

**T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**ÇOK SINIFLI ÇEKİRDEK FUKUNAGA-KOONTZ DÖNÜŞÜMÜ KULLANARAK
HİPERSPEKTRAL GÖRÜNTÜLERDE HEDEF TANIMA**

SEMİH DİNÇ

**YÜKSEK LİSANS TEZİ
KONTROL VE OTOMASYON MÜHENDİSLİĞİ ANABİLİM DALI**

**DANIŞMAN
DOÇ. DR. ABDULLAH BAL**

İSTANBUL, 2011

T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**ÇOK SINIFLI ÇEKİRDEK FUKUNAGA-KOONTZ DÖNÜŞÜMÜ KULLANARAK
HİPERSPEKTRAL GÖRÜNTÜLERDE HEDEF TANIMA**

Semih DİNÇ tarafından hazırlanan tez çalışması 14/07/2011 tarihinde aşağıdaki jüri tarafından Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Kontrol ve Otomasyon Mühendisliği Anabilim Dalı'nda **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Tez Danışmanı

Doç. Dr. Abdullah BAL

Yıldız Teknik Üniversitesi

Jüri Üyeleri

Doç. Dr. Abdullah BAL

Yıldız Teknik Üniversitesi

Yrd. Doç. Dr. Kayhan Gülez

Yıldız Teknik Üniversitesi

Yrd. Doç. Dr. Olcay Kurşun

İstanbul Üniversitesi

ÖNSÖZ

Öncelikle, bana katkısının bu tezin yazılmasından çok daha öte olduğunu düşündüğüm danışmanım Doç. Dr. Abdullah BAL'a, bu uzun yolda önümü açıp bana yol gösterdiği için şükranlarımı sunmayı bir borç biliyorum. Attığım her adımda emeği olduğunun bilinmesini istiyorum.

Ardından, çalışmalarım için bana uygun ortam oluşturup desteklerini eksik etmeyen, başta dekanımız Prof. Dr. Galip CANSEVER ve bölüm başkanımız Doç. Dr. Haluk GÖRGÜN olmak üzere tüm Yıldız Teknik Üniversitesi, Kontrol ve Otomasyon Mühendisliği ailesine teşekkürlerimi sunuyorum.

Bununla birlikte, kendileri ile çalışmaktan büyük zevk aldığım ve ihtiyacım olan her anda yardımlarını alabildiğim, Yıldız Teknik Üniversitesi Enformatik Bölümü ve TÜBİTAK'ta görev yapan çalışma arkadaşlarıma katkılarından dolayı teşekkür ediyorum.

Son olarak, bu konuma gelebilmemde en büyük emeğe sahip ve üzerimden desteklerini hiçbir zaman esirgemeyen aileme ve karşılaştığım zorluklara karşı her zaman yanımda olan müstakbel eşime teşekkür ediyorum.

Mayıs, 2011

Semih DİNÇ

İÇİNDEKİLER

	Sayfa
SİMGE LİSTESİ	vi
KISALTMA LİSTESİ	vii
ŞEKİL LİSTESİ.....	viii
ÇİZELGE LİSTESİ	x
ÖZET	xi
ABSTRACT	xiii
BÖLÜM 1.....	1
GİRİŞ.....	1
1.1 Literatür Özeti	1
1.2 Tezin Amacı	5
1.3 Hipotez	5
BÖLÜM 2.....	6
HİPERSPEKTRAL GÖRÜNTÜLER (HSG) ve HEDEF TANIMA	6
2.1 HSG'nin Genel Yapısı	6
2.2 Hiperspektral Görüntüleme Sistemi ve Spektral İmza.....	8
2.3 Hiperspektral Sensörler ve Kullanım Alanları	12
2.4 Hedef Tanıma Problemi	16
BÖLÜM 3.....	20
ÇOK SINIFLI ÇEKİRDEK FUKUNAGA-KOONTZ DÖNÜŞÜMÜ	20
3.1 Fukunaga-Koontz Dönüşümü.....	20
3.2 Çok Sınıflı Yapı	21
3.3 Çekirdek Dönüşümü.....	22
3.4 Eğitim Aşaması	24
3.5 Test Aşaması	27

BÖLÜM 5.....	30
ÇOK SINIFLI ÇEKİRDEK FKD YÖNTEMİ İLE HEDEF TESPİTİ	30
4.1 AVIRIS Görüntülerinde Bölge Tanıma	30
4.2 HYDICE – URBAN Görüntülerinde Hedef Tanıma	37
BÖLÜM 6.....	43
SONUÇ VE ÖNERİLER	43
KAYNAKLAR.....	45
ÖZGEÇMİŞ.....	48

SİMGE LİSTESİ

T_i	HSG üzerindeki i.sınıf
v_i^j	T_i Sınıfının j. özelliği
K	Sınıf sayısı
N	Özellik sayısı
Σ_i	i. Sınıfın kovaryans matrisi
$\phi(x)$	Map fonksiyonu
$\tilde{T}_i$	i. Sınıfın çekirdek dönüşümü sonrası değeri
V	Özvektör matrisi
D	Özdeğer matrisi
P	Dönüşüm operatörü
Θ_i	i. Sınıfın dönüşüm matrisi
z	Test vektörü
Z	Test vektörünün çekirdek matrisi
F	Test vektörünün özellik vektörü
R	Test sonuç vektörü

KISALTMA LİSTESİ

HSG	Hiperspektral Görüntüler
HSI	Hyperspectral Imagery
FKD	Fukunaga-Koontz Dönüşümü
FKT	Fukunaga-Koontz Transform
Ç-FKD	Çekirdek Fukunaga-Koontz Dönüşümü
K-FKT	Kernel Fukunaga-Koontz Transform
TBA	Temel Bileşen Analizi
Ç-TBA	Çekirdek Temel Bileşen Alanizi
DVM	Destek Vektör Makinaları
SVM	Support Vector Machines
DAA	Doğrusal Ayrım Analizi
AVIRIS	Airborne Visible InfraRed Imaging Spectrometer
ROSIS	Reflective Optics System Imaging Spectrometer
HYDICE	Hyper-spectral Digital Imagery Collection Experiment
ROC	Region of Convergence
IEEE	Institute of Electrical and Electronics Engineers

ŞEKİL LİSTESİ

	Sayfa
Şekil 1.1	Yapay sinir ağları yöntemi ile hedef tanıma..... 1
Şekil 1.2	Doğrusal ayırım analizi yöntemi ile hedef tanıma 2
Şekil 1.3	Destek vektör makinaları yöntemi ile boyut indirgeme 3
Şekil 1.4	Kullanılan HSG ve üzerindeki askeri hedeflerin doğrulama görüntüsü 4
Şekil 1.5	Kullanılan HSG ve üzerindeki ağaçların(hedef) doğrulama görüntüsü 5
Şekil 2.1	Işığın görülebilen dalga boyu aralığı. 6
Şekil 2.2	Mantis karidesinin göz yapısı 7
Şekil 2.3	Işığın dalga boylarına göre görüntü türleri 8
Şekil 2.4	Işığın yansıması ile HSG'nin elde edilişi..... 9
Şekil 2.5	Hiperspektral küp verisi 10
Şekil 2.6	Farklı türdeki maddeler için spektral imzalar..... 11
Şekil 2.7	Spektral imzalardaki bozulmalar 12
Şekil 2.8	Hiperspektal kamera 14
Şekil 2.9	Elma görüntülerindeki spektral imza farkları..... 15
Şekil 2.10	4 farklı insanın yüz resmindeki ten kısmının imzaları 16
Şekil 2.11	Aynı insanın 4 farklı yüz resmindeki ten kısmının imzaları 16
Şekil 2.12	Renkli görüntüdeki hedef 17
Şekil 2.13	Kızılötesi görüntüdeki hedefler 18
Şekil 2.14	Hiperspektral Küp 19
Şekil 3.1	Doğrusal sınıflandırıcı kullanarak hedef sınıfın ayrılması 21
Şekil 3.2	Doğrusal olmayan dağılım içeren veriler 22
Şekil 3.3	Kapalı karar sınırı kullanarak doğrusal olmayan verilerin sınıflandırması 23
Şekil 3.4	Doğrusal olmayan verilerindoğrusal sınıflandırılabilir hale getirilmesi 23
Şekil 3.5	Çekirdek dönüşümü ve veri dağılımının değiştirilmesi 25
Şekil 4.1	AVIRIS verisi..... 31
Şekil 4.2	AVIRIS verisi doğrulama görüntüsü..... 31
Şekil 4.3	13 numaralı sınıf için Klasik FKD sonuçları 32
Şekil 4.4	13 numaralı sınıf için Ç-FKD sonuçları 32
Şekil 4.5	İç içe girmiş sınıflar ve eşik değeri..... 33
Şekil 4.6	13 numaralı sınıf için ROC eğrisi sonuçları 34
Şekil 4.7	8 numaralı sınıf için Klasik FKD sonuçları 34
Şekil 4.8	8 numaralı sınıf için Ç-FKD sonuçları 35
Şekil 4.9	8 numaralı sınıf için ROC eğrisi sonuçları 35
Şekil 4.10	5 numaralı sınıf için ROC eğrisi sonuçları 36

Şekil 4.11	6 numaralı sınıf için ROC eğrisi sonuçları	37
Şekil 4.12	HYDICE verisi doğal görünümü	38
Şekil 4.13	HYDICE verisi doğrulama görüntüsü	38
Şekil 4.14	1.Havuz türü için gürültülü imza örnekleri	39
Şekil 4.15	2.Havuz türü için gürültülü imza örnekleri	39
Şekil 4.16	1.Havuz türü için sınıflandırma sonuçları.....	40
Şekil 4.17	2.Havuz türü için sınıflandırma sonuçları.....	40
Şekil 4.18	1.Havuz türü için 3 boyutlu sınıflandırma sonuçları	41
Şekil 4.19	2.Havuz türü için 3 boyutlu sınıflandırma sonuçları	42

ÇİZELGE LİSTESİ

	Sayfa
Çizelge 2. 1 Başlıca HSG sensörleri	13

ÇOK SINIFLI ÇEKİRDEK FUKUNAGA-KOONTZ DÖNÜŞÜMÜ KULLANARAK HİPERSPEKTRAL GÖRÜNTÜLERDE HEDEF TANIMA

Semih DİNÇ

Kontrol ve Otomasyon Mühendisliği Anabilim Dalı
Yüksek Lisans Tezi

Tez Danışmanı: Doç. Dr. Abdullah BAL

Gelişen sayısal görüntüleme teknolojisi, günümüzde birçok alanda hayatı kolaylaştırmasının yanında, bir ihtiyaç haline gelmiştir. Özellikle hedef tanıma problemi, başta askeriye olmak üzere güvenlik ile ilgili sektörlerin ilgisini çekmektedir.

Farklı türlerde görüntülerde otomatik hedef tanıma yapılabilmeyle birlikte, görüntü yüzeyindeki materyalin cinsine duyarlı olması, daha kesin sonuçlar vereceğinden hiperspektral görüntüler (HSG), diğer görüntülere göre bir adım öne çıkmaktadır.

Bu tezde, HSG üzerinde, çok sınıflı Çekirdek Fukunaga-Koontz Dönüşümü (Ç-FKD) kullanılarak hedef tanıma yapılmıştır. Temelde istatistiksel bir yöntem olan ve iki sınıflı doğrusal sınıflandırma problemlerinde kullanılan klasik FKD, çekirdek dönüşümü ve çok sınıflı yapı kullanılarak iyileştirilmiş ve hedef tanıma problemine uygulanmıştır.

Yönteme göre, eğitim aşamasında çekirdek dönüşümünden geçirilen veriler kullanılarak dönüşüm operatörü elde edilir ve ardından test aşamasında, bu dönüşüm operatörü kullanılarak, yine çekirdek dönüşümünden geçirilen test verisi sınıflandırılmıştır. Çok sınıflı yapı sayesinde veri seti üzerindeki bütün sınıflar tek bir eğitim aşaması ile sınıflandırılabilir.

Yapılan deneylerde, önerilen yöntem çok sınıflı Ç-FKD, öncelikle klasik FKD ile kıyaslanarak %10-20 oranlarında performans artışı olduğu görülmüştür. Ardından Destek Vektör Makinaları (DVM) gibi yüksek performanslı bir yöntemle karşılaştırılarak

DVM'nin doğrusal ve polinom tabanlı modellerinin üzerinde performans gösterdiği tespit edilmiştir. Bununla birlikte radyal tabanlı DVM modeli ile benzer oranda sonuçlar ürettiği görülmüştür.

Son olarak, çok sınıflı Ç-FKD ikinci veri setinde piksel seviyesinde küçük boyutlu hedeflere uygulanmış ve bu tür hedeflerde de yüksek doğruluk oranında sonuçlar ürettiği görülmüştür.

Anahtar Kelimeler: Fukunaga-Koontz Dönüşümü, Çekirdek Dönüşümü, Hiperspektral Görüntüler, Hedef Tanıma

**HYPERSPECTRAL TARGET RECOGNITION USING MULTICLASS KERNEL
FUKUNAGA-KOONTZ TRANSFORM**

Semih DİNÇ

Department of Control and Automation Engineering

MSc. Thesis

Advisor: Assoc. Prof. Dr. Abdullah BAL

Nowadays, growing digital vision systems have become fundamental need besides it makes our life easier. Particularly target recognition problem is one of the most challenging issues for security and military sectors.

Different types of images may be used for target recognition however Hyperspectral images (HSI) are one step ahead due to their sensitivity of the type of material on the image.

In this thesis, Multiclass Kernel Fukunaga-Koontz Transform (K-FKT) is used in order to target recognition on HSI. Classical Fukunaga-Koontz Transform (FKT), which is basically a statistical and two class classification approach, is enhanced by kernel transformatiton and multiclass classification structure.

According to proposed method, transformation operator is obtained in traning stage after transforming the training data to the kernel space. Then, the transformation operator is deployed to test vector which was also transformed to the kernel space, in order to decide if the test vector belongs to target class or not. And by using multiclass structure, just one traning stage can be enough for all cases.

Kernel Fukunaga-Koontz Transform is tested on two different HSI dataset. Experiment results for the first dataset shows that classification performance increased by 10-20%

than Classical FKT. In addition, K-FKT is compared with Support Vector Machine (SVM) method and according to the results, K-FKT gives better results than linear and polynomial based SVM models. However, radial based SVM has similar results with K-FKT.


And finally, K-FKT is tested with second dataset that has small (pixel) sized targets. Results show, K-FKT has high performance results with these type of targets too.

Key words: Fukunaga-Koontz Transform, Kernel Transformation, Hyperspectral images, Target recognition

1.1 Literatür Özeti

Hedef tanıma alanında hiperspektral görüntüler kullanılarak yapılmış birçok akademik çalışma mevcuttur. Bu çalışmalar eğitimsiz veya eğitimsiz biçimde farklı yöntemler ile hedef tanıma problemine çözüm önermişlerdir.


1999 yılında, Howard vd. [10] tarafından hiperspektral görüntülerde, piksel boyutunda veya daha küçük boyuttaki hedefleri tanımak için hazırlanan çalışma, sınıflandırmadan önce birkaç ön işleme basamağından oluşur. Şekil 1.1’de, yapılan işlemlerin bir akış diyagramı görülmektedir. Öncelikle alınan piksel vektörleri gruplara ayrılır. Ardından özvektörleri elde edilerek boyutları indirgenir. Son olarak da yapay sinir ağı (YSA) kullanılarak sınıflandırma yapılır.



Şekil 1.1 Yapay sinir ağı yöntemi ile hedef tanıma [10]

Bu şekilde orijinal veri ve gürültü eklenmiş veri üzerinde testler yapılmış, sonuç olarak kendi veri setleri için %100'e ulaşan başarı oranı elde etmişlerdir.


Benzer şekilde piksel boyutunda veya daha küçük boyutlu hedeflerin tanıma için 2001 yılında Bruce vd. [11] dalgacık dönüşümünü kullanmayı önermişlerdir. Sürekli ve kesikli dalgacık dönüşümü kullanarak elde edilen sonuçları özellikler olarak alıp bu özellikler Doğrusal Ayrım Analizi (DAA) yöntemi ile indirgenmiştir. Son olarak da sınıflandırma için maksimum benzerlik yaklaşımı kullanılmıştır. Şekil 1.2'de çalışmanın genel bir diyagramı görülmektedir.



Şekil 1.2 Doğrusal ayırım analizi yöntemi ile hedef tanıma [11]


Yapılan testler sonunda elde edilen %90-%100 arasındaki performans sonuçları, dalgacık dönüşümü yönteminin, öznitelik çıkarımı için yerinde bir yaklaşım olduğunu göstermiştir. Kesikli dalgacık dönüşümü hızlı sonuç üretirken sürekli dalgacık dönüşümü daha kesin ve doğru sonuçlar üretmiştir.

2006 yılında, G. Balasubramanian ve V.K. Shettigara[12], yayınladıkları makalelerinde, destek vektör makinaları kullanarak hiperspektral görüntülerde boyut indirgeme yapmışlardır. Kullandıkları veri setindeki 128 spektral bantı, şekilde gösterildiği gibi kümelerle ayırıp en uygun bant sayısına ulaşmaya çalışmışlardır.Şekil 1.3’de belirtilen sonuçlara göre 59 tane bant seçildiğinde en yüksek performansa ulaşılmıştır.



Şekil 1.3 Destek vektör makinaları yöntemi ile boyut indirgeme [12]


2008 yılındaki başka bir çalışmada ise Alam vd. [13], hiperspektral görüntülerde gauss filtresi ve ileri işleme yöntemini kullanarak hedef tanıma yapmış ve görüntü üzerindeki askeri hedefleri tanımışlardır. Yapay ve gerçek verilerle yapılan deneyler sonucunda yüksek oranda gürültü oranına sahip verilerde dahi, çok düşük yanlış alarm oranlarında %100 e yakın doğru tanıma oranları elde etmişlerdir. Şekil 1.4’de bahsi geçen çalışmada kullanılan HSG verisi ve görüntü üzerindeki hedeflerin doğrulama verisi gösterilmiştir.



Şekil 1.4 Kullanılan HSG ve üzerindeki askeri hedeflerin doğrulama görüntüsü [13]

Eğitimcili hedef tanıma yöntemlerinin yanında, birçok eğitimcisz yöntem de mevcuttur. 2001 yılında yapılan bir çalışmada S. Chiang ve arkadaşları[14] Projection Pursuit yöntemi ile görüntü üzerindeki pikselleri yüksek boyutlu uzaydan düşük boyutlu uzaya transfer etmişlerdir. Bu şekilde verideki istenen bilgileri saklarken gereksiz olanları temizlemişlerdir. Eğitimcisz olarak yapılan bu yöntemin uygun parametreleri, evrimsel algoritma kullanılarak elde edilmiştir.

Benzer şekilde, Plaza vd. [15] 2003 yılında sundukları çalışmalarında, hiperspektral görüntüler üzerindeki hedefleri, eğitimcisz bir yöntem olan genişletilmiş matematiksel morfolojik işlemler ile sınıflandırmayı önermişlerdir. Klasik morfolojik işlemleri geliştirerek sınıflandırmada yüksek performans elde etmişlerdir. Şekil 1.5’de HSG’den seçilmiş bir bant ve bu görüntüdeki doğrulama verisi görülmektedir. 1 ve 2 olarak farklı türlerdeki ağaçlar işaretlenmiştir. Bu sınıfları birbirinden ayırmak amaçlanmıştır.



Şekil 1.5 Kullanılan HSG ve üzerindeki ağaçların(hedef) doğrulama görüntüsü [15]

1.2 Tezin Amacı


Bu tez kapsamında Hiperspektral görüntüler üzerinde çoklu hedef tanıma algoritması geliştirmek amaçlanmıştır. Klasik Fukunaga Koontz Dönüşümünün çekirdek bir yapı ile güçlendirilmesi ve çoklu hedef tanımak için düzenlenmesi hedeflenmiştir.

1.3 Hipotez

Hiperspektral görüntülerde hedef tespiti problemi için bu tezde, çok sınıflı çekirdek Fukunaga-Koontz Dönüşümü (Ç-FKD) önerilmiştir. İstatistiksel alanda bir sınıflandırma yöntemi olarak Klasik Fukunaga-Koontz (FKD) dönüşümünün zayıf kalan noktaları olan doğrusal olmayan sınıflama ve çok sınıflı yapı gibi özellikleri geliştirilerek Ç-FKD hazırlanmıştır. Geliştirilen yöntem, HSG üzerinde hedef tanıma alanında kullanılmıştır.

HİPERSPEKTRAL GÖRÜNTÜLER (HSG) ve HEDEF TANIMA**2.1 HSG'nin Genel Yapısı**

Hiperspektral görüntüler klasik sayısal görüntülerin aksine ışığın dalga boyunun insan gözü ile görülemeyen kısımları hakkında da bilgi içeren özel bir görüntü şeklidir. Özel sensörlerle alınabilen bu görüntüler ultraviyole ışınları ile kızılötesi ışınları arasında kalan dalga boyu aralığında duyarlıdır. Şekil 2.1'de görüldüğü gibi insan gözünün algılayabileceği ışığın dalga boyu aralığı ortalama 400 nm ile 700 nm arasındayken, hiperspektral sensörler 350 nm ile 2500 nm arasını tespit edebilmektedir. Böylece elde edilen görüntülerde klasik görüntülere göre çok daha fazla ayırtedici özellik kullanılabilmektedir.



Şekil 2.1 Işığın görülebilen dalga boyu aralığı. [30]

Hiperspektral görüntüleri yakalayabilen sensörlerin yapımında dünya üzerinde 400 milyon yıldan beri yaşayan bir deniz canlısından ilham alınmıştır. Mantis karidesi olarak bilinen bu canlı, Şekil 2.2’de gösterilen gözlerindeki gelişmiş sensörler sayesinde dünya üzerinde başka hiçbir hayvanda bulunmayan bir algılama yeteneğine sahiptir. İnsanın göz yapısı 3 ana rengi görebilecek bir yapıdayken, mantis karidesinin 12 ayrı ana renge duyarlılığı vardır. Bu şekilde gözleri hiperspektral sensörler gibi çalışabilmektedir.




Şekil 2.2 Mantis karidesinin göz yapısı

Gri seviyeli görüntü algılayıcıları ışığın sadece görülebilen dalga boyunu algılayabilir ve o aralığı tek bir değer olarak kaydederler. Bu yüzden bu tür resimler sayısal ortamda tek bir matris ile ifade edilmektedir ve her bir piksel için yalnızca bir özellik bulunur.

Renkli resim algılayıcıları da gri seviyeli resimlere benzer şekilde ışığın görülebilen dalga boyu aralığını alır. Ancak bu aralığı insan gözünün duyarlı olduğu 3 ana renge böler ve bu şekilde renkli görüntüler gerçek dünya ile aynı şekilde görülebilmektedir. Dalga boyu aralığı 3 parçaya bölüldüğü için renkli görüntüler 3 farklı matrisin bir araya getirilmesi ile ifade edilir. Ve bu yüzden görüntü üzerindeki her bir pikselin 3 farklı değeri vardır.

Hiperspektral görüntülerde ise önceki türlerde olduğu gibi insan gözünün algılayabileceği dalga boyu aralığı için sınırlar yoktur. Kullanılan sensörün hassasiyetine göre seçilen bir dalga boyu aralığı çok sayıda parçaya ayrılabilir. Böylece istediğimiz

görüntüyü temsil edecek çok sayıda matris oluşacaktır ve her bir piksel için elde edilen matris sayısı kadar özellik var demektir.




Şekil 2.3 Işığın dalga boylarına göre görüntü türleri

Şekil 2.3, 3 farklı türdeki resmin karşılaştırılması verilmiştir. Resimden anlaşılacağı üzere kullanılan kameranın hassasiyeti attıkça her bir matris için alınan dalga boyu aralığı azalacak ve bu şekilde daha fazla matris elde edilecektir. Elde edilen matrislerin sayısının artması görüntünün daha fazla ayırt edici özelliğe sahip olmasını sağlar. Örneğin Şekil’de görülen dalga boyu aralığını her bir parça 10 nm olacak şekilde ayırdığımızda 300 nm’lik aralıkta 30 farklı parça oluşur. Yani bu durum, 30 farklı matris ve matristeki her piksel için 30 farklı özellik olacak demektir. Eğer hassasiyeti düşürüp parça aralığını 30 nm’ye çıkarırsak bu durumda 10 farklı matris oluşacaktır ve bu da görüntü üzerindeki her piksel için 10 farklı özellik olacak demektir.

2.2 Hiperspektral Görüntüleme Sistemi ve Spektral İmza


Güneş ışığı yüzeydeki maddenin cinsine göre belirli dalga boylarını emip belirli dalga boylarını yansıtır. Yansıyan kısmın yalnızca bir kısmı insan gözü tarafından hissedilebilir. Hissedilebilenden daha büyük bir aralığa ulaşmak için ise daha duyarlı sensörler kullanılmaktadır. İşte bu sensörler sayesinde yüzeyden yansıyan güneş ışınları yakalanabilmektedir.

Şekil 2.4 incelendiğinde güneş ışığının yüzeydeki maddelere çarpıp farklı şekillerde yansıdığı görülür. Yansıyan ışınlar, bir uydu veya uçağa yerleştirilmiş bir sensör yardımıyla yakalandığında yüzeydeki maddeler bu yansımalarından yararlanılarak ayırt edilebilmektedir.



Şekil 2.4 Işığın yansıması ile HSG'nin elde edilişi


Tüm görüntü yakalandıktan sonra Şekil 2.5'deki küp şeklindeki veri elde edilmiş olur. Şekil incelendiğine görüntü üzerinden bir piksel için alınan parçanın bir vektör oluşturduğu görülür. Bu vektör ilgili pikseli, görüntü üzerindeki diğer tüm piksellerden ayırır.



 ekil 2.5 Hiperspektral k p verisi [31]


Hiperspektral g r nt lerde maddenin cinsine g re spektral band deęerleri olu acaęından, g r nt   zerindeki piksel vekt rleri, yine maddenin cinsine g re birbirlerine benzerlik g stereceklerdir.  ekil 2.6'da g r ld ę  gibi resim  zerindeki farklı t rdeki alanlara ait piksellerin vekt rleri yakın deęerlere sahip olacaklardır.  rneęin; g le ait piksellerin vekt rleri birbirlerine daha  ok benzerken, bir dereye ait piksellerin vekt rleri birbirlerine daha  ok bezeyecektir. Aynı mantıkla bu vekt rler topraklı bir alana veya ormana ait piksellerin vekt rlerinden de farklılık g stereceklerdir.

G r ld ę  gibi bu vekt rleri kullanarak g r nt   zerindeki bu alanları birbirlerinden ayırt etmek m mk nd r. Bahsi ge en  zellikten dolayı bu vekt rlere "spektral imza" denilmektedir. Yani herhangi bir alana ait spektral imzayı kullanarak bu alanda ne olduęu hakkında fikir sahibi olunabilir. Eęer elimizde g r nt   zerinde bir evin  atısına ait spektral imza varsa, bu g r nt deki t m benzer  zellikteki  atıları da bu imzayı kullanarak anlama imk nı vardır.



Şekil 2.6 Farklı türdeki maddeler için spektral imzalar [32]

Spektral imzalar hakkında dikkat edilmesi gereken birkaç nokta mevcuttur. Birincisi piksellerin imzalarında %100 uyuma beklememek gerekmektedir. Sadece aynı materyal cinsine ait pikseller birbirlerine benzer davranışlar gösterirler. İkincisi ve en önemlisi ise ışığın yansıma sırasında uğradığı bozulmalardan dolayı elde edilen spektral bantların bir kısmı hatalı bilgi içerebilmektedir. Örneğin yakalanan görüntüde eğer 200 farklı bant varsa bunların ortalama 20 ila 30 tanesinde söz konusu bozulmalar bulunabilmektedir. Yapılması gereken ise deformasyona uğramış olan bantları görüntüden çıkarıp veriyi daha güvenilir bir hale getirmektir. Şekil 2.7’de bozulmuş bantları temizlenmemiş spektral imzalardan örnekler bulunmaktadır. Görüldüğü gibi 140 ile 160 numaralı bantlar arasında ve 200 numaralı banttıan sonrasındaki değerler sürekliliği bozmaktadır.



Şekil 2.7 Spektral imzalardaki bozulmalar

2.3 Hiperspektral Sensörler ve Kullanım Alanları

HSG sensörler ilk olarak havadan veya uzaydan yüzeyi taramak için kullanılmış özel kameralardır. Genellikle bir uçak yardımıyla üzerinden geçilen alanın belirli bir kısmı taranır ve Hiperspektral görüntüler elde edilir. Bunun yanında daha büyük alanları taramak için uydulara yerleştirilmiş sensörler de mevcuttur. Bu sensörler daha çok askeri amaçlar için kullanılmakta ve çok daha geniş alanların görüntüleri alınmaktadır. Çizelge 2. 1’de bilinen uydu ve uçak sensörleri ve bu sensörlerin özellikleri verilmiştir.

Çizelge 2. 1 Başlıca HSG sensörleri

TİP	ADI	ÜRETİCİ	BANT SAYISI	DALGA BOYU
Uydu	FTHSI on MightySat II	ABD Hava Kuvvetleri Araştırma Lab.	256	350 – 1050 nm
Uydu	Hyperion on EO-1	NASA Goddard Uzay Uçuş Merkezi	220	400 – 2500 nm
Uçak	AVIRIS	NASA Jet Propulsyon Lab.	224	400 – 2500 nm
Uçak	HYDICE	ABD Donanma Araştırma Lab.	210	400 – 2500 nm
Uçak	PROBE-1	Earth Search Sciences Şirketi	128	400 – 2500 nm
Uçak	CASI	ITRES araştırma şirketi	228'e kadar	400 – 1000 nm

Çizelgede gösterilen sensörlerin yanında günümüzde daha özel alanlar için üretilmiş küçük boyutlu görüntüler elde etmek amacıyla tasarlanmış HSG kameralar da vardır. Şekil 2.8'de bahsedilen kameralardan bir tanesi görülmektedir. Bu kameralar çeşitli alanlar için farklı dalga boyu aralıklarına ayarlanıp farklı sonuçlar alabilmektedir.




Şekil 2.8 Hiperspektal kamera

Son yıllarda gelişen teknoloji ile birçok alanda Hiperspektral görüntüler kullanılır hale gelmiştir. Sonuçlarının daha anlamlı olması ve bu şekilde çıkarımların daha kolay yapılması, savunma sanayiinden sağlık sektörüne birçok araştırmacı çok bantlı görüntüleri tercih etmesini sağlamaktadır. Başlıca çalışma konuları:

- Uzaktan Algılama
- Uzay Araştırmaları
- Besin Güvenliği ve Kalitesi
- Adli Tıp
- Biyoteknoloji
- Medikal Bilimler
- Mikroskop Kullanım Alanları
- Askeriye ve Savunma
- Maden arama ve işleme
- İlaç Üretimi
- Mikroişlemciler


Yukarıda belirtildiği gibi Hiperspektral sensörler kullanılarak bahsi geçen alanlarda birçok çözüm önerilmiştir. Kim vd. [1] 2001 yılında yaptıkları bir çalışmada Amerikan Tarım bakanlığı bünyesinde besin sağlığı üzerinde durmuş, Hiperspektral görüntüler kullanarak besinlerdeki sağlığı bozucu etkileri tespit etmişlerdir. Yaptıkları deneylerde taze elmalar ile mantar kiri ile bozulmuş elmaların spektral imzalarının farklı olduğunu görüp bu şekilde elmaları sınıflayabilmişlerdir. Şekil 2.9'da elma görüntüleri ve spektral imzaları görülmektedir.




Şekil 2.9 Elma görüntülerindeki spektral imza farkları [1]

2003 yılında Carrasco vd. [2] hiperspektral sensörler kullanarak çeşitli kanser türleri üzerinde teşhis yapmışlardır. Ayrıca aynı çalışmada besinlerin sağlıklı ve taze olup olmadığını da HSG ile tespit etmişlerdir. Çalışmalarında çok bantlı görüntülerin bu alanlarda henüz emekleme aşamasında olduğunu belirttikten sonra gelecekte önemli bir noktaya geleceğini ortaya koymuşlardır.

Pan ve vd. [3] ise 2003 yılında hiperspektral görüntüleri kullanarak yüz tanıma gerçekleştirmişlerdir. Kurdukları düzenekle 200'ün üzerinde yüz görüntüsü kaydedip incelemişlerdir. Sonrasında yüzün belirli bölgelerindeki imzaların aynı insanların farklı pozları için çok benzer farklı insanlar için ise dikkat çekici biçimde farklı olduğu sonucuna ulaşmışlardır. Şekil 2.10'da 4 farklı insan resmi için yüzün ten kısmının spektral imzaları görülmektedir. Şekil 2.11'de ise aynı insanın 4 farklı pozdaki teninin spektral imzası bulunmaktadır.



Şekil 2.10 4 farklı insanın yüz resmindeki ten kısmının imzaları [3]



Şekil 2.11 Aynı insanın 4 farklı yüz resmindeki ten kısmının imzaları [3]

2.4 Hedef Tanıma Problemi


Sayısal görüntüler üzerinde hedef tanıma problemi, zamanla daha çok dijital hale gelen dünyada oldukça önemli bir yere sahiptir. Özellikle savunma ve güvenlik sektörü olmak üzere birçok alanda, daha önce kaydedilmiş veya gerçek zamanlı sayısal görüntüler üzerinde hedef tanıma, en temel ihtiyaçlardan biridir ve önemi giderek artmaktadır.

Hedef tanıma, görüntü üzerindeki hedef bölgeleri tespit ve tanıma işleminden oluşmaktadır. İlk olarak, görüntü üzerinde normal dışı olan hedeflerin saptanması gerekir. Bu aşamada hedefin özellikleri bilinmesine gerek yoktur ancak sonrasında, tespit edilen hedefin türünün anlaşılması ile hedef tanıma işlemi tamamlanmış olur. Hedef tespiti, görüntü üzerinde ilgilenilen bölgenin, bilgisayar yardımı ile olarak ortaya çıkarılması anlamına gelmektedir. Oluşturulan sistem, kendisine verilen görüntüler üzerindeki aranan bölgeyi dışarıdan herhangi bir insan desteği olmadan tespit eder. Tespit işleminin ardından hedefin hangi türde olduğunun anlaşılması tanımadır. Hedefler, farklı türlerdeki görüntülerde bulunabilmektedir. Şekil 2.12 'de 3 bantlı(renkli) bir görüntü ve üzerinde işaretlenmiş hedef bulunmaktadır. Çıplak gözle incelendiğinde bile tespit edilmesi zor olan bu tür hedefler, bahsedilen hedef tespiti yöntemleri ile elde edilmeye çalışılmaktadır.




Şekil 2.12 Renkli görüntüdeki hedef [29]

Kızılötesi görüntüler, hedef tanıma alanında daha yaygın kullanılan bir görüntü türüdür. Işık yerine ısıya duyarlı görüntüler elde edildiği için, gece veya gündüz fark etmeyecektir. Ayrıca tek bantlı görüntüler olduğundan gerçek zamanlı uygulamalar için, işlem zamanı düşük tutulabilmektedir. Liu vd. çalışmasından[4] alınan Şekil 2.13'de kızılötesi bir görüntü üzerindeki hedefler görülmektedir. Açıkça anlaşılabileceği üzere ısı yayan tüm nesneler görüntüde farklı şekilde görülmektedir.



Şekil 2.13 Kızılötesi görüntüdeki hedefler [4]

Bu tezde kullanılan hiperspektral görüntüleri hedef tanıma yapabilmek için önceki görüntü türlerine göre farklı bir şekilde yaklaşmak gerekmektedir. Önceki türlerde büyük resim, alt resimlere ayrılarak, ayrılan her bir çerçevede hedefin bulunup bulunmadığı üzerinde durulur. Hedefin doğası ve onu diğerlerinden ayıran materyal özellikleri önemli değildir. Bununla birlikte hiperspektral görüntülerde tanımak istediğimiz hedefe özel, yani maddenin yapısına ait bir imza bulunmaktadır. Bundan dolayı görüntü çerçevelere ayrılmaz. Her bir piksel ayrı ayrı incelenerek hedefe ait olup olmadığı anlaşılır çünkü bu pikselin imzası, kendisine ait karakteristiği içermektedir. Şekil 2.14’de gösterilen örnek bir HSG incelendiğinde görüntüdeki her bir pikselin spektral imza vektörü vardır. Bu vektörler çok sayıda özellik içerdiğinden o pikseli diğerlerinden ayırmak diğer görüntülere göre çok daha kolaydır. Özellikle bir veya birkaç piksellik, küçük boyutlu hedefler düşünüldüğünde HSG açık bir şekilde avantajlıdır.



Şekil 2.14 Hiperspektral K p

Ancak ger ek zamanlı uygulamalar d         nde hiperspektral g r nt lerle  alı mak zaman kaybına neden olabilmektedir.   nk  daha  nce g r nt   zerindeki sınırlı sayıdaki  er evelerle i lem yapılırken HSG’da t m pikseller i in hedef tanıma yapılmalıdır. Bu durum da bize fazlasıyla zaman kaybı demektir. Yine de uygun ko ullarda kullanıldığında hedef tanıma konusunda hiperspektral g r nt ler, di er g r nt lere g re daha net sonu lar  retebilmektedir.


ÇOK SINIFLI ÇEKİRDEK FUKUNAGA-KOONTZ DÖNÜŞÜMÜ

3.1 Fukunaga-Koontz Dönüşümü

Fukunaga-Koontz Dönüşümü (FKD) 1970 yılında, Keinosuke Fukunaga ve Warren L. G. Koontz tarafından önerilmiş sınıflandırma alanlarında kullanılan bir yöntemdir[16]. K. Fukunaga ve W. Koontz yaptıkları çalışmada Karhunen-Loeve açılımını temel alarak yeni bir dönüşüm algoritması geliştirmişlerdir. Bu algoritma çok boyutlu uzaylarda öznitelik seçimi ve sıralaması üzerinde durmaktadır. Özellikle 2000’li yıllardan itibaren bu metot, hedef tanıma[17], boyut indirgeme[18] ve yüz tanıma[19] gibi birçok alanda kullanılmıştır.

FKD, gözetimli bir yöntemdir. Eğitim ve test aşamalarından oluşur. Eğitim aşamasında belirli sayılardaki eğitim vektörleri kullanılarak bu işlem tamamlanır. Ardından kalan veriler test için kullanılır. Dikkat çekilmesi gereken bir nokta olarak, yöntemde eğitim vektörlerinin sayısının düşük olduğu durumlarda dahi yüksek performans elde edilebilmektedir. Özellikle hedef tanıma problemlerinde görüntü üzerindeki hedeflerin küçük boyutlu olması bu alanda FKD’nin tercih edilebilirliğini artırmaktadır.

FKD, sınıflandırılması istenen farklı sınıflardaki verilerin ortak bir özuzaya aktarılması ile ayırt edici özelliklerin ortaya çıkması üzerine kurulmuş bir dönüşümdür. Temelde iki sınıflı sınıflandırma mantığına dayalı bir sistemdir. Bu yaklaşıma göre sınıflandırmak istediğimiz veri kümesi hedef sınıfı olarak adlandırılır ve kalan tüm sınıflar ortak bir sınıf şeklinde hedef dışı sınıf olarak seçilir. Sonrasında bir dönüşüm operatörü yardımıyla bu iki sınıf daha küçük boyutlu ortak bir özuzaya aktarılır. Özellik sayısı azaldığından ve kalan özellikler ayırt edici özellikler olduğundan sınıflandırma kolaylaşmaktadır.



Şekil 3.1 Doğrusal sınıflandırıcı kullanarak hedef sınıfın ayrılması

FKD'nin temel bileşen analizi (TBA) yöntemine[20] oldukça benzeyen ilerleyişi vardır. TBA veri kümelerinin özellik sayılarını azaltmak için kullanılan oldukça önemli bir yöntemdir. FKD dâhil birçok yöntem verileri sınıflandırmadan önce temel bileşenlerine ayırmayı tercih etmiştir. FKD, TBA'dan farklı olarak, adımlar tek bir dönüşüm matrisi ile değil hedef ve diğerleri olmak üzere 2 farklı dönüşüm matrisi ile birlikte ilerler. Hedef matrisi hedef sınıfı hakkında daha fazla bilgi içerirken diğer matris ise hedef dışında kalan alanlar hakkında daha fazla bilgi içermektedir.

3.2 Çok Sınıflı Yapı

Zaman içinde yapılan çalışmalarla temelde 2 sınıflı bir sınıflandırıcı olan FKD çok sınıflı hale de getirilmiştir[19]. 2007 yılında Yung-hui Li ve Marios Savvides'in yaptıkları yüz tanıma çalışmasında olduğu gibi çok sınıflı mantığa göre eğitim aşamasındaki her bir sınıf için ayrı şekilde ilerleme kaydedilir. Burada hedef sınıfı kavramı yoktur. Veride bulunan tüm sınıflara ait ayrı birer dönüşüm matrisi bulunmaktadır. Ve her matris kendi sınıfı hakkında en çok bilgiyi içerirken diğer sınıflar ile alakalı az bilgi içerir.


FKD'nin çok sınıflı yapıda olmasının en önemli avantajı eğitim aşamasında ortaya çıkmaktadır. İki sınıflı sınıflandırma yöntemlerinde sınıflandırma yapabilmek için tüm veriyi ikiye ayırmak gerekmektedir. Bundan sonra da eğitim ve test aşamaları bu iki sınıf üzerinden yapılır. 10 sınıf içeren bir veri kümesini sınıflandırırken eğitim aşamasında sadece 1 sınıf diğerlerinden ayrılabilir. Diğer sınıflar ayrılmak

istendiğinde ise tüm eğitim işlemi tekrar yapılmalıdır. Bu da kullanılabilirlik, işlem yükü ve zaman kaybından dolayı tercih edilebilir bir çözüm değildir.

Çok sınıflı yapıda ise eğitim aşamasında verideki tüm sınıflar ayrı ayrı katılabilmektedir. Böylece tek bir eğitim aşamasının ardından test aşamasında tüm sınıflar tekrar işlem yüküne ve zaman kaybına gerek kalmadan sınıflandırılabilir. Bu avantajından dolayı FKD çok sınıflı sınıflandırma yapabilecek şekilde geliştirilmiştir.


3.3 Çekirdek Dönüşümü

Klasik FKD doğrusal sınıflandırıcı yardımı ile ayrılacak dağılıma sahip problemlerde her ne kadar iyi sonuçlar verse de doğrusal olmayan veriler içeren sınıflama problemlerinde tatmin edici sonuçlar üretmemektedir. Bu nedenle'de görülen, verilerinin iç içe girdiği dağılımlar için FKD ve benzeri doğrusal sınıflandırıcılar yetersiz kalmaktadır.




Şekil 3.2 Doğrusal olmayan dağılım içeren veriler

Şekil 3.2'de görülen dağılıma sahip verileri sınıflandırabilmek için genel anlamda 2 farklı yöntem vardır. Bunlardan ilki doğrusal olmayan sınıflandırıcılar kullanmaktır. Bu tür sınıflandırıcılar verileri doğrusal bir çizgi ile ayırmazlar. Anlaşılacağı üzere bu sınıflandırıcıları hazırlamak ve kullanmak zordur. Kapalı karar sınırı kullanmak benzer bir yöntemdir. Bu yaklaşımda doğrusal karar sınırları yerine sınıf 1'i tamamen kapsayacak şekilde dairesel şekilde veya doğruların kesişmesi şeklinde bir ayırım yapılabilmektedir. Şekil 3.3, bu yaklaşımı açık bir şekilde göstermektedir.



Şekil 3.3 Kapalı karar sınırı kullanarak doğrusal olmayan verilerin sınıflandırılması

İkinci bir yöntem ise verileri bir dönüşüm işleminden geçirip dağılımını değiştirmektir. Bu yöntemde veriler kendi uzaylarındaki boyut sayısı artırılarak farklı bir uzaya aktarılır. Bu yeni uzayda her bir örnek öncekine göre farklı bir noktaya yerleşecektir. Eğer iç içe geçmiş dağılımdaki bir veri kümesine, uygun bir dönüşüm uygulanırsa yeni dağılım doğrusal sınıflandırıcılar ile ayrılabilir hale gelecektir. Şekil 3.4 bu durumu ifade etmektedir.



Şekil 3.4 Doğrusal olmayan verilerin doğrusal sınıflandırılabilir hale getirilmesi

Bir gauss dönüşümü yardımı ile iki boyutlu uzaydan önce üç boyutlu uzaya aktarılıp ardından farklı bir açıdan tekrar 2 boyutlu uzaya indirgenmesi ile Şekil 3.4'de görülen dağılım elde edilebilmektedir. Böylece yani dağılım, en basit doğrusal sınıflandırıcılar ile dahi sınıflandırılabilir hale gelecektir. Bahsi geçen bu dönüşüme “çekirdek dönüşümü” adı verilmektedir. Bu yöntem doğrusal olmayan sınıflandırıcılara göre daha fazla tercih edilmektedir çünkü verinin karakterine ait bir karar sınırına ulaşmak oldukça zordur. Bu

durum ayrıca kümeye eklenecek yeni veriler olduğunda daha karmaşık hale gelebilir. Çekirdek dönüşümü ve benzeri işlemler, verinin karakteristiğini çok değiştirmeden daha anlaşılır hale getirdiği için birçok çalışmada kullanılmaktadır.

Çekirdek dönüşümü yaklaşımını kullanan ilk yayınlardan biri 1999 yılında Sebastian Mika vd. [21] önerdikleri çalışmadır. Özellik uzayındaki gürültülerin bir çekirdek dönüşümünden geçirdikten sonra temel bileşen analizi yöntemi (Ç-TBA) uygulayarak temizlenmesi üzerinde durmuşlardır. Sonuçları incelendiğinde resimler üzerine eklenen yapay ve doğal gürültülerin başarılı bir şekilde temizlendiği görülmüştür.

Hiperspektral görüntülerde de 2009 yılında Fauvel vd. [22] Ç-TBA yöntemini kullanarak sınıflandırma yapmışlardır. Çoğunlukla şehir görüntülerinin alındığı ROSIS [23] verisini kullanarak yapılan bu çalışma doğrusal TBA'ya göre oldukça iyi sonuçlar vermiştir.

2007 yılında yapılan iki çalışma ise çekirdek dönüşümünün FKD yönteminden önce kullanılmasına birer örnektir. Liu vd. [17] çekirdek dönüşümü ve FKD kullanarak kızılötesi görüntülerde hedef tanıma yapmışlardır. Yoğun gürültülü resimlerdeki doğal ve yapay hedefleri başarılı bir şekilde tanıma yapmışlardır. Sonuç olarak doğrusal bir FKD ile karşılaştırıp sonuçların daha iyi olduğunu göstermişlerdir. Yung-hui Li ve Marios Savvides[19] ise benzer işlemleri yüz tanıma için uygulamışlardır. Carnegie Mellon üniversitesi bünyesinde toplanan yüz resimleri ile yapılan eğitim ve testlerde % 90'lara yaklaşan oranlarda başarı elde etmişlerdir.


3.4 Eğitim Aşaması

Yönteme problemdeki her sınıf için eğitim verilerini toplamak ile başlanır. Hiperspektral görüntülerde her bir eğitim verisi görüntü üzerindeki bir pikseli ifade etmektedir. Bu pikselin imzası bir vektörden oluşmaktadır ve bu vektör eğitim için kullanılmaktadır. HSG verisindeki sınıflardan eşit sayıda piksel imzası alınarak her biri kendi aralarında bir araya getirilir ve eğitim matrisleri oluşur.

$i = 1, 2, \dots, K$ gibi bir koşulda seçilen K tane sınıf içerisinde, i . sınıfa T_i denirse, $T_i = \{v_i^1, v_i^2, v_i^3, \dots, v_i^N\}$ eşitliği i . sınıfın eğitim vektörlerinin matrisini ifade eder. Küme içerisindeki v_i ilgili sınıfa ait bir eğitim vektörünü gösterir. Her sınıftan N tane alınan eğitim vektörleri ile ayrı T_i matrisleri elde edilir. Bu şekilde eğitimin ilk aşaması olan

verilerin toplanması işlemi tamamlanmıştır. Ardından her bir T_i matrisindeki eğitim vektörlerinin ortalamaları bulunup, bir ortalama vektörü oluşturulur. Tüm sınıflar için ayrı olarak oluşturulan bu ortalama vektörleri eğitim vektörlerinden çıkarılarak sıfır ortalamalı matrisler elde edilir. Karakter yoğunluğu olmaması için sıfır ortalamalı matrisler T_i ile ifade edilmektedir. Bu noktadan sonra klasik FKD yönteminde her bir T_i matrisi $\Sigma_i = T_i T_i'$ eşitliğinde görüldüğü gibi kendi evrik halleri ile çarpılması gereklidir ancak, verilerin daha kolay sınıflandırılabilmesi için çekirdek dönüşümü yapılmalıdır.

Çekirdek dönüşümünde her bir eğitim vektörü, $\phi(x)$ map fonksiyonu adı verilen bir fonksiyon ile dönüşümden geçirilerek çok boyutlu çekirdek (Hilbert) uzayına aktarılır. T_i matrisindeki tüm eğitim vektörleri $T_i = [\phi(v_i^1), \phi(v_i^2), \phi(v_i^3) \dots, \phi(v_i^N)]$ eşitliğinde olduğu gibi bir dönüşümden geçirildiğinde $\tilde{T}_i = [\tilde{v}_i^1, \tilde{v}_i^2, \tilde{v}_i^3 \dots, \tilde{v}_i^N]$ eşitliği elde edilecektir. Sonrasında yapılması gereken, her bir $\tilde{T}_i$ matrisini $\tilde{\Sigma}_i = \tilde{T}_i \tilde{T}_i'$ eşitliğinde ifade edildiği gibi evrik halleri ile çarpmaktır ve böylece çekirdek dönüşümleri yapılmış toplam matrisleri elde edilir.



Şekil 3.5 Çekirdek dönüşümü ve veri dağılımının değiştirilmesi

Teorik olarak bu şekilde düşünülse de pratikte bu yöntem kullanılmamaktadır. Çünkü her bir elemanın $\phi(x)$ fonksiyonundan geçirilmesi hesaplama zamanını ve yükünü artırır. Yerine daha hızlı ve kolay bir çözüm olan “kernel trick” yöntemi geliştirilmiştir. Bu yaklaşım FKD’de bir sonraki adımda yapılacak olan evrik halleri ile çarpma işlemi esas alır. Map fonksiyonu yerine kullanılacak olan bir çekirdek fonksiyonu ile her sınıfın eğitim matrisi işleminden geçirilir. (4.1)’desıklıkla kullanılan çekirdek fonksiyonlarından iki tanesi gösterilmiştir. Bunlardan ilki gauss çekirdeği ikincisi ise polinom çekirdeğidir. Seçilen çekirdek fonksiyonuna ve bu fonksiyonların parametrelerine göre verilerin çok boyutlu öznitelik uzayındaki dağılımları değişir.

$$K(x_i, x_j) = \exp\left(-\|x_i - x_j\|^2 / 2\sigma^2\right)$$

$$K(x_i, x_j) = (x_i \cdot x_j + 1)^d \quad (4.1)$$

Görüldüğü gibi bu çekirdek fonksiyonu sanki tüm örnekler map fonksiyonundan geçirilmiş ve ardından yeni matrisler evrikleri ile çarpılmış gibi sonuç üretir. Elde edilen kovaryans matrislerinin her biri artık kendi sınıfları için bilgiler içermektedir. Yöntemde bir sonraki adım bu matrislerin kendi aralarında toplanmasıdır. (4.2)'de görüldüğü gibi $\tilde{\Sigma}_i$ kovaryans matrisleri toplanarak Σ_{sum} toplam matrisine ulaşılır.

$$\Sigma_{sum} = \tilde{\Sigma}_1 + \tilde{\Sigma}_2 + \dots + \tilde{\Sigma}_K \quad (4.2)$$

Fukunaga-Koontz dönüşümünü yapabilmek için ihtiyacımız olan dönüşüm operatörüne ulaşmak için Σ_{sum} toplam matrisinin özdeğer ve özvektörleri hesaplanır. (4.3)'e bakıldığında V özvektör matrisini D ise özdeğer matrisini ifade etmektedir.

$$VDV' = \Sigma_{sum} \quad (4.3)$$

Özdeğer ve özvektör matrisleri P dönüşüm operatörünü hesaplamak için kullanılacaktır. Bu operatör, daha önceden tüm sınıflar için elde ettiğimiz kovaryans matrislerinin yeni bir dönüşümünü sağlamaktadır. (4.4)'de görüldüğü gibi P dönüşüm operatörü özdeğer ve özvektör matrislerinin çarpılması ile elde edilir.

$$P = VD^{-1/2} \quad (4.4)$$

Daha önce değindiğimiz gibi bahsi geçen dönüşüm, eğitim matrislerini yeni bir özuzaya aktarmayı amaçlar. Bu aktarım söz konusu matrislerin özellik sayılarını düşürerek içlerinden en belirgin olanları seçmektedir. (4.5) eşitliği, P dönüşüm operatörünü kullanarak nasıl tüm matrislerin özuzaya aktarıldığını göstermektedir. K tane sınıf için düşünüldüğünde her bir sınıfa ait Θ_i matrisi oluşacaktır.

$$\Theta_i = P\tilde{\Sigma}_iP' \quad i = 1, 2, \dots, K \quad (4.5)$$

Elde edilen Θ_i matrislerinin özelliği birbirlerini tamamlayan özellik göstermeleridir. Yani her bir matris sadece kendi sınıfına ait olan bilgileri içerisinde toplamıştır. Öyle ki, bu durumu ispatlamak için bu matrisleri toplamak yeterli olacaktır. (4.6)'da görüldüğü gibi K tane Θ_i matrisinin toplamı birim matrisi verecektir.

$$I = \Theta_1 + \Theta_2 + \dots + \Theta_K \quad (4.6)$$

Eşitlikten kolaylıkla anlaşılacağı üzere Θ_i matrisleri toplamaları birim matrise eşit olacak şekilde birbirlerini tamamlamaktadır. Ayrıca her bir matrisin baskın özdeğerlerine karşılık gelen özvektörleri kendi sınıfını daha iyi temsil edebilirken diğer özvektörleri ise o sınıf dışında kalan sınıflar hakkında bilgi içermektedir. $\theta\lambda = \theta\Theta_1$ gibi bir koşul altında (4.7) eşitliği incelendiğinde, yani Θ_1 matrisi θ özvektörü ve buna karşılık λ özdeğerine sahip ise, (4.6)'nın iki tarafını da θ ile çarpıp ardından Θ_1 matrisini içeren terimi karşıya alırsak, Θ_1 matrisini en iyi temsil eden özdeğeri 1'e tamamlayan özdeğer, diğer tüm sınıflar hakkında daha fazla bilgi temsil etmektedir.

$$I = \Theta_1 + \Theta_2 + \dots + \Theta_K$$

$$\theta = \theta\Theta_1 + \theta\Theta_2 + \dots + \theta\Theta_K$$

$$\theta(1 - \theta_1) = \theta\Theta_2 + \dots + \theta\Theta_K \quad (4.7)$$

$$\theta(1 - \lambda) = \theta\Theta_2 + \dots + \theta\Theta_K$$

(4.7)'deki ulaşılan sonuç, farklı Θ_i matrislerinin özdeğerleri için de geçerli olacaktır. Bu yaklaşım bize sınıflandırmanın çok sınıflı olabilmesini sağlamaktadır. Test aşamasında hangi sınıfı ayırt etmek istiyorsak o sınıfı en iyi temsil eden özdeğerleri bulup onlar üzerinden gitmemiz gerekir.

Yapılan işlemlerin ardından çok sınıflı ve çekirdek dönüşümü yapılmış FKD'nin eğitim aşaması tamamlanmış olmaktadır. Test aşamasında hangi sınıf tanınmak isteniyorsa o sınıfa ait Θ_i matrisi üzerinden gidilmelidir.

3.5 Test Aşaması

Test aşamasında görüntü üzerinden seçilen ve hangi sınıfa ait olduğunu bilmediğimiz bir piksel vektörünü sınıflandırmak amaçlanmıştır. Bu şekilde tüm pikseller test işleminden geçirilecek ve ait oldukları sınıflar tanınacaktır. Seçilen test piksel vektörü ilk

olarak eğitim aşamasında olduğu gibi bir çekirdek dönüşümünden geçirilerek doğrusal olarak sınıflandırılabilir hale gelir. Ardından yine benzer şekilde gereksiz özelliklerinden kurtulmak için yeni bir özuzaya aktarılır. Son olarak basit bir doğrusal sınıflandırıcı yardımı ile yine seçilen bir sınıfına ait olup olmadığı anlaşılır. Bu şekilde sınıflandırma tamamlanmış olacaktır.

Seçilen z test vektörü için yapılması gereken ilk işlem çekirdek dönüşümüdür. Eğitim aşamasında uygulanan “kernel trick” yöntemi bu kısımda da kullanılacaktır çünkü çok boyutlu çekirdek uzayına aktarım için herhangi bir map fonksiyonu kullanılmamıştır. (4.8)’de görüldüğü gibi z vektörü, seçilen sınıfın eğitim vektörleri ile birlikte çekirdek fonksiyonuna gönderilir.

$$Z = [K(v_i^1, z), K(v_i^2, z), K(v_i^3, z), \dots, K(v_i^N, z)] \quad (4.8)$$

(4.8) eşitliği incelendiğinde i ’inci sınıfa ait N tane eğitim vektörü ile z test vektörünün dönüşüm işlemine sokulduğu görülecektir. İşlem sonunda ilgili test pikseline ait bir Z çekirdek matrisi elde edilir. Bu matris, (4.11)’de ifade edilen F özellik vektörüne ulaşmak için kullanılacaktır.

Sonraki adımda, $N \times N$ boyutlarında ve tüm elemanları $1/N$ değerinde olan $I_{1/N}$ matrisi oluşturulur. (4.9) eşitliğindeki Ψ_i matrisi, test pikselinin ait olup olmadığının kontrolünün yapılacağı sınıf matrisi $\tilde{Z}_i$ ’nin yeni halidir. $I_{1/N}$ ve $\tilde{Z}_i$ matrisleri kullanılarak elde edilir.

$$\Psi_i = \tilde{Z}_i - I_{1/N} \tilde{Z}_i - \tilde{Z}_i I_{1/N} + I_{1/N} \tilde{Z}_i I_{1/N} \quad (4.9)$$

Ψ_i matrisi, Z matrisi ile birlikte sonuç için asıl hedefimiz olan F özellik vektörünü bulmak için kullanılacaktır. Öncelikle Ψ_i matrisinin özdeğer ve özvektörleri hesaplanır. $\Phi \Omega \Phi' = \Psi_i$ olacak şekilde, Φ özvektör matrisini ve Ω özdeğer matrisini ifade eder. (4.10)’de F özellik vektörünün nasıl bulunduğu gösterilmiştir.

$$F = \frac{1}{\sqrt{\Omega}} \Phi' Z \quad (4.10)$$

Elde edilen özellik vektörü ile seçilen sınıf matrislerinden Θ_i ’in özvektör matrisi çarpılarak sonuç vektörüne ulaşılır. (4.11)’de Π özvektör matrisini R ise sonuç vektörünü göstermektedir.

$$R = \Pi'F \quad (4.11)$$

Sonuç vektörünün normu alındığında ise sınıflandırmak istediğimiz test pikseli için bir değer elde edilmiş olur. Bu değer bir eşik değeri kullanarak seçilen pikselin hedef sınıfa ait olup olmadığına karar verilmesini sağlar. Eğer sayı büyük ise eşik üzerine çıkacak ve hedefe ait olduğu sonucuna ulaşılacaktır. Ancak eşik altında kalıyorsa hedef sınıfı dışında bir sınıfa aittir yorumu yapılır.


ÇOK SINIFLI ÇEKİRDEK FKD YÖNTEMİ İLE HEDEF TANIMA

Bu bölümde Çok sınıflı Ç-FKT kullanılarak iki ayrı veriseti üzerinde hedef tanıma işlemi gerçekleştirilmiştir. Performans ölçümlerinde, hedef bölgelerindeki her bir piksel ayrı birer hedef olarak düşünülerek her birinin ayrıca tanınmasına çalışılmıştır. Bu nedenle, bu çalışmada hedef üzerindeki herhangi bir pikselin tanınması, hedefin tanınması anlamına gelmemektedir.


4.1 AVIRIS Görüntülerinde Bölge Tanıma

Aviris sensörleri tarafından alınan bu görüntü, 1992 yılında Amerika’da Indiana eyaletinin kuzeyinde bulunan tarlaları içermektedir ve bu tarlalara ekilmiş farklı türden ürünleri sınıflandırmak amaçlanmıştır. Görüntü 145x145 piksellik 220 tane spektral bant içermektedir[27].

Veri üzerinde tanımlanmış 16 farklı sınıf bulunmaktadır. Şekil 4.1’de bu görüntü ve Şekil 4.2’de doğrulama görüntüsü görülmektedir. İçerisindeki sınıflar birbirlerine ciddi bir biçimde benzediğinden sınıflandırma yapabilmek için oldukça zorlu bir veridir. Görüntü üzerinde, ışın yansıması sırasında oluşan durumlardan dolayı anlamsız bantlar da bulunmaktadır. Bu bantlar daha önce bu konuda yapılmış çalışmalar [24], [25] göz önüne alınarak görüntüden ayrılmışlardır.



Şekil 4.1 AVIRIS verisi




Şekil 4.2 AVIRIS verisi doğrulama görüntüsü


Görüntü üzerinde bulunan 16 sınıftan örnek olarak seçilen ve şekil üzerinde işaretlenmiş 4 sınıf incelenerek sonuçları üzerinde durulmuştur. Yapılan deneylerde ilk olarak tezde önerilen yöntemin klasik FKD'ye olan üstünlüğü gösterilmiştir. Ardından alternatif yöntem olarak Destek Vektör Makinaları (DVM) yöntemi kullanılarak alınan sonuçlar ve karşılaştırmalar gösterilmiştir. Karşılaştırmalarda kullanılan yöntemlerde eğitim için her bir sınıftan 100 tane eğitim vektörü kullanılmış, kalan tüm piksel

vektörleri de test için kullanılmıştır. Düşük sayıdaki eğitim verileri ile de yüksek performans alındığı görülmüştür.

Çekirdek dönüşümü ile kullanılan FKD'nin klasik FKD'den daha iyi sonuçlar verdiğini görmek için Şekil 4.3 ve Şekil 4.4'e bakılmalıdır. Görüldüğü gibi 13 numaralı sınıf hedef olarak seçildiğinde, Şekil 4.3'de ifade edilen klasik FKD sonucu ve Şekil 4.4'de ifade edilen çekirdek dönüşümlü FKD sonucu arasında açık bir fark vardır. Çekirdek dönüşümü yanlış alarm oranlarını oldukça azaltmıştır. Klasik FKD ile yapılan sınıflandırma sonucunda hedef bölgesi tam olarak tanınmamaktadır.




Şekil 4.3 13 numaralı sınıf için Klasik FKD sonuçları



Şekil 4.4 13 numaralı sınıf için Ç-FKD sonuçları

Bahsi geçen yöntemler arasındaki performans farkını, ROC eğrisi ile sayısal olarak görmek de mümkündür. Bu eğri türleri, sınıflandırma başarımını ölçmek için kullanılmaktadır. Doğru tanıma oranı ve yanlış alarm oranı olarak iki eksen üzerinden


gösterilir. Hedef tanıma yapılırken kullanılacak olan herhangi bir eşik değerine göre doğru ve yanlış tanıma oranları düzlem üzerinde bir nokta ya işaret eder. Bu nokta, seçilen eşik değerindeki performansı ifade etmektedir. Eşik değeri genellikle en büyük değer seçilerek başladığından, oluşacak noktalardan ilki, iki boyutlu koordinat düzlemi üzerinde (0,0) noktasında olacaktır. Bu durum hiç doğru tanıma yapılmamışken, hiç yanlış alarm da verilmemiş anlamına gelir. Eşik değeri düştükçe hedefleri yakalama oranı artacaktır. Bununla birlikte yanlış alarm oranının da arttığı görülebilir. Her ne kadar idealde hedeflenen, tüm hedefleri tanımışken hiçbir yanlış alarm vermemekse de pratikte bu mümkün olmamaktadır. Şekil 4.5’de ifade edilen, iç içe girmiş iki sınıf tam olarak ayırlanamamaktadır.



Şekil 4.5 İçe içe girmiş sınıflar ve eşik değeri


Eşik değeri çok azaldığında ise tüm hedefler doğru tanınmış olacak ancak hedef olmayan alanlar da hedef olarak tanınacaktır. Yanlış alarm olarak nitelendirilen bu durumda, koordinat düzlemi üzerinde yerleştirilecek olan nokta, (1,1) noktasına yaklaşır. Eşik değeri en düşük değere ulaştığında ise (1,1) üzerine nokta yerleştirilir. Yerleştirilen noktaları birleştirdiğimizde ROC eğrisini elde etmiş oluruz. Yüksek performanslı sonuçların eğrilerinin altlarında kalan alan diğer yöntemlere göre daha büyüktür. Bu değer kullanılarak yöntemler arasında bir kıyaslama yapılabilir.

Şekil 4.6’da çekirdek dönüşümlü FKD ile klasik FKD’nin ROC eğrisi sonuçları görülmektedir. Sonuçlar incelendiğinde çekirdek dönüşümünün başarı oranını %10-20 civarında yükselttiği anlaşılmaktadır.




Şekil 4.6 13 numaralı sınıf için ROC eğrisi sonuçları

Bu duruma bir diğer örnek de 8 numaralı sınıfın hedef tanıma sonuçlarıdır. Şekil 4.7 klasik FKD sonuçlarını gösterirken, Şekil 4.8 çekirdek dönüşümlü FKD sonuçlarını göstermektedir. Şekiller incelendiğinde bir önceki sınıfta olduğu gibi bu sınıfta da çekirdek dönüşümünün sınıflandırmaya katkısı açık bir şekilde görülmektedir. Klasik FKD ile yapılan sınıflandırma hedefleri tanıyamazken çekirdek dönüşümü hata oranını düşürüp başarı oranını artırmıştır.




Şekil 4.7 8 numaralı sınıf için Klasik FKD sonuçları



Şekil 4.8 8 numaralı sınıf için Ç-FKD sonuçları

İki yöntem arasındaki farkı sayısal olarak görebilmek için Şekil 4.9'da gösterilen ROC eğrisine bakılmalıdır. Benzer şekilde çekirdek dönüşümü burada da başarıyı %20 civarında yükseltmiştir.




Şekil 4.9 8 numaralı sınıf için ROC eğrisi sonuçları

Çekirdek dönüşümünün sonuçlara etkisini gördükten sonra, önerilen yöntemi diğer yöntemlerle karşılaştırma yapabilmek için sınıflandırma alanında yüksek performans

gösteren DVM[26] yöntemi tercih edilmiştir. Yapılan deneylerde farklı türlerde DVM kullanılmış her biri karşılaştırmaya dâhil edilmiştir. Bu türlerden ilki doğrusal sınıflandırma yapan DVM, ikincisi polinom çekirdeği kullanan DVM, sonuncusu da Radyal Tabanlı Dönüşümü kullanan DVM'dir. Radyal tabalı dönüşümde, bu tezde önerilen yönteme uygulanan çekirdek dönüşümünde, olduğu gibi gauss fonksiyonu kullanılmaktadır. Deneylerde Ç-FKD, DVM'nin 2 türüne göre her zaman daha iyi sonuçlar verdiği bununla birlikte radyal tabanlı DVM ile eşik değerine göre farklı sonuçlar verdiği görülmektedir.


Şekil 4.10, görüntü üzerindeki 5. sınıfa ait sınıflandırma sonuçlarını gösteren ROC eğrisini içermektedir. Grafik incelendiğinde çekirdek dönüşümlü FKD'nin doğrusal ve polinom tabanlı DVM'ye göre daha iyi performans gösterdiği, yine de radyal tabanlı DVM'nin altında kaldığı görülmektedir. Bununla birlikte hata oranının artması ile doğruluk oranlarında FKD, radyal DVM'yi geçebilmiştir.



Şekil 4.10 5 numaralı sınıf için ROC eğrisi sonuçları

Bir diğer örnekte ise görüntüdeki 6. sınıf kullanılmıştır. Şekil 4.11'de gösterilen sonuçlarda da görülebildiği üzere FKD, DVM'nin doğrusal ve polinom tabanlı

sınıflandırma yöntemlerine göre başarılı sonuçlar vermiştir. Yine bir önceki sonuçta olduğu gibi burada da 0.25 gibi bir hata oranından önce DVM radyal tabanlı sınıflandırıcının daha iyi sınıflandırma başarısı gösterdiği, fakat ardından FKD'nin DVM'yi başarı oranında geçtiği görülmektedir.



Şekil 4.11 6 numaralı sınıf için ROC eğrisi sonuçları


4.2 HYDICE – URBAN Görüntülerinde Hedef Tanıma

Görüntü, HYDICE sensörleri tarafından kaydedilmiştir[28]. Bir kasaba üzerinden alınan görüntüyü yollar, ağaçlar, çatılar ve havuzlar gibi sınıflara ayırmak mümkündür. Her biri 307x307 piksellik, 210 adet spektral banttı oluşarı görüntüye ait doğrulama verisi olmadığından piksel sayısı az olan havuzlu bölgeler el ile tespit edilmiş ve sadece bu alanlar için doğrulama görüntüsü oluşturulmuştur. Bununla birlikte görüntü üzerinde 2 farklı türde havuz vardır. Benzer türdeki maddeleri ayırmak daha karmaşık olacağından sınıflandırma için havuzlu bölgeler seçilmiştir. Şekil 4.12'de kullanılan görüntünün doğal görüntüsü bulunmaktadır. Detaylı incelendiğinde görüntü üzerindeki evlerin önlerindeki havuzlar fark edilebilmektedir. Şekil 4.13'de ise havuzlar için doğrulama görüntüsü bulunmaktadır. Doğrulama görüntüsünde siyah olarak gösterilen bölgeler 1.

Havuz sınıfına ait pikselleri ifade ederken, kırmızı olarak gösterilen bölgeler ise 2. Havuz sınıfına ait pikselleri işaret etmektedir.




Şekil 4.12 HYDICE verisi doğal görünümü




Şekil 4.13 HYDICE verisi doğrulama görüntüsü

Görüntü üzerindeki havuzlu alanlara ait piksel sayıları yeterli olmadığı için her 2 tür havuz sınıfından alınan imza örneklerine belirli oranda gürültü eklenerek yapay olarak görüntü üzerine eklenmiştir. Şekil 4.14’de 1.tür havuzlara, Şekil 4.15’de ise 2. tür havuzlara ait spektral imzalar görülmektedir. Şekiller incelendiğinde benzer bir dağılım gösteren imzalara eklenen gauss gürültüleri de anlaşılabilmektedir.



Şekil 4.14 1.Havuz türü için gürültülü imza örneği




Şekil 4.15 2.Havuz türü için gürültülü imza örneği


Bu veriler altında, genel olarak veri 3 ayrı sınıfa bölünerek sınıflandırılmıştır. Bunlardan ilki havuz 1 sınıfı, ikincisi havuz 2 sınıfı ve sonuncusu ise geriye kalan tüm sınıfları içeren bir arka plan sınıfıdır. Havuzların piksel sayıları yetersiz olduğundan eğitim aşamasında her sınıftan 5'er tane piksel imzası kullanılmıştır. Arka plan sınıfı olan havuzlar dışında

kalan tüm sınıflardan da rasgele şekilde yine 5 tane piksel imzası seçilmiş bu şekilde eğitim tamamlanmıştır. Deneylerde küçük boyutlu hedefler kullanıldığından ve bunlar kalan bölümlere göre çok küçük oranlarda olduğundan ROC eğrileri ile performans hesaplamak tutarlı sonuçlar vermeyecektir. Bu yüzden bu kısım sadece hedef tanıma görüntüleri gösterilerek tamamlanmıştır.

Test işleminde her iki havuz sınıfı için sonuçlar elde edilmiştir. Test sonuçları incelendiğinde hedefteki piksellerin tamamına yakınının tanındığı edildiği görülmektedir. Şekil 4.16, 1. Havuz sınıfına ait sonuçları ifade etmektedir. Dikkatli incelendiğinde hedef sınıfına ait tüm havuzların tanındığı edildiği yalnızca bazı havuzlarda piksel kayıpları olduğu görülebilmektedir. Benzer şekilde Şekil 4.17’de de 2. Sınıfa ait havuzların tamamı düşük oranlarda piksel kayıpları ile tanınmıştır.




Şekil 4.16 1.Havuz türü için sınıflandırma sonuçları




Şekil 4.17 2.Havuz türü için sınıflandırma sonuçları

Tezde önerilen yöntem, test verilerine karar verirken bir eşik işlemi kullanmaktadır. Yönteme göre eşğin üstünde kalan alan hedef bölgeyi ifade ederken altında kalanlar ise hedef dışı bölgeleri ifade eder. Elde edilen sonuçlarda da bu şekilde bir eşik kullanılmış, eşğin altında kalan alana 0 değeri verilerek sonuçların daha net elde edilmesi sağlanmıştır.

Durumu daha iyi anlayabilmek için Şekil 4.18, 1. Havuz sınıfına ait olan sonuçları ve Şekil 4.19 ise 2. Havuz sınıfına ait sonuçları 3 boyutlu bir grafikte göstermektedir. Görüldüğü gibi hedef olarak tanınan havuzlu bölgeler yüksek değerleri ile ortaya çıkmakta ve bu şekilde sınıflandırma yapılabilmektedir.



Şekil 4.18 1.Havuz türü için 3 boyutlu sınıflandırma sonuçları



Şekil 4.19 2.Havuz türü için 3 boyutlu sınıflandırma sonuçları

SONUÇ VE ÖNERİLER

Bu çalışmada hiperspektral görüntülerde hedef tespiti problemine karşı çok sınıflı Çekirdek Funukunaga-Foontz Dönüşümü kullanılması önerilmiştir. İki farklı HSG veriseti seçilmiş ve bunlardan AVIRIS verisinde klasik FKD ve DVM yöntemleri ile kıyaslanarak ROC eğrileri ile hedef tanıma başarıları hesaplanmıştır.

AVIRIS verisi sonuçları, yöntemle eklenen çok sınıflı yapı ve çekirdek dönüşümü klasik FKD'ye göre çok daha iyi performans verdiğini göstermektedir. Çekirdek dönüşümünün hedef tanıma performansını belirgin bir biçimde artması ve çok sınıflı tanıma için birden fazla eğitime gereksinimi duyulmaması, klasik yöntemle göre sunulan Ç-FKD'nin üstün yanları olarak görülmektedir.

Diğer yandan, DVM gibi çok güçlü bir yöntemle karşılaştırıldığında, önerilen yöntem DVM'nin doğrusal ve polinom tabanlı modellerine karşı belirgin bir üstünlüğe sahip olduğu ve radyal tabanlı DVM ile de çok benzer sonuçlar verdiği görülmüştür. Bu durum çok sınıflı Çekirdek FKD yaklaşımının iyi bir performansa sahip olduğunu göstermektedir.

Yapılan çalışmada yukarıda değinilen önemli sonuçlar elde edilmekle beraber, çalışma sonrasında ileriye dönük üzerinde çalışılabilecek yeni konuların da ortaya çıktığı görülmüştür.

Spektral bantların seçim yöntemini değiştirmek ve güçlü bir bant seçim yöntemi kullanmak tanıma performansına etki eden önemli bir işlem basamağıdır. Bölüm 2'de değinildiği gibi HSG'de her bir piksel için yüzlerce elemandan oluşan bir vektör bulunmaktadır. Bu vektör değerlerinin bir kısmı anlamlı bilgi içermediğinden uygun bir

bant sayısı azaltma yöntemi kullandıktan sonra sınıflandırma yapılması performansı daha da artıracaktır. Bunun yanında düşük sayıda eleman içeren piksel vektörleri ile işlem yükü de azalacak bu da çalışma zamanını belirgin bir biçimde azaltacaktır. Bu nedenlerden dolayı iyi bir bant seçim yöntemi kullanmak yerinde bir devam çalışması olacaktır.

Tüm bu bilgiler ışığında, çok sınıflı çekirdek Fukunaga-Koontz Dönüşümü yöntemi HSG üzerinde hedef tanıma problemine karşı tercih edilebilir çözümler sunmaktadır. İçerdiği çekirdek dönüşümü ve çok sınıflı yapısı ile doğrusal olmayan çok sınıflı hedef tanıma problemlerine karşı yüksek başarı sunmaktadır.

KAYNAKLAR

- [1] Kim, M. S.ve Chen, Y. R., (2001). "Hyperspectral Reflectance and Fluorescence Imaging System for Food Quality and Safety", American Society of Agricultural Engineers, 44:721-729.
- [2] Carrasco, O. ve Gomez, R. B., (2003). "Hyperspectral Imaging Applied to Medical Diagnostics and Food Safety", Geo-Spatial and Temporal Image and Data Exploitation III, April 2003, Orlando,Amerika.
- [3] Pan Z. ve Healey, G.E.,(2003). "Face recognition in hyperspectral images", IEEE Computer Society Conference, 18-20 Haziran 2003, Irwine, Amerika.
- [4] Liu, R. ve Zhi, H., (2010). "Infrared Point Target Detection with Fisher Linear Discriminant and Kernel Fisher Linear Discriminant", Journal Of Infrared Millimeter And Terahertz Waves, 31:1491-1502.
- [5] Koponen, S., Jouni, P., Kari, K. ve Martti, H., (2002). "Lake water quality classification with airborne hyperspectral spectrometer and simulated MERIS data", Remote Sensing of Environment, 79:51-59.
- [6] Borges, J. S., Bioucas-Dias, J. M. ve Marçal A. R., (2007). "Bayesian Hyperspectral Image Segmentation with Discriminative Class Learning", IbPRIA '07, Proceedings of the 3rd Iberian conference on Pattern Recognition and Image Analysis, Berlin, Almanya.
- [7] Benediktsson, J.A. ve Palmason, J.A., (2005). "Classification of Hyperspectral Data From Urban Areas Based on Extended Morphological Profiles", IEEE Transactions On Geoscience And Remote Sensing, 43: 480-491.
- [8] Banarjee, A. ve Burlina, P., (2006). "A Support Vector Method for Anomaly Detection in Hyperspectral Imagery", IEEE Transactions On Geoscience And Remote Sensing, 44:2282-2291.
- [9] Manolakis D. ve Marden D., (2003). "Hyperspectral Image Processing for Automatic Target Detection Applications", Lincoln Laboratory Journal, 14:79-116.
- [10] Howard, A. ve Padgett, C., (1999). "Intelligent Target Detection in Hyperspectral Imagery", 13. International Conference on Applied Geologic Sensing, Mart 1999, Vancouver, Canada.

- [11] Bruce, L.M. ve Morgan, C., (2001). "Automated detection of subpixel hyperspectral targets with continuous and discrete wavelet transforms" IEEE Geoscience and Remote Sensing, 39:2217-2226.
- [12] Balasubramanian, G. ve Shettigara V.K., (2007). "Band Selection Using Support Vector Machines for Improving Target Detection in Hyperspectral Images", IEEE Digital Image Computing Techniques and Applications, Aralık 2007, Glenelg, Avusturalya.
- [13] Alam, M.S., Islam, M. N., Bal, A. ve Karim, M. A., (2008). "Hyperspectral target detection using Gaussian filter and post-processing", Optics and Lasers in Engineering, 46:817-822.
- [14] Chiang, S. ve Chang C., (2001). "Unsupervised Target Detection in Hyperspectral Images Using Projection Pursuit", IEEE Transactions On Geoscience And Remote Sensing, 39:1380-1391.
- [15] Plaza, A. ve Martinez P., (2003). "A New Method for Target Detection in Hyperspectral Imagery Based on Extended Morphological Profiles", IEEE Geoscience and Remote Sensing Symposium, July 2003, Toulouse, France.
- [16] Fukunaga F. ve Koontz W.,(1970) "Applications of the Karhunen-Loève expansion to feature selection and ordering," IEEE Transactions on Computers, 19:311-318
- [17] Liu R. ve Liu E., (2007). "Infrared small target detection with kernel Fukunaga-Koontz transform", Measurement Science and Technology, 18:3025-3035.
- [18] Ochilov, S., Alam, M. S. ve Bal, A., (2006). "Fukunaga-Koontz transform based dimensionality reduction for hyperspectral imagery" Algorithms and Technologies for Multispectral, Hyperspectral, and Ultraspectral Imagery XII. 6233:57-81.
- [19] Li, Y. ve Savvides, M.,(2007). "Kernel Fukunaga-Koontz Transform Subspaces For Enhanced Face Recognition". IEEE Conference on Computer Vision and Pattern Recognition, June 2007, Minneapolis, Amerika.
- [20] Turk M.A. ve Pentland A., (1991). "Face recognition using eigenfaces". IEEE Proceeding CVPR '91, June 1991, Hawaii, Amerika.
- [21] Mika, S. ve Schölkopf, B., (1998). "Kernel PCA and De-Noising in Feature Spaces" Proceedings of NIPS 1998, 536-542
- [22] Fauvel, M. ve Chanussot, J., (2009). "Kernel Principal Component Analysis for the Classification of Hyperspectral Remote Sensing Data over Urban Areas", EURASIP Journal on Advances in Signal Processing, 2009:1-15.
- [23] ROSIS Hipespektral sensörü, http://www.opairs.aero/rosis_en.html, 20 Aralık 2010.
- [24] Rajadell, O. ve Garc'ia-Sevilla, P., (2009). "Textural Features for Hyperspectral Pixel Classification", Proceedings of the 4th Iberian Conference on Pattern Recognition and Image Analysis, June 2009, Portugal.

- [25] Faulconbridge, R. I. ve Pickering, M. R., (2006).“Unsupervised band removal leading to improved classification accuracy of hyperspectral images”, Proceedings of the 29th Australasian Computer Science Conference, June 2006, Darlinghurst, Avusturalya.
- [26] Boser, B. E., Guyon, I. M. ve Vapnik, V. N., (1992). “A training algorithm for optimal margin classifiers”. Proc. 5th Annu. ACM Workshop Computational Learning Theory, July 1992, New York, Amerika.
- [27] AVIRIS Hiperspektral sensörü, <http://aviris.jpl.nasa.gov/html/data.html>, 16 Mayıs 2010.
- [28] HYDICE Görüntüleri, <http://www.agc.army.mil/hypercube/>, 10 Nisan 2010.
- [29] Hedef tanıma örneği, <http://ilab.usc.edu/classes/2001cs599/i018c.gif>, 24 Mart 2011.
- [30] Görünen ışığın dalga boyu aralığı, <http://www.overidon.com/wp-content/uploads/2010/06/wavelength-light1.jpg>, 24 Mart 2011.
- [31] Hiperspektral görüntüleme sistemi, http://www.csiro.au/news/newsletters/0611_metals/story2.htm, 24 Mart 2011.
- [32] Spektral imzalar, http://rst.gsfc.nasa.gov/Intro/Part2_24.html, 24 Mart 2011.

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı : Semih DİNÇ
Doğum Tarihi ve Yeri : 13.08.1986 - İZMİR
Yabancı Dili : İngilizce
E-posta : sdinc@yildiz.edu.tr

ÖĞRENİM DURUMU

Derece	Alan	Okul/Üniversite	Mezuniyet Yılı
Lisans	Bilgisayar Müh.	Dokuz Eylül Üniversitesi	2009
Lise	Fen / Matematik	Yahya Kaptan Anadolu Lisesi	2004

İŞ TECRÜBESİ

Yıl	Firma/Kurum	Görevi
2009 – Gün.	Yıldız Teknik Üniversitesi	Araştırma Görevlisi

YAYINLARI

Bildiri

1. **Dinç S.** ve Bal A., “A statistical approach for multi-class target detection”. Complex Adaptive Systems, Kasım 2011, Illinois, Amerika(Kabul Edildi)
2. **Dinç S.**, Ayan U. ve Bal A., “Gene Classification using Appropriate Feature Selection Method and Fukunaga-Koontz Transform Kernel”, IEEE 6th National Conference On Electrical And Electronics Engineering, Aralık 2010, Bursa, Türkiye.
3. **Dinç S.** ve Bal A., “Detection of Product Surface Defects by Learnable Transform Filters”, IEEE 18th Conference on Signal Processing and Communications Applications, Nisan 2010, Diyarbakır, Türkiye

Proje

1. Termik Santral Performans İzleme ve Değerlendirme Sistemi Tasarımı Ve Uygulaması (Peridsis)