

T.C.
VAN YÜZÜNCÜ YIL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

**BULANIK C-ORTALAMALAR KÜMELEME ALGORİTMASI
KULLANILARAK ARAÇ TANIMA**

YÜKSEK LİSANS TEZİ

HAZIRLAYAN: Nooshin NEMATİ
DANIŞMAN: Doç. Dr. Rıdvan SARAÇOĞLU

VAN-2020

T.C.
VAN YÜZÜNCÜ YIL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

**BULANIK C-ORTALAMALAR KÜMELEME ALGORİTMASI
KULLANILARAK ARAÇ TANIMA**

YÜKSEK LİSANS TEZİ

HAZIRLAYAN: Nooshin NEMATİ

VAN-2020

KABUL VE ONAY SAYFASI

Elektrik-Elektronik Mühendisliđi Anabilim Dalı'nda Doç. Dr. Rıdvan SARAÇOĐLU danışmanlığında, Nooshin NEMATİ tarafından sunulan “Bulanık C-Ortalamalar Kümeleme Algoritması Kullanılarak Araç Tanıma” isimli bu çalışma Lisansüstü Eğitim ve Öğretim Yönetmeliđi'nin ilgili hükümleri gereğince 06/01/2020 tarihinde ařağıdaki jüri tarafından oy birliđi ile başarılı bulunmuş ve Yüksek Lisans tezi olarak kabul edilmiştir.

Başkan:.Doç Dr. Emre ÇOMAK

İmza:

Üye:. Doç Dr. Rıdvan SARAÇOĐLU

İmza:

Üye:.Dr. Öğr. Üyesi Özkan ATAN

İmza:

Fen Bilimleri Enstitüsü Yönetim Kurulu'nun/..../..... tarih ve sayılı kararı ile onaylanmıştır.

İmza

Prof. Dr. Suat ŞENSOY

Enstitü Müdürü

TEZ BİLDİRİMİ

Tez içindeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edilerek sunulduğunu, ayrıca tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

(İmza)

Nooshin NEMATİ

ÖZET

BULANIK C-ORTALAMALAR KÜMELEME ALGORİTMASI KULLANILARAK ARAÇ TANIMA

NEMATI, Nooshin

Yüksek Lisans Tezi, Elektrik-Elektronik Mühendisliği Anabilim Dalı

Tez Danışmanı: Doç. Dr. Rıdvan SARAÇOĞLU

Ocak 2020, 40 sayfa

Araç algılama ve tanımlama, trafik kontrolü ve yönetimi alanında önemli bir işlemdir. Genellikle bu işlevin ele alınması, büyük veri kümeleri ve alana özgü özellikler üzerinde çalışmayı gerektirir. Bu verilere en iyi şekilde uyacak modelin bulunmasına çalışılır. Ayrıca veriler için hazırlanan bu model temelde görüntü içindeki öğeleri tanımayı amaçlar. Bir başka deyişle öğeleri ayırt edebilmeyi veya doğru sınıflara atamayı amaçlar. Bu açıdan bir görüntü sınıflandırması yapılır. Bu çalışmada hareketli görüntüler için bir araç tanıma ve sayma uygulaması gerçekleştirilmiştir. Görüntü segmentasyonu için Bulanık C Ortalamalar ve görüntü sınıflandırması için Destek Vektör Makinesi (DVM) tercih edilmiştir. Kullanılacak olan bu yöntemlerinin güncel olmaları önemli bir özellikleridir. DVM, hem regresyon hem de desen tanıma için geçerli olan güncel bir evrensel öğrenme makinesidir. Makine öğrenmesinde DVM'ler, verileri analiz eden ve kalıpları tanıyan ilişkili öğrenme algoritmaları üzerinde çalışan denetimli öğrenme modelleridir.

Anahtar kelimeler: Araç tanıma, Bulanık C-ortalamar, Destek vektör makinesi, Kümeleme.

ABSTRACT

VEHICLE DETECTION USING FUZZY C-MEANS CLUSTERING ALGORITHM

NEMATİ, Nooshin

M. Sc. Thesis, Electrical-Electronics Engineering

Supervisor: Assoc. Prof. Dr. Rıdvan SARAÇOĞLU

January 2020, 40 pages

Vehicle detection and identification is an important function in the field of traffic control and management. Often handling this function requires working on large data sets and site-specific features. This model, which is prepared for the data, aims to recognize the elements in the image. In other words, it aims to distinguish items or assign them to the correct classes. In this study, a vehicle recognition and counting application was performed for moving images. Fuzzy C Means for image segmentation and Support Vector Machine (DVM) for image classification were preferred. It is important that these methods to be used are up to date. DVM is a current universal learning machine for both regression and pattern recognition. In machine learning, DVMs are supervised learning models that work on associated learning algorithms that analyze data and recognize patterns.

Keywords: Vehicle recognition, Fuzzy C-means, Support vector machine, Clustering.



ÖN SÖZ

Benim tezimin tüm aşamalarında hiçbir desteğini esirgemeyen danışmanım Sayın Doç.Dr. Rıdvan SARAÇOĞLU'na yürekten şükranlarımı sunmak istiyorum. Özellikle Dr.Öğr. Üyesi Özkan ATAN'na tez konusunda yardım ettiği için ve maddi, manevi yanımda olan abime, dualarını esirgemeyen anneme teşekkür etmek istiyorum.

2020

Nooshin NEMATİ



İÇİNDEKİLER

	Sayfa
ÖZET	i
ABSTRACT	iii
ÖN SÖZ.....	v
ÇİZELGELER LİSTESİ	ix
ŞEKİLLER LİSTESİ.....	xi
SİMGELER VE KISALTMALAR	xiii
1. GİRİŞ.....	1
1.1. Amaç ve Tezin Önemi	3
2. KAYNAK BİLDİRİŞLERİ	5
3. MATERYAL VE YÖNTEM.....	9
3.1. Segmentasyon	9
3.1.1. Görüntü segmentasyon algoritmaları:	12
3.1.2. Kenar Belirleme	12
3.1.3. Kenar belirleme yöntemleri.....	12
3.1.4. Temel bilgi	13
3.1.5. Türeve dayalı kenar belirleme (Laplasiyan).....	13
3.2. FCM	16
3.3. TBA	18
3.4. Destek Vektör Makineleri.....	20
3.4.1. Doğrusal destek vektör makineleri.....	21
3.4.2. Doğrusal ayrılamayan veriler için DVM.....	23
4. BULGULAR.....	29
4.1. Veri Seti.....	30
4.2. Segmentasyon Aşaması.....	31
4.3. Bulanık C-Ortalamlar Uygulaması.....	31
4.4. Temel Bileşen Analizi Aşaması	32
4.5. Destek Vektör Makinesi Aşaması	33
5. TARTIŞMA VE SONUÇ	35

	Sayfa
KAYNAKLAR.....	37
ÖZ GEÇMİŞ.....	41



ÇİZELGELER LİSTESİ

Çizelge	Sayfa
Çizelge 3.1. Destek vektör makinelerinde kullanılan temel çekirdek fonksiyon ve parametreleri.....	26
Çizelge 4.1.Videoların gerçek ve tesbit edilen sonuçlar	34



ŞEKİLLER LİSTESİ

Şekil	Sayfa
Şekil 3.1. Örnek arka plan bölümlendirme ve ön plan çıkarımı.....	11
Şekil 3.2. Laplasyon görüntüsünde sıfır geçiş noktalarının belirlenmesi için basit bir yaklaşım.....	15
Şekil 3.3. Sıfır geçiş örneği.....	15
Şekil 3.4. Laplasyon örnek.....	16
Şekil 3.5. TBA.....	18
Şekil 3.6. TBA amacı.....	19
Şekil 3.7. TBA verileri.....	20
Şekil 3.8. Doğrusal olarak ayrılabilen veri setleri için hiper düzlemin belirlenmesi	23
Şekil 3.9. Doğrusal hiper belirleme.....	25
Şekil 3.10. Çekirdek fonksiyonu ile verinin daha yüksek bir boyuta dönüştürülmesi	25
Şekil 4.1. Tez aşaması.....	29
Şekil 4.2. Kullanılan Veri setine ait görüntüler.....	30
Şekil 4.3. Farklı görüntüler için FCM uygulaması sonuçları	32



SİMGELER VE KISALTMALAR

Bu çalışmada kullanılan bazı kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur.

Kısaltmalar	Açıklama
FCM	Fuzzy C-means
BM	Bulanık Mantık
DVM	Destek Vektör Makinesi
TBA	Temel Bilişim Analizi
CNN	Convolutional Neural Network
LDA	Discriminant Analysis
KPCA	Kernel Principal Component Analysis



1. GİRİŞ

Günümüzde, bilgisayar tüm yaşantımıza hızla ve yaygın bir şekilde girip yapmakta zorlandığımız işleri daha kısa sürede ve daha iyi sonuçlar göstererek yapmamızı sağlamıştır. Yaşantımızın bir parçası olan görüntüleri bilgisayar yardımıyla analiz etmemizi sağlayan Bilgisayar biliminin alt dalı olan görüntü işleme teknolojilerinden faydalanmaktadır. Görüntü işleme, herhangi bir aygıt tarafından görüntülere işlem yapabilmeyi sağlayan tekniğe verilen isimdir. Görüntü işleme, genelde resim olan bilgilerin analizine yönelik bir yöntemdir. Günlük yaşamımız içerisinde görüntü işlemenin örnekleriyle çok karşılaşılabilir. Bunların örnekleri arasında gözlüklerin yer aldığı söylenebilir. Numaralı gözlükler, görülen görüntüleri gözdeki yön değişmeye göre değiştirip yerini doldurup görüntü göz ile temasından önce görüntünün düzeltilmesi için hazırlanmaktadır. Bir diğer görüntü işleme örneği olarak televizyondaki parlaklık ve en parlak ve en karanlık ayarlamalarıdır. Bu ayarları yaparak, öznel görüntüyü bizim için iyi imaj haline gelene kadar ayarlayabiliriz. Her gün karşımızda olan ve güçlü görüntü işlem sisteminin örneği, insan beyin ve gözü olmaktadır. Bu sistem görüntüleri hızla alır, güçlendirir, keser, analiz eder ve saklar. Bu sistem, başka sistemlere göre daha yaygındır. Görüntü işleme araç algılama, tanımlama, trafik kontrolü ve yönetimi alanında önemli bir işlemdir. Genellikle bu işlemin ele alınması, büyük veri kümeleri ve alana özgü özellikler üzerinde çalışmayı gerektirir. Bu verilere en iyi şekilde uyacak modelin bulunmasına çalışılır. Ayrıca veriler için hazırlanan bu model temelde görüntü içindeki öğeleri tanımayı amaçlar. Bir başka deyişle öğeleri ayırt edebilmeyi veya doğru sınıflara atamayı amaçlar. Bu açıdan bir görüntü sınıflandırması yapılır. Görüntü sınıflandırması, çeşitli faktörlere bağlı olan karmaşık bir süreçtir. Nesneye, o nesneye karşılık gelen özniteliklere bağlı olarak belirli bir grup veya sınıfa atanması gerektiğinde sınıflandırma ihtiyacı ortaya çıkar. Görüntüler gürültü, düşük kalite, tıkanıklık veya arka plan karmaşası içerebilmektedir. Bu sebeplerden dolayı görüntüdeki bir nesneyi tanımlamak oldukça zorlaşır. Bir görüntü birden fazla nesne içerdiğinde bu zorluk katlanır. Bir görüntüde bulunan özelliklerin doğru tanımlanması, görüntü sınıflandırmasının temel amacıdır. Görüntü sınıflandırmasında hem denetimli hem de denetimsiz sınıflandırmalar

kullanılabilmektedir. Denetimli sınıflandırma için, insan müdahalesi ile birlikte eğitilmiş bir veri sisteminden yararlanılır. Denetimsiz sınıflandırma durumunda ise insan müdahalesi hiç bulunmamaktadır. Tamamen bilgisayar tarafından işletilen bir süreç bulunmaktadır (Robert, 2007). Araçlar genellikle insan gözü tarafından belli başlı yönlerinden dolayı (araç logosu vb.) kolayca tanınabilirler. Ancak bu, araçların görsel karmaşıklığından dolayı bilgisayarlar için oldukça zor bir görevdir. Genellikle küçük farklılıkların öğrenilebilmesi için büyük miktarda veri kullanmak gerekir. Bununla birlikte sınırlı zaman, hesaplama gücü veya veri içeren ortamda bu tanıma işi zorlaşmaktadır. Görüntülerdeki araçlara farklı açılardan bakılıyor olması bu görüntülerin serbest biçimli bir yapısı olduğu anlamına geldiğinden özellikle zorlayıcı olmaktadır. Görüntü sınıflandırması temel olarak; görüntünün algılanması, görüntü ön işleme, nesne algılama, nesne segmentasyonu, özellik çıkarma ve nesne sınıflandırmasını içerir. Görüntü sınıflandırması için birçok sınıflandırma tekniği geliştirilmiştir. Bunlardan en önemlileri olarak Yapay Sinir Ağı (YSA), Karar Ağacı, Destek Vektör Makinesi (DVM) sayılabilir (Chi ve Benediktsson, 2008). Bu çalışmada kullanılmış olan yöntemlerin ve tekniklerin (DVM ve FCM) güncel olmaları önemli bir özellikleridir. DVM, hem regresyon hem de desen tanıma için geçerli olan güncel bir evrensel öğrenme makinesidir. Makine öğrenmesinde DVM'ler, verileri analiz eden ve kalıpları tanıyan ilişkili öğrenme algoritmaları üzerinde çalışan denetimli öğrenme modelleridir. Görüntü sınıflandırması, görüntülerin bir dizi önceden tanımlanmış kategoriden birine işaretlenmesini ifade ettiği için burada başarılı bir DVM kullanılması uygun olacaktır.

Son yıllarda araç sayısının artması ve trafikte olan sorunlar, otomatik araç tanıma ve trafik akış kontrolü sistemlerine ihtiyacı arttırmıştır. Bu amaca yönelik çalışmalar temel olarak araçları özel bir noktadan geçerken tanımlamak, araç konumu belirlemek, davranış gözlemek ve bu verileri kullanarak trafik denetimi sağlamaya yöneliktir.

Araç sınıflandırması trafik gözetimi ve yönetiminde önemli bir kullanım alanına sahiptir. Bu görevi gerçekleştirmek için çeşitli algoritmalar kullanarak önerilen birçok yöntem vardır. Bu çalışmada, her aracın boyutlarını kullanan bulanık c-ortalamalar (FCM) kümelemesine dayalı bir yöntem tanıtılmıştır. Araçların boyutunu ve kenarların doğrusallığını çıkarmak için bir yöntem önerilmiştir. Bu iki özelliği kullanarak, araçları

“küçük araba”, ”büyük araba” ve “diğer” olarak sınıflandırmak amacıyla bir sınıflandırıcı kullanılmıştır.

Temel Bileşenler Analizi (TBA), yüz tanımda ve resimleri sıkıştırma da yaygın olarak kullanılan istatistiksel bir metottur. TBA de öncelikle öz değer konusunun incelenmesi gerekmektedir. Özdeğer-Özvektör Hesaplaması TBA'nın anlaşılması için incelenmesi gereken konular arasına girmektedir. Bu nedenle çalışmada önce bahsi geçen konulara göz atılmış ve matematiksel temel açıklandıktan sonra yöntemin uygulama alanlarına yer verilmiştir. Kümelerin sınıflandırılması için ise DVM yöntemi kullanılmıştır.

DVM temelde, öncelik değişkenini bir özelliikle çağırıp, çok boyutlu düzlemde kullanılan niteliğe dönüştürür. En uygun temsili seçme amacı, özellik seçimi bilindir. Özellikler doğru seçildiğinde iyi temsiller elde edilerek doğru sonuçlara ulaşılabilir. Olayın tanımlayan özellik takımı bir vektör ile çağırılır. Bundan dolayı DVM modelinin amacı, hedef değişkeninin bir kategorisiyle olayların vektör kümelerini ayıran düzlemi bulmaktır. Aşırı düzlemin yanındaki vektörler destek vektörleridir.

1.1. Amaç ve Tezin Önemi

Akıllı şehir düzenlerinin hayatımıza girdiği bu çağda ulaşım sıkıntısını büyük ölçüde azaltacak ulaşımın daha düzenli ve koordineli bir şekilde ilerlemesini sağlamak adına gerçekleştirilmiş olan bu çalışmada akan trafikteki araçların tespit edilmesi ve sınıflarına göre sayılması amaçlanmıştır. Temel olarak trafikteki nesnelere üç sınıf olarak (büyük araç, küçük araç ve diğer) ele alınmıştır. Örneğin bazı bölgelerde trafikteki büyük araçların sayısının fazla olması problem oluşturabilir. Yapılan bu çalışmayla araç yoğunlukları tespit edilerek trafiğin uygun bölgelere yönlendirilmesi ve trafiğin daha hızlı akması sağlanabilecektir. Araç sınıfına göre yapılacak bir sayma işlemi bu yoğunluğun tespiti ve çözüm arayışında faydalı olacaktır. Aynı zamanda bu model zaman ve kirlilik faktörlerinin tespiti ve azaltılmasına yönelik çalışmalara da faydalı olacaktır.

Bu çalışmada, farklı olabilen ve farklı açılardan görüntülenebilen araçların tespit edilmesi ve sayılması amaçlanmıştır.



2. KAYNAK BİLDİRİŞLERİ

FCM algoritması çeşitli veri analizi problemlerine uygulanabilmektedir. Bu yöntem, herhangi bir sayısal veri seti için bulanık bölümler ve prototipler üretmektedir. Bu bölümler, bilinen örüntüleri doğrulamak veya verilerde yeni örüntüler keşfetmek için kullanışlıdır. Bu yöntemin özellikleri arasında, üçlü normlar (Öklid, Köşegen veya Mahalonobis), gürültüye karşı hassasiyeti esas olarak alan ayarlanabilir bir ağırlık faktörü, değişken sayı kümelerinin kabulü ve çeşitli kümelenme geçerliği ölçümleri içeren çıktılar yer alır. Geleneksel bulanık c-ortalama (Fuzzy C-Means, FCM) kümeleme algoritmasının gürültü duyarlılığını aşmak için yöntem geliştirilmeye çalışılmaktadır.

Bezdek (1981) çalışmasında görüntü işlemedeki FCM yönteminin gürültü duyarlılığı problemini aşmak için komşu piksellerin merkezdeki pikseller üzerindeki etkisini dikkate alan bir ceza mekanizması geliştirmiştir. Algoritmanın performansı tartışılmış ve karşılaştırılmıştır. Sentetik ve gerçek görüntülerin segmentasyonu üzerine deneysel sonuçlar, önerilen algoritmanın etkili ve sağlam olduğunu göstermiştir.

Bir başka çalışmasında, görüntü bölümlendirme için yeni bir yöntem önerilmiştir. İlkel bölgelerin ve sınırların bazı yararlı bilgileri elde edildikten sonra her bir piksel için bulanık üyelik değerlerini hesaplayan FCM algoritması kenar gösterge fonksiyonunu yeniden tanımlamada kullanılmıştır. Algoritmanın verimliliği ve doğruluğu, MR beyin görüntülerinde yapılan deneylerle kanıtlanmıştır (Bezdek, 1982). Microarray teknolojisi binlerce genin aynı anda izlenmesini sağlar. Gen ekspresyonu ölçümlerine dayanarak, mikrodizi teknolojisi, yeni hastalık tiplerini keşfetmek ve bir hastalığın tipini tahmin etmek için gen ekspresyonu profillemesinde güçlü olduğunu kanıtlamıştır. Mikrodizi görüntü analizinde üç önemli adım; Gridding, segmentasyon ve yoğunluk çıkarımıdır. Noktaları için belirli bir şekil ve boyutla sınırlı olmadığında kümeleme algoritmaları kullanılır. Tek özellikli kümeleme algoritması kullanmak yerine, piksel yoğunluğu, spotun merkezinden uzaklaşan ve etraftaki piksellerin medyanı gibi her bir piksel için üç özellikli çoklu özellik kümeleme algoritması kullanılabilir (Duda ve Hart, 1973). Deneysel sonuçlar, çoklu özellikli FCM'in mikrodizi görüntüsünü diğer algoritmalara göre daha doğru bir şekilde bölümlere ayırdığını göstermektedir.

Pham ve ark. (1999) çalışmalarında MRI verilerinin bulanık bölünmesi ve bulanık mantık kullanılarak yoğunluk homojensizliklerinin tahmini için yeni bir algoritma sunmuşlardır. Butür homojensizlikleri telafi etmek ve bir pikselin etiketlenmesini yakın komşuluktaki etiketlerden etkilenmesini sağlayan standart FCM algoritmasının amaç işlevinin değiştirilmesi ile sağlanır. Hem yapay görüntüler hem de MR verileri üzerindeki deneysel sonuçlar, önerilen algoritmanın etkinliğini ve verimliliğini göstermiştir. (Zanaty,2013)Kümeleme algoritmaları, kullanılan özelliklere ve belirli bir görüntüdeki nesnelerin türüne büyük ölçüde bağımlıdır. Nesnebenzer yüzey varyasyonlarının (SSV) yanı sıra piksel için FCM algoritmasının esnekliğini dikkate alarak, nesne yüzeyini göz önünde bulunduran bulanık bir görüntü segmentasyonu geliştirilmiştir (Dhanachandra ve ark,2015). SSV ile nesnelerin bölümlendirilmesinde yöntemin etkinliğini artırmak için nesne SSV'sini doğrudan göz önünde bulunduran ve piksel kullanılarak bastırılmış FCM kullanımını içeren bir yaklaşım benimsenmiştir. Algoritma ayrıca algısal olarak insan görsel algı aralığı içindeki eşiği seçmektedir. Niteliksel ve niceliksel sonuçlar, birçok farklı görüntü için önerilen algoritmanın performansını doğrulamaktadır.

Bir görüntünün piksel bandına bölünmesi eylemi olarak tanımlanan Görüntü segmentasyonunun amacı pikselleri bölgelere ayırmaktır. Uydu görüntüleri, yüz tanıma, iris tanıma, tarımsal görüntüleme, tıbbi görüntüleme nesneleri yerleştirme kullanılır. Kümeleme, benzer nesneleri grup haline getiren ve beyin tümörü taraması için yaygın olarak kullanılan bir tekniktir. Ambroise ve Govaert (1998), yoğunluğun homojen olmaması ve gürültüden kaynaklanan görüntülerin segmentasyonu için mesafe metriğine dayanan yeni bir yöntem kullanılarak değiştirilmiş FCM algoritması önermişlerdir.

Bulanık kümeleme modeli, model ve görüntü sınıflandırmasında belirli veri kümelerinin uygun küme yapısını bulmak için gerekli bir araçtır. Mcinerney ve Terzopoulos (1996) çalışmasında, yüksek boyutlu çok-sınıflı model tanıma problemlerinde FCM ve FWCM modellerinin performansını arttırmak için yeni bir geliştirilmiş algoritma önermişlerdir. Bu çalışmanın motivasyonu, iyi bilinen FCM ve yakın zamanda önerilen bulanık ağırlıklı C-Means algoritmasını (FWCM) geliştirmektir. Hem sentetik hem de gerçek veriler üzerindeki deneysel sonuçlar,

önerilen kümeleme algoritmasının özellikle hiperspektral görüntüler için FCM ve FWCM algoritmalarından daha iyi kümelene sonuçları ürettiğini göstermektedir.

Zhang ve Chen (2003) polarimetrik bir sentetik açıklık radar görüntüsü sınıflandırılarak beş kümeleme tekniğini karşılaştırmıştır. Pikseller, karmaşık Wishart dağılımına sahip olduğu bilinen karmaşık kovaryans matrisleridir. İki teknik, standart I1 ve I2 ölçümlerine dayanan bulanık kümeleme algoritmalarıdır. Diğer ikisi yeni, güçlü FCM kümeleme tekniğini Wishart dağılımına dayalı bir uzaklık ölçüsü ile birleştirilmiştir. Beşinci kümeleme tekniği, beklenti-maksimizasyon algoritmasının bir uygulamasıdır. Sonuçlar, piksel modelinin kümelene mekanizmasından daha önemli olduğu sonucunu desteklemektedir.

Bir görüntünün farklı homojen bölgelere sınıflandırılması problemi, yoğunluk uzayındaki piksellerin kümelene görevi olarak görülmektedir. Özellikle, uydu görüntüleri bazılarının (örneğin köprüler ve yollar) nispeten çok daha küçük bölgeleri işgal ederken, bazıları önemli ölçüde geniş alanları kapsayan arazi örtüsü tiplerini içerir. Geniş çapta değişen boyutlardaki bölgeleri veya kümeleri otomatik olarak tespit etmek zorlu bir iştir. Meyer ve Beucher (1990), yeni bir kodlanmış modifiye diferansiyel evrime dayalı otomatik bulanık küme algoritması, kümelene sayısını ve bir veri kümesinden doğru bölümlenmeyi otomatik olarak geliştiren bir yaklaşım önermişlerdir. Önerilen tekniğin etkinliği, ilk olarak, özellik vektörleri açısından açıklanan ve daha sonra uzaktan algılama görüntülerinde farklı arazi alanlarının tanımlanmasında kullanılan iki sayısal uzaktan algılama verisi için gösterilmektedir. Yeni yöntemin üstünlüğü, mevcut olanla karşılaştırılarak gösterilmiştir.

Bir görüntünün farklı homojen bölgelere sınıflandırılması problemi, yoğunluk uzayındaki piksellerin kümelene görevi olarak görülmektedir. Shamsive ark. (2012) çalışmasında, kümelene melerin otomatik evrimi ile gerçek kodlu değişken dizi uzunluğu genetik bulanık kümeleme kullanmıştır. Küme merkezleri kromozomlarda kodlanmış ve Xie – Beni indeksi karşılık gelen bölümün geçerliliğinin bir ölçüsü olarak kullanılmıştır. Önerilen tekniğin etkinliği, uzaktan algılama görüntülerinde farklı arazi alanlarının sınıflandırılması için gösterilmiştir. Sonuçlar, FCM algoritması kullanılarak elde edilenlerle karşılaştırılmıştır.

Görüntü bölümlendirme, bir görüntünün daha anlamlı ve analiz edilmesi kolay şekilde basitleştirmek veya değiştirmek için kullanılır. FCM, görüntü bölümlenme için en

yaygın kullanılan yöntemlerden biridir, çünkü daha önce herhangi bir bilgi olmaksızın orijinal görüntüden daha fazla bilgi elde edebilir. Yang ve ark (2008) çalışmalarında, tıbbi görüntülerin bölümlendirilmesi için güçlü bilgi kümelenmesine (RIC) dayanan yeni FCM algoritması geliştirmek için yukarıda bahsedilen eksiklikleri dikkate almışlardır. Amaç tıbbi görüntünün segmentasyonu için etkili FCM yöntemine dayalı yeni bir otomatik segmentasyon algoritması geliştirmektir. Önerilen yöntemin performansı deneysel çalışma ile kanıtlanmıştır.

Bilgisayar tabanlı araç plakası tanıma yeni gelişen bir sistemdir. Bu sistemlerinin ticari değerinin yüksek olmasından dolayı yapılan çalışmaların detayları hakkında literatür bilgisi birkaç yaklaşımla sınırlıdır. Genelde araç plakası tanıma işlemi iki adımda gerçekleştirilir; plaka yer tespiti ve plaka üzerindeki karakterlerin tanınması (Auty ve ark. 1995; Setchell, 1997). Çalışmalarda plaka yeri bulma işleminde görüntü işleme rutinlerinden ya da yapay sinir ağlarından yararlanılmıştır. Plaka tanımının ikinci adımı olan karakter tanıma işleminde ise genelde üç yöntem kullanılır: Örnek eşleştirmek (template matching) karakteristik tabanlı tanımak ve yapay sinir ağları (Draghici, 1997; Collomosse ve ark. 2001; Hauslen, 1977).

3. MATERYAL VE YÖNTEM

Bu bölümde, en büyük avantajı, bir dizi veri göz önüne alındığında, kümeleme teknikleri, verileri bir grup içinde güçlü ve farklı gruplardaki veriler arasında zayıf olacak şekilde birkaç gruba ayırır (Grosse ve ark,2000). Klasik kesin kümeleme teknikleri, her bir veri noktasının sadece bir kümeye ait olabileceği keskin bölmeler ile sonuçlanır. Bulanık kümeleme, veri noktalarının birden fazla gruba ait olmasını sağlar.

3.1. Segmentasyon

Segmentasyon genel olarak görüntü analizinin ilk aşamasıdır. Görüntü bölütleme, bir görüntüde her birinin içerisinde farklı özelliklerin olduğu anlamlı bölgelere ayırmak olarak anlatılmaktadır. Örneğin, görüntü içerisindeki benzer parlaklıklar olabilir ve bu parlaklıklar ilgili görüntünün farklı yerlerde nesnelerin temsilcisi olmaktadır. Uygulamaya bağlı olan değişebilen bu segmentlere (bölütler-elemanlar) başka bir örnek olarak; hava-yer fotoğrafında, yolda hareket eden araçları ve çevreyi yoldan ayırt edebilmek için bir segmentleme yapılabilir (Yolu çevreden ayırabilen bir segmentleme). Tüm görüntülere uygulanabilecek genel bir bölütleme yöntemi yoktur ve hiçbir bölütleme yöntemi mükemmel değildir. Bir başka deyimle, görüntüyü iyileştirme ve onarma problemlerinde olduğu gibi görüntü bölütleme için de tasarlanan yöntemler ve bu yöntemlerin başarıları, görüntüden görüntüye ve uygulamaya dayalı olarak değişiklik istemektedir. Otomatik görüntü segmentasyonu görüntü işlemenin zor işlemlerinden biridir. Segmentasyon görüntü bölümlendirme, bir görüntü grubunun bölümlere ayırmaktır. Pikselleri yoğunluk, renk ve doku gibi benzer özelliklere sahip olan ayrı bölgeler kümesi haline getirir. Görüntünün özellik alanını bölümlere ayıran kümelemeli yöntemdir. Küme ve orijinal görüntünün K-ortalamlar, FCM ve ortalama kayma algoritmalarından ibarettir. FCM algoritması görüntü segmentasyonuna geniş çapta uygulanır çünkü belirsizlik ve eşik tabanlı segmentasyon metodlarına kıyasla çok daha fazla bilgiyi tutma kabiliyetine sahiptir. FCM kümeleme, görüntüleri benzer spektral özelliklere sahip kümelere ayırmak için uygulanan denetimsiz bir kümeleme tekniğidir. Üyelik işlevini hesaplamak için spektral alandaki pikseller ve küme merkezleri arasındaki mesafeyi kullanır. Bir görüntüdeki pikseller

yüksek oranda ilişkilidir ve bu bilgi kümelemeyi geliştirmek için kullanılabilir önemli bir özelliktir. İlk 1981 yılında Bezdek tarafından daha önceki kümeleme yöntemlerinde bir gelişme olarak tanıtılmıştır. Çok boyut olan alanların belirli sayıda farklı kümelerde toplanmasını sağlayan veri noktalarının nasıl gruplandırılacağını gösteren bir yöntem sağlar.

Hedef:

$$J_{fcm} = \sum_{k=1}^k \sum_{i=1}^{M*N} |u_{ik}^m d_{ik}^2| = \sum_{k=1}^k \sum_{i=1}^{M*N} u_{ik}^M \|x_i - u_k\|^2 \quad 1 \leq m \leq \infty$$

$m = 1$ 'den büyük herhangi bir gerçektek sayı

$M \times N =$ görüntüdeki piksel sayısı

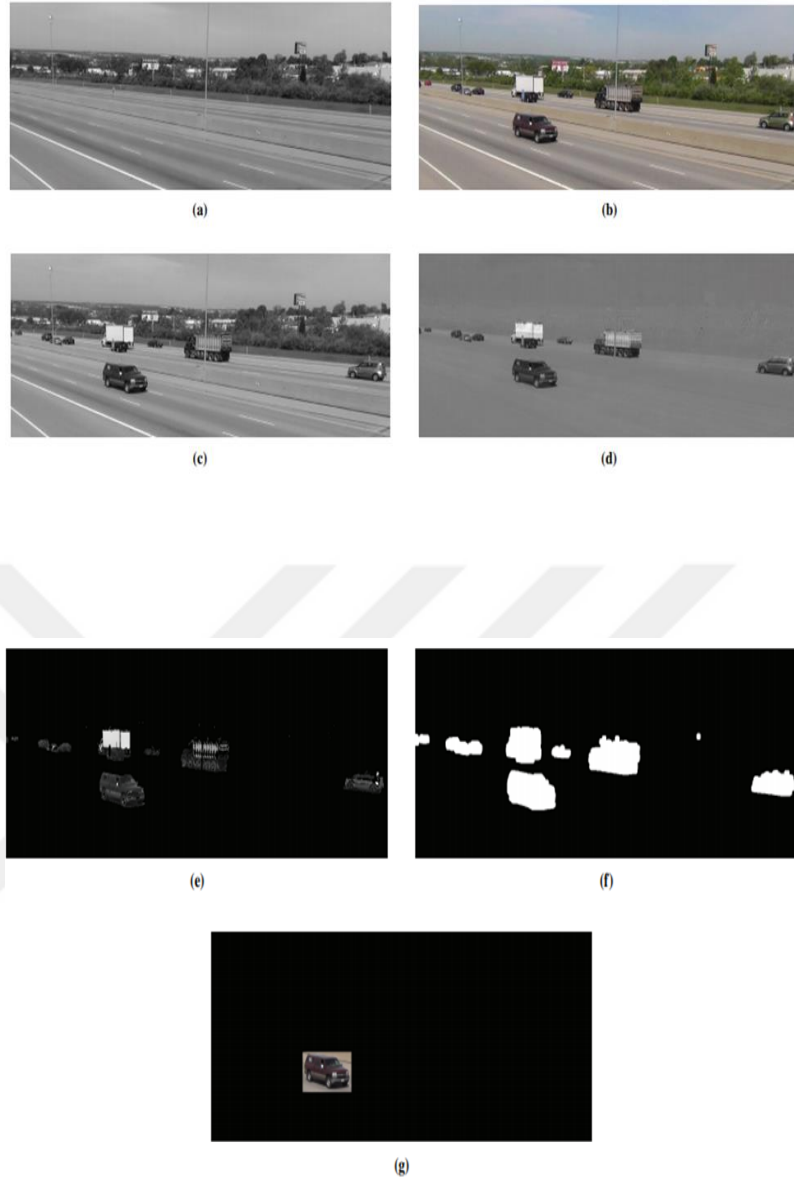
u_{ik}^m = küme k 'ye x_i üyeliği derecesi

$X_i = d$ boyutlu ölçülen verilerin i 'nci elementi

$U_k = d$ boyutlu küme merkezi ($d = 2$ görüntüler için)

$d_{i,k}^2 =$ nesne x_i ve küme merkezi μ_k arasındaki mesafe ölçüsü

$\|*\| =$ ölçülen herhangi bir veri ile merkez μ_k arasındaki benzerliği anlatan herhangi bir norm.



Şekil 3.1. Örnek arka plan bölümlendirme ve ön plan çıkarımı: (a) Görüntü 1, arka plan; (b) Resim 2, yeni video çerçevesi; (c) Resim 3, gri tonlamalı yeni video karesi; (d) Resim 3, Resim 1'den çıkarır (başka bir resimden çıkartılan tüm resmin dijital sayısal değeri); (e) Görüntü 5, siyah-beyaz eşiklenmeden sonra ortaya çıkan görüntü; (f) Görüntü 6, Görüntü 5'in ikili görüntüsü; ve (g) Görüntü 7, Resim 6'yı Resim 2 ile çarparak parçalara ayrılmış ön plan görüntüsü.

3.1.1. Görüntü segmentasyon algoritmaları:

Gri seviye değerlerindeki benzerliklere göre görüntü bölütleme, bölge bölütlemesi (region segmentation) olarak da adlandırılır. Eşikleme (thresholding), büyütme (growing), ve yarma - kaynaştırma (split- and -merge) işlemlerine dayalıdır. Piksellerin gri seviye değerlerinde benzer olması veya farklı olmasının görüntünün bölütlenmesi Kavramı, hem durağan (static) hem de dinamik (zamanla değişen) görüntülere uygulanmaktadır.

3.1.2. Kenar Belirleme

Bir görüntüdeki kenar, ışık veya yüzey yansımalar gibi görüntünün fiziksel görünüşünde oluşan önemli değişime karşı olur, bu değişim kendisini parlaklık, renk ve doku olarak gösterir Kenar belirlemede, sadece görüntü parlaklıklarındaki değişikliklerle ilgilenilecektir. Bu anlamda, görüntünün gri seviyesinde ani değişikliklerin olduğu bölgelere kenar adı verilmektedir. Nesne tanıma Problemi bir örnek olarak verilebilmektedir. Nesne tanımadaki ilk adım, bir görüntüyü farklı nesnelere karşı olan farklı bölgelere bölmelemektir. Kenar belirleme işleminin kullanışlı olduğu diğer bir örnek, sadece görüntüye ilişkin kenarların kodlandığı düşük bir oranlarında görüntü kodlama uygulamasıdır. Nesnelere fiziksel özellikleri ile kenarları arasında bir ilişki söz konusudur, görüntünün fiziksel özelliği kenar bilgisinden çıkarılabilir.

3.1.3. Kenar belirleme yöntemleri

Görüntüde ilgilenilen bölgelerin içerisinde homojen olması varsayılacak ve iki bölge arasında geçiş sadece gri seviye süreksizliklerine dayalı olarak tanımlanabilecektir. Kenarları doğru konumlarda belirleyebilmelidir, Bir kenar için tek bir kenar görüntüsü oluşturabilmeli yani yapay kenarlar olmamalıdır. Görüntü içerisinde görüntünün varlığı, kenar belirleme ve konumlama ölçütleri arasındaki karşılıklı ilişki ve kenarların çok ölçekli yapısı, kenar belirleme aşamasında karşılaşılabilecek önemli sorunlardır.

3.1.4. Temel bilgi

- 1.derece Türev :

$$\frac{\partial f}{\partial x} = f'(x) = f(x+1) - f(x)$$

- 2.derece türev İşlemi

$$\frac{\partial^2 f}{\partial x^2} = f(x+1) + f(x-1) - 2f(x)$$

- Birinci dereceden türevler, görüntüde genellikle kalın kenarlar üretir.
- İkinci dereceden türevler ince çizgiler
- İkinci dereceden türev basamak(keskin)geçiş de bir çift kenar tepki oluşturur.
- İkinci türevin işareti aydınlık- karanlık veya karanlık-aydınlık bir kenar geçiş olup olmadığını belirlemek için kullanılabilir

3.1.5. Türeve dayalı kenar belirleme (Laplasiyan)

Herhangi bir işarete ilişkin geçiş noktasının belirlenmesi için yöntemlerden diğeri, fonksiyona ilişkin 2.türevi kullanılmaktadır. İşarete ilişkin 1.türevin en büyük veya en küçük olduğu noktada işaretin 2.türevi sıfıra eşittir. Bu gerçeğe dayanarak, bir görüntü fonksiyonuna ilişkin 2.türev alınıp sıfır geçiş noktalarının tespit edilmesiyle görüntüye ilişkin kenar görüntüsüne ulaşmak mümkündür. 2-Boyutlu bir $f(x, y)$ fonksiyonunun x ve y değişkenlerine göre 2.türevi, $f(x, y)$ 'nin ayrık (Diskrate) laplasyeni olarak adlandırılır. 1.türeve göre önemli bir avantaja sahiptir. Bu da rotasyon altında değişmez olduğudur. Aşağıdaki ifadelerle verilir. Bu durum 3*3'lük bir filtre matrisle de ifade edilebilir.

$$\frac{\partial^2 f}{\partial x^2} \approx [f(x+1) - f(x)] - [f(x) - f(x-1)] = f(x+1) - 2f(x) + f(x-1) \quad (3.1)$$

$$\begin{aligned} \nabla^2 f(x, y) &= \frac{\partial^2}{\partial x^2} + \frac{\partial^2}{\partial y^2} \\ &= f(x+1, y) + f(x-1, y) + f(x, y+1) + f(x, y-1) - 4f(x, y) \end{aligned}$$

- Laplasyen da ikinci dereceden türevler olduğundan dolayı, gradientine bir görüntünün laplasyeni kabul edilemez derecede gürültüye duyarlı olacaktır.

- Görüntünün laplasyeninin mutlak değeri çift kenarların oluşmasına neden olacaktır ki bu durumda kenar yönünün belirlenmesi mümkün olmayacaktır.

- Sıfır geçişleri, görüntü içerisindeki nesnelere ilişkin sınırları gösterdiği için kenar görüntüsü sürekli çizgili olacaktır.


- Görüntü içerisinde küçük değişimler bile bir sıfır geçişi oluşturacakları için, laplasyen yöntem ile elde edilen kenar görüntülerinde çok fazla sayıda yanlış kenar noktalarının oluşması kaçınılmazdır.

1. Gri-ton görüntünün laplasyenini elde etmek için, görüntü fonksiyonu $f(x, y)$ laplasyen maskesi ile konvolüsyona tabi tutulur.

2. Laplasyen görüntüsü tüm sıfır geçiş noktaları (zerocrossing points) elde edilir. Genelde laplasyen görüntüsünde sıfır geçiş noktasına karşı düşen pikseller tam sıfıra eşit olmayabilir. Bu durumda, ilgilenilen pikselin bir sıfır geçiş noktasına karşı düşüp düşmediğini belirlemek için komşuluktaki piksel değerlerine bakıp ve $\{-,+\}$ veya $\{+,-\}$ şeklinde işaret değişimleri olup olmadığı belirlenir. Eğer işaret değişimi varsa, sıfır geçişin eğimi bir eşik değeri ile karşılaştırılır. Eşik değerinden büyük olan eğimler kenar noktası olarak belirlenir. Eşik değeri, laplasyen görüntüsünün mutlak değerinin ortalamasının %75'i alınarak belirlenmektedir.

Laplasyen filtresinden geçirilmiş görüntü matrisinde; aşağıdaki özelliklerden birini sağlayan piksel sıfır geçiş pikselidir ve dolayısıyla kenar üzerinde bir noktadır.

- 1- Negatif bir gri değerine sahip olmalı ve bağlantılı komşu piksellerinden en az birisinin gri değeri pozitif olmalıdır.
- 2- Pikselin değeri sıfır olsa, onun yatay veya dikey komşu piksellerinin değeri farklı işaretlerle olmalıdır.



Şekil 3.2. Laplasyen görüntüsünde sıfır geçiş noktalarının belirlenmesi için basit bir yaklaşım.

50	50	50	50	50	50	50	50	50	50
50	50	50	50	50	50	50	50	50	50
50	50	200	200	200	200	200	200	50	50
50	50	200	200	200	200	200	200	50	50
50	50	200	200	200	200	200	200	50	50
50	50	200	200	200	200	200	200	50	50
50	50	50	50	200	200	200	200	50	50
50	50	50	50	200	200	200	200	50	50
50	50	50	50	50	50	50	50	50	50
50	50	50	50	50	50	50	50	50	50

(a) örnek görüntü

-100	-50	-50	-50	-50	-50	-50	-50	-50	-100
-50	0	150	150	150	150	150	150	0	-50
-50	150	-300	-150	-150	-150	-150	-300	150	-50
-50	150	-150	0	0	0	0	-150	150	-50
-50	150	-150	0	0	0	0	-150	150	-50
-50	150	-300	-150	0	0	0	-150	150	-50
-50	0	150	300	-150	0	0	-150	150	-50
-50	0	0	150	-300	-150	-150	-300	150	-50
-50	0	0	0	150	150	150	150	0	-50
-100	-50	-50	-50	-50	-50	-50	-50	-50	-100

(b) Laplasyen filtreden sonra

Şekil 3.3. Sıfır geçiş örneği.

Görüntüdeki en küçük gri seviyeler değişimlerde bile sıfır geçiş noktası üretebileceği ve Görüntünün küçük seviyelerde de olsa gürültü ile etkilenmiş olduğu göz önüne alınırsa, laplasyen-tabanlı yöntemlerin doğrudan doğruya görüntü üzerine uygulanması pek sık kullanılan bir yol değildir. Bu durum aşağıdaki şekillerden de görülmektedir.



Şekil 3.4. Laplasyon filtreden önce ve sonra.

3.2. FCM

Görüntülerin araştırılması ve uygulanmasında, görüntünün yalnızca bazı bölgeleri ilgiyi çekebilir. Bu bölgelere, kendine özgü belirli bölgelere karşılık gelen hedefler veya ön plan denir. Hedefleri belirlemek ve analiz etmek için bu bölgelerin bölümlere ayrılması ve analiz edilmesi gerekir. Görüntü bölümlendirme, görüntünün sayıya bölündüğü teknoloji ve süreçtir.

Bulanık c-ortalama (FCM) kümelemesi, gerçek uygulamada en yaygın kullanılan algoritmalarından biridir. FCM ilk olarak Dunn tarafından önerildi ve en küçük kareler prensibine dayanan yinelemeli optimizasyon yöntemini sağlayan ve algoritmanın yakınsaklığını kanıtlayan Bezdek tarafından değiştirildi. FCM, manyetik rezonans görüntülerinde, uzaktan algılama uydu görüntülerinde geniş ve başarılı bir şekilde kullanılır Kümeleme algoritmalarının sakıncalarını gidermek için, yerel mekansal bilgi dahil edilerek birçok yöntem önerilmiştir. Bunlar arasında Ahmed ve ark. önyargı düzeltilmiş bir FCM (BCFCM) önerdiler. Chen ve Zhang BCFCM'yi iyileştiren FCM S'yi önerdi. Bununla birlikte, ortalama ya da ortanca değer seçimi önceden bilgi olmasını gerektirir ve mekansal komşuları seçmektedir. FCM ve FCM S'den daha etkili olduğunu gösteriyor. Ruspini tarafından tanımlanan FCM kavramına dayanan Dunn, net FCM kavramını ortaya attı. Eklentinin anlamlı olması için Dunn,

grup içi kare hatanın objektif işlevini kare ağırlıklı hata versiyonunun grup toplamına genişletmiştir ve aşağıdaki şekilde verilmiştir:

$$J(U, V) = \sum_{i=1}^n \sum_{j=1}^c u_{ij}^2 d^2(x_i, v_j)$$

3.2.1. Değiştirilmiş FCM

Gürültüden etkilenen görüntüler standart FCM tarafından bölümlere ayrılırsa, bölümlendirme performansı kötü olur. Ancak, görüntüler genellikle görüntüleme, saklama veya aktarma sırasında gürültüden etkilenir. Bu nedenle, gürültünün etkisini bastırmak için görüntü bölümlenmesinde gürültü dikkate alınmalıdır.

Ahmed ve ark .2012 yeni amaç işlevini FCM'nin nesnel işlevinde mekansal bir kısıtlama terimi aşağıda verilmiştir:

$$J_m = \sum_{i=1}^c \sum_{k=1}^n u_{ik}^p \|x_k - v_i\|^2 + \frac{\alpha}{NR} \sum_{i=1}^c \sum_{k=1}^n u_{ik}^p \left(\sum_{x_y \in N_k} \|x_y - v_i\|^2 \right) \quad (3.2)$$

$[U_{ik}] = U$, üyelik derece matrisidir

N_{k,x_k} etrafındaki bir pencereye düşen komşular kümesi anlamına gelir ve N_R , kardinalitesidir.

İkinci terimdeki α parametresi, cezanın etkisini kontrol eder.

Bu formülün bir eksikliği, şartlarının hesaplanmasının FCM'den çok daha fazla zaman alacağıdır. Aday görüntünün boyutu büyük olduğunda, hesaplama süresi de artmaktadır.


(2) 'ye dayanarak, Chen ve arkadaşları bir basitleştirme yaklaşımı önermiştir. FCM S olarak adlandırılan düşük karmaşıklığa sahip yeni hedef işlevi ise:

$$J_m = \sum_{i=1}^c \sum_{k=1}^N u_{ik}^m \|x_k - v_i\|^2 - \alpha \sum_{i=1}^c \sum_{k=1}^N u_{ik}^m \|\bar{x}_k - v_i\|^2 \quad (3.3)$$

3.3. TBA

Birçok makine öğrenme problemi, her eğitim örneği için binlerce özelliği içermektedir. Bu sadece eğitimi yavaşlatmakla kalmaz, iyi çözüm bulmayı da zorlaştırır. Bu sorun genellikle boyut laneti (the curse of dimensionality) olarak adlandırılmaktadır. Bir veri setinin bilgi içeriğini özgün kümelerden daha düşük boyutlara, yeni bir özellik altuzayına dönüştürerek özetlememize yardımcı olacak üç temel teknik vardır. TBA, Linear Discriminant Analysis (LDA) ve Kernel Principal Component Analysis (KPCA).

TBA, boyutsallığı azaltmak için yaygın olarak kullanılan denetimsiz lineer dönüşüm tekniği olmaktadır. TBA, özellikler arasındaki korelasyona dayanarak verilerdeki desenleri (pattern) tanımlamamıza yardımcı olmaktadır. Özetle, TBA, yüksek boyutlu verideki maksimum varyansları bulmaya ve orjinal olanıkiyle eşit veya daha az boyuta sahip yeni bir altuzay üzerine yansıtmayı sağlamaktadır. Şekil 3.5'te görüldüğü üzere yeni altuzayın ortogonal eksenleri (PC1 ve PC2 ana bileşenler) maksimum varyansın yönü olmaktadır.



Şekil 3.5. TBA'nın eksenleri.

Tanıma, sınıflandırma, boyut indirgenmesi ve yorumlanmasını sağlayan, çok değişkenli bir istatistik yöntemidir. Bu yaklaşım verinin içindeki en güçlü örüntüyü bulmaya çalışır. Bu yüzden örüntü bulma tekniği olarak da kullanılabilir. Verinin sahip olduğu çeşitlilik, tüm boyut takımından seçilen küçük bir boyut setiyle yakalanabilir. Verideki gürültüler, örüntülerden daha güçsüz olduklarından, boyut küçültme sonucunda bu gürültüler temizlenebilir.

TBA'nın üç temel amacı vardır:

1. Verilerin boyutunu azaltma
2. Tahminleme yapma
3. Veri setini, bazı analizler için görüntülemek



TBA uygulandığında p boyutlu uzayın gerçek boyutu belirlenir. Bu gerçek boyuta temel bileşenler adı verilir. Temel bileşenlerin üç özelliği vardır:

1. Kolerasyonsuzlardır.
2. Birinci temel bileşen toplam değişkenliği en çok açıklayan değişkendir.
3. Bir sonraki temel bileşen kalan değişkenliği en çok açıklayan değişkendir.

Temel Bileşen Analizi şu şekilde yaklaşmaktadır:

a. Çok boyutlu olan verilere doğru açıdan bakarak genellikle verideki ilişkiler açıklanabilir.

b. TBA'nın amacı "doğru açığı" bulmaktır




Veri çok boyutlu ve ilişkiler açık değildir


Doğru açıdan bakıldığında çok boyutlu Karmaşık veri setindeki ilişkinin lineer Olduğu görülmektedir.

Şekil 3.6. TBA'nın amacı

TBA kilit noktası, problemi çözmek üzere görsel incelemek için uygun bir "açı" başka deyişle uygun bir koordinat sistemi seçmektir.



(a) Karmaşık veri seti



(b) Lineer hali

Şekil 3.7.TBA verileri.

Sonuç :

- TBA, boyut azaltmada faydalı bir yöntemdir
- TBA, çok boyutlu verileri yaklaşık olarak ve daha az boyutlu veriyle temsil eder.
- TBA, orijinal veriler için dik-olan-en-büyük-varyans-yönleri bulup orijinal verileri koordinat sisteminde gösterir.
- TBA, çok boyutlu verilerin görsel gösterilmesi ve incelenmesi için kullanılabilir.
- TBA, makine öğrenmesi olarak, verilerin boyutu azaltabilir—az değişen TBA özellikleri modelleme için önemsiz olabilir, bu şekilde modelleme ile ilgili hesaplama hızlandırabilir.
- TBA, veri sıkıştırma için kullanılabilir.

TBA, istatistiksel bir metottur. Bir veri setinde örüntünün tanımlanmasında, veri setinin açıklanmasında, veri içindeki benzer ve farklı desenlerin tanımlanmasında kullanılabilir. TBA verinin sıkıştırılmasına boyut azaltarak imkân vermektedir, boyut azaltılırken veri kaybı yaşanmamaktadır. Bu teknik bilgisayar bilimleri görüntü işleme alanında kullanılmaktadır.

3.4. Destek Vektör Makineleri

Destek vektör makineleri (DVM) istatistiksel öğrenme teorisine dayalı parametrik olmayan bir makine öğrenmesi sınıflandırma yöntemidir (Vapnik, 1995). DVM ikili sınıflandırmalar için geliştirilmiştir ve bu yöntem ile az sayıda örnekleme

verisi ile doğru sınıflandırma sonuçları elde etmek mümkündür (Foody ve Mathur, 2004). Sınıflar arasındaki sınırı belirlemek için Optimizasyon algoritmasının kullanıldığı bir yöntemdir. Başlangıçta iki sınıflı doğrusal verilerin sınıflandırılması için tasarlanmış olan yöntem daha sonra çok sınıflı ve doğrusal olmayan verilerin sınıflandırılması için geliştirilmiştir. Temel olarak iki sınıflı birbirinden ayırabilen hiper düzlemin belirlenmesi prensibine dayanmaktadır (Vapnik, 1995). Farklı alanlarda kullanılan DVM ler uzaktan algılama alanında kullanımı ile ilgili çok sayıda çalışma gerçekleştirilmiştir (Zhu ve Blumberg 2002, Pal ve Mather 2005, Dixon ve Candade 2008, Kavzoglu ve diğ., 2009; Song vd. 2012). Bu yöntem çekirdek fonksiyonları kullanılarak çok boyutlu özellik uzayında çalışma özelliğine sahip ve yöntemden elde edilen sonuçlar seçilen çekirdek ve parametrelerin özelliklerine bağlıdır (Kavzoglu ve Çölkesen, 2009).

Avantajlar:

- Yüksek boyutlu uzaylarda etkilidirler.
- Karar fonksiyonunda bir takım eğitim noktaları kullanılır (“support vectors”).
- Karar fonksiyonu için çok farklı çekirdek fonksiyonları (“kernel functions”) kullanılabilir.

Veri setleri için sınıflandırma probleminin çözümüne ilişkin Destek Vektör Makineleri'nin uygulanması sürecinde çekirdek fonksiyonu seçiminin ve parametre optimizasyonunun önemli yeri vardır.

3.4.1. Doğrusal destek vektör makineleri

Destek vektör makineleri ile sınıflandırmada genellikle $\{-1,+1\}$ şeklinde sınıf etiketleri ile gösterilen iki sınıfa ait örneklerin, eğitim verisi ile elde edilen bir karar fonksiyonu yardımıyla birbirinden ayrılması amaçlanır. Karar fonksiyonu kullanılarak eğitim verisini en uygun şekilde ayırabilecek hiper-düzlem bulunur. Şekil 1(a)'da gösterildiği üzere iki sınıflı verileri birbirinden ayırabilen birçok hiper-düzlem çizilebilir. Ancak DVM'nin amacı kendisine en yakın noktalar arasındaki uzaklığı maksimuma çıkaran hiper-düzlemi bulabilmektir. Şekil 1(b)'de görüldüğü üzere sınırı maksimuma çıkararak en uygun ayrımı yapan hiper-düzleme optimum hiper-düzlem ve sınır genişliğini sınırlayan noktalar ise destek vektörleri olarak adlandırılır. Doğrusal

olarak ayrılabilen iki sınıflı bir sınıflandırma probleminde DVM'nin eğitimi için k sayıda örnekten oluşan eğitim verisinin $1, \dots, k = \{i \mid x_i, y_i\}$, i kabul edilirse, optimum hiperdüzleme ait eşitsizlikler aşağıdaki şekilde olur

$$w \cdot x_i + b \geq +1 \quad \text{her } y_i = +1 \quad \text{için}$$

$$w \cdot x_i + b \leq -1 \quad \text{her } y_i = -1 \quad \text{için}$$

Burada $x \in \mathbb{R}^N$ olup N -boyutlu bir uzayı, $y \in \{-1, +1\}$ ise sınıf etiketlerini, w ağırlık vektörünü (hiper-düzlemin normali) ve b eğilim değerini göstermektedir (Osuna vd., 1997). Optimum hiper-düzlemin belirlenebilmesi için bu düzleme paralel ve sınırlarını oluşturacak iki hiper-düzlemin belirlenmesi gerekir. Bu hiper-düzlemleri oluşturan noktalar destek vektörleri olarak adlandırılır ve bu düzlemler $w \cdot x_i + b = \pm 1$ şeklinde ifade edilirler.

Optimum hiper-düzlemin sınırının maksimuma çıkarılması için $\|w\|$ ifadesinin minimum hale getirilmesi gerekmektedir. Uygun hiperdüzlemin belirlenmesi aşağıdaki sınırlı optimizasyon probleminin çözümünü gerektirir.

$$\text{Min}_{\frac{1}{2}} \|w\|^2$$

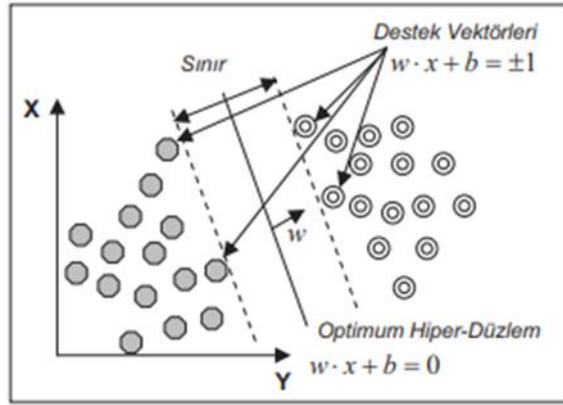
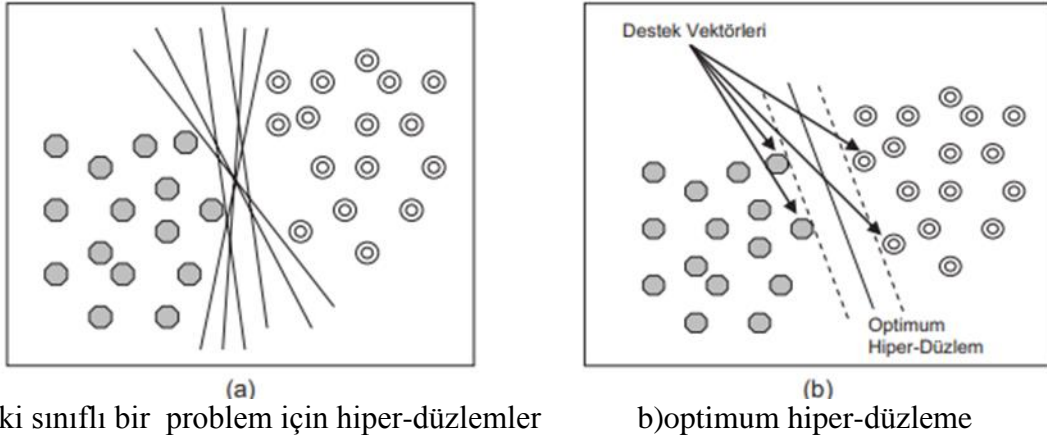
Buna bağlı sınırlamalar ise;

$$y_i(w \cdot x_i + b) - 1 \geq 0 \quad \text{ve} \quad y_i \in [1, -1]$$

şeklinde ifade edilir (Vapnik, 1995). Bu optimizasyon problemi Lagrange denklemleri kullanılarak çözülebilir. Bu işlem sonrasında;

$$l(w, b, a) = \frac{1}{2} \|w\|^2 - \sum_{i=1}^k \alpha_i y_i(w \cdot x_i + b) + \sum_{i=1}^k \alpha_i$$

eşitliği elde edilir. Sonuçta doğrusal olarak ayrılabilen iki sınıflı bir problem için karar fonksiyonu aşağıdaki şekilde yazılabilir (Osuna vd., 1997).



Şekil 3.8. Doğrusal olarak ayrılabilen veri setleri için hiper-düzlemin belirlenmesi.

$$f(x) = \text{sign} \left(\sum_{i=1}^k h_i y_i (x \cdot x_i) + b \right)$$

3.4.2. Doğrusal ayıramayan veriler için DVM

Uydu görüntülerinin sınıflandırılmasında olduğu gibi birçok problemde verilerin doğrusal olarak ayrılması mümkün değildir [Şekil 3(a)]. Bu durumda eğitim verilerinin bir kısmının optimum hiper-düzlemin diğer tarafında kalmasından kaynaklanan problem pozitif bir yapay değişkenin (ξ_i) tanımlanması ile çözülür [Şekil 3(b)]. Sınırın maksimum hale getirilmesi ve yanlış sınıflandırma hatalarının minimum hale getirilmesi arasındaki denge pozitif değerler alan ve C ile gösterilen bir düzenleme parametresi ($0 < C < \infty$) tanımlanmasıyla kontrol edilebilir (Cortes vd., 1995). Düzenleme

parametresi ve yapay deęişken kullanılarak doğrusal olarak ayırılmayan veriler için optimizasyon problemi:

$$\min \left[\frac{\|w\|^2}{2} \right] + c \cdot \sum_{i=1}^r \xi_i$$


şeklini alır.

baęlı sınırlamalar ise;

$$y_i (w \cdot \varphi(x_i) + b) - 1 \geq 1 - \xi_i$$

$$\xi_i \geq 0 \quad \text{ve } i = 1, \dots, N$$

şeklinde ifade edilir.




a) doğrusal olarak ayırlamayan veriseti

b) Doğrusal ayırlamayan veri seti

Şekil 3.9. Doğrusal hiper-düzlem.

Eşitlik ifade edilen optimizasyon probleminin çözümü için Şekil (3.7) de görüleceęi üzere girdi uzayında doğrusal olarak ayırlamayan veri, özellik uzayı olarak tanımlanan yüksek boyutlu bir uzayda görüntülenir. Bu işlemi yapabilmemiz için çekirdek (kernel) fonksiyonları kullanılmaktadır. Verilerin doğrusal olarak ayrımı yapılabilmekte ve sınıflar arasındaki hiper-düzlem belirlenebilmektedir.



Şekil 3.10. Çekirdek fonksiyonu ile verinin yüksek boyuta dönüştürülmesi.

Destek vektör makineleri matematiksel olarak $K(x_i, x_j) = \varphi(x_i) \cdot \varphi(x_j)$ şeklinde ifade edilen bir çekirdek fonksiyonu yardımıyla doğrusal olmayan dönüşümler yapılabilir ve bu şekilde verilerin yüksek boyutta doğrusal olarak ayrımına yardım sağlamaktadır. Çekirdek fonksiyonu kullanarak doğrusal olarak ayrılamayan iki sınıflı bir problemin çözümü ile ilgili karar kuralı aşağıdaki şekilde yazılabilir (Osuna ve ark., 1997):

$$F(x) = \text{sign}(\sum_i x_i y_i \varphi(x) \cdot \varphi(x_i) + b)$$

Destek vektör makineleri (DVM) ile gerçekleştirilecek bir sınıflandırma işlemi için kullanılacak çekirdek fonksiyonu ve bu fonksiyona ait optimum parametrelerin belirlenmesi şarttır. Çekirdek fonksiyonu olarak en sık kullanılan polinom, radyal tabanlı fonksiyon, Pearson VII (PUK) fonksiyonu ve normalleştirilmiş polinom çekirdekleri Tablo 1’de formülleri ve parametreleriyle birlikte sunulmuştur. Tablodan görüleceği üzere her çekirdek fonksiyonu için bazı parametrelerin kullanıcı tarafından belirlenmesi gerekmektedir. PUK çekirdeği için belirlenmesi gereken parametre sayısı iki iken, diğer fonksiyonlar için sınıflandırmaya esas olacak model oluşumunda bir parametrenin belirlenmesini gerektirmektedir. Çekirdek fonksiyonları karşılaştırıldığında polinom ve radyal tabanlı çekirdeklerin daha sade ve anlaşılabilir olduğu ifade edilebilir. Matematiksel olarak basit görünse de, polinomun derecesindeki artış algoritmanın karmaşık bir hal almasına neden olmaktadır. Bu da hem işlem süresini önemli ölçüde artırmakta hem de bir noktadan sonra sınıflandırma doğruluğunu düşürmektedir. Buna karşın radyal tabanlı fonksiyonun çekirdek boyutu (γ) olarak ifade edilen parametresindeki değişimlerin sınıflandırma performansına etkisinin daha az olduğu görülmüştür (Hsu ve ark., 2010). Normalleştirilmiş polinom fonksiyonu ise veri

setinin normalleştirilmesi yerine polinom çekirdekte ait matematiksel ifadenin normalleştirilmesi amacıyla Arnulf vd. (2001) tarafından önerilmiştir. Normalleştirilmiş polinom çekirdekinin polinom çekirdekinin genelleştirilmiş bir hali olduğu söylenebilir. Diğer taraftan, PUK çekirdeki Pearson genişliği olarak bilinen (σ, ω) iki parametresi ile diğer çekirdek fonksiyonlarına göre daha karmaşık bir matematiksel yapıya sahiptir. Bu iki parametre sınıflandırma doğruluğuna etki etmekte ve hangi parametre çiftinin en iyi sonuç vereceği önceden bilinmemektedir. Bu nedenle PUK çekirdekinin kullanımında en uygun parametre çiftinin belirlenmesi önemli bir aşamadır.

Çizelge 3.1. Destek vektör makinelerde kullanılan temel çekirdek fonksiyonları ve parametreleri.

Kernel Fonksiyonu	Matematiksel ifadesi	Parametre
Polinom kerneli	$k(x, y) = ((x \cdot y) + 1)^d$	Polinom derecesi(d)
Normalleştirilmiş polinom	$k = (x, y)$ $= \frac{((x, y) + 1)^d}{\sqrt{((x, y) + 1)^d ((y, y) + 1)^d}}$	Polinom derecesi(d)
Radyal Tabanlı Fonksiyon	$k(x, y) = e^{-\gamma \ x - x_i\ ^2}$	Kernel boyutu (Y)
Pearson vll(PUK) kerneli	$\frac{1}{\left[1 + \left(\frac{2 \cdot \sqrt{\ x-y\ ^2} \sqrt{\frac{1}{2w}}}{\sigma} - 1 \right)^2 \right]^w}$	Pearson genişliği Parametreleri(σ, w)

Çekirdek fonksiyonuna özgü parametrelerin yanında tüm DVMler için düzenleme parametresi C'nin kullanıcı tarafından belirlenmesi gerekmektedir. Bu parametre için olması gerekenden çok küçük veya çok büyük değerler seçilmesi durumunda optimum hiper-düzlem doğru belirlenemeyeceğinden sınıflandırma doğruluğunda ciddi düşüş beklenir. Diğer taraftan $C = \infty$ olması durumunda DVM modeli sadece doğrusal olarak ayrılabilen veri setleri için uygun hale gelir. Buradan da görüleceği üzere parametreler için uygun değerlerin seçimi DVM sınıflandırıcısının performansını direkt olarak etkileyen bir faktör durumundadır. Genellikle deneme ve hata stratejisi kullanılmasına karşın, çapraz doğrulama yaklaşımı başarılı sonuçlara


ulařılmasına olanak saęlamaktadır. apraz doęrulama yaklařımında ama oluřturulan sınıflandırma modelinin performansının belirlenmesidir ve veri seti iki kısma ayrılır. Birinci kısım sınıflandırmaya esas olan model oluřumunda eęitim verisi olarak kullanılırken ikinci kısım modelin performansının belirlenmesi amacıyla test verisi olarak iřleme konur. Eęitim seti ile oluřturulan modelin test veri setine uygulanması sonucunda doęru sınıflandırılan rneklerin sayısı sınıflandırıcının performansını gsterir. Dolayısıyla apraz geerlilik yntemi kullanılarak en iyi sınıflandırma performansının elde edildięi ekirdek parametrelerinin belirlenmesi ve sınıflandırmaya esas olacak modelin oluřturulmuřtur.





4. BULGULAR

Bu bölüme kadar görüntü işlemenin temel kavramlarından; bazı matematiksel operasyonlardan, sayısal görüntü işlemenin ilk adımları arasında yer alan görüntünün iyileştirilmesinden; görüntü pekiştirmede kenar tanıma filtreleri arasında yer alan Laplasyan süzgeçlerinden bahsedilmiştir. Diğer taraftan bu alt yapı yardımıyla BM temel prensibi ve BM tekniği de detaylı olarak incelenmiştir. Bu bölümde ise, kenar bulma yöntemleri arasındaki sıfır geçiş algoritmasını kullanan ve BM'nin dezavantajlarını önlemeyi amaçlayan alternatif bir yaklaşım önerilmiştir. Bu yaklaşım DVM tekniğindeki parametrelerin en uygun değerlerinin seçimi ile mümkün olmaktadır. Diğer taraftan filtre işleme ile görüntü kapsamında kullanılan kenar bulma Laplasyan süzgeçlerin BM tekniği için kullanımı karşılaştırmalı olarak incelenmiştir. Yapılan işlemler sırasıyla Şekil 4.1 de verilen blok diyagram ile gösterilmiştir.



Şekil 4.1. Tez aşamaları.




Şekil 4.2 Kullanılan veri setlerine ait görüntüler(devam).

4.2.Segmentasyon Aşaması


Segmentasyon, görüntüdeki araçların daha belirgin olmasını sağlar ve aracın tanımlanmasını kolaylaştırır. İlk adım, kenar düzenlemesini yapmaktır. Görüntüler daha sonra vektörlere dönüştürülür, araç mı yoksa diğer nesnelere mi olduğunu belirlemek için sınıflandırma yapılır. Görüntülerin matris dönüşümü ile vektör haline getirilmesinden sonra nitelik azaltma için istatistiksel bir yöntem olan TBA kullanılmıştır. Nesnelere tanımlamak için özelliklerini belirlemek gerekir. Gri tonlamalı resim bir dizi rakamdır bu rakamlar sıfır ve ikiyüz ellibeş arasında değer alır. Görüntünün her pikselini temsil eden bu sayılar aynı zamanda pikseller ile boyutları arasındaki konumu tanımlar. Komşu piksellerin nesne olarak kabul edilmesi kenar bulma yöntemiyle yapılır.

4.3. Bulanık C-Ortalamalar Uygulaması

Bulanık C ortalamalar(FCM) segmentasyon için kullanılmaktadır. Adım adım kenarları bulmayı ve nesnelere diğer bölgelere göre daha belirgin gösterilmesini sağlamayı amaçlar. Şekil 4.2’te görüldüğü üzere FCM yönteminde nesnelere koyu gösterilmektedir.



(a)



(b)



(c)

Şekil 4.3. Farklı görüntüler için FCM uygulaması sonuçları.

4.4. Temel Bileşen Analizi Aşaması

TBA, görüntüleri ayırma ve sınıflandırmada görüntü boyutunu küçültmek amacıyla kullanılmıştır. Görüntüleri sınıflandırmak için DVM yöntemini kullanılmıştır. Görüntünün özellik vektörü 400 niteliğe sahiptir. TBA ile bu değer 10'a azaltılıp veriler görüntü vektör matrisine dönüştürülmüştür. Nesne tanıma için SVM yapısı önce eğitilmek zorundadır. Bu işlem için iki sınıfa ait verilerden oluşan (Araç ve diğerleri) bir veri seti kullanılmıştır.

Videoların her saniyesi yirmi beş kareden (görüntüden) oluşmaktadır. İlk önce aracın olduğu bölgenin tespit edilip kırılması gerekir. Hareket eden nesnelere için arka

plan ve ön plan yöntemleri kullanılmaktadır. Nesne tanımlamanın doğruluğunu artırmak için kenar algılama yöntemini kullanılmaktadır. Eklenen tüm nesnelere bir kenar oluşturur çünkü piksellerin değeri görüntünün kontrastına bağlıdır. Kontrast, komşu pikseller iki farklı nesneye ait olduğunda, komşu piksellerin mesafesindeki bir artıştır. KONTRAST yüksek olursa, görüntü o kadar net olur. Ön planın arka plandan ayrılmasında nesnelere beyazdır ve arka plan siyah olarak işaretlenmiştir.

Filtre gürültülü değerleri düzeltmek için kullanılır, bazen pikselleri azaltmak veya gürültüyü ortadan kaldırmak için de kullanılmaktadır. *imcrop* komutu, görüntüdeki nesnelere birbirinden ayırmak için kullanılır.

4.5. Destek Vektör Makinesi Aşaması

Bir araç mı yoksa diğer bir nesne mi olduğunu belirlemek için kırılmış görüntüden elde edilen nitelikler TBA ile azaltılıp SVM'ye verilir. SVMnin çıktısı bir vektördür, tüm görüntülerden elde edilen vektörler bir matris oluşturur. Bir matrisin her satırı bir kareyi temsil eder ve her sütun bir nesneyi temsil eder. Buraya kadar bir 100*5 matris oluşmuştur. 100 burada çerçeveyi ve 5 nesnelere bu çerçevede göstermektedir. SVM liner olduğu için sadece araç ve diğerleri olarak ayırt etmede kullanılmaktadır. Büyük araç algılaması için alan yöntemi kullanılmıştır. Alan boyutu belirli bir eşik değerinden büyük olursa o nesnenin büyük araba olduğunu gösterir.

Çizelge 4.1. Videoların gerçek ve tespit edilen sonuçları.

Video no	Gerçek değer			Tespit edilen		
	Küçük Araç	Büyük Araç	Diğer	Küçük Araç	Büyük Araç	Diğer
1	4	1	0	3	1	1
2	5	2	0	6	3	1
3	4	1	0	3	1	1
4	4	1	1	4	1	2
5	5	1	1	6	1	1
6	3	0	1	3	0	1

Sınıflandırılan nesnelere araç olanlar ise daha sonra içerdikleri piksel sayısına (alanına) göre büyük/ küçük araç olarak ayrılmıştır. Böylece son aşamada 3 sınıfa ayırma işlemi gerçekleştirilmiştir.

Çizelge 4.1’de gerçek ve tespit edilen sonuçlar videolardan yazılmıştır.



5. TARTIŞMA VE SONUÇ

Görüntü işleme çalışmaları oldukça yaygındır. Özellikle iletişimde, güvenlik sistemlerinde, robot uygulamalarında sıkça karşımıza çıkmaktadır. Görüntü işlemede ilk aşama görüntünün elde edilmesidir. Daha sonra çeşitli ön işleme safhaları ve görüntüdeki belirli desenlerin tespiti yapılmaktadır. Bu desenlerin anlamalı hale gelmesi için bir tanıma veya sınıflandırma aşamasından geçirilmesi gerekir. Bu işlem için ise nitelik çıkarma uygulanmaktadır. Bir görüntüde yer alan birden fazla desenin veya nesnenin tanınması için yukarıda bahsedilen aşamalar kullanılır. Özetle bu aşamalar, ön işleme, nitelik çıkarma ve sınıflandırmadır.

Görüntü ön işleme adımında genellikle görüntü iki renge indirgenir. Bu sayede renkli bir görüntüye göre çok daha kolay işlenebilir hale gelmiş olur. Daha sonra ise segmentasyon işlemi uygulanarak görüntüdeki farklı nesnelere yerleri belirlenmeye çalışılır. En son aşamada ise belirlenen nesnelere ilgili bir tanıma veya sınıflandırma işlemi yapılacaktır. Bu çalışmada özellikle Bulanık C ortalamalar kümeleme yöntemi kullanılarak bir segmentasyon yapılmıştır.

Deneysel çalışma olarak ise Van Yüzüncü Yıl Üniversitesi ana giriş kapısı güvenlik kameralarından alınan çeşitli görüntüler kullanılmıştır. Bu çalışmada özellikle vurgulanan nokta bulanık C ortalamalar kümeleme yöntemi ile yapılan segmentasyondur. Başarılı bir şekilde gerçekleştirilen segmentasyondan sonra elde edilen nesnelere araç ve diğer nesnelere olarak iki sınıfa ayrılmıştır. Bu sınıflandırma için kullanılan yöntem DVM olup güçlü bir sınıflandırıcıdır (Pal ve Mather, 2005). Araç olarak tanımlanan nesnelere ise daha sonra sahip oldukları toplam piksel sayısına bakılarak büyük araç / küçük araç olarak ayrılmıştır. Çalışmada ayrıca veriboyutu azalma amacıyla TBA yöntemi de kullanılmıştır.

Gelecek çalışma olarak sınıflandırma amacı ile kullanılan DVM yerine güncel bir araştırma alanı olan derin öğrenme teknikleri ve Konvolüsyonel nöral ağ (CNN) yapıları kullanılabilir. Bu ağlar kullanılan görsel imgelerin analiz edilmesinde kullanılan derin, ileri beslemeli yapay sinir ağlarıdır (Kamavisder ve ark., 2013). CNN'ler, diğer görüntü sınıflandırma algoritmalarına kıyasla nispeten az ön işlem kullanırlar. Bu, ağın geleneksel algoritmalarda el yapımı olan filtreleri öğreneceği anlamına gelir. CNN'de

birçok mimari bulunup farklı katman sayıları, farklı aktivasyon fonksiyonları bulunmaktadır.



KAYNAKLAR

- Ambroise, C., Govaert, 1998. G: Convergence of an EM-type algorithm for spatial clustering. *Pattern Recognition Letters* **19**: 919–927.
- Bandyopadhyay, B. U., Maulik, and A. Mukhopadhyay, May 2007. Multiobjective genetic clustering for pixel classification in remote sensing imagery, *IEEE Trans. Geosci. Remote Sens.*, **45** (5): 1506–1511.
- Bezdek, J. C., 1981. *Pattern Recognition with Fuzzy Objective Function Algorithms: Plenum*, New York, 256.
- Bezdek, J. C., Trivedi, M., Ehrlich, R., and Full, W., 1982. Fuzzy clustering; a new approach for geostatistical analysis: *Int. Jour. Sys., Meas., and Decisions*.
- Chi M. M., Qian Q., and Benediktsson J. A., 2008. Cluster-based ensemble classification for hyperspectral remote sensing, *in Proc. IEEE IGARSS*, 209–212.
- Chintalapudi K.K and Kam M., 1998. A noise-resistant fuzzy C-means algorithm for clustering, in Proc. *IEEE World Congr. Comput. Intell. Fuzzy Syst*, **2**:1458–1463.
- Çulha, S. 1996. *Sayısallaştırılmış Bilgisayarlı Tomografi ve Magnetik Rezonans Tomogramları Üzerinde Görüntü İşleme Tekniği Uygulamaları*. Yüksek lisans tezi., Fen Bilimleri enstitüsü, Ankara Üniversitesi, Ankara.
- Dalleck L. C., Kravitz L., Robergs R. A. 2006: Development of a Submaximal Test to Predict Elliptical Cross-Trainer VO₂max, *National Strength and Conditioning Association*, **20**(2):278-283.
- Dennis, J. E., Jr. and Moré, J. J. 1977. Quasi-Newton methods, motivation and theory. *SIAM Review*, **19**: 46-89.
- Dhanachandra, N., Manglem K. and Chanu Y. J., 2015. Image segmentation using k-means clustering algorithm and subtractive clustering algorithm, *Procedia Computer Science*, **54**:764-771.
- Duda, R., and Hart, P., 1973. Pattern classification and scene analysis: Wiley-Interscience, New York, 482. Full, W., Ehrlich, R., and Bezdek, J., 1982, FUZZY QMODEL: A new approach for linear unmixing: *Jour. Math. Geology*.
- Elnomery Allam Zanaty, 2013. *An Adaptive Fuzzy C Means Algorithm for Improving MRI Segments*, Mathematics Department, Sohag University.
- Ferrari, J. A., Flores, J. L., Perciante, C. D. and Frins, E. 2009. Edge enhancement and image equalization by unsharp masking using self-adaptive photochromic filters. *Applied Optics*, **48** (19): 3570-3579.
- France S. L., Carroll J. D. and Xiong H, 2012. Distance metrics for high dimensional nearest neighborhood recovery: compression and normalization, *Information Sciences*, **184**, (1): 92- 110.
- Francisco, G. L., Billups, R. B., Dehorn, T., Anstett, F., O'Hara, M. and Fisher, D. A. 2003. Thermal imaging for law enforcement and security, post 9-11. *Proceedings of SPIE – The International Society for Optical Engineering* **5071**: 453-464.
- George J. D., Paul S. L., Hyde A., Bradshaw D. I., Vehrs P. R., Hager R. L. 2009: Prediction of Maximum Oxygen Uptake Using Both Exercise and Non-Exercise Data, *Measurement in Physical Education and Exercise Science*, **13**(1):1–12.

- Givens, G. H. and Hoeting, J. A. 2005. **Computational Statistics**. Wiley-Interscience, NJ.
- Grosse, H. J., Varley MR., Terreli, T. J., Chan, Y. K., 2000. Improved Coding Of Transform Coefficients in JPEG-like image compression schemes, *Pattern Recognit. Lett.*, **21**:1061-1069.
- Hall, F. G., Townshend, J. R., and Engman, E. T., (1995). Status of remote sensing algorithms for estimation of land surface state parameters. *Remote Sensing of Environment*, **51**:138–156.
- Hansen, M., DeFries, R. S., Townshend, J. R. G., ve Sohlberg, R., 2000. Global land cover classification at 1 km spatial resolution using a classification tree approach. *International Journal of Remote Sensing*, **21**:331–1364.
- Hansen, M., Dubayah, R., ve DeFries, R., 1996. Classification trees: an alternative to traditional land cover classifiers. *International Journal of Remote Sensing*, **17**:1075–1081.
- Huang, C., Townshend, J.R.G., Liang, S., Kalluri, S.N.V. and Defries, R.S., 2001. "Impact of sensor's point spread function on land cover characterization: assessment and deconvolution. *Remote Sensing of Environment*, **80**: 203–212.
- Kamavisdar, Pooja ve ark, 2013. A Survey on Image Classification Approaches and Techniques: *International Journal of Advanced Research in Computer and Communication Engineering* **2**(1).
- Kavzoğlu, T. ve Mather, P.M., 2003. *The use of backpropagating artificial neural networks in land cover classification. International Journal of Remote Sensing*, **24**:4907–4938.
- Kaufman L. and Rousseeuw P. J. 1987. *Clustering by means of medoids*, Statistical Data Analysis Based on The L1– Norm and Related Methods, pp. 405–416.
- McInerney, T and D. Terzopoulos, 1996. "Deformable models in medical image analysis: A survey, *Medical Image Analysis*, **1**(2):91108.
- Meyer F. and Beucher S., 1990. Morphology segmentation, *Journal Visual Communications and Image Representation*, **1**(1) :2126.
- Nielson E. D., 2009. *Predicting VO2max in College-Aged Participants Using Cycle Ergometry and Nonexercise Measures*, Department of Exercise Sciences Brigham Young University, Master of Science, December.
- Pal, M., Mather, P.M., 2005, Support Vector Machines for Classification in Remote Sensing, *International Journal of Remote Sensing*, **26**(5): 1007-1011.
- Paola, J.D., 1994, *Neural Network Classification of Multispectral Imagery*. Yüksek Lisans Tezi, The University of Arizona, USA.
- Pham, D. L., Prince, J. L, 1999. Adaptive Fuzzy Segmentation of Magnetic Resonance Images. *IEEE Trans. Medical Imaging*, **18**: 737–752.
- Robert A, October 2012. *Remote Sensing: Models and Methods for Image Processing*, 3rd ed. New York: Elsevier, 2007.
- Suzuki, S. 1985. Topological structural analysis of digitized binary images by border following, *Computer vision, graphics, and image processing*, **30**(1): 32-46.
- Shamsi, H, et al, 2012. "A modified fuzzy c means clustering with spatial information for image segmentation" *International journal of computer theory and engineering*, IACSIT.
- Shrestha, D.P., Zinck, J.A., 2001. Land Use Classification in Mountainous Areas: Integration of Image Processing, Digital Elevation Data and Field Knowledge

- (Application to Nepal). *International Journal of Applied Earth Observation and Geoinformation*, **3**(1): 78-85.
- Tso, B., Mather, P.M., 2001, *Classification Methods for Remotely Sensed Data*, Taylor & Francis, London.
- Vapnik, V.N., 1995, *The Nature of Statistical Learning Theory*, Springer-Verlag, New York.
- Vapnik, V.N., 2000, *The Nature of Statistical Learning Theory*, 2. Baskı, Springer-Verlag, New York.
- Vehrs P. R., George J. D., Fellingham G. W., Plowman S. A., Dustman-Allen K. 2007. Submaximal Treadmill Exercise Test to Predict VO₂max in Fit Adults, *Measurement in Physical Education and Exercise Science*, **11**(2):61–72.
- William L., Wilkins A. 2000. *ACSM's Guideline for Exercise Testing and Prescription (6th ed.)*, American College of Sports Medicine, Philadelphia.
- Yang C, Lu L. J., Lin H. P., Guan R. C., Shi X. H., and Liang Y. C., 2008. A fuzzy-statistics-based principal component analysis(FS-PCA) method for multispectral image enhancement and display, *IEEE Trans. Geosci. Remote Sens.* **46**(11):3937–3947.
- Zhang. D. Q., Chen, S. C.. 2003. Clustering in completed data using Kernelbased fuzzy cmeans algorithim, *Neural Processing Letters*, **18**(3): 155162.



ÖZ GEÇMİŞ

Nuşin Nemati 1985 yılında Urumiye’de doğmuştur. İranda Qazvin Üniversitesinde, Bilgisayar Mühendisliği Bölümü lisans eğitimini tamamlamıştır. Yüksek lisansa 2017 yılında Van Yüzüncü Yıl Üniversitesi Elektrik-Elektronik Mühendisliği Anabilim Dalı’nda başlamıştır.



T.C
VAN YÜZÜNCÜ YIL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
LİSANSÜSTÜ TEZ ORJİNALLİK RAPORU

Tarih: 30/01/2020

Tez Başlığı / Konusu: Bulanık C-Ortalamalar Kümeleme Algoritması Kullanılarak Araç Tanıma

Yukarıda başlığı/konusu belirlenen tez çalışmamın Kapak sayfası, Giriş, Ana bölümler ve Sonuç bölümlerinden oluşan toplam 11 sayfalık kısmına ilişkin, 30/01/2020 tarihinde şahsım/tez danışmanım tarafından Turnitin intihal tespit programından aşağıda belirtilen filtreleme uygulanarak alınmış olan orijinallik raporuna göre, tezimin benzerlik oranı % 0 (sıfır) dır.

Uygulanan filtreler aşağıda verilmiştir:

- Kabul ve onay sayfası hariç,
- Teşekkür hariç,
- İçindekiler hariç,
- Simge ve kısaltmalar hariç,
- Gereç ve yöntemler hariç,
- Kaynakça hariç,
- Alıntılar hariç,
- Tezden çıkan yayınlar hariç,
- 7 kelimededen daha az örtüşme içeren metin kısımları hariç (Limit inatch size to 7 words)

Van Yüzüncü Yıl Üniversitesi Lisansüstü Tez Orijinallik Raporu Alınması ve Kullanılmasına İlişkin Yönergeyi inceledim ve bu yönergede belirtilen azami benzerlik oranlarına göre tez çalışmamın herhangi bir intihal içermediğini; aksinin tespit edileceği muhtemel durumda doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi ve yukarıda vermiş olduğum bilgilerin doğru olduğunu beyan ederim.

Gereğini bilgilerinize arz ederim.

30/01/2020

Adı Soyadı: Nooshin NEMATİ

Öğrenci No: 169101193

Anabilim Dalı: Elektrik Elektronik Mühendisliği ABD

Programı:

Statüsü: Y. Lisans

Doktora

DANIŞMAN ONAYI
UYGUNDUR

ENSTİTÜ ONAYI
UYGUNDUR

Doç. Dr. Rıdvan SARAÇOĞLU

(Unvan, Ad Soyad, İmza)