

KIRIKKALE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ELEKTRİK - ELEKTRONİK ANABİLİM DALI
YÜKSEK LİSANS TEZİ

UYDU GÖRÜNTÜLERİNDEN DURAGAN HALDEKİ UÇAKLARIN
ALGILANMASI VE TANINMASI

Cihat YILDIZ

EYLÜL 2010

Elektrik - Elektronik Anabilim Dalında Cihat YILDIZ tarafından hazırlanan UYDU GÖRÜNTÜLERİNDEN DURAGAN HALDEKİ UÇAKLARIN ALGILANMASI VE TANINMASI adlı Yüksek Lisans Tezinin Anabilim Dalı standartlarına uygun olduğunu onaylarım.

...../...../.....

Doç. Dr. Ediz POLAT

Anabilim Dalı Başkanı

Bu tezi okuduğumu ve tezin **Yüksek Lisans Tezi** olarak bütün gereklilikleri yerine getirdiğini onaylarım.

Doç. Dr. Ediz POLAT

Danışman

Jüri Üyeleri

Başkan : Prof. Dr. Şerafettin EREL _____

Üye (Danışman) : Doç. Dr. Ediz POLAT _____

Üye : Yrd. Doç. Dr. Tolga EREN _____

Bu tez ile Kırıkkale Üniversitesi Fen Bilimleri Enstitüsü Yönetim Kurulu Yüksek Lisans derecesini onaylamıştır.

Prof. Dr. İhsan ULUER

Fen Bilimleri Enstitüsü Müdürü

ÖZET

UYDU GÖRÜNTÜLERİNDEN DURAGAN HALDEKİ UÇAKLARIN ALGILANMASI VE TANINMASI

YILDIZ, Cihat

Kırıkkale Üniversitesi

Fen Bilimleri Enstitüsü

Elektrik - Elektronik Anabilim Dalı, Yüksek Lisans Tezi

Danışman: Doç. Dr. Ediz POLAT

Eylül 2010, 61 sayfa

Uydu görüntüleri kullanılarak yeryüzündeki nesnelere tanımak görüntü işlemedeki yaygın problemler arasındadır. Hava limanları gibi alanlar ise uçakların park edildikleri ve konuşlandıkları yerlerdir. Özellikle askeri uygulama olarak düşündüğümüzde hedef bölgelerde bulunan nesnelere tespit edilmesi, sayılarının uzaktan ve gizli bir şekilde elde edilmesi gibi işlemleri yapmak sağlıklı strateji geliştirmek açısından verimli sonuçlar vermektedir.

Bu itibarla belirlediğimiz bir bölgede (Havaalanı veya uçuş bölgesi gibi) bulunan hava araçlarına ait görüntülerden, kullanılabilir, yararlı bilgiler elde etmeyi amaçlamıştır.

Bu çalışmada, belirli bir yükseklikten çekilmiş havaalanı görüntülerinden uçakların bulunması işlemi gerçekleştirilmiştir. Bu amaç dahilinde bir çerçeve, giriş verisi üzerinde gezdirilmiştir. Gezilen her bölgede uçak olduğu varsayılır.

Alınan görüntüde uçağa ait niteliklerin daha belirginleştirilmesi ve öznelik vektörünün elde edilmesi için gabor filtresi kullanılmıştır. Elde edilen öznelik verileri SVM sınıflandırma işlemi uygulanarak elde edilen verinin uçak olup olmadığı belirlenmiştir.

Bu uygulamanın gerçekleştirilmesinde *Google Earth* uygulaması yardımıyla havaalanlarına ait uydu görüntülerinden faydalanılmıştır.

Anahtar Kelimeler: uçak tanıma, gabor filtresi, destek vektör makinesi,

ABSTRACT

DETECTION AND IDENTIFICATION OF STATIC AIRCRAFTS FROM SATELITTE IMAGES

YILDIZ, Cihat

Kırıkkale University

Graduate School of Natural and Applied Sciences

Department of Electrical and Electronics, M.Sc. Thesis

Supervisor: Assoc. Prof. Dr. Ediz POLAT

September 2010, 61 Pages

It is one of the common problems to identify the objects on earth using satellite images. Airports are such places where aircrafts are parked and deployed. Especially for the military applications, to identify the objects in target areas and counting of aircrafts remotely and undercoverly gives effective results in terms of making right strategies

Therefore our goal is to obtain useful information from airport and fly zone images where we can find aircrafts in.

In this paper we performed identifying of aircrafts from airport images taken from a specific altitude. For this purpose a frame has been masked over input data. Each zone has been masked is considered as it contains an aircraft.

Gabor filter is used to refine the features of aircraft and extract the feature vector. Feature data's acquired were classified using SVM classification to identify the aircraft on image.

We used satellite images from airports derived from Google Earth™ application.

Keywords: aircraft recognition, Gabor filter, support vector machine

Annem, Babam, Kardeşlerim

ve

Kendim

için

TEŐEKKÜR

Tezin hazırlanması esnasında desteęini benden esirgemeyen, tavsiyeleriyle beni yönlendiren hocam Sayın Doç. Dr. Ediz POLAT'a,

Tez alıřmalarım sırasında yardımlarını esirgemeyen arkadaşlarım Halil Ketencioęlu ve Turan Güneř'e;

Her zaman yanımda olan ve desteęini ben den esirgemeyen Ailem ve Dostlarıma içten teşekkürlerimi sunarım.

İÇİNDEKİLER

	<u>Sayfa</u>
ÖZET	i
ABSTRACT	iii
TEŞEKKÜR	v
İÇİNDEKİLER	vi
ÇİZELGELER DİZİNİ	viii
ŞEKİLLER DİZİNİ	ix
KISALTMALAR DİZİNİ	x
1. GİRİŞ	1
1.1 Literatürde Yapılmış Olan Çalışmalar.....	2
1.2 Çalışmanın Amacı.....	3
1.3 Kaynakların Analiz Edilmesinde İzlenen Yol.....	4
1.3.1 Eğitim Verilerinin Elde Edilmesi	4
1.3.2 Özniteliklerin Belirlenmesi	4
1.3.3 Sınıflandırma İşlemi	5
1.3.4 Uçakların Resim İçinde Bulunması	6
2 MATERYAL VE YÖNTEM	7
2.1 Gabor Süzgeçleri Ve Özniteliklerin Belirlenmesi	8
2.1.1 Gabor Süzgeci.....	9
2.1.2 Gabor Süzgeç Bankası	19
2.1.3 Özniteliklerin Elde Edilmesi.....	22
2.2 Verilerin Eğitimi Ve Sınıflandırması.....	25
2.2.1 Destek Vektör Makineleri (SVM)	26
2.2.2 İkili Sınıflandırma İçin SVM Uygulaması	26
2.2.2.1.1 Doğrusal Svm	27
2.2.2.1.1.1 Ayrılabilir Veri Durumu	27
2.2.2.1.1.2 Ayrılamayan Veri Durumu	30
2.2.2.1.2 Lineer Olmayan Svm	32
2.2.3 Çoklu Sınıflandırma İçin Svm Uygulaması	34
2.2.4 Çok Katmanlı Algılayıcı (MLP)	35
2.2.5 Radyal Tabanlı Fonksiyon (RBF) Ağı	38
2.2.6 Eğitim Verilerinin Temin Edilmesi	41
2.2.7 Eğitim	41
2.2.8 Sınıflandırma	42
2.2.9 K – En Yakın Komşuluk Algoritması	42
3 SONUÇ VERİLERİ VE TARTIŞMA	44
3.1 Veri Setlerinin Temin Edilmesi	44
3.2 Ön İşlemler	44
3.3 Yapılan Uygulamanın Gerçekleştirilmesi	45
3.4 Sonuç	57
KAYNAKLAR	58

ÇİZELGELER DİZİNİ

Çizelge	Sayfa
2.1 Dört Temel Kernel Tipi Ve Fonksiyonları	34

ŞEKİLLER DİZİNİ

Şekil	Sayfa
1.1. Uygulama Temel Gösterimi	2
1.2. Öznitelik çıkartılmasında izlenen yol	5
1.3. Eğitim ve sınıflandırma Temel Gösterimi.....	6
1.4. Uçağın Resim Bulunması Temel Gösterimi	7
2.1. Uygulama Genel Gösterimi	8
2.2. Tek boyutlu Gaussian dalga	10
2.3. Tek boyutlu Gaussian dalganın ölçek ve ortalama değerlerine göre değişimi	10
2.4. İki boyutlu Gaussian dalga	11
2.5. Farklı ölçek değerleri için iki boyutlu Gaussian dalga	13
2.6. İki boyutlu Gabor dalgacığının gerçek(real) bileşeni.....	16
2.7. İki boyutlu Gabor dalgacığının sanal (imaginary) bileşeni.....	17
2.8. İki boyutlu Gabor dalgacığının genlik (mutlak değer) ifadesinin gösterimi	18
2.9. İki boyutlu Gabor dalgacığının farklı yönelimler için görünüşleri.....	19
2.10. İki boyutlu Gabor dalgacığının farklı merkez frekanslar için görünüşleri	20
2.11. İki boyutlu Gabor dalgacığının farklı ölçek değerleri için görünüşleri	21
2.12. Uçağın boyutunun indirgenmesi ve özneliliğın elde edilmesi (A).....	23
2.13. Uçağın boyutunun indirgenmesi ve özneliliğın elde edilmesi (B).....	23
2.14. Uçağın özneliliğın elde edilmesi	24
2.15. SVM, $(w,x)+b=0$ aşırı düzlemi	27
2.16. Geçici değişkenlerin Gösterimi	31
2.17. Lineer olmayan SVM gösterimi	32
2.18. Giriş, gizli ve çıkış katmanlarından oluşan MLP.....	35
2.19. n adet girişli nöronun matematiksel gösterimi.....	36
2.20. Sigmoid fonksiyonu.....	37
2.21. Radyal tabanlı fonksiyon ağının yapısı	39
2.22. Girdi, gizli ve çıktı katmanından oluşan RBF sınıflandırıcısı	40
2.23. k-NN sınıflandırma örneği	43
3.1. Eğitim için kullanılan uçak resimleri	46
3.2. Uçağa ait olmayan eğitim resimleri	47
3.3. Farklı yönlerdeki uçakların gabor çıktıları	48
3.4. Örnek Uygulama Sonucu – 1	54
3.5. Örnek Uygulama Sonucu – 2	54
3.6. Örnek Uygulama Sonucu – 3	55
3.7. Örnek Uygulama Sonucu – 4	55
3.8. Örnek Uygulama Sonucu – 5	56

SİMGE VE KISALTMALAR

SVM	Support Vector Machine
SVM 1	SVM (One-Vs-One) Classifier
SVM 3	SVM 2 SVM (One-Vs-Rest) Classifier
SVM 3	SVM (Multi-Class) Classifier

1. GİRİŞ


Uydu görüntüleri kullanılarak yeryüzündeki cisimlerin tanınması veya analiz edilmesi stratejik önem içeren birçok alanda kullanılmaktadır. Özellikle askeri uygulamalarda bu amaçla birçok uygulama geliştirilmiş ve halen geliştirilmektedir. Uçakların da uydu görüntüleri üzerinden tanınması askeri ve stratejik değerlendirilebilecek bir uygulama olarak gerçekleştirilmiştir. Bu itibar ile elde edilen istatistiksel veriler ve zamanla veriler üzerinde gerçekleşen değişimler stratejik karar mekanizmalarının daha sağlam ve başarılı sonuçlar almasında yardımcı olacaktır.

Görüntü işleme teknikleri ile uçakların tanınması, uçağın dış geometrisinin öğrenilmesine bağlıdır (1). Uçakların dış görünüşlerinin daha belirginleştirilmesi ve on plana çıkartılması bu uçakların tanınmasında önemli bir değer taşımaktadır. Hava alanları gibi uçakların konuşlandıkları yerlerde uçakların etrafında birçok nesne bulunabilir. Bu tür nesnelere uydu fotoğraflarından bakıldığı zaman uçak nesnelere algılanmasında gürültü olarak değerlendirilmektedir. Bu itibar ile uçakların algılanması için, uçağa ait özniteliklerin belirginleştirilmesinde bant geçiren bir süzgeç kullanılması anlamlıdır. Yapılan çalışmada uçağa ait niteliklerin belirginleştirilmesi için bant geçiren bir süzgeç olan *Gabor Süzgeci*'ni farklı açı değerleri ile kullanmış ve bu sayede öznitelikler ortaya çıkartılmıştır.

Uçağa ait olan niteliklerin belirginliği sınıflandırma işlemi için yapılacak olan eğitim işlemi ve uygulamanın gerçekleştirilmesi esnasında sağlıklı sonuçlar elde edilmesi açısından oldukça önemlidir.

Uygulama gerçekleştirilirken giriş imgesinden elde edilen özniteliklerin bir uçağa ait olduğunun anlaşılabilmesi için sınıflandırma metotları kullanılması gerekmektedir. Bu amaçla uçağın özelliklerini belirginleştiren Gabor filtresi, belirlenmiş olan parametre değerleri kullanılarak uygulanır. Elde edilen sonuçlar ile sınıflandırma işlemi gerçekleştirilir ve elde edilen verinin uçak olup olmadığı anlaşılabilir olur.

Bu çalışmada verilerin uçak olup olmadığını anlamamız için bir sınıflandırma yöntemi olan Destek Vektör Makineleri (Support Vector Machines - SVM) kullanılmıştır.



Şekil 1.1. Uygulama Temel Gösterimi

1.1 Literatürde Yapılmış Olan Çalışmalar

Uydu görüntüleri yardımıyla uçakların tanınması ile ilgili yapılan literatür araştırmasında sayı olarak çok az uygulama ile karşılaşmıştır. Ancak uydu görüntülerinin analizi ile ilgili birçok uygulama literatürde mevcuttur

Rebollo ve Escudero (2) 1975 de Uydu görüntülerinden alınan uçak resimlerinin sınıflandırılmasında karışık integer programlama yöntemini kullanmıştır.

Hsieh ve Hsieh (3) 2004 yılında uydu görüntülerinden alınan uçak resimlerini hiyerarşik sınıflandırmaya tabi tutarak türlerini ayırt etmeye çalışmıştır.

Geman and Jedynak (4) 1996 da Uydu görüntüleri üzerinden otoyolları izleme uygulamasını gerçekleştirmiştir.

Shi ve Zhu (5) 2002 de Uydu görüntülerini kullanarak yeryüzündeki otoyolları çıkartan bir çalışma gerçekleştirmiştir.

Greenberg ve Guterman (6) 1996 da uydu görüntüleri kullanmadan hava araçlarını yapay sinir ağları kullanarak tanıyan ve sınıflandıran bir uygulama gerçekleştirmiştir.

San ve Türker (7) 2008 de yüksek çözünürlüklü uydu görüntülerini kullanarak yeryüzündeki binaları destek vektör makineleri yöntemi ile belirlemiştir.

Chen (8) 2004 yılında içinde uçakların da bulunduğu askeri kara ve hava araçlarının tanınmasında sınıflandırma metotlarını kullanmış ve karşılaştırmıştır. Bu uygulama gerçekleştirilirken uydu görüntüleri kullanılmamıştır.

1.2 Çalışmanın Amacı

Bu çalışmada belli bir yükseklikten çekilmiş olan uydu fotoğraflarından yer yüzeyinde konuşlanmış olan durağan uçakların tanınması amaçlanmıştır. Hiç bir zorluk çekmeden gözlerimiz yardımı ile ayırt edebildiğimiz bu nesnelerin, bilgisayar programı vasıtası ile ve uygun yöntemlerle eğitildiği zaman tanınabileceği aşikârdır.

Bu amaç doğrultusunda, yapılan çalışmada literatürde sık rastlanan algoritmalar kullanılarak, hızlı ve doğru bir şekilde yeryüzündeki uçakların tanınması için geniş bir araştırma yapılmıştır. Çalışmanın temeli uçak objelerinin de içinde bulunduğu yeryüzü fotoğraflarından Gabor filtreleri kullanılarak uçaklara ait niteliklerin belirginleştirilmesi ve özneliklerin elde edilmesi üzerinde kurulmuştur.

Bu ifade ile yola çıkarak uçakların algılanmasında bize yardımcı olan uçağın kendi geometrisini on plana çıkartan gabor filtreleri ile modellenebilmesi, öznelik elde edilmesinde bu filtrenin seçiminde en önemli bir etkidir.

Elde edilen gabor çıktıları SVM ile sınıflandırma işlemine tabi tutulmuştur. Bu işlemin sonucunda da verinin uçak olup olmadığı algılanmıştır. Uçak nesnesinin içinde bulunduğu bir uydu fotoğrafı belli bir çerçeve boyutunda gezdirilir ve gezilen her alanda çerçeve 360 derece döndürülerek uçağın yönünden bağımsız bir tanıma uygulamasını gerçekleştirmek amaçlanmıştır.

1.3 Kaynakların Analiz Edilmesinde İzlenen Yol

1.3.1 Eğitim Verilerinin Elde Edilmesi

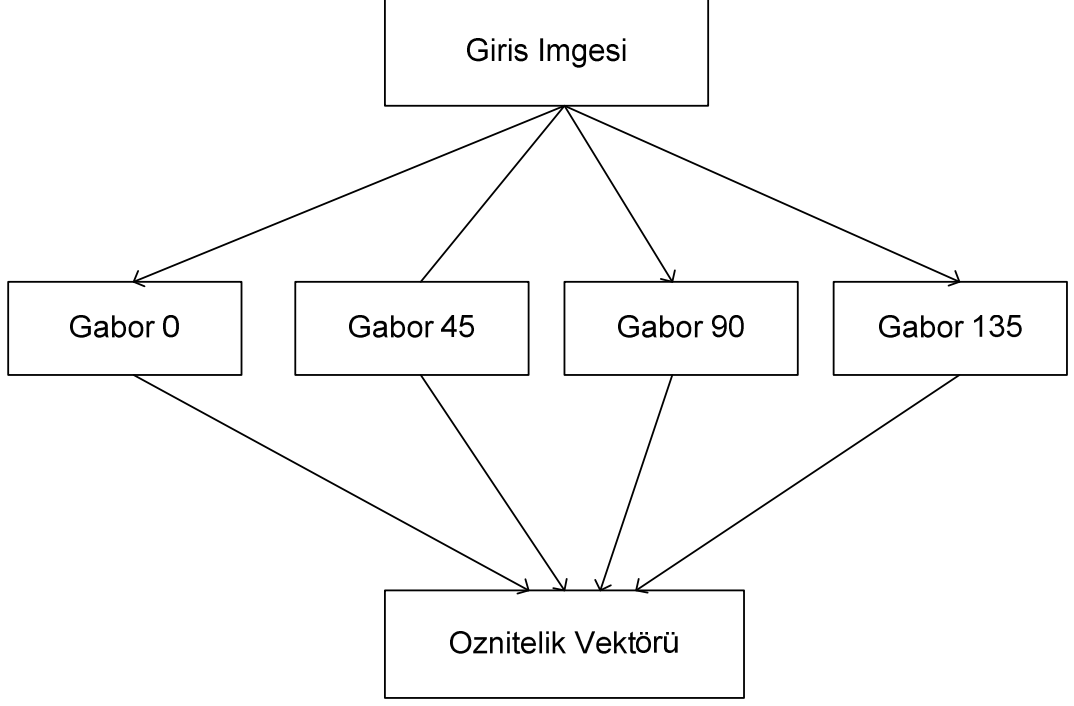
Yapılan uygulama için uydu görüntülerinden alınmış uçak resimlerine ait bir uçak veritabanı bulunmamaktadır. Bu nedenle ticari veya akademik olarak uydu görüntüsü veren uygulamalar test edildi ve en iyi sonucu Google™ firmasının bir ürünü olan *Google Earth* uygulamasının en iyi sonucu verdiği gözlemlendi.

Bu itibar ile bu program vasıtasıyla özellikle hava trafiğinin çok yoğun olduğu Amerika ve Avrupa kıtalarındaki havaalanları üzerinde detaylı araştırmalar yapıldı. Bu araştırma sonucunda 120 adet amaca uygun uçak resmi çıkartılmıştır. Bu resimler özellikle sınıflandırma işleminde eğitim amacıyla kullanılmıştır. Uçağın içinde bulunduğu geniş alanı kapsayan ve uygulamaya giriş resmi olarak kullanılan uydu görüntüsünden ise yaklaşık 20 adet çıkartılmıştır.

Uydu görüntülerin içerisinde uçakların seçilip çıkartılmasında düşük gürültüye sahip zeminde bulunan, açık renkli ve zemin yüzeyi koyu uçaklar seçilmiştir.

1.3.2 Özniteliklerin Belirlenmesi

Özniteliklerin belirlenmesi için Gabor filtresi dört farklı açı kullanılarak gabor değerleri elde edilmiştir. Bu değerler kullanılarak tek boyutla bir öznitelik vektörü elde edilmiştir. Elde edilen bir öznitelik vektörü SVM için giriş verisini oluşturmaktadır.

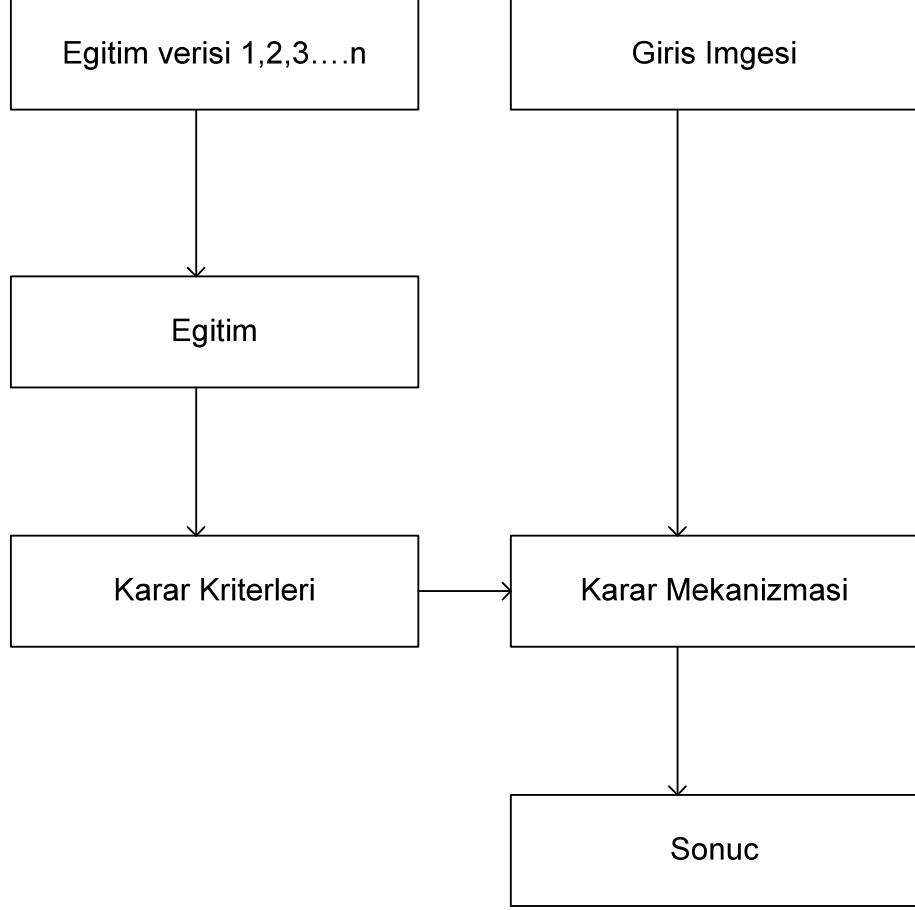


Şekil 1.2. Öznitelik çıkartılmasında izlenen yol

1.3.3 Sınıflandırma İşlemi

Belirlenmiş olan öznitelikler eğitim için belirlenmiş olan algoritmaya giriş olarak verilir ve amaca uygun olarak eğitim verileri elde edilir. Elde edilen bu eğitim verileri ile yapılan uygulamada giriş verisinin uçak olup olmadığı kararına varılır.

Uçakların eğitiminde kullanılan eğitim verisi ne kadar çeşitli ve fazla sayıda olursa kararın başarısı da o oranda artar. Bu nedenle olumlu veya olumsuz eğitim verilerinin çok sayıda olması oldukça önemlidir.




Şekil 1.3. Eğitim ve sınıflandırma Temel Gösterimi

1.3.4 Uçakların Resim İçinde Bulunması

Uçağın belir bir yükseklikteki uydu görüntüsü içerisinde bulunabilmesi için belirlenmiş olan bir çerçeve boyutu resim içerisinde x ve y koordinatları doğrultusunda gezdirilir. Gezdirilen her alanda çerçeve belirlenmiş açı adımlar ile toplam 360° döndürülür ve her dönüş sonrasında gabor filtresinden geçirilir, Gabor filtresinden sonra elde edilen öznitelik vektörü sınıflandırma işlemi için SVM metodunu kullanan algoritmaya gönderilir. Böylece aranan uçağın resim içerisinde ve hangi açıda olduğu belirlenmiş olur.

Uygulamada yapılan alıřmalarda ereveye ait znitelik ıkartma ve SVM'den nce niřlem olarak *Template matching* ve *Shape matching* uygulamaları denenmiř ancak istenilen bařarım saėlanamamıřtır.



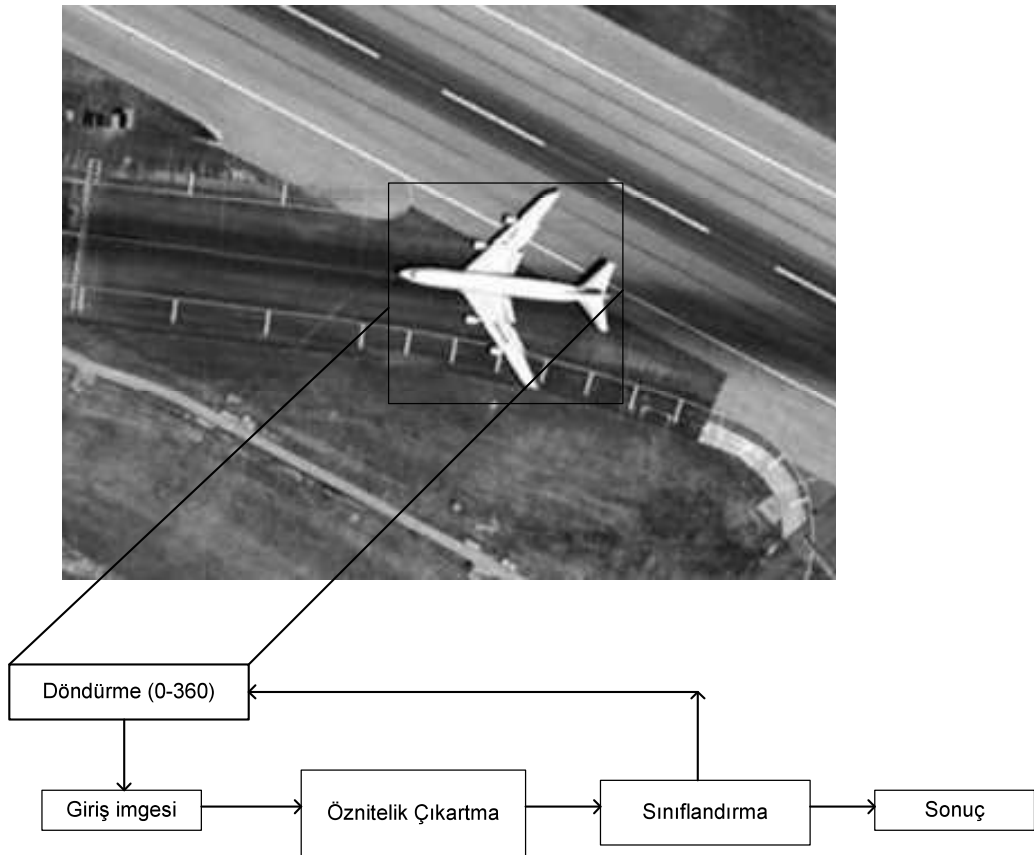
řekil 1.4. Uaėın Resim Bulunması Temel Gsterimi

2. MATERYAL VE YÖNTEM

Bu bölümde yapılmış olan uygulamada kullanılan yöntemler hakkında ayrıntılı bilgi verilmeye çalışılacaktır. Uygulamanın gerçekleşmesinde daha önce de bahsetmiş olduğumuz üzere *Gabor* filtrelerin geniş bir ölçüde kullanılmaktadır. Kullanılan *Gabor* değerleri ile elde edilen öznelik vektörü karar mekanizmasında önemli rol oynamaktadır.

Yapılan çalışmalarda kullanılan yöntemin belirlenmesi aşamasında, birçok uygulama ve yöntem denenmiş, bu yöntemlerden bazıları başarısızlıkla sonuçlanmış, bazıları ise sonuçları itibari ile istenilen nitelikte olmamıştır.

Gerçekleştirmiş olduğumuz bu uygulama sonuçları itibari ile başarılı ancak parametrelerin iyileştirilmesi ile bu uygulamanın başarımı ve sonuçların başarısı daha da artırılabilir durumdadır.



Şekil 2.1. Uygulama Genel Gösterimi

2.1 Gabor Süzgeçleri ve Özniteliklerin Belirlenmesi

Öznitelik çıkartılması, uçak görüntülerinde farklı ifadeler sonucu oluşan değişikliklerin sayısal gösterimidir. Bu ifadelerinin neden olduğu değişikliklere ait bilgilerin, yani özniteliklerin çıkartılmasında genel olarak;

- Geometrik tabanlı öznitelik çıkartım metotları
- Görüntü tabanlı öznitelik çıkartım metotları

Olmak üzere 2 tür yaklaşım vardır. Geometrik öznitelikler, uçak bileşenlerinin yerleri ve şekillerini ifade ederler. Uçak bileşenlerine ait öznitelik noktaları, uçak geometrisini belirten bir öznitelik vektörü oluşturmak için çıkartılır. Görüntüye dayalı metotlarda ise öznitelik vektörü, Gabor dalgacıkları gibi bir görüntü filtresinin resmin tümüne veya belli bir bölgesine uygulanması suretiyle elde edilir(9).

2.1.1 Gabor Süzgeci


Gabor süzgeci, 1940'lı yıllarda Macar bilim adamı Dennis Gabor tarafından haberleşme sisteminde tek boyutlu olarak kullanılmış. (10) Daugman insan beynindeki görmeyi sağlayan sinir hücrelerinin yön hassasiyeti ve bant geçiren doğasından esinlenerek Gabor süzgecini iki boyutlu olarak uyarlamıştır. (11,12). Gabor süzgeçlerinin uzay ve frekans eksenlerinin her ikisi için de mümkün en yüksek çözünürlüğü sağladığını ortaya koymuştur.

Gabor süzgeçleri, merkez frekans, süzgeç yönelimi (orientation) ve ölçek (scale) değerleri olmak üzere üç farklı faktöre göre analize imkan verdiği için imge analizinde geçmişten günümüze birçok farklı uygulamada kullanılmıştır.

Gabor süzgecini incelemeden önce Gabor süzgecinin zarfı olan Gaussian fonksiyonuna kısaca göz atacağız. Tek boyutlu bir $B(x, y, \sigma_x)$ Gaussian fonksiyonu


$$B(x, y, \sigma_x) = \frac{1}{\sigma_x \sqrt{2\pi}} \exp\left\{-\frac{1}{2}\left(\frac{x - \mu}{\sigma_x}\right)^2\right\} \quad (2.1)$$

Şeklinde ifade edilir. (Şekil 2.2)



Şekil 2.2. Tek boyutlu Gaussian dalga.


Fonksiyon σ_x -veya s - ölçek değeri ve μ - veya m - ortalama değer ifadelerine bağlı olarak Şekil 2.3 deki gibi değişir.



Şekil 2.3. Tek boyutlu Gaussian dalgasının ölçek ve ortalama değerlerine göre değişimi


Şekil 2.4'de görülmekte olan, iki boyutlu bir $C(x, y, \sigma_x, \sigma_y)$ Gaussian yüzeyi şu şekilde ifade edilir.

$$C(x, y, \sigma_x, \sigma_y) = \frac{1}{2\pi\sigma_x\sigma_y} \exp\left[-\frac{1}{2}\left\{\left(\frac{x}{\sigma_x}\right)^2 + \left(\frac{y}{\sigma_y}\right)^2\right\}\right] \quad (2.2)$$




Şekil 2.4. İki boyutlu Gaussian dalga.

İki boyutlu Gabor süzgecinin daha iyi anlaşılması için, Gabor dalgacığının zarfı niteliğindeki iki boyutlu Gaussian fonksiyonu farklı ölçek değerleri için incelenmiştir. Gaussian yüzeyin şekli σ_x ve σ_y ölçek değerlerine bağlı olarak değişebilir. Şekil 2.5 'da σ_x ve σ_y ölçek değerlerinin birden dörde değiştirilmiştir, elde edilen gaussian yüzeyin değişimleri gözlenmiştir. a-) $\sigma_y=1$ ve $\sigma_x=1..4$, b-) $\sigma_y=2$ ve $\sigma_x=1..4$, c-) $\sigma_y=3$ ve $\sigma_x=1..4$ d-) $\sigma_y=4$ ve $\sigma_x=1..4$ ölçek değerleri için iki boyutlu Gaussian dalga şekilleri gösterilmektedir.




a)




b)

Şekil 2.5. a-) $\sigma_y=1$ ve $\sigma_x=1..4$ ölçek değerleri için, b-) $\sigma_y=2$ ve $\sigma_x=1..4$ ölçek değerleri için iki boyutlu Gaussian dalga, c-) $\sigma_y=3$ ve $\sigma_x=1..4$ ölçek değerleri için, d-) $\sigma_y=4$ ve $\sigma_x=1..4$ ölçek değerleri için iki boyutlu Gaussian dalga.

Devam ediyor,



c)



d)

İki boyutlu Gabor süzgeci, iki boyutlu Gaussian yüzey ile tek yöndeki iki boyutlu düzgün dalganın birleşimidir. Gabor süzgeci Gaussian yüzeyin genliği, düzgün dalganın yayılım yönü ve frekansı ile tanımlanır.

Gabor süzgeci;

$$G(x, y, \theta, f, \sigma_x, \sigma_y) = g(x, y, \theta, \sigma_x, \sigma_y) \exp(i2\pi fx') \quad (2.3)$$

$$g(x, y, \theta, \sigma_x, \sigma_y) = \frac{1}{2\pi\sigma_x\sigma_y} \exp\left[-\frac{1}{2}\left\{\left(\frac{x'}{\sigma_x}\right)^2 + \left(\frac{y'}{\sigma_y}\right)^2\right\}\right] \quad (2.4)$$

Şeklinde ifade edilir. x' ve y' ifadeleri

$$x' = x \cos(\theta) + y \sin(\theta) \quad (2.5)$$

$$y' = y \cos(\theta) - x \sin(\theta) \quad (2.6)$$

Şeklinde tanımlamıştır.


$G(x, y, \theta, f, \sigma_x, \sigma_y)$ ifadesinde f süzgeç frekansını, σ_x ve σ_y ölçek değerleri, yayılma yönü ve buna dik yöndeki süzgeç genliklerini, θ ise düzgün dalganın yayılma yönünü ve x eksenini arasındaki açıyı temsil eder.

Gabor süzgeci, gerçekte (G_R) ve sanal (G_I) olmak üzere iki bileşen içeren karmaşık bir yapıdır.


$$G(x, y, \theta, f, \sigma_x, \sigma_y) = G_R(x, y, \theta, f, \sigma_x, \sigma_y) + iG_I(x, y, \theta, f, \sigma_x, \sigma_y) \quad (2.7)$$

$$G_R = g(x, y, \theta, \sigma_x, \sigma_y) \cos[2\pi f\hat{x}] \quad (2.8)$$


$$G_I = g(x, y, \theta, \sigma_x, \sigma_y) \sin[2\pi f\hat{x}] \quad (2.9)$$



Şekil 2.6. İki boyutlu Gabor dalgacığının gerçekte(real) bileşeni.



Şekil 2.7. İki boyutlu Gabor dalgacığının sanal (imaginary) bileşeni.



Şekil 2.8. İki boyutlu Gabor dalgacığının genlik (mutlak değer) ifadesinin gösterimi.

Şekil 2.6, Şekil 2.7, Şekil 2.8 de sırasıyla Gabor süzgecinin gerçek, sanal ve genlik bileşenlerine yer verilmiştir. Gabor süzgeç genlik ifadesi şu şekildedir:

$$\begin{aligned}
 \text{Gabor_Genlik} &= |G(x, y, \theta, f, \sigma_x, \sigma_y)| \\
 &= \sqrt{G_R(x, y, \theta, f, \sigma_x, \sigma_y)^2 + G_I(x, y, \theta, f, \sigma_x, \sigma_y)^2}
 \end{aligned}
 \tag{2.10}$$

$I(x, y)$ imgesi Gabor süzgeci ile iki boyutlu konvolüsyon işlemine sokularak $F(x, y, \theta, f, \sigma_x, \sigma_y)$ süzgeçlenmiş imgesi elde edilir.

\


$$F_R(x, y, \theta, f, \sigma_x, \sigma_y) = \sum_{l=-k}^k \sum_{m=-k}^k I(x+l, y+m) G_R(x, y, \theta, f, \sigma_x, \sigma_y) \quad (2.11)$$

$$F_I(x, y, \theta, f, \sigma_x, \sigma_y) = \sum_{l=-k}^k \sum_{m=-k}^k I(x+l, y+m) G_I(x, y, \theta, f, \sigma_x, \sigma_y) \quad (2.12)$$

$$\text{ve } F(x, y, \theta, f, \sigma_x, \sigma_y) = \left[\left(F_R(x, y, \theta, f, \sigma_x, \sigma_y) \right)^2 + \left(F_I(x, y, \theta, f, \sigma_x, \sigma_y) \right)^2 \right]^{1/2} \quad (2.13)$$


2.1.2 Gabor Süzgeç bankası

İncelenecek dokuya göre belirlenmiş farklı süzgeçlerin bir araya getirilmesiyle oluşturulan süzgeç bankaları doku bölümlenmede geniş kullanım gören yapılardır. Bant geçiren karakteristiği ile tanınan Gabor süzgeçleri, değişebilen merkez frekans, yönelim ve ölçek değerleriyle süzgeç bankası oluşturulmaya oldukça uygundur.




Şekil 2.9. İki boyutlu Gabor dalgacığının farklı yönelimler için görünüşleri

Şekil 2.9'de iki boyutlu Gabor dalgacığının 0 dan π 'ye kadar $\pi/4$ radyanlık değişen süzgeç yönelimleri için zaman ekseninde üstten görünüşü görülmektedir.



Şekil 2.10. İki boyutlu Gabor dalgacığının farklı merkez frekanslar için görünümleri

İki boyutlu Gabor süzgecinin yönelimi (0 rad) ve $\sigma_x = \sigma_y = 3$ alınarak, frekans değerleri 0.1 den 0.4'e düzenli olarak artırılmış, elde edilen süzgeçlerin gerçekte bileşenleri Şekil 2.10'de görülmektedir.



Şekil 2.11. İki boyutlu Gabor dalgacığının farklı ölçek değerleri için görünümleri

İki boyutlu Gabor süzgecinin yönelimi (0 rad) ve frekans (0.3) değerleri sabit tutulmuş, $\sigma_x = \sigma_y$ alınarak eşit aralıklarla 2 den 5'e kadar artırılmıştır, elde edilen süzgeçlerin gerçek bileşenleri Şekil 2.11'da görülmektedir.

Görüldüğü üzere yönelim, merkez frekans ve ölçek parametreleri değiştirilerek birçok farklı Gabor süzgeci elde edilebilir, elde edilen bu süzgeçler süzgeç bankasını oluşturur.

Gabor süzgeçleri kullanılarak oluşturulan süzgeç bankaları, incelemek dokunun özellikleri göz önünde bulundurularak oluşturulurlar, örneğin retina, parmak izi gibi imgeler incelenirken oluşturulan süzgeç bankasıyla, kumaş incelerken kullanacağımız süzgeç bankası birbirinden farklıdır. Bir sonraki

bolümde uçakların özniteliklerinin ortaya çıkartılmasında Gabor filtrelerinin kullanımı anlatılacaktır.

2.1.3 Özniteliklerin Elde Edilmesi

Yapılan uygulamada, uydu görüntüleri kullanılarak yeryüzündeki uçakların özniteliklerinin çıkartılmasında Gabor filtreleri farklı açı değerleri ile hesaplanmaktadır. Özellikle eğitim verilerinin elde edilmesinde temiz ve az gürültülü resimler kullanılmıştır.

Resim içerisinde uçak olduğu varsayılan resim çerçevesi içerisinde 4 farklı açıda Gabor filtre değerleri hesaplanır. Bu işlem için sırasıyla aşağıdaki adımlar izlenmiştir.

- Uçak olduğu varsayılan çerçeve seçilir
- Çerçeve, filtreleme işlemi için daha küçük bir boyuta indirgenir
- 0, 45, 90, 135 dereceler kullanılarak Gabor değerleri hesaplanır
- Hesaplanan değerler tek bir vektör haline getirilir



Kaynak



0



45



90



135

Şekil 2.12. Uçağın boyutunun indirgenmesi ve özniteliğın elde edilmesi (A)



Kaynak



0



45




90



135

Şekil 2.13. Uçağın boyutunun indirgenmesi ve özneliliğın elde edilmesi (B)



Şekil 2.14. Uçağın özneliliğın elde edilmesi

Normal boyutlardaki bir çerçevede Gabor işleminin uygulandığında, ortaya çok fazla öznelilik elde edilmektedir. Bu durum veri analizi, makine öğrenmesi, örüntü tanıma, metin sınıflandırma, web madenciliği ve biyolojik gen analizi uygulamalarında karşılaşılan en büyük problemlerden biridir. Bu nedenle,

yapılan analize ilişkin etkili ve doğru sonuçlar alınması amacıyla veri boyutunun indirgenmesi çoğu zaman yararlı olmaktadır.

Birçok makine öğrenme ve örüntü tanıma uygulamalarında kullanılan algoritmalar literatürde “boyutun laneti”(13) olarak bilinen probleme karşı hassas olduklarından, öznelik sayısının artması kullanılan öğrenme algoritmasının performansının azalmasına neden olmaktadır. Zira Gabor filtreleme sonucu elde edilen özneliklerin tamamı yüz ifade analizi için gerekli olmayıp ifade sınıflandırması için önemi ve yararı olmayan bilgiler içermektedirler. Bu nedenle, yapılan çalışmalarda çoğu zaman büyük boyutlu veri kümelerinden çeşitli boyut indirgeme teknikleri kullanılarak daha küçük boyutta azaltılmış yeni veri kümeleri oluşturulmuştur. Sınıflandırma ve kümeleme üzerine yapılan çalışmalarda boyutu indirgenmiş verilerin kullanılması ile daha doğru ve anlaşılabilir sonuçlar elde edilmiştir(14) .

Boyut indirgeme yapılmasının nedenleri ve avantajları.

- Boyutu indirgenmiş verideki öznelikler daha fazla ayırt edici olabilmektedirler.
- Birçok öğrenme algoritması için eğitim ve sınıflandırma zamanı boyutun indirgenmesiyle önemli ölçüde azalır.
- Önemsiz ve yararı olmayan öznelikler sınıflandırma performansını olumsuz yönde etkilemektedirler.
- Kullanılan algoritmalar daha hızlı çalışır ve sistem belleğinin gereksiz yere kullanılması önlenmiş olur.

biçiminde sıralanabilir(15).

Uygulamanın gerçekleştirilmesinde Gabor kernel boyutu 7 olarak belirlendi, frekans değeri olarak 10 genlik değeri olarak da 1 değeri yapılan testler sonucunda belirlenmiştir. Bu değerlerin belirlenmesinde kernel seviyesi 3 ile

9 arası, genlik değeri olarak 0 ile 3 arası, frekans değeri olarak ise 0 ile 20 arasındaki değerler test edilmiştir.

Gabor süzgeçleri kullanılarak elde edilen farklı açılardaki verilerin elde edilmesi ile ortaya çıkan öznitelik vektörü, sınıflandırma işleminin giriş değeri olarak elde edilmektedir.

2.2 Verilerin Eğitimi ve Sınıflandırması

Nesne analizinde son adım, çıkarılan özniteliklerin ifadelere göre sınıflandırılmasıdır. İfade sınıflandırması, bir karar işlemi ile bağlantılı örüntü dağılımı modelleri içeren bir sınıflandırıcı ile gerçekleştirilmektedir. Bu işlem için öncelikle makine, sınıflandırması istenen öge kümesinden belli sayıda örnekle eğitilir ve diğer ögeler eğitim örneklerine göre sınıflandırılırlar(16).

Nesnelerin tanınmasında birçok sınıflandırma yöntemi kullanılmaktadır. *Destek Vektör Makineleri, Bayes Ağları, Karar Ağacı, Yapay Sinir Ağları, en yakın komşuluk ve Saklı Markov Modeli* gibi yöntemler sınıflandırma yöntemlerinden bazılarıdır. Yapılan uygulamada sınıflandırma işlemi için Destek Vektör Makineleri (SVM) kullanılmıştır. Destek Vektör Makineleri ile ilgili detaylı açıklama ilerleyen bölümlerde detaylı olarak anlatılacaktır.

2.2.1 Destek Vektör Makineleri (SVM)

Destek vektör makineleri sınıflandırma ve değişkenler arasındaki ilişkileri hesaplama yöntemleri (regression) için kullanılan bir danışmanlı (Supervised) öğrenme yöntemidir.(17). Bu tekniğe ait sınıflandırma algoritması ilk olarak 1992 yılında Vapnik ve çalışma arkadaşları tarafından ikili sınıflandırma çerçevesi içinde ileri sürülmüştür (18,19). Son yıllarda bu metot, kernel metotları(20,21) olarak bilinen tüm istatistiksel öğrenme algoritma ailesinin doğmasına yol açan makine öğrenme çerçevesinde büyük bir ilgi kazanmıştır. SVM, optik karakter tanıma(22), metin madenciliği(23), yüz tanıma(24,25), yüz ifade analizi(26) ve biyotıp(27) gibi birçok uygulamada başarılı olmuş ve çoğu yaklaşıma üstünlük sağlamıştır.

2.2.2 İkili Sınıflandırma İçin SVM Uygulaması

En basit SVM biçimi, örnekler ve bu örneklere ait etiketlerden oluşan kümenin bir ikili sınıflandırma kuralı öğrenme algoritmasıdır. Biçimsel olarak ifade edilirse, her bir örneğe ilişkin ikili olarak etiketlenmiş bir küme olsun. Örneğin bu küme $S = \{(x_1, y_1), \dots, (x_l, y_l)\}$ olmak üzere $(x_i, y_i) \in X \times \{-1, +1\}$ ve $i = 1, 2, 3, 4, \dots, l$ biçimindedir.

Burada X, \mathbb{R}^d biçiminde olup, analiz edilecek veri uzayını belirtir. Örneğin d boyutlu yüz görüntülerine ait ifadeler veri uzayını, etiketler $+1$ ve -1 de ifadelerin ikili sınıflarını belirtmektedirler. SVM'nin amacı, S den $f: X \rightarrow \{-1, +1\}$ şeklinde bir sınıflandırma fonksiyonu öğrenmektir. SVM sınıflandırıcı çıkışı, lineer bir fonksiyonun işaretine dayalıdır.

$$f(x) = \text{sign}(w \cdot x + b) \quad (2.14)$$


Geometrik olarak, bir $(w, x) \in X \times \mathbb{R}$ ikilisi $H_{w,b} = \{x \in X: (w, x) + b = 0\}$ biçiminde bir aşırı düzlem tanımlar ki bu düzlem, giriş uzayı X 'i iki yarım uzaya böler ve böylece yeni bir noktanın sınıf tahmini, bu noktanın düzlemin hangi tarafında bulunduğuyla bağlı olacaktır.

2.2.2.1.1 Doğrusal SVM

2.2.2.1.1.1 Ayrılabilir Veri Durumu

Eğitim seti lineer bir şekilde ayrılabilir olduğunda, başka bir deyişle pozitif ve negatif örneklerin aşırı düzlemin farklı taraflarında bulunduğu bu durum, SVM'nin en basit çeşidi olan Hard Marjın SVM' dir. Hard Marjın SVM, sonsuz sayıdaki aşırı düzlem arasından, S ' den en yakın veri noktasına en geniş

aralıklı olanı seçer. Bu aralık, aşırı düzlemin marjini olarak bilinir ve genellikle γ ile belirtilir. Aşırı düzlem ise Şekil 2.6' da gösterildiği gibi maksimum marjin sınıflandırıcıyı tanımlar(28).



Şekil 2.15. SVM, maksimum marjin γ olmak üzere, pozitif (beyaz daireler) ve negatif (siyah daireler) örnekleri ayıran $\langle w, x \rangle + b = 0$ aşırı düzlemini bulur.

$(x_i, y_i) \in S$ noktasından $H_{w,b} = \{x \in X: \langle w, x \rangle + b = 0\}$ aşırı düzlemine olan uzaklık $\frac{|\langle w, x_i \rangle + b|}{\|w\|}$ ile verilir. Eğer $H_{w,b}$ bir ayırma aşırı düzlemi ise, bu aralık $y_i \frac{|\langle w, x_i \rangle + b|}{\|w\|}$ ya eşit olur ve buna ilişkin marjin;

$$\gamma = \min_{i=1, \dots, l} y_i \frac{|\langle w, x_i \rangle + b|}{\|w\|}, \quad (x_i, y_i) \in S \quad (2.15)$$

ile verilir. Aşırı düzlemler, önlerine bir ölçeklendirme sabiti olarak tanımlandıkları için, genel durum kaybı olmaksızın $H_{w,b}$ tanımına;

$$\min_{i=1, \dots, l} y_i (\langle w, x_i \rangle + b) = 1, \quad (x_i, y_i) \in S \quad (1.15)$$

kısıtı eklenebilir. Bu ifade S' e göre aşırı düzlemlere kanonik bir tanım verir ve buradan (2.14) denkleminde $H_{w,b}$ ayırma aşırı düzleminin marjini $\frac{1}{\|w\|}$ ile verilir.

SVM algoritması, maksimum marjine sahip olan H_{w^*,b^*} kanonik ayırma aşırı düzlemini arar ve sözü edilen maksimum marjin,

$$(w^*, b^*) = \underset{\substack{w \in X \\ b \in \mathbb{R}}}{\operatorname{argmin}} \frac{1}{2} \|w\|^2 \quad (2.16)$$

$$y_i (\langle w, x_i \rangle + b) \geq 1, \quad i = 1, \dots, l \quad (2.17)$$

biçiminde bir optimizasyon problemi olarak formülize edilebilir. Amaç fonksiyon (2.16) ve eşitsizlik kısıtlarının (2.17) konveks olmasından dolayı bu problem konveks problemler sınıfına aittir. Ayrıca, amaç fonksiyon tam anlamıyla konveks olduğundan, bu problemin tek bir çözümü vardır (BOYD ve VANDENBERGHE, 2004). Optimizasyon problemleri pratikte Lagrange duality çerçevesi içinde çözülebilir. (2.16) ve (2.17) ile belirtilen primal optimizasyon problemlerine bağlı olan Lagrange;

$$L(w, b, \alpha) = \frac{1}{2} \|w\|^2 - \sum_{i=1}^l \alpha_i (y_i (\langle w, x_i \rangle + b) - 1) \quad (2.18)$$

biçimindedir. Burada $\alpha_i \geq 0$ katsayıları Lagrange çarpanları olup $y_i (\langle w, x_i \rangle + b) \geq 1$ kısıtıyla ilişkilendirilir. Bu optimizasyon probleminin tek çözümü Lagrange'ın eyer noktasında, yani $L(w, b, \alpha)$ 'nin (w, b) 'ye göre minimumunda ve α 'ya göre bir maksimumunda verilir. Sabit bir α için w ve b 'ye göre Lagrange minimize edilir. Bu $L(w, b, \alpha)$ 'nin w ve b 'ye göre kısmi türevleri alınarak gerçekleştirilir ve buradan sırasıyla;

$$\frac{\partial}{\partial w} L(w, b, \alpha) = 0 \quad \Rightarrow \quad w = \sum_{i=1}^l \alpha_i y_i x_i \quad (2.19)$$

$$\frac{\partial}{\partial b} L(w, b, \alpha) = 0 \quad \Rightarrow \quad \sum_{i=1}^l \alpha_i y_i = 0 \quad (2.20)$$

(2.19) ve (2.20) ifadeleri (2.18) ile verilen Lagrange denkleminde yerine konulursa orijinal problem şu şekildeki dual probleme dönüşür:

$$\alpha^* = \operatorname{argmax}_{\alpha \in \mathbb{R}^l} \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i,j=1}^l \alpha_i \alpha_j y_i y_j \langle x_i, x_j \rangle \quad (2.21)$$

$$\alpha_i \geq 0, \quad i = 1, \dots, l \quad (2.22)$$

$$\sum_{i=1}^l \alpha_i y_i = 0 \quad (2.23)$$

Bu problem Sequential Minimal Optimization (SMO) (PLATT, 1999) algoritması ile çözülür ve optimum α^* ile karşılaşıldığında karar fonksiyonu $f(x) = \operatorname{sign}(\langle w^*, x \rangle + b^*)$ şu şekilde olur:

$$f(x) = \operatorname{sign} \left(\sum_{i=1}^l \alpha_i^* y_i \langle x, x_i \rangle + b^* \right) \quad (2.24)$$

b^* kayması da optimumda elde edilir ve noktalar Karush-Kuhn-Tucker durumunu doğrular:

$$\alpha_i^* (y_i (\langle w^*, x_i \rangle + b^*) - 1) = 0, \quad i = 1, \dots, l \quad (2.25)$$


Bu duruma göre sıfır olmayan α_i^* Lagrange çarpanları sadece $y_i (\langle w^*, x_i \rangle + b^*) = 1$ olduğu durumdaki (x_i, y_i) noktalarına karşılık gelir. Bu noktalar aşırı düzlemin marjini üzerinde bulunurlar ve sınıflandırıcının “destek vektörleri” olarak adlandırılırlar.

2.2.2.1.1.2 Ayrılamayan Veri Durumu

Yukarıda bahsedilen ayrılabilir veri için olan durumun aksine, genel olarak veriyi ayırabilen lineer bir aşırı düzlem bulunmayabilir. Ayrılamayan veri kümeleri, pratikte her $(x_i, y_i) \in S$ noktası için, primal problemin (2.17) ile verilen ayrılabilirlik kısıtlarını sağlamak amacıyla, $x_i^3 \geq 0$ geçici değişkenlerin kullanılması şeklinde düşünülebilir:

$$y_i(\langle w, x_i \rangle) + b \geq 1 - x_i \quad (2.26)$$

x_i terimi, (x_i, y_i) noktasının sınıflandırılmasında yapılan hatayı açıklamaktadır: Eğer $x_i = 0$ ise (x_i, y_i) noktası doğru bir şekilde sınıflandırılır ve marjinin dışında bulunur, $0 < x_i < 1$ ise (x_i, y_i) noktası yine doğru sınıflandırılır, fakat marjinin içinde bulunur ve eğer $x_i > 1$ ise (x_i, y_i) noktası sınıflandırılmaz. Bu anlatılanlar Şekil 4.3' te gösterilmektedir. Aşırı düzlemin marjininin $x_i = 0$ için $(x_i, y_i) \in S$ noktalarından tanımlandığına dikkat edilmelidir.



Şekil 2.16. Geçici değişkenlerin gösterimi. $x_i > 1$ sınıflandırılmayan noktaları, $0 < x_i < 1$ marjin içinde doğru bir şekilde sınıflandırılmış noktaları ve $x_i = 0$ marjin dışında doğru bir şekilde sınıflandırılmış noktaları belirtir.

Geçici değişkenlerin toplamı, ayrılabilirlik kısıtlarının miktarının eğitim seti üzerindeki ihlalini açıklar, dolayısıyla bunlar öğrenme işlemi süresince kontrol edilmelidir. Bu işlem, geçici değişken niceliğinin SVM optimizasyon problemi objektif fonksiyonuna eklenmesiyle yapılır:

$$(w^*, b^*, x^*) = \underset{\substack{w \in X, \\ b \in \mathbb{R}, \\ x \in \mathbb{R}^l}}{\operatorname{argmin}} \quad \frac{1}{2} \|w\|^2 + C \sum_{i=1}^l \alpha_i x_i \quad (2.27)$$


$$y_i (\langle w, x_i \rangle) + b \geq 1 - x_i, \quad i = 1, \dots, l \quad (2.28)$$

$$x_i \geq 0, \quad i = 1, \dots, l \quad (2.29)$$

(2.27) ile belirtilen amaç fonksiyondaki C sabiti, $\frac{1}{2} \|w\|^2$ terimi ile ifade edilen marjin maksimizasyonu arasındaki ilişkiyi gösterme anlamındadır. C ' nin azaltılması, artan marjinin yararı için eğitim kümesi üzerindeki büyük sayıdaki sınıflandırılmayışın tolere edilmesini sağlar. "Soft Marjin SVM" olarak bilinen bu formülasyon, ayrılabilir durumdaki Hard Marjin formülasyonunun tam tersidir. Hard Marjin formülasyonu eğitim seti lineer olarak ayrılabilir olmasına rağmen $C = +\infty$ için düzelme gösterirken, Soft Marjin formülasyonu ise gürültü ve olabilecek aykırı değerlere karşı uyumu önler.

2.2.2.1.2 Lineer Olmayan SVM

Şekil 12' nin sol tarafında görüldüğü gibi lineer olarak ayrılamayan problemlerde, lineer sınıflandırıcılar kümesi düzgün bir sınıflandırma fonksiyonu sağlamak için yeterli olmayabilir.



Şekil 2.17. Linear olmayan SVM gösterimi. $\phi = \mathbb{R}^2 \rightarrow \mathbb{R}^3$ şeklindeki eşleştirme $\phi([x_1, x_2]) = [z_1, z_2, z_3]$ ile tanımlanır. ($z_1 = x_1^2$, $z_2 = x_2^2$ ve $z_3 = \sqrt{2}x_1x_2$)

Destek vektör makineleri linear olmayan durumda orijinal veri yerine dönüştürülmüş veri $\phi(x_1), \dots, \phi(x_i)$ ' ye linear yaklaşım kullanılarak genelleştirilebilir. Burada ϕ giriş uzayı X ' ten yeni öznitelik uzayı H ' ye linear olmayan dönüşümü gösterir. (2.21) denklemindeki $\langle x_i, x_j \rangle$ yerine $\langle \phi(x_i), \phi(x_j) \rangle_H$ konulmasıyla yeni öznitelik uzayında linear bir aşırı düzlem hesaplanır ve buradan giriş uzayındaki linear olmayan ayırma fonksiyonu f ;

$$f(x) = \text{sign} \left(\sum_{i=1}^l \alpha_i \langle \phi(x_i), \phi(x) \rangle_H + b \right) \quad (2.30)$$

biçimindedir. Şekil 4.4' te giriş uzayı $X = \mathbb{R}^2$ ' de elipsoidal ayırma fonksiyonu, yeni öznitelik uzayındaki ($H = \mathbb{R}^3$) aşırı düzlemine göre eşleştirildiğinde;

$$\begin{aligned} \phi: \quad \mathbb{R}^2 &\rightarrow \mathbb{R}^3 \\ (x_1, x_2) &\text{ a } (z_1, z_2, z_3) = (x_1^2, x_2^2, \sqrt{2}x_1x_2) \end{aligned} \quad (2.31)$$

biçimine gelir.

Bununla birlikte, eğitim kümesindeki vektörlerin daha yüksek boyutlu uzaya dönüştürülmesinde bazı sayısal problemler meydana gelir. Yeni yüksek boyutlu öznitelik uzayı, eğitim vektörü x_i ' lere karşılık gelen $\phi(x_i)$ öznitelik vektörlerinin ifade edilmesini hafıza ve zaman bakımından çok zahmetli kılar. Ayrıca, dönüştürülen veriyi lineer olarak ayıran ϕ dönüşümünün bulunması çok zor olabilir.

Dikkat edilirse önceden bahsedilen amaç fonksiyon ve aşırı düzlemin tanımı vektörler arasındaki iç çarpıma bağlıdır. Eğer, x_i ' den dönüştürülmüş $\phi(x_i)$ öznitelik vektörleri arasındaki iç çarpımlarını, $\phi(x_i)$ ' yi gerçekten düşünmeden hesaplamamıza izin verecek bir fonksiyon bulunursa, hesap karmaşıklığı büyük ölçüde giderilebilir. Böyle bir fonksiyon Kernel Fonksiyonu ile gerçekleştirilebilir ve kernel fonksiyonu;

$$K(x_i, x_j) \equiv \phi(x_i)^T \phi(x_j) \quad (2.32)$$

biçimindedir (VANSCHOENWINKEL ve MANDERICK, 2005). Araştırmacılar tarafından yeni kernel çeşitleri geliştirilmesine rağmen, literatürde ve bir çok SVM kitabında bulunan dört temel kernel Çizelge 2.1' de gösterilmektedir:

Çizelge 2.1. Dört temel Kernel Tipi ve Fonksiyonları

KERNEL TİPİ	FONKSİYON
Lineer	$K(x_i, x_j) = x_i^T x_j$
Polinomial	$K(x_i, x_j) = (\gamma x_i^T x_j + r)^d, \gamma > 0$
Radial Basis Function (RBF)	$K(x_i, x_j) = \exp(-\gamma \ x_i - x_j\ ^2), \gamma > 0$
Sigmoid	$K(x_i, x_j) = \tanh(\gamma x_i^T x_j + r)$

2.2.3 Çoklu Sınıflandırma İçin SVM Uygulaması

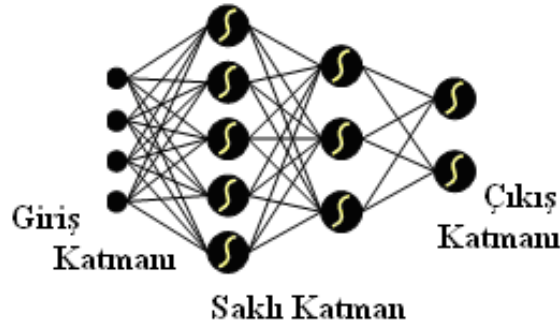
Destek vektör makineleri aslında ikili sınıflandırma için tasarlanmışlardır. Bunların etkin bir şekilde çoklu sınıflandırma için kullanılabilmesi hala devam eden bir araştırma konusudur. Buradan çoklu sınıflandırma problemlerinin (sınıf sayısı k olmak üzere $k > 2$) SVM kullanılarak çözülmesinde genel olarak 3 metot vardır:

- **Multi-Class Ranking SVM (Çoklu Sınıflandırma):** Bu yaklaşımda tüm sınıfların sınıflandırılması için tek bir SVM karar fonksiyonu vardır.
- **One-Against-Rest (One-Vs-Rest) Classification (Bir Sınıfın Diğerlerinden Ayrılması):** Bu yaklaşım k tane ikili sınıflandırıcının düzenlenmesine göre çalışır. i ' nci sınıflandırıcı, i ' nci sınıftaki pozitif etiketli tüm örnekler ile negatif etiketli diğer tüm örneklerle eğitilir. Final çıkışı, en yüksek değerli sınıflandırıcıya karşılık gelen sınıftır (Winner Takes All).
- **One-Against-One (One-Vs-One) Classification (Bir Sınıfın Diğer Bir Sınıftan Ayrılması):** Bu yaklaşım k sınıfın eğitim setinden olabilecek tüm ikili sınıflandırıcıları düzenler. Dolayısıyla k sınıfın ikili kombinasyonu şeklinde $\binom{k}{2} = \frac{k(k-1)}{2}$ tane sınıflandırıcı oluşacaktır. Final çıkışında ise her sınıflandırıcı tercih ettiği sınıf için bir oy verir ve en çok oy alan sınıfa göre çıkış belirlenir (Voting).

2.2.4 Çok Katmanlı Algılayıcı (MLP)

Çok katmanlı algılayıcı (MLP) sınıflandırıcısı birden fazla katmana (layers) sahip olan ve genellikle ileri yönlü (feed-forward) bağlantıya sahip olan bir Yapay Sinir Ağı (YSA) türüdür. YSA, genel anlamda beynin bir işlevini yerine


getirme yöntemini modellemek için tasarlanan bir sistem olarak tanımlanabilir. MLP YSA türleri içerisinde en çok kullanılanıdır. MLP hem basit hem de sağlam bir matematik temele dayanmaktadır. Şekil-4.5'de giriş, saklı katmanlar ve çıkış katmanından oluşturulmuş bir MLP yapısı gösterilmektedir.




Şekil 2.18. Giriş, gizli ve çıkış katmanlarından oluşan MLP

Giriş katmanı; giriş veri gruplarının ağına sunulduğu katmandır. Bu katmanda nöron sayısı, giriş veri sayısı kadardır ve her bir giriş nöronu bir veri alır. Burada veri işlenmeden bir sonraki katman olan gizli katmana geçer. Gizli katman; ağın temel işlevini gören katmandır. Bazı uygulamalarda ağda birden fazla gizli katman bulunabilir. Şekildeki MLP yapısı 2 gizli katmandan teşekküldür. Gizli katman sayısı ve katmandaki nöron sayısı, probleme göre değişir, herhangi bir şekilde bir sabit sayıya sahip değildir. Bu katman; giriş katmanından aldığı ağırlıklandırılmış veriyi probleme uygun bir fonksiyonla işleyerek bir sonraki katmana iletir(70). Bu katmanda gereğinden az nöron kullanılması giriş verilerine göre daha az hassas çıkış elde edilmesine sebep olur. Aynı şekilde gerektiğinden daha çok sayıda nöron kullanılması durumunda da aynı ağda yeni tip veri gruplarının işlenmesinde zorluklar ortaya çıkar. Çıkış katmanı gizli katmandan aldığı veriyi ağın kullandığı fonksiyonla işleyerek çıktısını verir. Çıkış katmanındaki nöron sayısı, ağına sunulan her verinin çıkış sayısı kadardır. Bu katmandan elde edilen değerler yapay sinir ağının söz konusu problem için çıkış değerleridir. MLP temel olarak, ağırlıklandırılmış şekilde birbirlerine bağlanmış birçok işlem

elemanlarından (nöronlar) oluşan matematiksel sistem olarak da ifade edebiliriz. Şekil-4.6'da matematiksel model olarak basit bir tek katman yapay sinir ağı gösterilmiştir.



Şekil 2.19. n adet girişli nöronun matematiksel gösterimi



Şekil 2.20. Sigmoid fonksiyonu

“x” giriş değerlerini “w” nöronlar arası ağırlıkları, toplam işareti olan kısım ise nöronu ifade etmektedir. Giriş değerleri ağırlıklar ile çarpılır ve nörona gönderilir. Nörona gelen bu değerler nöron içinde toplanır ve aktivasyon fonksiyonu kullanılarak bir çıkış değeri elde edilir. Aktivasyon fonksiyonu olarak genellikle sigmoid fonksiyonu ve türevleri kullanılır.

Bu çalışmada karmaşık verilerin sınıflandırılmasında kullanılan etkin YSA modellerinden birisi olan; ilk olarak Werbos tarafından düzenlenen daha sonra Parker, Rummelhart ve McClelland tarafından geliştirilen geri yayılım ağı kullanılmıştır.

Geri yayılım algoritması birçok uygulamalarda kullanılmış en yaygın öğrenme algoritmasıdır. Anlaşılması kolay ve tercih edilen öğretim algoritmasıdır. Bu algoritma; hataları geriye doğru çıkıştan girişe azaltmaya çalışmasından dolayı geri yayılım ismini almıştır. Geri yayımlı öğrenme kuralı ağ çıkışındaki mevcut hata düzeyine göre her bir tabakadaki ağırlıkları yeniden hesaplamak için kullanılmaktadır.

$$E = \frac{1}{2} \sum_s^N \sum_o^L (t_o^{(s)} - x_o^{(s)})^2 \quad (2.33)$$

Burada N veri kümesindeki örnek sayısı L ise çıkış nöronu sayısını göstermektedir t_o ise verilen eğitim kümesidir. Hatayı küçültmek için nöronlar arasındaki ağırlıklar, ağ çıkışındaki mevcut hata düzeyine göre değiştirilir.

Hatayı geriye yayılım algoritmasına göre; her nöron arasındaki bağlantının ağırlığı aşağıda belirtildiği gibi değiştirilerek hata (E) küçültülmeye çalışılır. Bu işlem ağırlıkların en uygun değeri bulunana kadar devam ettirilir.

$$\Delta w_{ho} = -\eta \frac{\partial E}{\partial w_{ho}} = -\eta \delta_o x_h \quad (2.34)$$

$$\Delta w_{ih} = -\eta \frac{\partial E}{\partial w_{ih}} = -\eta \delta_h x_i \quad (2.35)$$


Bu denklemlerdeki E, denklem 4.22'te tanımlanan hata fonksiyonudur. Giriş değerleri ağırlıklar ile çarpılır ve nörona gönderilir. Bu matematiksel işlemler denklem (2.36) deki gibi ifade edilir.

$$y = f\left(\sum w_i * x_i\right) \quad (2.36)$$

Denklem(4.25)'de “ f ” aktivasyon fonksiyonudur. Aktivasyon fonksiyonu olarak “tansig” kullanılmıştır. Eğitim algoritması olarak adaptif öğrenme ve momentuma sahip geri yayılım algoritması kullanılmıştır. Adaptif eğitim algoritmasının en büyük özelliği adaptif bir yapıya sahip olması ve yapay sinir ağının öğrenme parametrelerini o anki öğrenme koşullarına göre otomatik olarak değiştirmesidir. Adaptif eğitim algoritması gradientin azalan momentumuna göre ağırlıkları, biası ve öğrenme oranını adaptif olarak değiştirmektedir.

4.5 Radyal Tabanlı Fonksiyon (RBF) Ağı

Radyal tabanlı fonksiyon ağları çok boyutlu uzayda eğri uydurma yaklaşımıdır. RBF'nin eğitimi ise , çok boyutlu uzayda eğitim verilerine en uygun bir yüzeyi bulma problemi şeklinde tanımlana bilir RBF sınıflandırıcılarında temel fikir, bir grup radyal taban fonksiyonu istenen f fonksiyonuna yaklaşacak şekilde ağırlıklandırarak toplamaktan ibarettir. Şekil–2.21'de Radyal tabanlı fonksiyon ağının yapısı gösterilmiştir (Hacıoğlu, 2006).



Şekil 2.21. Radyal tabanlı fonksiyon ağının yapısı

RBF giriş, çıkış ve gizli katman olmak üzere üç katmanlı bir yapıdan oluşmaktadır. Giriş katmanı giriş vektör uzayına bağlantılı olan katmandır. Çıkış katmanı ise örüntü sınıfı yani tanımlanacak olan gruplar ile ilişkili olan katmandır. Buradaki giriş ve çıkış katmanını birbirine bağlayan gizli katmandaki ağırlıkların belirlenmesi ile sınıflandırıcı elde edilmiş olur (Bolat, 2005).


Gizli katmandaki nöronların aktivasyon fonksiyonları bir C_j merkezi ve σ_j bant genişliği ile belirlenir. Aktivasyon fonksiyonu,

$$\varphi_j(X) = \exp\left(-\frac{\|X - C_j\|^2}{2\sigma_j^2}\right) \quad (2.37)$$

eşitliği ile tanımlanan bir Gauss eğrisidir. Çıkış katmanındaki j . nöronun çıkışı için genel eşitlik ise denklem(2.38)' de verilmiştir.

$$s_j(X) = \sum_{i=1}^K w_{ij} \varphi_i(X) + b_j \quad (2.38)$$

Burada w_{ij} gizli nöron i ve çıkış nöronu j arasındaki ağırlık katsayısıdır.



Şekil 2.22. Girdi, gizli ve çıktı katmanından oluşan RBF sınıflandırıcısı

Mimarisi Şekil -4.9'de gösterilen RBF'da, m adet örnek içeren eğitim seti ve her örnekteki n adet parametreden oluşan girdi verilerine bağlı olarak,

$$u_i^k = \sum_{j=1}^n (x_j^k - x_j^i) \quad (i=1,m \text{ ve } k=1,m) \quad (2.39)$$

$$h_i^k = \phi(u_i^k) \quad (2.40)$$

$$[h]\{w\} = \{f\} \quad (2.41)$$

denklemleriyle, her bir girdi grubu için önce m adet radyal taban (h) ve sonra çıktı değerlerine (f) bağlı olarak, gizli katman ile çıktı katmanı arasındaki ağırlıklar w_j hesaplanır. Eğitim setindeki m adet örneğin tamamı radyal merkez olarak kullanıldığında, (h) matrisi $m \times m$ boyutunda kare matris olur. Burada (2.39-2.41) denklemlerindeki ϕ radyal fonksiyondur ve değişik şekillerde tanımlanmaktadır. Bu çalışmada yapılacak uygulamalarda Gauss formunda

$$\phi(u) = e^{-\frac{u}{rs}} \quad (2.42)$$

Ve kuadratik formda

$$\phi(u) = \frac{1}{\sqrt{rk^2 + u}} \quad (2.43)$$

bağıntıları kullanılacaktır (rs ve rk kullanıcının belirlediği reel sayılardır). Eğitim sonunda (2.41) denklemiyle w_j ağırlıkları belirlendikten sonra, bağıntısı ile herhangi bir x girdisi için, denklem(2.39) ve denklem(2.40) ile u ve h değerleri, hesaplandıktan sonra $f(x)$ çıktısı tahmin edilir.

$$y = f\left(\sum w_j * h_j\right) \quad (2.44)$$

2.2.5 Eğitim Verilerinin Temin Edilmesi

Uygulamanın gerçekleştirilmesinde kullandığımız eğitim verilerinin temininde Google™ firmasının bir ürünü olan *Google Eath™* uygulaması kullanılmıştır. Bu uygulama sayesinde özellikle Amerika ve Avrupa'daki hava limanlarındaki

uçaklar aranmıştır. Özellikle eğitim için kullanılan verilerde doğal uçak resimlerinin yanında gürültüden arındırılmış yapay uçak resimleri de kullanılmıştır böylece eğitim sonuçlarında daha kararlı eğitim parametrelerinin elde edilmesi amaçlanmıştır.

2.2.6 Eğitim

Verilerin SVM ile eğitilmesinde, dünyanın birçok yerinde bulunan havaalanlarındaki aynı uzunluktaki uçaklar kullanılmıştır. Yapılan uygulamada alınan uydu görüntüleri özellikle üstten görünüşleri aynı 72 ve 68 metre uzunluğundaki iki uçak verisi toplanmıştır. Toplanan bu uçak verileri ile eğitim işlemi gerçekleştirilmiştir.

Eğitim işlemi için 50 adet uçağa ait resimler ile 450 adet uçak olmayan resim eğitim işlemine sokulmuştur. Bu eğitim işlemine giriş olarak verilen resimler gabor filtre işleminden hemen önceki adımda 40x40 formatına indirgenir. İndirgeme işleminden sonra gabor filtresi ile öznitelik vektörü elde edilen resim eğitim işlemine gönderilir. Eğitim işleminde uçağa ait olan resimler pozitif (1), uçağa ait olmayan resimler ise negatif (-1) sonuca göre eğitimlerini gerçekleştirilirler

2.2.7 Sınıflandırma


Sınıflandırma işlemi için eğitim sonucunda elde edilen eğitim verileri çok önemlidir. Bu değerler sayesinde sınıflandırma algoritması gerekli olan parametreler ile yüklenir ve karar mekanizmasında önemli rol oynar.

Sınıflandırma işleminde resim içerisinde gezdirilen çerçeve içerisinde uçak olduğunu varsayarak boyut indirgeme ve öznitelik çıkarma işlemine tabi tutulur. Bu işlemin sonucunda elde edilen öznitelik vektörü eğitilmiş olan SVM verileri ile karar işlemine sokulur. Bu işlem sonucunda uygulama geri dönüş değeri olarak pozitif (+1) veya negatif (-1) bir değer ile döner. Bu değer elimizdeki çerçevenin uçak olup olmadığının bir göstergesidir.

2.2.8 K – En Yakın Komşuluk Algoritması

k-NN sınıflandırıcı (k-Nearest Neighbor – k-NN), bir örnek tabanlı öğrenme algoritması olup, gözlem çiftlerinin Öklidyen uzaklık gibi bir fonksiyonuna ayarlıdır. Bu sınıflandırma örneğinde, önce eğitim kümesinin k yakın komşuları hesaplanır. Sonra test verisinden, bir örneğin k en yakın komşuluklarına olan benzerlikler, komşulukların sınıflarına göre kümelenir ve test örneği en benzer sınıfa atanır. k-NN' in avantajı, sınıflandırma kararının benzer nesnelerin küçük komşuluklarına dayalı olmasından ötürü, çoklu sınıflar için uygun olmasıdır. Buradan hedef sınıfı çoklu (örneğin, içerdiği nesnelerin bağımsız değişkenleri farklı altkümeler için farklı karakteristiklere sahip) ise k-NN doğruluğunu yine de devam ettirir. k-NN' de kullanılan benzer değerlerin en büyük dezavantajı, tüm öznitelikleri eşit hesaplama benzerlikleri içinde kullanmasıdır. Bu, sınıflandırma için sadece küçük bir öznitelik kümesi faydalı iken, zayıf ölçümler ve sınıflandırma hatalarına neden olur.

Genel olarak en iyi k parametresinin seçimi veriye bağlı olup k ' nın büyük değerleri sınıflandırma üzerindeki gürültüyü azaltır, fakat sınıflar arasındaki sınırların belirginliğini en aza indirir. İyi bir k değerinin seçimi, çapraz geçerlilik (cross-validation) gibi bir teknikle gerçekleştirilebilir. Şekil 2.5 k-NN sınıflandırma örneği Şekil 2.23' te gösterilen k-NN sınıflandırma örneğine göre test örneği (yeşil daire), Sınıf1 (mavi kareler) veya Sınıf2 (kırmızı üçgenler)' den birine sınıflandırılmalıdır.



Şekil 2.23. k-NN sınıflandırma örneği

Eğer $k = 3$ ise yeşil daire Sınıf2' ye sınıflandırılır. Çünkü içteki dairenin içinde 2 tane üçgen ve sadece 1 tane kare bulunmaktadır. Eğer $k = 5$ ise yeşil daire Sınıf1' e sınıflandırılır. Çünkü dıştaki dairenin içinde 3 tane kare, 2 tane üçgen var. Bir sınıfın en yakın eğitim örneğinin sınıfı olarak tahmin edildiği özel durum ($k = 1$ olduğu durum) en yakın komşuluk algoritması olarak bilinir. k-NN algoritmasının doğruluğu, gürültülü ve ilgisiz özniteliklerin bulunmasından veya özniteliklerin önemlerine uygun bir şekilde ölçeklendirilmemesinden dolayı ciddi miktarda düşebilir

3. SONUÇ VERİLERİ VE TARTIŞMA

Uydu görüntüleri kullanılarak yer yüzeyinde konuşlanmış uçakların tanınması uygulaması için bir deney yapılmıştır. Yapılan deneyde daha önce de açıkladığımız gabor filtresi ile SVM (Destek Vektör Makineleri) sınıflandırma yöntemleri kullanılmıştır.

Yapılan deneyler *Microsoft™* firmasının *Visual Studio 2008* programlama arabirimi yardımıyla, görüntü işleme kütüphanesi olan *OpenCV* kullanılarak yapılmıştır. Donanım olarak incelediğimizde ise deneylerin yapıldığı bilgisayar *Intel Core 2 Duo, 3GB ram*'li bir bilgisayar üzerinde gerçekleştirilmiştir.

3.1 Veri Setlerinin Temin Edilmesi

Yapılan bu uygulama için hazır bir veri seti veya imge veritabanı bulunmamaktadır. Bu nedenden dolayı veriler *Google Earth* programı yardımıyla havaalanlarındaki görüntüler araştırılarak temin edilmiştir. Verilerin temini sırasında uçakların etrafında oluşan, gürültü sayılabilecek nesnelerin az olmasına, temin edilen uçakların açık renkte ve buldukları zeminin koyu renkte olmasına özen gösterilmiştir. Bu ölçütler sağlıklı veriler ile başarılı bir sonuç elde etmek amacıyla belirlenmiştir. Şekil 3.1 ve 3.2 de eğitim işlemi sırasında kullanılan veri setlerinden bazıları görülmektedir.

3.2 Ön işlemler

Bu uygulama özneteliğin hesaplanmasından önce gerçekleştirilen iki tane ön işlem adımı vardır.

- Resim gri skalaya çevirilir
- Boyut indirgeme işlemine tabi tutulur.

Uygulamada kullanılan her imgenin kaç tane renk matrisi olduğu kontrol edilir ve skalası birden fazla olan imgelerde gri skalaya çevirme işlemi gerçekleştirilir.

Normal pencere (veya maske) boyutları kullanılarak uygulama gerçekleştirilecek olsaydı, uygulamanın üzerindeki işlem yükü çok fazla olacağından bu verilerin boyu makul bir boyuta indirgenir. İndirgeme işleminde ihtiyacımız olan anlamlı verilere zarar vermeyecek şekilde bir boyut indirgemesi gerçekleştirilir.


3.3 Yapılan Uygulamanın Gerçekleştirilmesi

Uygulama için yapılan işlemler 4 adımda gerçekleştirilmiştir. Bu işlemleri sırasıyla açıklayacağız.


Adım 1: Veri Setlerinin hazırlanması

Uygulama için gerekli olan veriler daha önce de belirttiğimiz gibi Google Earth uygulaması ile toplanmıştır. Bu uygulamanın kullanılmasına karar verilmeden önce dünya da bu amaçla kullanılan birçok uygulama denendi ve en uygun sonucu *Google Earth* vermiştir. Bu yolla havaalanlarındaki uçaklar incelenerek 120 adet uçak resmi elde edilmiştir. Bu uçak resimlerinden uygun olan 50 resim seçilmiş ve bu resimlerin yanında uçağa ait olmayan 450 adet resim eğitim verisi olarak kullanmak amacıyla temin edilmiştir.

Uygulama gerçekleştirilirken bu resimler gri skalada ve 40x40 boyutlarına indirgenmiş bir şekilde işleme sokulurlar. Boyutlandırma işleminin amacı sistem üzerinde bulunan aşırı işlem yükünü en az derecede azaltmak ve bununla beraber yapılan tarama işleminin süresini makul düzeye indirmektir.



Şekil 3.1. Eğitim için kullanılan uçak resimleri




Şekil 3.2. uçağa ait olmayan eğitim resimleri

Adım 2: Özniteliklerin elde edilmesi

Uçağa ait verilerin elde edilmesinden sonra uçak resimlerinden uçağa ait özniteliklerin temin edilmesi için Gabor filtreleri kullanılır. Kullanılan bu gabor çıktıları toplanarak tek boyutlu bir öznitelik vektörü elde edilir.

Elde edilen bu öznitelik vektörü SVM için giriş verisini oluşturmaktadır. Öznitelik vektörü elde edilirken Gabor filtresinin farklı açısai değerlerinin toplamı ile birlikte hesaplanır. Böylelikle elde edilen veriler uçağa ait daha çok öznitelik içereceğinden eğitim işleminde elde edilen sonuçların daha kararlı sonuçlar vermesi amaçlanmıştır. Bu itibarla işleme alınan her çerçevede sırasıyla 0, 45, 90, 135 derecelik yönelimlerle Gabor değerleri hesaplanır.



Şekil 3.3. Farklı yönlerdeki uçakların gabor çıktıları

Bu işlemle elde edilen değerler sırasıyla birbirlerine eklenerek bir öznitelik vektörü elde edilir. Elde edilen bu öznitelik vektörünün belirlenmiş bir değerler aralığına normalize edilmesi sonucun kararlılığı açısından da önemlidir.

Gabor filtresinden elde edilen veriler ile sınıflandırma işlemine girmeden önce verilerin ölçeklendirilmesi sınıflandırma sonucunda elde edilen eğitim parametrelerini doğrudan etkiler. Gabor çıktıları sonucunda elde edilen dizilerin sayıların en yüksek ve en düşük değerlerindeki değişkenlik arz edebilir. Bu nedenle verilerin sınıflandırma ve eğitim işlemlerinin öncesinde ölçeklenmesi gerekmektedir. Sarle(30) herhangi bir sınıflandırıcı kullanılırken neden ölçeklendirme yapılması gerektiğini açıklamıştır.

Ölçeklendirme yapılmasının en büyük avantajı, öznitelikleri daha küçük sayısal değer aralığına indirgeyerek çok büyük sayısal aralıklardan

kaçınmaktadır. Diğer bir avantaj ise hesaplamalar boyunca meydana gelen sayısal zorluklardan kurtulmaktır. Çünkü kernel değerleri genellikle öznitelik vektörlerinin iç çarpımlarına bağlıdır ve büyük öznitelik değerleri sayısal problemler doğurabilir. Hsu vd.(32), öznitelik değerlerinin $[-1, +1]$ veya $[0, +1]$ aralığına gelecek biçimde ölçeklendirilmesini önermektedir.

Yapılan çalışmada veri kümesi $[0, +1]$ aralığına ölçeklendirilmiş ve bu işlem;

$$\vec{X}(i) = \left[\frac{X(i) - \min A}{\max A - \min A} \right] (\text{yeni_max } A - \text{yeni_min } A) + \text{yeni_min } A \quad (3.1)$$

formülasyonu ile gerçekleştirilmiştir. O halde N öznitelik sayısını göstermek üzere, A veri setinde bulunan her bir X(i) özniteliği $[0,+1]$ aralığına ölçeklendirilmiş olur.

Öznitelik çıkartma işleminin adımları aşağıdaki gibi maddeler halinde açıklayabiliriz,

- Belirlenmiş çerçeve boyutlarındaki imge alınır.
- 0 Derece yönelimli Gabor filtresi elde edilir
- 45 Derece yönelimli Gabor filtresi elde edilir
- 90 Derece yönelimli Gabor filtresi elde edilir
- 135 Derece yönelimli Gabor filtresi elde edilir
- Elde edilen Gabor çıktıları birleştirilir.
- Elde edilen öznitelik verisi $[0, 1]$ aralığına normalize edilir.

Böylelikle eğitim ve sınıflandırma işlemlerinde kullanılacak olan öznitelik verisi elde edilmiş olur.

Aşağıdaki *pseudo* kod örneği resim içinde verilerin özniteliklerinin çıkartılması ve eğitilmesi işlemini genel olarak açıklamaktadır.

BEGIN

İmgeyi yükle

İmgeye 0 derece Gabor uygula

İmgeye 45 derece Gabor uygula

İmgeye 90 derece Gabor uygula

İmgeye 135 derece Gabor uygula

4 x imge boyutunda bir başka imge oluştur.

Sırayla 0, 45, 90, 135 gabor çıktılarını uç uca ekle

Elde edilmiş olan veriyi [0,1] aralığında ölçeklendir

END

Adım 3: Verilerin Eğitilmesi

İşlem yapılan imgenin öznitelik vektörü elde edildikten sonra eğitim işlemine sokulması ve uçaklara ait sınıflandırma parametrelerinin elde edilmesi gerekmektedir. Yeterli sayıda uçağa ait olan ve olmayan öznitelik vektörleri kullanılarak eğitim işleminin yapılması gerekmektedir. Böylelikle uçaklara ait SVM sınıflandırma parametreleri elde edilmiş olacaktır

Hazırlanmış olan eğitim verileri için uçağa ait olan verilerde eğitim sonucu +1 değerine ve negatif olan veriler için ise eğitim sonucu -1 değerine ayarlanmıştır. Bu değerler ile birlikte eğitim işleminin sonlandırılma kistası da önemlidir. Yapmış olduğumuz uygulamada %1 yakınsaklığa ulaşıldığında veya 100000 iterasyon'dan sonra eğitim kendini sonlandırır ve elde ettiği parametreler değerli olarak kabul edilir ve sınıflandırma işleminde kullanılmak üzere veriler kaydedilir. Sınıflandırma işleminde bu veriler kullanılarak incelenen çerçeveler içerisinde uçaklar ile ilgili önemli değerler elde edilecektir.

Eđitimler sırasında SVM için gerekli olan C ve γ deęerleri için en uygun deęerlerin bulunması amacıyla apraz geerlilik teknięi uygulanmaya alıřılmıştır. *v-fold* apraz geerlilik teknięinde eđitim kumesi *v* tane eřit boyuttaki alt kumeye blnr. Bu kmeler sırasıyla dięer alt kmeler zerinde elde edilen sınıflandırıcı kullanılarak test edilir. Bu iřlemde tn eđitim kmelerinin mesafeleri tahmin edilir. Bylece apraz geerlilik doęruluęu, doęru bir biimde sınıflandırılan verinin yzdesel oranı olacaktır.

Veri setinin eđitilmesi ile ilgili ařaęıdaki adımlar uygulanmaktadır.

- Uaklara ait olan resimler gruplandırılır.
- Uaklara ait olan resimler gruplandırılır.
- apraz doęrulama ile en iyi SVM parametreleri bulunur.
- Elde edilen veriler sınıflandırma iřlemi için kaydedilir.

Ařaęıdaki *pseudo* kod rneęi resim ierinde verilerin zniteliklerinin ıkartılması ve eđitilmesi iřlemini genel olarak aıklamaktadır.

BEGIN

.....

FOR i = 1'den veritabanındaki toplam uak resim sayısı kadar

i .nci resmi ykle,

0, 45, 90, 135 dereceli Gabor deęerlerini elde et,

Verileri [0,1] aralıęına normalize et ve znitelik vektrn ıkart,

Eđitim setinin i nci sırasına ekle,

END

FOR j = 1'den veritabanındaki toplam uak olmayan resim sayısı kadar

j .nci resmi ykle,

0, 45, 90, 135 dereceli Gabor deęerlerini elde et,

Verileri [0,1] aralıęına normalize et ve znitelik vektrn ıkart,

Eđitim setinin (maksimum uak resmi sayısı + j) nci sırasına ekle,

END

Eđitim iin gerekli olan C deęerini hesapla

Eđitim iin gerekli olan γ deęerini hesapla

Verileri 0.1 yakınsaklık veya 10000 iterasyona kadar SVM iřlemine uygula

Elde edilen parametreleri .xml veya .conf dosyası olarak kaydet.

.....

END

Adım 4: erevenin Resim İerisinde Gezdirilmesi ve Uaęın Bulunması

Sınıflandırma iřlemine gemeden nce uaęın uydu fotoęrafı zerinde gezdirilebilir ve gezilen her alanda uak olduęu varsayılarak znelik ıkartma iřlemi gerekleřtirilir. Bu iřlem gerekleřtirilirken uaęın tek bir ynde olduęu deęil, her ynde olabileceęi varsayılır ve ereve belirlenmiř bir aı deęeri ile adım bir tam turu tamamlayana kadar dndrlr. Her adımda znelik ıkartma ve sınıflandırma iřlemi gerekleřtirilir. Bu iřlemlerde ıkan sonular uak ile ilgili bilgi tařımaktadırlar.

İki adet yeryz fotoęrafından uak objeleri bulunmaya alıřılmıř 0 ve 90 derecelik aılara gelindięinde sınıflandırma iřlemi sonucu olumlu cevap vermektedir. Uaęın geometrisinden dolayı zellikle 90 dereceye denk gelen durumlarda da sınıflandırma iřlemi pozitif sonu vermektedir. Bu nedenle Kullanılan SVM parametrelerinin iyileřtirilmesi uygulama sonucunun bařarımını artıracaktır.

Ařaęıdaki *pseudo* kod rneęi resim ierinde erevenin gezdirilmesi ve uaęın bulunması iřlemine genel olarak aıklamaktadır.

BEGIN

.....

Çerçeve boyutunu belirle

FOR i = 0'dan başlayarak resmin maksimum yüksekliğine kadar,

FOR ii = 0'dan başlayarak resmin maksimum genişliğine kadar,

i ve ii noktalarında başlayarak çerçeve boyutundaki alan çıkartılır,

çıkartılan alanda GABOR filtresi ile öznelik vektörü çıkartılır

Çıkartılan değer SVM sınıflandırmaya sokulur

IF svm sonuç değeri 1 ise;

Uçak bölgesi olarak tanımlanır ve işaretlenir,

ii = ii + 1,

END,

i = i + 1,

END

.....


END



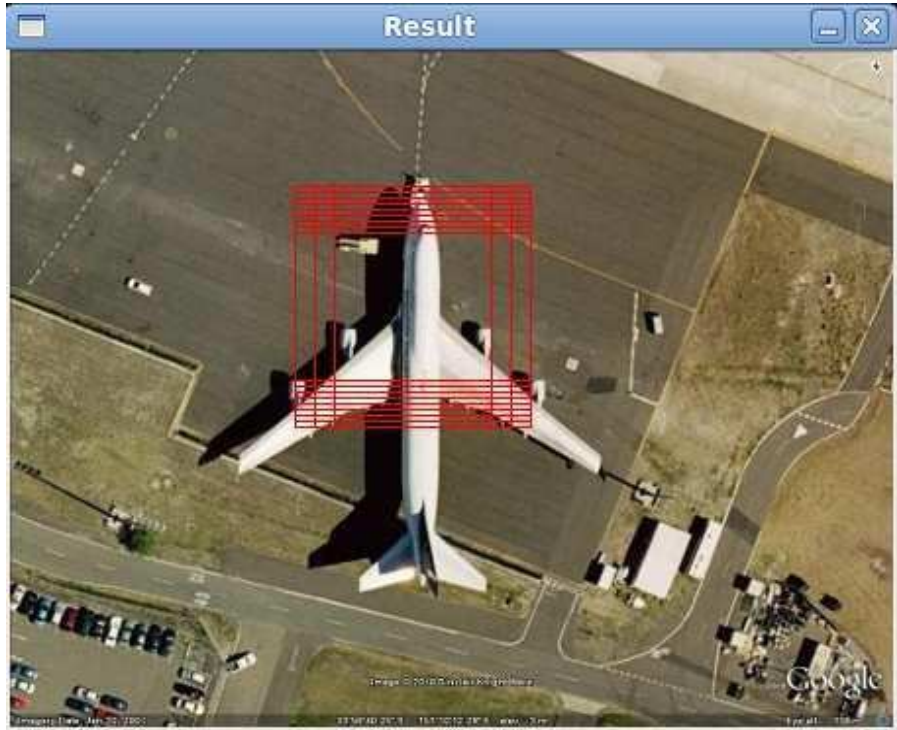
Şekil 3.4. Örnek Uygulama Sonucu -1



Şekil 3.5. Örnek Uygulama Sonucu -2



Şekil 3.6. Örnek Uygulama Sonucu -3



Şekil 3.7. Örnek Uygulama Sonucu -4



Şekil 3.8. Örnek Uygulama Sonucu -5

3.4 Sonuç

Bu çalışmanın sonucunda uydu görüntüleri kullanılarak yeryüzündeki uçaklar bulunmuştur. Şekil 3.3, 3.4, 3.5, 3.6, 3.7 ve 3.8 de yapılan uygulamanın sonucunda elde edilen ekran görüntüsü görülmektedir. Bu uygulamada özneliklerin belirlenmesinde Gabor filtresi kullanılmıştır. Uçakların belirlenmesi için kullanılan sınıflandırma işlemi ise SVM (Destek Vektör Makineleri) kullanılmıştır. Uygulamada uçak verileri toplanarak veri tabanı oluşturulmuştur. Veritabanı ile eğitimler yapılmıştır. Uygulamanın alanında çok fazla çalışma yapılmamış olması önemlidir. Bu uygulamanın başarımını veritabanındaki verilerin çeşitliliği, SVM için kullanılan parametreler ile doğru orantılıdır. Bu itibar ile yapılan uygulamada elde edilen parametrelerin iyileştirilmesi uygulamanın başarısını daha da artıracaktır.

Veritabanı oluşturulurken Dünya üzerinde, özellikle hava trafiğinin yoğun olduğu Amerika Birleşik Devletleri'ndeki havaalanları taranarak belirlenen

kıstaslardaki uçak resimleri bulunmuştur. Alınan resimlerin belirli bir yükseklikten elde edilmiş olmasına özen gösterilmiştir. Ancak programdan elde edilen verilerde farklı koordinatlardan elde edilmiş, aynı yükseklikten çekilmiş resimlerin çözünürlüklerinin aynı kalitede aynı kalitede olmadığı gözlemlenmiştir. Bu itibarla uygulamada aynı yükseklikten alınmış olan gerçek (yazılımsal olarak yakınlaştırılmamış) uydu veya hava aracı resimlerinin kullanılması uygulamanın başarısını artıracaktır.

Bu uygulama ile birlikte, elde edilen istatistiksel veriler ve veriler üzerinde gerçekleşen değişimler ile stratejik karar mekanizmalarının daha sağlam ve başarılı sonuçlar almasında yardımcı olacak gerçek dünya uygulamalarının gerçekleştirilebileceği görülmüştür.

KAYNAKLAR

- (1) Aircraft Recognition online. Wikipedia Public Encyclopedia
http://en.wikipedia.org/wiki/Aircraft_recognition
(ErişimTarihi:28.05.2010)
- (2) Rebollo, M., Escudero F.L., Automatic Classification of Aircraft and Satellite Images Using Mixed Integer Programming, 1975
- (3) Kao-Chin, Chin-Chuan, Jun-Wei, Hsieh, Jian-Ming, Chen, Aircraft Type Recognition in Satellite Images, 2004
- (4) Geman D., Jedynak B., "An Active Testing Model for Tracking Roads in Satellite Images," *IEEE Transactions on Pattern Analysis and Machine Intelligence*. vol. 18, no. 1, pp.1-14, January 1996.
- (5) Shi W., Zhu C., "The line segment match method for extracting road network from high-resolution satellite images," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 40, no. 2, pp.511-514, Feb 2002.
- (6) Greenberg and Guterman J., "Neural-network classifiers for automatic real-world aerial image recognition," *Applied Optics*, vol. 35, no. 23, pp.4598-4608, Aug. 1996.
- (7) Koç D., Türker M., Destek vektör makineleri ile yüksek çözünürlüklü görüntülerden binaların belirlenmesi TMMOB Harita ve Kadastro Mühendisleri Odası Ankara Şubesi I. CBS Günleri Sempozyumu, Ankara, 2008,
- (8) Chen V. C., Evaluation of Bayes, ICA, PCA and SVM Methods for Classification Radar Division, US Naval Research Laboratory, 2004

- (10) Tian Y. L., Kanade T., and Cohn J. F., Facial Expression Analysis. In: Li, S.Z., Jain, A.K. (eds.) Handbook of Face Recognition, Springer Inc., New York, 2005.
- (11) Gabor D., "Theory of communication", Journal of I.E.E. 93,pp 429-441, 1946
- (12) Daugman J.G., Vision Research, 20, pp. 847-856, 1980.
- (13) Daugman J. G., Uncertainty Relation for Resolution in Space, Spatial Frequency and Orientation Optimized by Two-Dimensional Visual Cortical Filters, J. Opt. Soc. Am. A, vol. 2, no. 7, pp. 1160 – 1169,1985.
- (14) Jain A. K., Duin R. P., Mao J., IEEE Trans. Pattern Analysis and Machine Intelligence, 22, 4(2000).
- (15) Gilad-Bachrach R., Navot A., Tishby N., 21st International Conference on Machine Learning (ICML04), 69, 43(2004).
- (16) Cunningham P., Cord M., Cunningham P., Machine Learning Techniques for Multimedia: Case Studies on Organization and Retrieval, Springer Inc., Berlin, 2008.
- (17) Pantic M., Rothkrantz L. J. M., IEEE Trans. on PAMI, 22, 1424(2000).
- (18) Support Vector Machines. Wikipedia Public Encyclopedia http://en.wikipedia.org/wiki/Support_vector_machine (Erişim Tarihi:28.05.2010)
- (19) Boser B. E., Guyon I. M., Vapnik V. N., Proceedings of the 5th annual ACM workshop on Computational Learning Theory, 1, 144(1992).
- (20) Vapnik V. N., Statistical Learning Theory, John Wiley and Sons Inc., New York, 1998.

- (21) Scholkopf B., Smola A. J., Learning with Kernels: Support Vector Machines, Regularization, Optimization, and Beyond, MIT Press, Cambridge, MA, 2002.
- (22) Shawe J., Taylor J., Cristianini N., Kernel Methods for Pattern Analysis, Cambridge University Press, 2004. 73
- (23) Scholkopf B., Burges C., Vapnik V., Proceedings of the First International Conference on Knowledge Discovery & Data Mining, AAAI Press, 1, 252(1995).
- (24) Joachims T., Learning to Classify Text Using Support Vector Machines, Kluwer Academic Publishers, 2002.
- (25) Deniz O., Castrillon M., Hernandez M., Pattern Recognition Lett. 24, 2153(2003).
- (26) Shaoning P., Daijin K., Sung Y. B., Pattern Recognition Lett. 24, 215(2003).
- (27) Littlewort G., Bartlett M. S., Fasel I., Susskind J., Movellan J., Image and Vision Computing, 24, 615(2006).
- (28) Shaoning P., Daijin K., Sung Y. B., Pattern Recognition Lett. 24, 215(2003).
- (29) Vapnik V. N., Statistical Learning Theory, John Wiley and Sons Inc., New York, 1998.
- (30) Güneş T., Görüntü Dizilerinden İnsan Yüz İfade Analizi, Yüksek Lisans Tezi, Kırıkkale, 2009.
- (31) Hsu C. W., Chang C. C. and Lin C. J., A practical guide to support vector classification, Department of Computer Science and Information Engineering, National Taiwan University, 2003.

- (32) Normalization online. Wikipedia Public Encyclopedia
[http://en.wikipedia.org/wiki/Normalization_\(image_processing\)](http://en.wikipedia.org/wiki/Normalization_(image_processing))
- (33) Rifkin R., Klautau A., Journal of Machine Learning Research,
5,141(2004).