle PSO algoritması kullanılmaktadır. Bu şekilde optimum parametreler seçilerek en yüksek başarıyı veren karar modeli oluşturulmaya çalışılır. En küçük kareler ile DVM yönteminin denklem (2.8) ve (2.9) hesaplamadan nasıl çözümünün bulunduğu (Kılıkçılar ve Yılmaz 2011)'de basitçe anlatılmaktadır.

3.6. TMS 320C6416 DSP

Metotların uygulanabileceği uygun bir DSP kartı olarak Texas Instruments firmasının TMS 320c6416 DSK kartı seçilmiştir. C6416 modeli yoğun hesaplamalar yapabilen özel amaçlı sabit noktalı bir DSP entegresidir. Şekil 3.4'te kartın resmi verilmiştir.



Şekil 3.4. TMS 320c6416 DSK kartı

TMS320c6416 DSK başlangıç kiti, C6416 DSP entegresinin çalıştıracağı kodu üreten Code Composer Studio (CCS) yazılımıyla beraber gelmektedir ve C dilinde programlar yazılmasına olanak vermektedir. CCS yazılımı sayesinde yazılmak istenen program geliştirme aşamasında adım adım kontrol edilebilmektedir.

Görüntü işleme uygulamaları için TI firması CCS yazılımında kullanılmak üzere IMLIB kütüphanesini çıkarmış bulunmaktadır. Histogram çıkarma, filtreleme, eşikleme ve konvolüsyon gibi bazı temel işlemler bu kütüphanede tanımlanmış ve kullanıcılara hazır fonksiyonlar olarak sunulmuştur.


DVM ve imge eşikleme gibi algoritmalar bu kart üzerinde rahatlıkla gerçekleştirilebilmektedir. Veriler işlendikten sonra dosyalara kaydedilerek farklı ortamlarda kontrol edilebilmektedir.

4. BULGULAR VE TARTIŞMA

Bu bölümde kullanılan ve denenmiş olan diğer metotların verdiği sonuçlardan bahsedilecektir. Literatürdeki bağlı bileşen analizi metotları ve morfolojik gradyen yöntemi denenmiştir. Kullanılan veri seti için eşikleme metodunun daha iyi bölütleme sonuçları verildiği gözlemlenmiştir. DVM'den farklı olarak en küçük kareler DVM yöntemi seçilmiştir. Bu metot ile eğitim süresinin daha kısa zamanlarda gerçekleştirilebildiği için optimizasyona daha fazla zaman ayrılabilir. En küçük kareler DVM yönteminde lagrange katsayıları hesaplanırken en küçük kareler yöntemi kullanılır. Bu sayede lagrange katsayılarının hesaplanması daha az işlem ile gerçekleştirilebilir. Lagrange katsayıları hesaplanması işlemi lineer bir denklem takımı denklem (3.10) yardımıyla gerçekleştirilebilmektedir.




Şekil 4.1. Veri setinden örnek olarak alınan 007080 numaralı imge



Şekil 4.2. Kenar tespit için RCMG metodu ile işlenmiş 007080 numaralı imge

İmgelerin eşiklenmesi için morfolojik gradyenler, bağlı bileşen analizi ve eşikleme metotları denenmiştir. Yapılan çalışmalarda morfolojik gradyenlerin her zaman verimli olmadığı gözlemlenmiştir. Sınırların her zaman düzgün bir şekilde tespit edilemediği ve çok sayıda olası ilgi duyulan alan bulunduğu saptanmıştır. Şekil 4.1’de kullanılan veri setinden alınmış bir imge verilmiştir.


Bu imgenin (Evans ve Liu 2006) önerdiği gürbüz renkli morfolojik gradyen (RCMG) işleminden geçmesi sonucunda şekil 4.2 ortaya çıkmıştır. Çıkan sonuçtan da görülebileceği gibi yüksek frekanslı bileşenler korunmuştur. Yumuşak geçişlere sahip nesnelere gözükmeyen bir birine çok yakın düşük ilintili nesnelere sınırları belirsizleşmiştir.



Şekil 4.3. 007080 numaralı imgenin (60,20) Epsilon delta komşuluğu ile etiketlenmiş hali

Benzer şekilde bağlı bileşen metotlarında iyi bir bölütleme için komşuluk tanımının belirlenmesinin bir problem olduğu gözlemlenmiştir Farklı İmgeler için farklı komşuluk tanımlarının yapılması gerekmektedir. Şekil 4.3'te kullandığımız imgenin gri renklisinden elde edilmiş bağlı bileşen analizi sonucu verilmiştir. Bağlılık tanımı (Wang ve Bhattacharya 1995) önerdiği epsilon delta komşuluğu ile tanımlanmış, epsilon değeri altmış, delta değeri yirmi olan komşuluk için tanımlanmıştır.


Bu yöntemde dikkat edilmesi gereken diğer bir nokta komşuluk için imgenin taranma yönünün farklılık yaratmakta olmasıdır. Yukarıdan aşağı veya soldan sağa doğru yapılan komşuluk kontrolleri farklı sonuçlar verebilmektedir.



Şekil 4.4. Tek eşik seviyesi ile eşiklenmiş imge eşik seviyesi 113


Tezde hedef problemimiz için kullandığımız bölütleme metodunun sonuçları ise şekil 4.4-8’de verilmiştir. Eşik seviyeleri belirlenirken Otsu kriteri kullanılmış ve seviyeler teker teker bulunmuştur.

Şekil 4.4’te tek eşik seviyesi için bölüt sonucu görülmektedir. İmgenin tanımlayıcı nitelikleri büyük ölçüde kaybolduğu görülmektedir.

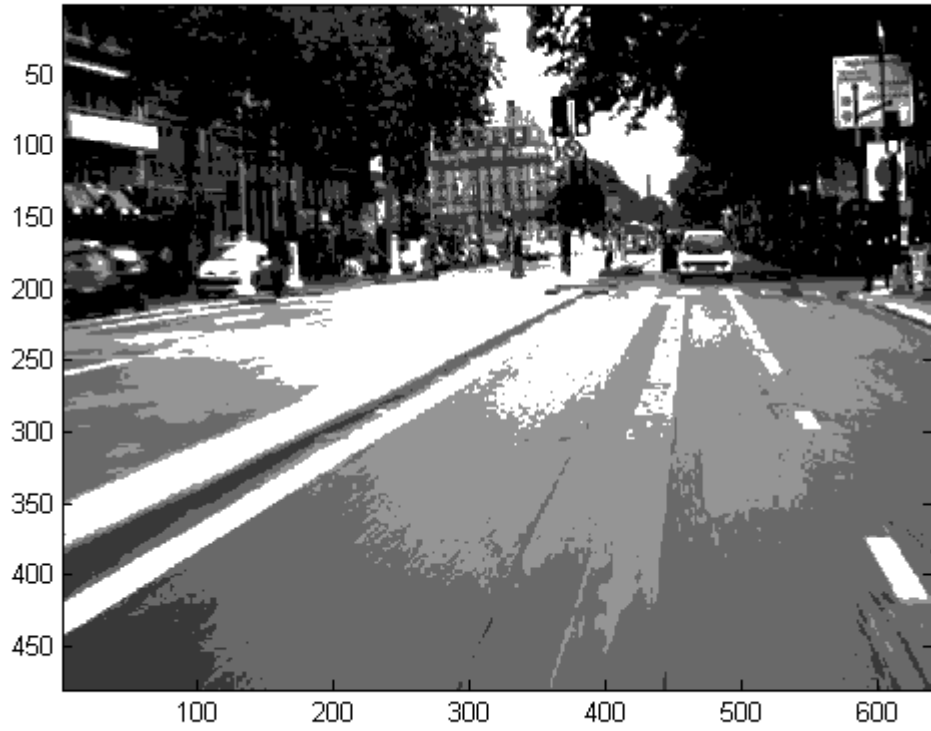


Şekil 4.5. İkinci eşik seviyesi eklenmiş hali, eşik seviyeleri 113 ve 180

Bulunan ilk eşik seviyesinden sonra birinci eşik seviyesi sabit tutularak ikinci eşik aranmıştır. Şekil 4.5'te detaylar tek eşik seviyeli olana göre artmış olsa da hedefin bulunabilmesi yeterli anlamlı sonuçlar verememektedir.

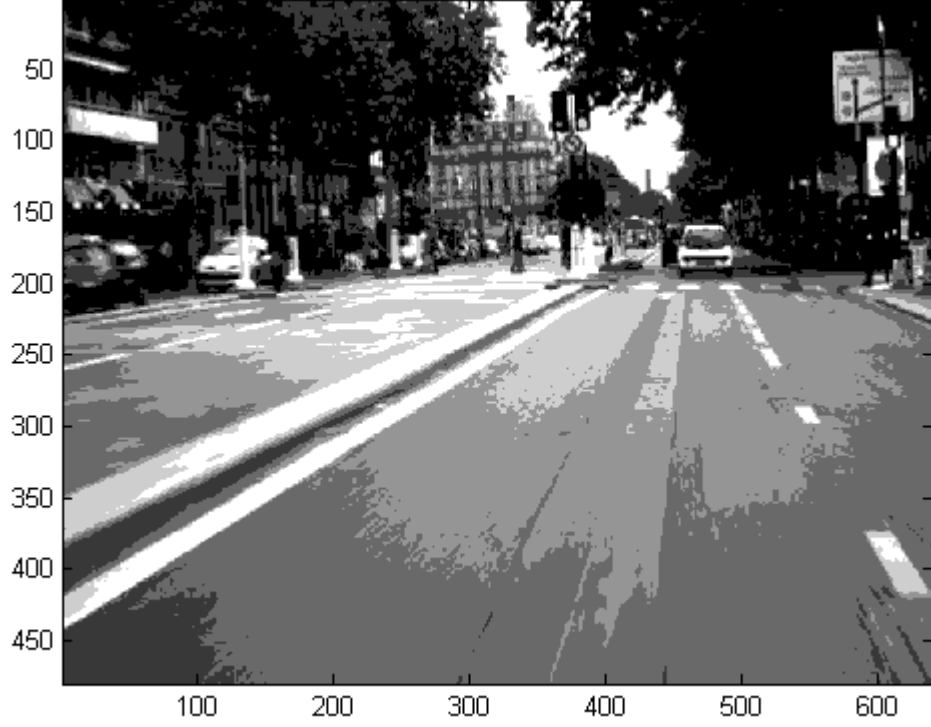


Şekil 4.6. Üçüncü eşik seviyesi eklenmiş hali, eşik seviyeleri 113, 180 ve 71



Şekil 4.7. Dördüncü eşik seviyesi eklenmiş hali, eşik seviyeleri 113, 180, 71 ve 146

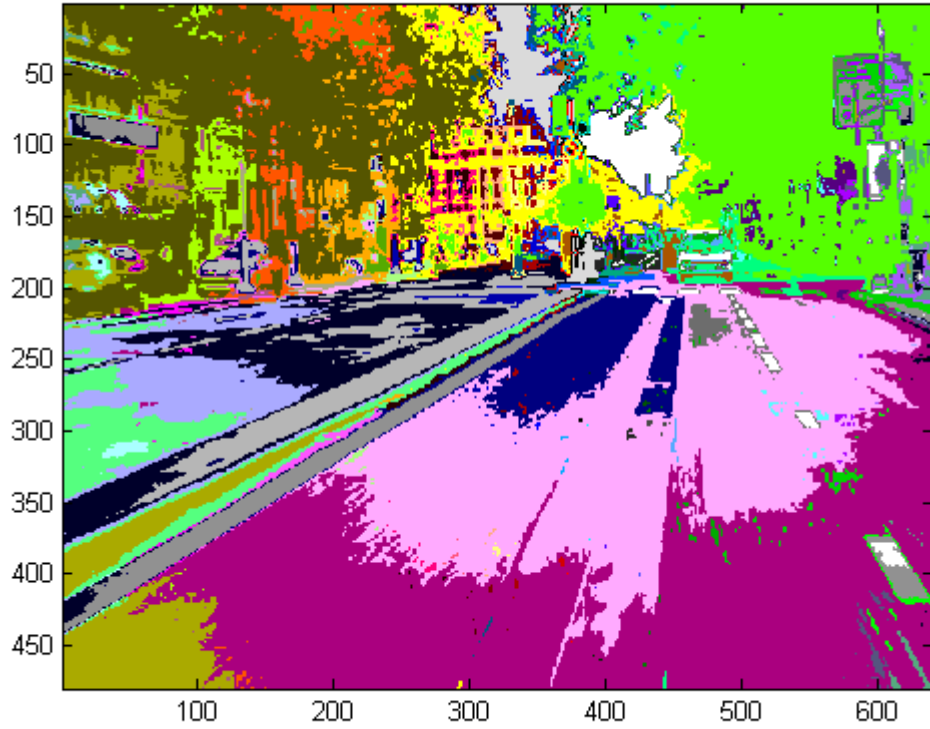
Üçüncü eşik seviyesinin eklenmesiyle hedeflerden biri görünür bir hal almıştır. Ancak bu her imge için geçerli bir durum değildir. Bu sebeple daha fazla seviye sayısının kullanılması gerekmektedir. Şekil 4.6 ve 7’de üç ve dört eşikli durumlar verilmiştir.



Şekil 4.8. Beşinci eşik seviyesi eklenmiş hali, eşik seviyeleri 113, 180, 71, 146 ve 220

Belirlediğimiz hedefin tespiti için seviye sayısının beş seçilmesinin ideal olduğu belirlenmiştir. Seviye sayısının beş olduğu durumlarda hedef olarak belirlediğimiz trafik ışıklarının sınırları doğru bir şekilde ayırt edilebilmektedir.


Eşik sayısının daha da arttırılmasının sonucu iyileştirmediği gözlemlenmiştir. Tersine aşırı bölütleme problemleri ortaya çıkmaya başlamaktadır. Ayrıca seviye sayısının arttırılmasının ek bir işlem yükü getirdiği de unutulmamalıdır. Eşiklemeye kullanılan PSO algoritmasında parçacık sayısı yirmi ve iterasyon sayısı da on olarak alınmıştır.



Şekil 4.9. İmgenin çoklu eşiklemeden sonra etiketlenerek bölütlenmiş hali

Eşikleme işlemi tamamlandıktan sonra sıra anlamlı bölütler bulunabilmesi imgenin bağlı bileşen etiketleme yöntemiyle etiketlenmesine gelir. İmge üzerinde biri birinden bağımsız bölgeler farklı rakamlarla etiketlenilerek farklı bir şekilde değerlendirilmeleri sağlanır. Şekil 4.9'da örnek imgenin etiketlenmiş hali verilmiştir bir biri ile bağlı olmayan tüm bölütler kendilerine özgü renklerle gösterilmiştir.


Eşiklenmiş ve çok seviyeli etiketleme ile etiketlenerek bölütlenmiş olan imge bölütleme aşamasından sonra bölüt seçme aşamasına geçilir. Bir imgede ortalama bin ila iki bin civarında bölüt bulunabilmektedir. Seçilmiş olan bölütler pencereler içine alınıp işaretlenmiştir. İmgemizde ilgi duyulan alanlarımız pencere içine alınır ve sınıflandırma işlemine tabi tutulmak üzere DVM'de işlenir. Örnek imgemiz Şekil 4.10'daki haline dönüşür burada ilgi duyulan elli dokuz pencere bulunmuştur. Pencere sayısı bölüt seçmede kullandığımız ölçütleri değiştirerek azaltılabilmektedir fakat o zamanda hedefin ihmal edilmesi olasılığı artmaktadır.



Şekil 4.10. İmgenin bölütleri seçilmiş hali

Sınıflandırma için kullanılan en küçük kareler DVM yönteminde lineer çekirdek fonksiyonun trafik ışığı diğerleri arasındaki ayrımı diğer çekirdek fonksiyonlarından daha iyi yaptığı gözlemlenmiştir. Trafik ışıkları arasındaki sınıflandırmada ise çekirdek fonksiyonu olarak gauss radyal baz fonksiyonu alındığında daha başarılı bir sınıflandırma gerçekleştirilmektedir.

DVM girişine veriler girilirken her bir seçili bölüt sekiz yüz altmış yedi uzunluklu bir vektör ile ifade edilmiş ve sınıflandırılmıştır. Her bir giriş için on yediye on yedilik seçilen pencerelerden önce satır sonra sütunlar olmak üzere her bir pikselin RGB değerleri sırasıyla alınmış ve üç çarpı on yedi çarpı on yedi elemanı olan yani sekiz yüz altmış yedi uzunluklu bir vektör oluşturulmuştur. Benzer işlem gri seviyeli imgeler içinde iki yüz seksen dokuz uzunluklu vektörler için denemiş ve renkli imge kullanıldığında daha iyi sınıflandırma sonuçları alındığı görülmüştür.



Şekil 4.11. İmgenin DVM ile sınıflandırma işlemi sonucu

Şekil 4.11’de ikili ağaç yapısını kullanan en küçük kareler DVM ile sınıflandırılmış imgenin sonuç görüntüsü verilmiştir. Mavi kutular trafik ışığı olmayan bölütler, yeşil kutular ise bulunan trafik ışığını belirtmektedir.

DVM modelinin oluşturulması işleminde eğitim kümesi için, önerilen bölütleme ve bölüt seçme yönteminin verdiği sonuçlar kullanılmıştır. Seçilen imgeler üzerindeki pencereler seçilerek eğitim örnekleri olarak eğitimde kullanılmıştır. Model parametreleri PSO yöntemiyle iyileştirilmiştir. Seçilen örneklerle DVM eğitim kümesinin yüzde yüz başarı ile eğitilebildiği görülmüştür. Ayrıca eğitim sırasında bazı durumlarda modelin hızlı bir şekilde eğitim kümelerine ayak uydurduğu ve genelliğini kaybettiği görülmüştür. Bu sebeple eğitim örneklerinin seçimi ve PSO başlangıç parametrelerinin seçimi önemli bir yer tutmaktadır.

Ayrıca sarı trafik ışığı bulunan örneklerin çok az olması dolayısıyla sarı renk trafik ışıkları sınıflandırmaya alınmamıştır. Benzer problemi veri setini paylaşan Charette belirtmiştir.

5. SONUÇ

Bu tez çalışmasında araç içi kamera tarafından alınan imgelerde yer alan trafik ışıklarının tanınması problemi ele alınmıştır. Seçilen problemin çözümünde kullanılabilecek güncel hedef tanıma yöntemleri incelenmiş ve DVM ile problemin çözümü başarılı bir şekilde gerçekleştirilmiştir.

İmgeler eşiklenerek bölütlendikten sonra ilgi duyulan alanların seçimi probleme özel kriterler aracılığı ile gerçekleştirilmiştir. Eşikleme işleminin daha az işlem yükü ile gerçekleştirilebilmesi için tekrarsız ayrık ikili PSO temelli yeni bir yaklaşım önerilmiştir. İlgi duyulan bölütler DVM girişleri olarak kullanılmıştır. Karar mekanizmasında ikili karar ağaç yapısı kullanılmıştır. Karar ağacı bir kök ve bir alt düğüm içermekte ve her düğümde farklı bir DVM kullanılmaktadır. Kök düğümde imgeden alınan ilgi duyulan bölütün trafik ışığı olup olmadığı kararı verilirken alt düğümde trafik ışığı olarak karar verilen bölütlerin durumu (kırmızı, yeşil) tespit edilmiştir.

Kök düğümünde yer alan DVM'in çekirdek fonksiyonu olarak lineer çekirdek fonksiyonunu seçilmiş, alt düğümdeki DVM'de ise Gauss radyal baz fonksiyonu kullanılmıştır. Her iki düğümde kullanılan DVM'lerin parametreleri PSO aracılığı ile optimize edilmiştir.

Kaynaklar

- Arora, S., Acharya, J., Verma, A., & Panigrahi, P. K. 2008.** Multilevel thresholding for image segmentation through a fast statistical recursive algorithm. *Pattern Recognition Letters*, 119-125.
- Bankman, I. 2000.** *Handbook of Medical Imaging: Processing and Analysis Management*. USA: Academic Press.
- Burges, C. J. 1998.** A Tutorial on Support Vector Machines for Pattern Recognition. *Data Mining and Knowledge Discovery*, 121-167.
- Chander, A., Chatterjee, A., & Siarry, P. 2011.** A new social and momentum component adaptive PSO algorithm for image segmentation. *Expert System with Applications*, 4998-5004.
- CHARETTE, R. d. 2009, 10 15.** *Traffic Lights Recognition (TLR) public benchmarks*. 11 17, 2012 tarihinde <http://www.lara.prd.fr/benchmarks/trafficlightrcognition> adresinden alındı
- Charette, R. d., & Nashashibi, F. 2009.** Real Time Visual Traffic Lights Recognition Based on Spot Light Detection and Adaptive Traffic Lights Templates. *IEEE Intelligent Vehicles Symposium* (s. 358-363). Xian, Çin: IEEE.
- Djerou, L., Dehimi, H., Khelil, N., & Batouche, M. 2009.** Using the BPSO Algorithm in Image Segmentation for Dynamic Thresholding. *Fourth International Conference on Bio-Inspired Computing* (s. 402-407). Beijing : IEEE.
- Evans, A. N., & Liu, X. U. 2006.** A Morphological Gradient Approach to Color Edge Detection. *IEEE TRANSACTION ON IMAGE PROCESSING*, 1454-1463.
- Gao, H., Xu, W., Sun, J., & Tang, Y. 2010.** Multilevel Thresholding for Image Segmentation Through an Improved Quantum-Behaved Particle Swarm Algorithm. *IEEE TRANSACTIONS ON INSTRUMENTATION AND MEASUREMENT*, 934-945.
- Gueguen, L., Soille, P., & Pesaresi, M. 2010.** Differential Morphological Decomposition Segmentation: A Multi-Scale Object Based Image Description. *International Conference on Pattern Recognition* (s. 938-941). İstanbul: IEEE.
- Haralick, R. S. 1987.** Image Analysis Using Mathematical Morphology. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 532-550.
- Karasik, Y. B. 1999.** How to reduce 3-D Gray-Scale Mathematical Morphology to 2-D. *IEEE Transactions on Signal Processing*, 3410-3412.

- Kennedy, J., & Eberhart, C. R. 1997.** A discrete binary version of the particle swarm algorithm. *Systems Man, and Cybernetics*, 4104-4108.
- Kılıkçier, Ç., & Yılmaz, E. 2011.** Thyroid Diagnosis with Least Squares SVM utilizing a BDT. *ELECO International Conference on Electrical and Electronics Engineering*, (s. vol 2 295-297). Bursa.
- Kılıkçier, Ç., & Yılmaz, E. 2012.** İmge Eşiklemeye Ayrık İkili PSO Temelli Yeni Bir Yaklaşım. *Eleco*. Bursa.
- Kim, S., & Kang, M. 2012.** Multiple -Region Segmentation Without Supervision by Adaptive Global Maximum Clustering. *IEEE Transactions on Image Processing*, 1600-1612.
- Lezoray, O., & Charrier, C. 2009.** Color image segmentation using morphological clustering and fusion with automatic scale sselection. *Pattern Recognition Letters*, 397-406.
- Maitra, M., & Chatterjee, A. 2008.** A hybrid cooperative-comprehensive learning based PSO algorithm for image segmentation using multilevel thresholding. *Expert Systems with Applications*, 1341-1350.
- Mushrif, M. M., & Ray, A. K. 2009.** A-IFS Histon Based Multithresholding Algorithm for Color Image Segmentation. *IEEE SIGNAL PROCESSING LETTERS*, 168-171.
- Nabizadeh, S., Faez, K., Tavassoli, S., & Rezvanian, A. 2010.** A Novel Method for Multi-Level Image Thresholding Using Particle Swarm Optimization Algorithms. *2nd International Conference on Computer Engineering and Technology (IC CET)* (s. V4.275-V4.275). Çengdu: IEEE.
- Otsu, N. 1979.** A threshold selection method from gray-level histograms. *IEEE Trans. Sys., Man.*, 62-66.
- Ratches, J. A. 1997.** Aided and Automatic Target Recogniton Based Upon Sensory Inputs From Image Forming Systems. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1004-1019.
- Rosenfeld, A., & Pfaltz, J. L. 1966.** Sequential Operations in Digital Picture Processing. *Journal of the Association for Computing Machinery*, 471-494.
- Sezgin, M. (2002).** *İmge Eşikleme Yöntemlerinin Başarımı Değerlendirilmesi ve Tahribatsız Muayenede Kullanımı*.
- Sezgin, M., & Sankur, B. 2004.** Survey over image thresholding techniques and quantitative performance evaluation. *Journal of Electronic Imaging*, 146-165.

Shih, F. Y. 2010. *Image Processing and Pattern Recognition: Fundamentals and Techniques*. Wiley.

Soille, P. 2008. Constrained Connectivity for Hierarchical Image Partitioning and Simplification. *IEEE Transaction on Pattern Analysis and Machine Intelligence*, 1132-1145.

Sonka, M., Hlavac, V., & Boyle, R. 2008. *Image Processing, Analysis; and Machine Vision Third Edition*. Stamford: CENGAGE Learning.

Suykens, J., & Vandewalle, J. 1999. Least Squares Support Vector Machine Classifiers. *Neural Processing Letters*, 293-300.

Wang, X.-Y., Wang, Q.-Y., Yang, H. y., & Bu, J. 2011. Color image segmentation using automatic pixel classification with support vector machine. *Neurocomputing*, 3898-3911.

Wang, X.-Y., Wang, T., & Bu, J. 2011. Color image segmentation using pixel wise support vector machine classification. *Pattern Recognition*, 777-787.

Wang, Y., & Bhattacharya, P. 1995. A Theory of parameter-dependent connected components of gray images and segmentation. *International Conference on Image Processing*, (s. 69-72). Washington, DC.

Westman, T., Harwood, D., Laitinen, T., & Pietikainen, M. 1990. Color Segmentation by Hierarchical Connected Component Analysis with image enhancement by symmetric neighborhood filter. *10th International Conference on Pattern Recognition*, (s. 796-802). Atlantic City, NJ.

Wu, X., Kumar, V., Quinlan, J. R., Ghosh, J., Yang, Q., Motoda, H., Steinberg, D. J. 2008. Top 10 algorithms in data mining. *Knowledge and Information Systems*, 1-37.

Ying, W. Y., Jingqi, Y., Zhenyu, Z., Deneen, K. v., & Pengfei, S. 2011. An Algorithm for License Plate Recognition Applied to Intelligent Transportation System. *IEEE Transactions on Intelligent Transportation Systems*, 830-845.

Yu, Z., Wong, H.-S., & Wen, G. 2011. A modified support vector machine and its application to image segmentation. *Image and Vision Computing*, 29-40.

ÖZGEÇMİŞ

Adı Soyadı : Çağlar Kılıkçier
Doğum Yeri ve Tarihi : Bursa, 13.05.1986
Yabancı Dili : İngilizce

Eğitim Durumu (Kurum ve Yıl)

Lise : Gazi Anadolu Lisesi, 2004
Lisans : Uludağ Üniversitesi, 2008

Çalıştığı Kurum ve Yıl : Uludağ Üniversitesi, 2011-...

İletişim (e-posta) : caglark@uludag.edu.tr

Yayınları

:

Kılıkçier, Ç., & Yılmaz, E. 2011. Thyroid Diagnosis with Least Squares SVM utilizing a BDT. ELECO International Conference on Electrical and Electronics Engineering, (s. vol 2 295-297). Bursa.

Kılıkçier, Ç., & Yılmaz, E. 2012. İmge Eşiklemeye Ayrık İkili PSO Temelli Yeni Bir Yaklaşım. Eleco. Bursa.