

**RADAR HEDEFLERİNİN SINIFLANDIRILMASI İÇİN SAÇICI
MERKEZLERİN KESTİRİMİNDE GENETİK TABANLI
CLEAN ALGORİTMASINA DAYALI KARMA BİR
YAKLAŞIM**

**YÜKSEK LİSANS TEZİ
Müh. Özgür GÜLTEKİN
(705031007)**

**Tezin Enstitüye Verildiği Tarih : 6 Mayıs 2005
Tezin Savunulduğu Tarih : 2 Haziran 2005**

**Tez Danışmanı : Prof.Dr. Tayfun GÜNEL
Diğer Jüri Üyeleri : Prof.Dr. İbrahim AKDUMAN
Prof.Dr. Ercan TOPUZ**

HAZİRAN 2005

ÖNSÖZ

Tezimi hazırlamamda beni değerli zamanından ve bilgilerinden faydalandıran Sayın Prof. Dr. Tayfun Günel'e ve çalışmam boyunca bana yol gösteren Sayın Yrd. Doç. Dr. Işın Erer'e gönülden teşekkür ederim.

Uzun öğrenim hayatım boyunca bana maddi manevi sürekli destek olan aileme de sevgilerimi sunarım.

Mayıs 2005

Özgür Gültekin

İÇİNDEKİLER

KISALTMALAR	v
TABLO LİSTESİ	vi
ŞEKİL LİSTESİ	vii
SEMBOL LİSTESİ	ix
ÖZET	x
SUMMARY	xii
1. GİRİŞ	1
1.1 Bir Boyutlu (Menzil) İşaret İşleme	1
1.2 İki Boyutlu (Doppler) İşaret İşleme	7
1.3 Yüksek Çözünürlüklü Görüntüleme Yöntemleri	12
1.3.1 Model Tabanlı Spektral Kestirim Yöntemleri	12
1.3.1.1 Prony Yöntemi	12
1.3.1.2 MUSIC Yöntemi	15
1.3.1.3 ESPRIT Yöntemi	18
1.3.1.4 Model Derecesi Seçimi	19
1.3.2 İteratif Yöntemler	20
1.3.3 Evrimsel Yöntemler	22
1.4 Hedef Tanıma ve Sınıflandırma Yöntemleri	23
1.4.1 Öznitelik Olarak Saçıncı Merkezler	23
1.4.2 Uyumluluk Derecesi Yöntemi	25
1.4.3 Bayes Sınıflandırması	26
1.4.4 Yapay Sinir Ağları	28
2. EVRİMSEL ALGORİTMALAR VE YAPAY SİNİR AĞLARI	29
2.1 Evrimsel Algoritmalar	29
2.1.1 Genetik Algoritmalar	30
2.1.1.1 Sürekli Genetik Algoritma	32
2.1.2 Evrimsel Programlama	34
2.2 Yapay Sinir Ağları	35
2.2.1 Çok Katmanlı Perseptron Modeli	39
2.2.2 Radyal Tabanlı Ağ Modeli	40
2.2.2.1 Birinci Tipte Radyal Tabanlı Ağlar	41
2.2.2.2 İkinci Tipte Radyal Tabanlı Ağlar	42
3. UYGULAMALAR	44
3.1 Saçıncı Alanların Oluşturulması	44

3.2	Saçıcı Merkez Parametrelerinin Kestirimi	49
3.3	Sınıflandırma Sonuçları	54
4.	SONUÇ VE ÖNERİLER	65
	KAYNAKLAR	68
	ÖZGEÇMİŞ	71

KISALTMALAR

FFT	: Hızlı Fourier Dönüşümü (Fast Fourier Transform)
PSF	: Nokta Dağılım Fonksiyonu (Point Spread Function)
SAR	: Yapay Açıklıklı Radar (Synthetic Aperture Radar)
ISAR	: Ters Yapay Açıklıklı Radar (Inverse Synthetic Aperture Radar)
MUSIC	: Çoklu İşaret Sınıflandırma (Multiple Signal Classification)
ESPRIT	: İşaret Parametrelerinin Dönmesel Değişmezlik İle Kestirimi (Estimation Of Signal Parameters Via Rotational Invariance Technique)
MAP	: En Büyük Sonsal Olasılık (Maximum A Posteriori Probability)
ML	: En Büyük Benzerlik (Maximum Likelihood)
GA	: Genetik Algoritma
İGA	: İkili Genetik Algoritma
SGA	: Sürekli Genetik Algoritma
YSA	: Yapay Sinir Ağları
MLP	: Çok Katmanlı Perseptron (Multilayer Perceptron)
RBF	: Radyal Tabanlı Fonksiyonlar (Radial Basis Functions)
CAD	: Bilgisayar Destekli Tasarım (Computer Aided Design)

TABLO LİSTESİ

Tablo 2.1: Aktivasyon Fonksiyonları.....	38
Tablo 3.1: Saçıcı Parametreleri	50
Tablo 3.2: SGA Parametreleri.....	50
Tablo 3.3: SGA Parametreleri.....	51
Tablo 3.4: Uyumluluk derecesi yöntemi için doğru sınıflandırma yüzdesi P_C (gürültüsüz durum).....	57
Tablo 3.5: Bayes sınıflandırıcısı için doğru sınıflandırma yüzdesi P_C (gürültüsüz durum).....	57
Tablo 3.6: Çok katmanlı perseptron ağı için doğru sınıflandırma yüzdesi P_C (gürültüsüz durum).....	58
Tablo 3.7: Radyal tabanlı ağ için doğru sınıflandırma yüzdesi P_C (gürültüsüz durum).....	59
Tablo 3.8: Uyumluluk derecesi yöntemi için doğru sınıflandırma yüzdesi P_C (gürültülü durum).....	61
Tablo 3.9: Bayes sınıflandırıcısı için doğru sınıflandırma yüzdesi P_C (gürültülü durum).....	61
Tablo 3.10: Çok katmanlı perseptron ağı için doğru sınıflandırma yüzdesi P_C (gürültülü durum).....	62
Tablo 3.11: Radyal tabanlı ağ için doğru sınıflandırma yüzdesi P_C (gürültülü durum).....	63

ŞEKİL LİSTESİ

Şekil 1.1 :	Bir boyutlu görüntüleme için sistem geometrisi	2
Şekil 1.2 :	İdeal menzil fonksiyonunun gösterilimi	3
Şekil 1.3 :	İki boyutlu görüntüleme için sistem geometrisi	8
Şekil 1.4 :	Spotlight SAR için nokta hedef modeli	9
Şekil 1.5 :	Basamaklı frekans modeliyle görüntü oluşturulması	13
Şekil 1.6 :	ESPRIT yöntemi için blok diyagramı	18
Şekil 1.7 :	CLEAN algoritması akış şeması	21
Şekil 1.8 :	Evrimsel tabanlı CLEAN algoritması akış şeması	22
Şekil 1.9 :	FFT başlangıç koşullu evrimsel tabanlı CLEAN algoritması akış şeması	23
Şekil 2.1:	SGA akış şeması	33
Şekil 2.2:	McCulloch ve Pitts Nöron Modeli	37
Şekil 2.3:	Aktivasyon fonksiyonları	38
Şekil 2.4:	Çok katmanlı perseptron yapısı	39
Şekil 2.5:	Radyal tabanlı aktivasyon fonksiyonları	40
Şekil 2.6:	Radyal tabanlı ağ örneği	41
Şekil 3.1:	Uçak modelleri (Tel kafes)	45
Şekil 3.2:	Uçak modelleri (Katı cisim)	46
Şekil 3.3:	Saçıcıların konumsal dağılımı	47
Şekil 3.4:	Saçıcıların 128*128 piksel boyutunda konumsal dağılımı	48
Şekil 3.5:	SGA-CLEAN ile kestirilen saçıcı parametreleri	51
Şekil 3.6:	FFT başlangıç koşullu SGA-CLEAN ile kestirilen saçıcı parametreleri	52
Şekil 3.7:	SGA-CLEAN ile kestirilen saçıcı parametreleri	52
Şekil 3.8:	F-14 uçağının 0° açısındaki menzil profili ve FFT başlangıç SGA-CLEAN algoritması ile kestirilen saçıcı parametreleri (gürültüsüz durum)	53
Şekil 3.9:	F-14 uçağının 0° açısındaki menzil profili ve FFT başlangıç SGA-CLEAN algoritması ile kestirilen saçıcı parametreleri (gürültülü durum) ..	54
Şekil 3.10:	F-14 uçağının 0° açısındaki menzil profili ile hedefler arasındaki uyumluluk değerleri sonuçları (gürültüsüz durum)	55
Şekil 3.11:	F-14 uçağının 0° açısındaki menzil profili ile hedefler arasındaki uyumluluk değerleri sonuçları (gürültülü durum)	55
Şekil 3.12:	Bayes sınıflandırıcısı için doğru sınıflandırma yüzdesi P_C (gürültüsüz durum)	58
Şekil 3.13:	Çok katmanlı perseptron ağı için doğru sınıflandırma yüzdesi P_C (gürültüsüz durum)	59
Şekil 3.14:	Radyal tabanlı ağ için doğru sınıflandırma yüzdesi P_C (gürültüsüz durum)	60

Şekil 3.15: Bayes sınıflandırıcısı için doğru sınıflandırma yüzdesi P_C (gürültülü durum).....	62
Şekil 3.16: Çok katmanlı perseptron ağı için doğru sınıflandırma yüzdesi P_C (gürültülü durum).....	63
Şekil 3.17: Radyal tabanlı ağ için doğru sınıflandırma yüzdesi P_C (gürültülü durum).....	64

SEMBOL LİSTESİ

P	: Nokta saçıcı sayısı
R₀	: Radar anteninin cisme uzaklığı
B	: Radar işaretinin bant genişliği
f_C	: Radar işaretinin merkez frekansı
λ_C	: Radar işaretinin merkez dalga boyu
θ	: Radar anteninin dönme açısı
M	: Frekans örnek sayısı
N	: Gözlem açısı sayısı
s	: Saçılan alan vektörü
S	: Saçılan alan matrisi
Δ_x	: Menzil çözünürlüğü
Δ_y	: Çapraz menzil çözünürlüğü
x_p	: p. Saçıcının menzil koordinatı
a_p	: p. Saçıcının şiddeti
H	: Hata fonksiyonu
C	: Normalize ilişki katsayısı
f	: Öznitelik vektörü, YSA aktivasyon fonksiyonu
w	: YSA ağırlık katsayıları
P_C	: Doğru sınıflandırma yüzdesi

RADAR HEDEFLERİNİN SINIFLANDIRILMASI İÇİN SAÇICI MERKEZLERİN KESTİRİMİNDE GENETİK TABANLI CLEAN ALGORİTMASINA DAYALI KARMA BİR YAKLAŞIM

ÖZET

Radar görüntüleri, menzil profilleri ve saçıcı merkezler radar hedeflerinin sınıflandırılma uygulamalarında öznitelik parametreleri olarak kullanılmaktadır. Saçıcı merkez parametrelerinin öznitelikler olarak belirlenmesi ile radar görüntüsü ve menzil profillerini temel alan klasik hedef belirleme uygulamalarına göre öznitelik uzayının etkili bir şekilde sıkıştırılması mümkün olmaktadır. Saçıcı merkezlerin öznitelik parametresi olarak belirlendiği sınıflandırma algoritmalarında saçıcı merkezlerin etkin kestirimi karşımıza bir problem olarak ortaya çıkmaktadır.

Saçıcı merkezlerin kestirimi için uygulanabilecek en temel yöntem radar işaretinin ters hızlı Fourier dönüşümü alınarak çıkartılan menzil profilinin istenilen sayıda tepe noktalarının saçıcı merkezler olarak varsayılmasıdır. Ancak menzil profilinin çıkartılmasında kullanılan ters FFT algoritmasının uygulanması sırasında periyodik olmayan radar işaretinin periyodikleştirilme varsayımından dolayı spektral sızıntı meydana gelmektedir. Bu durum nedeniyle güçlü saçıcıların yan lobları da göreceli olarak zayıf saçıcıların yerine yalancı saçıcılar olarak çekilebilmektedir.

Saçıcı merkezlerin yan lobların bastırılarak kestirimi için kullanılan bir yöntem CLEAN algoritmasıdır. CLEAN algoritması saçıcı merkezleri frekans domeni yerine konum domeninde kestirerek frekans domenindeki yan lobların bastırılmasını beraberinde getirir. Her iterasyonda bulunan frekans domeni işareti bir sonraki iterasyon adımı için kullanılır. İterasyon önceden belirlenmiş sayıda saçıcı merkezin kestirilmesi veya önceden belirlenmiş bir eşik enerji seviyesinin altına düşülmesi durumunda sona erer.

Klasik CLEAN algoritması sadece FFT kullanıldığından düşük işlem hızı ve yüksek işlem verimliliğine sahiptir. Algoritmanın dezavantajı ise düşük çözünürlüktür. Yüksek çözünürlük için model temelli spektral kestirim yöntemleri kullanılabilir. Bu

yaklaşımında model derecesinin seçimi büyük önem taşımaktadır. Düşük dereceli bir model spektrumunda bazı tepelerin atlanmasına, yüksek dereceli model ise spektrumda tepelerin ayrılarak yalancı saçıcı merkezlerin oluşmasına neden olur.

Yüksek çözünürlük için evrimsel algoritma teknikleri de kullanılabilir. Bu yöntemler çok sayıda saçıcının yüksek çözünürlükle kestirilmesinde iyi sonuçlar vermektedir. Ancak bu yöntemlerde başlangıç değerlerinin uygun seçilmemesi durumunda işlem verimliliği düşmektedir.

Bu çalışmada, saçıcı merkezlerin kestirimi için model tabanlı Prony, MUSIC ve ESPRIT ve evrimsel tabanlı CLEAN yöntemleri uygulanmış, evrimsel tabanlı CLEAN yönteminin yakınsama hızını arttıracak karma bir yöntem önerilmiştir.

Bahsedilen yöntemlerle kestirilen saçıcı merkezler özilişki tabanlı uyumluluk derecesi yöntemi, Bayes sınıflandırıcısı ve yapay sinir ağları kullanılarak sınıflandırılmıştır. Yapay sinir ağ modeli olarak çok katmanlı perseptron ve radyal tabanlı ağ modelleri kullanılmıştır.

Sınıflandırma dört farklı uçak tipi için farklı frekans ve açı aralıklarında nokta hedef modeli uyarınca simüle edilen yapay veri üzerinden gerçekleştirilmiştir.

A HYBRID APPROACH TO RADAR TARGET CLASSIFICATION USING GENETIC BASED CLEAN ALGORITHM FOR THE ESTIMATION OF SCATTERING CENTERS

SUMMARY

Radar images, range profiles and scattering centers are used as feature parameters in radar target classification applications. Scattering center parameters, when used as feature parameters, enable an efficient compression of feature space compared to classical target classification methods based on radar images and range profiles. In classification algorithms where scattering centers are being used as feature parameters, effective estimation of scattering centers presents itself as a problem.

The most basic method for the estimation of the scattering centers is to associate the peak points of the range profile, which is found by the inverse Fast Fourier Transform of the radar signal, to corresponding scattering centers. However, in order to be used by FFT algorithms, the radar signals must be assumed to be periodic, thus spectral leakage occurs. For that reason side lobes of strong scatterers might be extracted as false scatterers in lieu of relatively weak true scatterers.

A method used for the estimation of scattering centers via cancellation of side lobes is the CLEAN algorithm. The CLEAN algorithm extracts the scattering centers in the range domain rather than the frequency domain so that in the frequency domain the associated side lobes are cancelled. The CLEANed frequency domain signal forms the base signal for the next iteration step. Iteration is repeated until either a predetermined number of scattering centers has been estimated or the given noise level has been reached.

The classical CLEAN algorithm relies on FFT so that it is fast and efficient. The associated disadvantage is low resolution. Model based spectral estimation techniques can be used to improve the resolution. In this approach the choice of model order is of crucial importance. A model of lower degree tends to bypass some

peaks, whereas a model of higher degree may cause artificial peaks due to spectral splitting.

Methods based on evolutionary algorithms can also be used to acquire higher resolution. These methods yield good results for the high resolution estimation of scatterers. However, an improper choice of initial values lowers computing efficiency.

In this work, model based Prony, MUSIC and ESPRIT and evolutionary based CLEAN methods are applied for the estimation of scattering centers. A hybrid method is proposed which improves the convergence of evolutionary based CLEAN.

Scattering centers which are estimated by aforementioned methods are classified using correlation based matching score method, Bayes classifier and artificial neural networks. Multilayer perceptron and radial based network models are used as neural network models.

Classification is accomplished using simulated data of four different aircraft models created by the point target model at different frequency bands and aspect angles.

1. GİRİŞ

1.1 Bir Boyutlu (Menzil) İşaret İşleme

Radar sistemi sınırlı sayıda saçıcıdan oluşan bir hedefe elektromanyetik dalgalar gönderme ve hedeften saçılan dalgaları toplama prensibine dayanmaktadır. Dolayısıyla radar alıcısında elde edilen işaret, hedef cismi oluşturan ayrık saçıcılara karşılık düşen saçılan alanların *süperpozisyonu* olmaktadır. Saçıcılar kenar, köşe ve boşluklar gibi farklı süreksizlik noktaları olabilir. Alıcıya ulaşan saçılan alanlardan hedef hakkında bilgilere ulaşılmaya çalışılır. Alınan radar işaretinden yararlanarak oluşturulan saçıcıların konumsal dağılımına *radar görüntüsü* ismi verilmektedir.

Radar görüntüsü saçıcıların konumsal dağılımı hakkında bir fikir verdiğinden görüntünün görsel benzerlikten çok cismin *yansıtıcılık* özelliğini mümkün olduğunca iyi temsil etmesi beklenmektedir.


Radar sisteminin çalışma mantığı ile insan algılaması arasında bir analogi kurulabilir. Dağlık bir bölgede bir tepeden bağırıldığında ses farklı bölgelerden yankılanıp geri dönecektir. Sesin hava içindeki yayılma hızı kullanılarak yankıların dönüş süresinden yankıya neden olan cisimlerin uzaklıkları belirlenebilir. Ayrıca genel olarak büyük cisimlerin daha güçlü bir yankıya neden oldukları varsayımından hareketle yankıya neden olan cisimlerin türü hakkında da bir fikrimiz olmaktadır.

Radar görüntüleme de yankı deneyinin gelişmiş bir hali olarak düşünülebilir. Bu durumda amaç, saçılan alanlar yardımıyla hedeflerin *uzaklığını*, bir sonraki aşamada ise *hedef tipini* belirleyebilmektir.

Radar görüntülemeye radarın görüş doğrultusuna *menzil*, görüş doğrultusuna dik olan doğrultuya *çapraz menzil* adı verilmektedir. Menzil görüntüleme çapraz menzilin sabit olarak düşünüldüğü Şekil 1.1'deki sistem geometrisi ile temsil edilebilir. Şekil uyarınca hedefin $x_1, x_2, \dots, x_P$ koordinatlarında bulunan $a_1, a_2, \dots, a_P$ şiddetindeki P


adet ayırık, bağımsız nokta saçıcıdan meydana geldiği varsayılmaktadır. Saçıcıların bulunabileceği $[X_C - X_0, X_C + X_0]$ aralığı *konum destek bölgesi* adını almaktadır. Konum destek bölgesi, radar sisteminin görüntüleme alanının sınırlarını belirlemektedir. Bölge dışına düşen saçıcılardan radar alıcısına her hangi bir işaret ulaşmaz. İlerleyen bölümlerde görüleceği üzere konum destek bölgesi radar işaretinin oluşturmakta kullanılan frekans ve gözlem açısı örnek sayılarına bağlı olarak değişmektedir.

Şekil 1.1'den yola çıkılarak incelenecek menzil görüntüleme için bir boyutlu işaret işleme teknikleri geçerli olacaktır. Bir boyutlu işaret işleme algoritmalarının iki boyutlu işaret işleme algoritmalarına göre daha az karmaşık olması nedeniyle ilk olarak bu durum ele alınacaktır.



Şekil 1.1 : Bir boyutlu görüntüleme için sistem geometrisi

Hedefin P adet ayırık, bağımsız nokta saçıcıdan meydana geldiği varsayılarak oluşturulan Şekil 1.1'deki model için *ideal menzil fonksiyonu* $s(x)$ grafiksel olarak Şekil 1.2'deki gibi gösterilebilir.



Şekil 1.2 : İdeal menzil fonksiyonunun gösterilimi

Matematiksel olarak $s(x)$ fonksiyonu ağırlıklandırılmış birim darbe fonksiyonu notasyonu kullanılarak

$$s(x) = \sum_{p=1}^P a_p \delta(x - x_p) \quad (1.1)$$

şeklinde ifade edilir. Hedefin *kütle merkezi* X_C şu şekilde tanımlanmaktadır [1]:

$$X_C = \frac{\sum_{p=1}^P x_p |a_p|^2}{\sum_{p=1}^P |a_p|^2} \quad (1.2)$$

Tanımdan hareketle kütle merkezi X_C geometrik merkeze eşit olmak zorunda değildir. Eşit olma durumu ancak saçıcıların homojen dağılımı durumunda geçerli olacaktır. Pratikte genel olarak hedef kütle merkezi X_C hakkında önceden bir fikir sahibi olunmaktadır.

Saçılan alanların frekans değişimi çeşitli yöntemlerden yola çıkarak elde edilmektedir. Radar sistemlerinde temel olarak doğrusal frekans modülasyonlu işaretler kullanılmaktadır. Bu çalışmada frekans yanıtını oluşturmak için *basamaklı frekans modeli* kullanılacaktır. Basamaklı frekans işaretinin doğrusal frekans işaretinden farkı frekans artırımlarının sürekli değerler yerine ayırık değerler üzerinden gerçekleşmesidir. Bu yöntem uyarınca radar, merkez frekansı sabit frekans adımlarıyla artmakta olan P adet dar frekans bantlı darbe göndermektedir. Radar tarafından toplanan geri saçılan alanlar ayırık frekanslarda cisim yansıtıcılığının zaman geçmişi olarak değerlendirilebilir.

R_0 görüntülenecek cismin uzak alanında bulunan radar anteninin kütle merkezine olan uzaklığını, c ışık hızını temsil etmek üzere gönderilen işaretin p . saçıcıdan alıcıya geri dönmesi esnasında harcanan gidiş-geliş zamanı

$$t_p = \frac{2(R_0 + x_p)}{c} \quad (1.3)$$

şeklinde hesaplanır. (1.1) ve (1.3) eşitlikleri kullanılarak ideal durumda geri saçılan alanın zamanla değişimi için

$$s(t) = \sum_{p=1}^P a_p \delta(t - t_p) = \sum_{p=1}^P a_p \delta\left(t - \frac{2(R_0 + x_p)}{c}\right) \quad (1.4)$$

ifadesi kullanılabilir.

Saçılan alanların frekans yanıtının bulunması için (1.4) ile verilen $s(t)$ işaretinin Fourier dönüşümü alınmalıdır [2].

$$\begin{aligned} S(f) &= F[s(t)] = \int_{-\infty}^{\infty} s(t) e^{-j2\pi ft} dt = \int_{-\infty}^{\infty} \left[\sum_{p=1}^P a_p \delta\left(t - \frac{2(R_0 + x_p)}{c}\right) \right] e^{-j2\pi ft} dt \\ &= \sum_{p=1}^P \left[\int_{-\infty}^{\infty} a_p \delta\left(t - \frac{2(R_0 + x_p)}{c}\right) e^{-j2\pi ft} dt \right] = \sum_{p=1}^P a_p \left[\int_{-\infty}^{\infty} \delta\left(t - \frac{2(R_0 + x_p)}{c}\right) e^{-j2\pi ft} dt \right] \\ &= e^{-j4\pi f \frac{R_0}{c}} \sum_{p=1}^P a_p \left[\int_{-\infty}^{\infty} \delta\left(t - \frac{2x_p}{c}\right) e^{-j2\pi ft} dt \right] = e^{-j2\pi f \frac{2R_0}{c}} \sum_{p=1}^P a_p e^{-j2\pi f \frac{2x_p}{c}} \\ &= e^{-j4\pi f \frac{R_0}{c}} \sum_{p=1}^P a_p e^{-j4\pi f \frac{x_p}{c}} \end{aligned} \quad (1.5)$$

(1.5) denkleminde görüldüğü gibi görüntülenecek cismin radar anteninden uzaklığı R_0 'ın bilinmesi durumunda $e^{-j4\pi f_m \frac{R_0}{c}}$ faz terimi, eşleniği olan $e^{j4\pi f_m \frac{R_0}{c}}$ ile çarpılarak yok edilebilir.

Basamaklı frekans yöntemi uyarınca gönderilen işaret frekansı belirli bir f_0 değerinden itibaren eşit aralıklarla arttırılmaktadır. Alıcıda elde edilen işaretin (1.5) ile verilen frekans yanıtının

$$f_m = f_0 + m\Delta f \quad m = 0, \dots, M-1 \quad (1.6)$$

frekanslarında örneklenmiş değerleri olduğu görülmektedir. Bu şekilde alıcıda M elemanlı bir s frekans vektörü elde edilmektedir.

$$S(f_m) = s[m] = e^{-j4\pi f_m \frac{R_0}{c}} \sum_{p=1}^P a_p e^{-j4\pi f_m \frac{x_p}{c}} = \sum_{p=1}^P a_p e^{-j4\pi (f_0 + m\Delta f) \frac{(R_0 + x_p)}{c}} \quad (1.7)$$

Frekans bölgesinde tanımlanmış olan bu vektörün M örnek üzerinden ters ayrık Fourier dönüşümü alınırsa saçılan alanların zaman değişimi bulunur. Saçılan alanların zamanla değişiminden hareketle de saçıcıların konumsal dağılımı belirlenebilir. Bu şekilde frekans bölgesindeki geri saçılan alanlardan yararlanılarak oluşturulan saçıcıların konumsal dağılımına *menzil profili* ismi verilmektedir.

$$\begin{aligned} s_0(t) &= F^{-1}[s[m]] = F^{-1}\left[\sum_{p=1}^P a_p e^{-j4\pi f_m \frac{(R_0 + x_p)}{c}}\right] = \frac{1}{M} \sum_{m=1}^M \left[\sum_{p=1}^P a_p e^{-j2\pi f_m t_p}\right] e^{j2\pi f_m t} \\ &= \sum_{p=1}^P a_p \left[\frac{1}{M} \sum_{m=1}^M e^{-j2\pi f_m t_p} e^{j2\pi f_m t}\right] = \sum_{p=1}^P a_p \left[\frac{1}{M} \sum_{m=1}^M e^{j2\pi f_m (t - t_p)}\right] \\ &= \sum_{p=1}^P a_p f(t - t_p) = \sum_{p=1}^P a_p f(t) * \delta(t - t_p) = f(t) * \sum_{p=1}^P a_p \delta(t - t_p) \\ &= f(t) * \sum_{p=1}^P a_p \delta\left(t - \frac{2(R_0 + x_p)}{c}\right) = f(t) * s(t) \end{aligned} \quad (1.8)$$

Denklemden görülen $*$ operatörü konvolüsyon işlemini temsil etmektedir. (1.8) ile verilmiş olan saçılan alanların zamanla değişim denklemi (1.4) ile verilmiş olan durumdan farklılık göstermektedir. Bunun nedeni radar bant genişliğinin sınırlı olması dolayısıyla saçılan alanların sonlu frekans bandında frekans örnekleri kullanılarak oluşturulmuş olunmasıdır.

(1.8) denkleminde $s_0(t)$ işaretinin ideal durumu temsil eden $s(t)$ işareti ile $f(t)$ işaretinin konvolüsyonu olduğu görülmektedir. $f(.)$ fonksiyonu literatürde radar görüntüleme sisteminin *nokta dağılım fonksiyonu* (*point spread function, PSF*) olarak anılmaktadır. Bu nedenle $f(.)$ yerine bundan sonra $psf(.)$ notasyonu kullanılacaktır.

Nokta dağılım fonksiyonu kullanarak saçılan alanların zamanla değişimi için

$$s_0(t) = s(t) * psf(t) \quad (1.9)$$

yazılabilir. İdeal nokta dağılım fonksiyonu birim darbe fonksiyonu şeklinde olmalıdır. Ancak radar sisteminin sonlu bant genişliği nedeniyle bu durum pratikte gerçekleşmez.

İdeal olmayan nokta dağılım fonksiyonları iki istenmeyen duruma yol açarlar. Birinci sorun ideal durumdaki birim darbeye karşılık gelen ana lobun belirli bir genişliğe sahip olmasıdır. Bu durum nedeniyle saçıcıların yerleri kesin bir doğrulukla belirlenemez, ancak hangi aralıkta bulunduğu hakkında bilgi sahibi olunabilir. Bu aralık radar görüntülemeye *menzil çözünürlüğü* adını almaktadır.

Temel bant genişliği B ile belirlenmiş bir nokta dağılım fonksiyonu frekans bölgesinde ideal bir pencere fonksiyonu ile temsil edilebilir. B bant genişlikli ideal pencere fonksiyonun Fourier dönüşümü $\text{sinc}(.)$ formundadır. Zaman bölgesindeki bu fonksiyonun ana lobu zaman eksenini $\Delta_t = B^{-1}$ noktasında kesmektedir. Δ_t noktası zaman destek bölgesinin sınır değeridir ve menzil çözünürlüğü Δ_x 'i de belirler. Menzil çözünürlüğü bu bilgiler ve (1.3) eşitliği uyarınca

$$\Delta_t = \frac{2\Delta_x}{c} \Rightarrow \Delta_x = \frac{c\Delta_t}{2} = \frac{c}{2B} \quad (1.10)$$

olarak bulunur.

İdeal olmayan nokta dağılım fonksiyonlarının yol açtığı diğer bir istenmeyen durum ana loblarla birlikte ortaya çıkan yan loblar olmasıdır. Yan lobların doğru teşhis edilemediği durumda alıcı bunları bağımsız saçıcılarmış gibi değerlendirilebilir. Saçıcıların kendileri ile birlikte ortaya çıkan yan lobların gerçekte var olmayan saçıcılar olarak algılanma durumu *yalancı saçıcı* olarak adlandırılmaktadır. Ayrıca yan lobların başka saçıcıların ana lobları ile kesişmesi durumunda kesiştiği ana lobun ait olduğu saçıcının kestirilmesi güçleşmektedir.

Görüldüğü gibi radar görüntülemeye kullanılan Fourier dönüşümü iki soruna yol açmaktadır. Nokta dağılım fonksiyonunun ana lob genişliğinin azaltılması menzil çözünürlüğünü arttıracak, yan lobların bastırılması yalancı saçıcı algılanmasını engelleyecek ve birbirlerine yakın saçıcıların daha doğru olarak kestirimini sağlayacaktır. Bu sorunların azaltılması için pencere fonksiyonları kullanılabilir. Pencere fonksiyonlarının kullanımı ise bir dualite durumu ortaya çıkarmaktadır. Yan lobların bastırılması ana lobun genişletilmesi, ana lobun daraltılması yan lobların belirginleştirilmesi pahasına gerçekleşmektedir.

Bu sorunun çözülmesi amacıyla geliştirilmiş yöntemlere ilerleyen bölümlerde değinilecektir.

1.2 İki Boyutlu (Doppler) İşaret İşleme


Bir önceki bölümde görüntüleme işlemi çapraz menzil bilgisinin sabit olarak kabul edildiği Şekil 1.1'deki bir boyutlu sistem geometrisinden yararlanarak oluşturulmuştu. Bu bölümde ise çapraz menzil bilgisinin serbest bırakıldığı iki boyutlu sistem geometrisi incelenecek ve iki boyutlu durum için sistem modeli oluşturulacaktır. $(x_1, y_1), (x_2, y_2), \dots, (x_P, y_P)$ koordinatlarında bulunan $a_1, a_2, \dots, a_P$ şiddetindeki P adet ayrık, bağımsız nokta saçıcıdan meydana gelen bir hedef için sistem geometrisi Şekil 1.3'te görülmektedir.

Hedefin P adet ayrık, bağımsız nokta saçıcıdan meydana geldiği varsayılarak oluşturulan ideal hedef fonksiyonu $s(x,y)$ ağırlıklandırılmış birim darbe fonksiyonu notasyonu kullanılarak

$$s(x, y) = \sum_{p=1}^P a_p \delta(x - x_p, y - y_p) \quad (1.11)$$

şeklinde ifade edilebilir. Kütle merkezinin menzil koordinatı X_C (1.2) ile verilen eşitlikten hesaplanabilir, çapraz menzil ordinatı Y_C de benzer şekilde tanımlanmaktadır:

$$Y_C = \frac{\sum_{p=1}^P y_p |a_p|^2}{\sum_{p=1}^P |a_p|^2} \quad (1.12)$$



Şekil 1.3 : İki boyutlu görüntüleme için sistem geometrisi


Menzil görüntülemeye olduğu gibi kütle merkezinin geometrik merkeze eşit olması zorunluluğu yoktur.

Görüntüleme sistemi olarak radar anteninin hedefin etrafında dairesel bir hareket yapmakta, bu nedenle hedefe göre bağlı uzaklığının sabit kalmakta olduğu *spotlight SAR* kullanılması durumunda tek bir nokta hedefin görüntülenmesi Şekil 1.4'teki gibi olmaktadır. Radar anteninin hareketi θ açısıyla belirlenmektedir. Her görüntüleme açısı için alınan işaret cismin u eksenindeki izdüşümü olmaktadır.

Gönderilen işaretin saçıcıdan alıcıya geri dönmesi esnasında harcanan gidiş-geliş zamanının, R_θ görüntülenecek cismin θ açısında radar anteninin kütle merkezine olan uzaklığını, c ışık hızını temsil etmek üzere

$$t_p = \frac{2(R_\theta + u_p)}{c} \quad (1.13)$$

olduğu görülmektedir.



Radar anteninin cismin kütle merkezine olan uzaklığının cismin boyutlarından yeterince fazla olduğu, bir başka deyişle cismin *uzak alama*nda bulunduğu durum için anteninin cisme uzaklığı $R_\theta \approx R_0$ olmak üzere sabit kabul edilebilir. Bu yaklaşım sonucu eş menzil çizgileri bakış açısına dik çizgiler meydana getirmektedir. u_p için Şekil 1.4'ten yararlanarak (x_p, y_p) koordinatlarından dönüşüm

$$u_p = x_p \cos \theta - y_p \sin \theta \quad (1.14)$$

şeklinde elde edilmektedir. Konum düzleminde hedef fonksiyonunun (1.11) ile verilen ifadesinden yola çıkılarak geri saçılan alanın θ bakış açısı ve t zamana bağlı değişimi için şu ifade elde edilir:

$$s(t, \theta) = \sum_{p=1}^P a_p \delta \left(t - \frac{2(R_0 + x_p \cos \theta - y_p \sin \theta)}{c} \right) \quad (1.15)$$

(1.15) ile verilen ifadenin Fourier dönüşümü alınarak saçılan alanın frekans yanıtı bulunabilir.

$$\begin{aligned}
S(f, \theta) &= F[s(t, \theta)] = \int_{-\infty}^{\infty} s(t, \theta) e^{-j2\pi ft} dt \\
&= \int_{-\infty}^{\infty} \left[\sum_{p=1}^P a_p \delta \left(t - \frac{2(R_0 + x_p \cos \theta - y_p \sin \theta)}{c} \right) \right] e^{-j2\pi ft} dt \\
&= \sum_{p=1}^P \left[\int_{-\infty}^{\infty} a_p \delta \left(t - \frac{2(R_0 + x_p \cos \theta - y_p \sin \theta)}{c} \right) e^{-j2\pi ft} dt \right] \\
&= \sum_{p=1}^P a_p \left[\int_{-\infty}^{\infty} \delta \left(t - \frac{2(R_0 + x_p \cos \theta - y_p \sin \theta)}{c} \right) e^{-j2\pi ft} dt \right] \\
&= e^{-j2\pi f \frac{2R_0}{c}} \sum_{p=1}^P a_p \left[\int_{-\infty}^{\infty} \delta \left(t - \frac{2(R_0 + x_p \cos \theta - y_p \sin \theta)}{c} \right) e^{-j2\pi ft} dt \right] \\
&= e^{-j2\pi f \frac{2R_0}{c}} \sum_{p=1}^P a_p e^{-j2\pi f \frac{2(x_p \cos \theta - y_p \sin \theta)}{c}} = e^{-j4\pi f \frac{R_0}{c}} \sum_{p=1}^P a_p e^{-j4\pi f \frac{(x_p \cos \theta - y_p \sin \theta)}{c}}
\end{aligned} \tag{1.16}$$

(1.16) denkleminde görüldüğü gibi görüntülenecek cismin radar anteninden uzaklığı R_0 'ın bilinmesi durumunda $e^{-j4\pi f \frac{R_0}{c}}$ faz terimi eşleniği olan $e^{j4\pi f \frac{R_0}{c}}$ ile çarpılarak yok edilebilir.

Spotlight-SAR modeline göre (veya eşdeğer olarak ölçüm platformunun sabit, hedefin hareketli olduğu *ISAR*) radar anteni görüntülenecek cismin kütle merkezi çevresinde $[\theta_0; \theta_{N-1}]$ aralığında $\Delta\theta$ artırımlarla N gözlem açısından görüntülenmektedir. Her gözlem açısında $[f_0; f_{M-1}]$ frekans bandında Δf artırımlı M adet darbe gönderilmektedir. Alıcıda elde edilen işaretin (1.16) ile verilen frekans yanıtının

$$\begin{aligned}
f_m &= f_0 + m\Delta f \quad m = 0, \dots, M-1 \\
\theta_n &= \theta_0 + n\Delta\theta \quad n = 0, \dots, N-1
\end{aligned} \tag{1.17}$$

noktalarında örneklenmiş değerleri olduğu görülmektedir. Bu şekilde alıcıda $M \times N$ elemanlı bir $\mathbf{S}$ matrisi oluşmaktadır. Frekans bölgesinde tanımlanmış olan bu matrisin M örnek üzerinden ters ayrık Fourier dönüşümü alınırsa saçılan alanların zaman değişimi bulunabilir.

$$\begin{aligned}
s_0(t, \theta) &= F^{-1}[S(f, \theta)] = F^{-1} \left[\sum_{p=1}^P a_p e^{-j4\pi f_m \frac{(R_0 + x_p \cos \theta - y_p \sin \theta)}{c}} \right] \\
&= \frac{1}{M} \sum_{m=1}^M \left[\sum_{p=1}^P a_p e^{-j2\pi f_m t_p} \right] e^{j2\pi f_m t} \\
&= \sum_{p=1}^P a_p \left[\frac{1}{M} \sum_{m=1}^M e^{-j2\pi f_m t_p} e^{j2\pi f_m t} \right] = \sum_{p=1}^P a_p \left[\frac{1}{M} \sum_{m=1}^M e^{j2\pi f_m (t-t_p)} \right] \\
&= \sum_{p=1}^P a_p f(t-t_p) = \sum_{p=1}^P a_p f(t) * \delta(t-t_p) = f(t) * \sum_{p=1}^P a_p \delta(t-t_p) \\
&= f(t) * \sum_{p=1}^P a_p \delta \left(t - \frac{2(R_0 + x_p \cos \theta - y_p \sin \theta)}{c} \right) = f(t) * s(t, \theta)
\end{aligned} \tag{1.18}$$

(1.18) denkleminde $s_0(t)$ işaretinin ideal durumu temsil eden $s(x,y)$ işareti ile $f(t, \theta)$ işaretinin konvolüsyonu olduğu görülmektedir. $f(\cdot)$ fonksiyonu bir boyutlu duruma benzer olarak radar görüntüleme sisteminin *nokta dağılım fonksiyonu* olarak anılmaktadır. Nokta dağılım fonksiyonu kullanarak saçılan alanların zamanla değişimi için

$$s_0(t, \theta) = s(t, \theta) * psf(t) \tag{1.19}$$

ifadesi yazılabilir.

Radar görüntüsün oluşturulması sürecinde ilk aşamada *menzil işleme* gerçekleştirilmektedir. Menzil işleme süresince **S** matrisinin farklı gözlem açılarındaki saçılan alanları ifade eden N adet satırının her biri için M nokta üzerinden ters Fourier dönüşümü alınmaktadır. Böylece her biri M adet menzil hücresinden oluşan N adet menzil profili elde edilmiş olunmaktadır.

İkinci aşamada *çapraz menzil işleme* gerçekleştirilmektedir. Bu aşamada N adet menzil profilinin M menzil hücresinin her biri için N elemanlı birer dizi oluşturduğu gerçeğinden hareket edilmektedir. Bu diziler ilişkin menzil hücresinin *zaman geçmişi* olarak değerlendirilebilir. Radar görüntüsü, her menzil hücresinin zaman geçmişi oluşturan M adet zaman dizisine N nokta üzerinden Fourier dönüşümü alınarak bulunmaktadır. Görüntünün oluşturulması süreci Şekil 1.5'te görülmektedir.

İki boyutlu *spotlight-SAR* görüntüleme sistemlerinde *menzil çözünürlüğü* Δ_x (1.10) ile verilen şekilde işaretin B bant genişliğine [$B = (f_{M-1} - f_0)$] bağlı iken *çapraz menzil çözünürlüğü* Δ_y işaretin f_C merkez frekansı ve ölçüm platformunun θ dönüş

açısının $[\theta = (\theta_{N-1} - \theta_0)]$ bir fonksiyonudur. (1.10) denklemine benzer şekilde çapraz menzil çözünürlüğü Δ_y

$$\Delta_y = \frac{c}{2f_c \theta} \quad (1.20)$$

şeklinde verilmektedir [4]. Böylece basamaklı frekans modeli uyarınca görüntüleme süreci f_c merkez frekansı, B bant genişliği, θ dönüş açısı, M frekans örneği ve N gözlem açısı parametrelerinin belirlenmesine indirgenmiş olmaktadır.

1.3 Yüksek Çözünürlüklü Görüntüleme Yöntemleri

1.3.1 Model Tabanlı Spektral Kestirim Yöntemleri

Bir önceki bölümde saçılan alanların üstel terimlerin doğrusal bileşimi şeklinde ifade edilebildiği gösterilmiştir. Bu bölümde *harmonik işaret modeli* olarak da adlandırılan bu işaret modeli için çok kullanılan yüksek çözünürlüklü yöntemlerden bazıları anlatılacaktır. Yöntemlerin bir boyutlu ve iki boyutlu türleri bulunmasına karşın iki boyutlu durumda işlemlerin karmaşık olmasından ötürü sadece bir boyutlu türler açıklanacaktır.

1.3.1.1 Prony Yöntemi


(1.7) denkleminde görüldüğü üzere bir boyutlu saçılan alanlar

$$s[m] = \sum_{p=1}^P a_p e^{-j4\pi f_m \frac{(R_0 + x_p)}{c}} = e^{-j4\pi(f_0 + m\Delta f) \frac{R_0}{c}} \sum_{p=1}^P a_p e^{-j4\pi(f_0 + m\Delta f) \frac{x_p}{c}} \quad (1.21)$$

ile verilen s vektörüyle ifade edilebilir. s vektörünün fazının düzeltilmesiyle

$$x[m] = \sum_{p=1}^P a_p e^{-j4\pi(f_0 + m\Delta f) \frac{x_p}{c}} \quad (1.22)$$

olmak üzere bir x vektörü oluşturulabilir.



Şekil 1.5 : Basamaklı frekans modeliyle görüntü oluşturulması

(1.22) ifadesinde

$$h_p = a_p e^{-j4\pi f_0 \frac{x_p}{c}} \quad z_p = e^{-j4\pi f_0 \frac{x_p}{c}} \quad (1.23)$$

değişken dönüşümleri yapılırsa $\mathbf{x}$ vektörü

$$x[m] = \sum_{p=1}^P h_p z_p^{m-1} \quad (1.24)$$

şeklini alır. (1.24) dizisi matris şeklinde ifade edilirse

$$\begin{bmatrix} z_1^0 & z_2^0 & \dots & z_P^0 \\ z_1^1 & z_2^1 & \dots & z_P^1 \\ \vdots & \vdots & \ddots & \vdots \\ z_1^{P-1} & z_2^{P-1} & \dots & z_P^{P-1} \end{bmatrix} \begin{bmatrix} h_1 \\ h_2 \\ \vdots \\ h_P \end{bmatrix} = \begin{bmatrix} x[1] \\ x[2] \\ \vdots \\ x[P] \end{bmatrix} \quad (1.25)$$

eşitliği elde edilir. $\mathbf{Z}$ matrisini oluşturan elemanların belirlenebilmesi durumunda (1.22) denklemi P değişkenli doğrusal denklem takımının çözümüne indirgenmektedir. z_k katsayılarının bulunması için (1.24) denkleminin sabit katsayılı doğrusal bir fark denklemini temsil ettiği gerçeğinden yararlanılmaktadır. Bu fark denklemini oluşturmak için kökleri z_k katsayıları olan $\phi(z)$ polinomu tanımlanır. Polinom güç serisine açılırsa $b[m]$ katsayı serisinin bulunması gerekecektir.

$$\phi(z) = \prod_{p=1}^P (z - z_p) = \sum_{m=0}^P b[m] z^{P-m} \quad (1.26)$$

Bir miktar cebirsel işlemin ardından [5]

$$\begin{bmatrix} x[P] & x[P-1] & \dots & x[1] \\ x[P+1] & x[P] & \dots & x[2] \\ \vdots & \vdots & \ddots & \vdots \\ x[2P-1] & x[2P-2] & \dots & x[P] \end{bmatrix} \begin{bmatrix} b[1] \\ b[2] \\ \vdots \\ b[P] \end{bmatrix} = - \begin{bmatrix} x[P+1] \\ x[P+2] \\ \vdots \\ x[2P] \end{bmatrix} \quad (1.27)$$

formuna ulaşılır. Denklemin sol tarafında görülen matris Toeplitz formundadır. Toeplitz formunda bir matrisin oluşturduğu doğrusal denklem sistemi Levinson algoritması kullanılarak çözülüp $b[m]$ katsayıları belirlenebilmektedir.

Sonuç olarak Prony yönteminin ilk aşamasında $M=2P$ örnek sayısından (1.27) denklemi uyarınca $b[m]$ katsayıları bulunur. Bulunan katsayılar kullanılarak (1.26) polinomunun kökleri olan z_p katsayıları hesaplanır. Üçüncü adımda ise ikinci adımda bulunan kökler yardımıyla oluşturulan matris kullanılarak aranan P adet h_p parametresi bulunur.

1.3.1.2 MUSIC Yöntemi

MUSIC (*Çoklu İşaret Sınıflandırma, MULTIPLE Signal Classification*) yöntemi gürültülü işaretin bilgi işareti ve gürültü olarak ayrılması üzerine kuruludur [6]. (1.22) denkleminde hareketle gürültü içindeki işaret, $w[m]$ gürültü bileşenini göstermek üzere

$$x[m] = \sum_{p=1}^P a_p e^{-j4\pi(f_0+m\Delta f)\frac{x_p}{c}} + w[m] \quad (1.28)$$

şeklinde modellenebilir.

MUSIC yönteminde işaretin belirli bir zaman penceresinde gözlenmesi gerekmektedir. Bu amaçla $x[m]$ işaretinin N örnek değeri üzerinden oluşturulan zaman penceresi

$$\vec{x}[m] = [x[m] \quad x[m+1] \quad \dots \quad x[m+N-1]]^T \quad (1.29)$$

şeklinde oluşturulur. (1.28) ile verilen işarete

$$\alpha_p = a_p e^{-j4\pi f_0 \frac{x_p}{c}} \quad f = \Delta f \frac{2x_p}{c} \quad (1.30)$$

değişken dönüşümleri uygulandığında (1.29) notasyonu kullanarak gürültü içindeki işarete ait N uzunluklu zaman penceresi vektörü

$$\vec{x}[m] = \sum_{p=1}^P \alpha_p \vec{v}[f] e^{-j2\pi m f} + \vec{w}[m] = \vec{s}[m] + \vec{w}[m] \quad (1.31)$$

$$\vec{v}[f] = [1 \quad e^{-j2\pi f} \quad \dots \quad e^{-j2\pi(N-1)f}] \quad (1.32)$$

olarak ifade edilebilir.

(1.31) denkleminde görülen $\mathbf{v}[f]$ vektörünün N uzunluklu DFT operatörü olduğu (1.32)'de görülmektedir. (1.31) ile ifade edilen $\mathbf{x}[m]$ zaman pencereli vektör için *özilişki matrisi*

$$\begin{aligned} R_x &= E[\tilde{\mathbf{x}}[m]\tilde{\mathbf{x}}^H[m]] = R_s + R_w \\ &= \sum_{p=1}^P |\alpha_p|^2 \tilde{\mathbf{v}}(f_p)\tilde{\mathbf{v}}^H(f_p) + \sigma_w^2 \bar{\mathbf{I}} = \bar{\mathbf{V}}\mathbf{A}\bar{\mathbf{V}}^H + \sigma_w^2 \bar{\mathbf{I}} \end{aligned} \quad (1.33)$$

şeklinde oluşturulur. Burada $\mathbf{V}$ matrisi $\bar{\mathbf{V}}[f] = [\tilde{\mathbf{v}}[f_1] \ \tilde{\mathbf{v}}[f_2] \ \dots \ \tilde{\mathbf{v}}[f_P]]$ olmak üzere (1.32) ile tanımlanan $\mathbf{v}$ vektörlerinden oluşturulmaktadır. $\mathbf{V}$ matrisi $N \times P$ boyutlu zaman pencereli frekans vektörlerinden oluşmaktadır. $\mathbf{A}$ matrisi ise

$$\mathbf{A} = \begin{bmatrix} |\alpha_1|^2 & 0 & \dots & 0 \\ 0 & |\alpha_2|^2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & |\alpha_P|^2 \end{bmatrix} \quad (1.34)$$

şeklinde ifade edilen ilişkin üstel terimlerden oluşan bir diyagonal matristir.

Özilişki matrisi özvektörler yardımıyla da oluşturulabilir.

$$R_x = \sum_{n=1}^N \lambda_n \tilde{\mathbf{q}}_n \tilde{\mathbf{q}}_n^H = \bar{\mathbf{Q}} \mathbf{\Lambda} \bar{\mathbf{Q}}^H \quad (1.35)$$

(1.35) denkleminde görünen λ_n 'ler azalan şekilde sıralanmış özdeğerler, $\mathbf{q}_n$ vektörleri ise λ_n özdeğerlerine karşılık düşen özvektörler olmaktadır. $\mathbf{\Lambda}$ matrisi köşegenleri üzerindeki elemanları özdeğerler olan, diğer elemanları sıfır olan bir matris, $\mathbf{Q}$ ise sütunları özvektörler olan bir matristir.

Pencere uzunluğu N 'nin P 'den büyük seçilmesi durumunda λ_n özdeğerleri

$$\lambda_n = \begin{cases} N |\alpha_n|^2 + \sigma_w^2 & n \leq P \\ \sigma_w^2 & n > P \end{cases} \quad (1.36)$$

şeklinde ifade edilir. σ_w beyaz gürültü sürecinin standart sapmasını göstermektedir. (1.36)'dan görüldüğü üzere P en büyük özdeğer bilgi işaretini oluşturan harmonik bileşenlere, diğer özdeğerler gürültü bileşenine aittir. Bu bilgi kullanılarak özilişki matrisi işaret ve gürültü özvektörlerinin meydana getirdiği iki parçaya ayrılabilir.

$$\bar{R}_x = \sum_{n=1}^P (N |\alpha_n|^2 + \sigma_w^2) \bar{q}_n \bar{q}_n^H + \sum_{n=P+1}^N \sigma_w^2 \bar{q}_n \bar{q}_n^H = \bar{Q}_s \bar{\Lambda}_s \bar{Q}_s^H + \sigma_w^2 \bar{Q}_w \bar{Q}_w^H \quad (1.37)$$

Denklemden görünen $\mathbf{Q}_s$ ve $\mathbf{Q}_w$ matrisleri

$$\bar{Q}_s = [\bar{q}_1 \quad \bar{q}_2 \quad \dots \quad \bar{q}_P] \quad \bar{Q}_w = [\bar{q}_{P+1} \quad \bar{q}_{P+2} \quad \dots \quad \bar{q}_N] \quad (1.38)$$

λ_n özdeğerlerine karşılık düşen $\mathbf{q}_n$ özvektörleri ile tanımlanmaktadır. Λ_s matrisi ise köşegenleri üzerindeki elemanları özdeğerler olan, diğer elemanları sıfır olan $P \times P$ boyutunda bir matristir.

Böylece (1.29)'da verilmiş olan zaman penceresi boyunca gözlenmiş halini içeren N boyutlu altuzay *işaret altuzayı* ve *gürültü altuzayı* olarak iki ayrı parçaya ayrılabilir. Özilişki matrisi Hermityen simetrik olduğundan bu iki alt uzay birbirlerine dik olmak zorundadır. Ayrıca bu diklik nedeniyle bütün zaman pencereli frekans vektörleri de gürültü altuzayına dik olmaktadır.

Bu ilişki kullanılarak $P < n < N$ aralığında her özvektör için

$$\bar{v}^H [f_p] \bar{q}_n = \sum_{k=1}^N q_n(k) e^{-j2\pi f_p(k-1)} = 0 \quad (1.39)$$

eşitliği yazılabilir.

(1.39) uyarınca her gürültü özvektörü için *sözde spektrum* olarak anılan

$$\bar{R}_n(e^{j2\pi f}) = \frac{1}{\bar{v}^H [f] \bar{q}_n} = \frac{1}{|Q_n(e^{j2\pi f})|} \quad (1.40)$$

büyüklüğü oluşturulabilir. Tanımın sözde spektrum şeklinde yapılması (1.40) ile oluşturulan frekans yanıtının sadece frekans değerlerini belirlemesinden, gerçek $|a_p|^2$ işaret gücü ve σ_w^2 gürültü gücü hakkında bir bilgi vermemesinden kaynaklanmaktadır. (1.40) fonksiyonu P tanesi işaret harmoniklerine karşılık gelmekte olan $N-1$ kutba sahiptir. $x[m]$ işaretinin M kutbundan kalan $M-P$ adet kutbun da işaret uzayına ait olması gerektiği düşünülürse bu kutupların birim çembere yakın olmaları durumunda oluşan sözde spektrumda P 'den fazla sayıda bileşen görülebilir. Bu istenmeyen bileşenleri azaltmanın bir yolu her biri farklı bir gürültü özvektöründen elde edilen $M-P$ sözde spektrumun ortalamasını almaktır.


Bu şekilde oluşturulan MUSIC sözde spektrumu

$$\bar{R}_{MUSIC}(e^{j2\pi f}) = \frac{1}{\sum_{n=P+1}^N |\bar{v}^H[f] \bar{q}_n|^2} = \frac{1}{\sum_{n=P+1}^N |Q_m(e^{j2\pi f})|^2} \quad (1.41)$$

şeklinde ifade edilmektedir.

1.3.1.3 ESPRIT Yöntemi

İşaretin alt uzaylara ayrılması prensibine dayanan bir diğer kestirim yöntemi ESPRIT (*İşaret Parametrelerinin Dönmesel Değişmezlik İle Kestirimi, Estimation of Signal Parameters via Rotational Invariance Technique*) yöntemidir. MUSIC yönteminde işaret parametrelerinin kestirimi özilişki matrisi kullanılarak yapılmaktayken ESPRIT yönteminde *veri matrisi* kullanılarak yapılmaktadır. Yöntem diğer kestirim yöntemine göre matematiksel olarak daha fazla formülasyon gerektirdiğinden detaylı olarak anlatılmayacak, sadece ana hatlarıyla verilecektir [7]. Dönmesel değişmezlik özelliği zamanda kaydırılmış birbirini kesen pencerelerde işaretin gözlenmesiyle elde edilmektedir. Yöntemin blok diyagramı Şekil 1.6’da görülmektedir.



Şekil 1.6 : ESPRIT yöntemi için blok diyagramı

$\mathbf{V}$ matrisi $N \times P$ boyutlu zamanda pencerelenmiş frekans vektörlerinden oluşmaktadır. Φ matrisi komşu zaman örnekleri arasındaki faz farklarının oluşturduğu köşegen bir matristir. $\mathbf{X}$ giriş matrisinin tekil değer ayrıştırmasından (singular value decomposition, SVD) yararlanarak oluşturulan $\mathbf{U}$ matrisi; $\mathbf{V}$ ve $\mathbf{U}_s$ matrislerinin aynı alt uzaya ait olduğu gerçeğinden yola çıkarak oluşturulan $\mathbf{T}$ notasyon matrisi kullanılarak dönme matrisi Ψ elde edilmektedir. Ψ matrisinin özdeğerleri olan ϕ_p değerleri kullanılarak frekans kestirimi yapılmaktadır.

1.3.1.4 Model Derecesi Seçimi

Bu bölüm altında bahsedilen bütün yöntemlerde model derecesi seçimi karşımıza bir sorun olarak çıkmaktadır. Radar görüntüleme uygulamaları açısından model derecesinin seçimi büyük önem taşımaktadır. İdeal spektrum bir boyut için (1.1), iki boyut için (1.11)'de verilen biçimde ağırlıklandırılmış birim darbe fonksiyonlarından oluşmaktadır. Düşük dereceli bir model aşırı düzgün bir spektrum yaratarak bazı tepelerin atlanmasına, yüksek dereceli model ise spektrumda tepelerin ayrışarak yalancı saçıcı merkezlerin oluşmasına neden olmaktadır.

Model seçimi probleminin çözümü için farklı ölçütler geliştirilmiştir. En basit yaklaşım model derecesini adım adım yükselterek derece artırımının modelleme hatası üzerinde etkili olmadığı en düşük dereceyi seçmektir. Ancak bu durumda hata fonksiyonunun genel olarak monoton azalan bir karakterde olması söz konusudur. Ayrıca model derecesi yükseldikçe işlemsel karmaşıklık artmaktadır ve spektrum ayrışması söz konusu olmaktadır.

Literatürde yer alan karar ölçütleri genel olarak hata fonksiyonuna model derecesi ile birlikte artan bir ceza puanı ekleyerek düşük dereceli modelleri öne çıkarmaktadır. Bu ölçütlerden çok kullanılan dört tanesi aşağıda tanımlanmıştır [7]. Denklemlerde görülen değişkenlerden P model derecesini, M veri uzunluğunu, σ_P ise modelleme hatasını temsil etmektedir.

- Nihai öngörü hatası (Final Prediction Error, FPE)

$$FPE(P) = \frac{M + P}{M - P} \hat{\sigma}_P^2 \quad (1.42)$$

- Akaike bilgi ölçütü (Akaike Information Criterion, AIC)

$$AIC(P) = M \log \hat{\sigma}_p^2 + 2P \quad (1.43)$$

- Minimum tanımlama uzunluğu (Minimum Description Length, MDL)

$$MDL(P) = M \log \hat{\sigma}_p^2 + P \log M \quad (1.44)$$

- Özbağımlı transfer ölçütü (Criterion Autoregressive Transfer, CAT)

$$CAT(P) = \frac{1}{M} \sum_{k=1}^P \frac{M-k}{M \hat{\sigma}_k^2} - \frac{M-P}{M \hat{\sigma}_p^2} \quad (1.45)$$


1.3.2 İteratif Yöntemler

Yüksek çözünürlük sağlayan yöntemlerden bir bölümü iteratif yöntemler altbaşlığı altında işlenebilir. Genel olarak bu yöntemler her bir iterasyon adımımda bir veya birkaç saçıcı merkezin parametrelerini belirlemeye çalışmakta, bir sonraki iterasyon adımımda geçmeden önce parametreleri belirlenen saçıcılarla ilgili bilgiyi saçılan alan bilgisinden çıkarmakta ve bir sonraki iterasyon adımımda bir önceki iterasyonda kullanılan farklı bir saçılan alan kullanılmaktadır.

İteratif yöntemlerden literatürde en çok rastlanı olarak CLEAN algoritması ve bu algoritmanın çeşitli varyasyonları karşımıza çıkmaktadır. Bu bölümde de iteratif yöntemlerin açıklanması için CLEAN algoritması kullanılacaktır.

CLEAN algoritmasının ilk uygulamaları 1970'yi yılların ortalarında astronomi dalında görülmektedir [8]. Bölüm 1.1'de gösterilmiş olduğu gibi ideal olmayan nokta dağılım fonksiyonları ana loblarla birlikte istenmeyen yan loblara neden olmaktadır. Nokta dağılım fonksiyonlarının dikkate alınmadan hedef kestiriminin yapılması güçlü hedeflerin yan loblarının bağımsız hedefler olarak algılanmasına yol açar. CLEAN algoritması alıcı sistemin nokta dağılım fonksiyonunun kullanılarak güçlü hedeflerin (astronomi bilim dalı için parlak yıldızlar) kestirilmesi amacını gütmektedir. Bu nedenle kestirilen hedef yan loblarıyla birlikte kestirilmekte ve yan lobların zayıf saçıcıları bastırması önlenmektedir.

Bu yaklaşımı temel alan klasik bir boyutlu CLEAN algoritması Şekil 1.7'deki akış şeması ile temsil edilebilir.



Şekil 1.7 : CLEAN algoritması akış şeması

Ayrık bağımsız saçıcıların süperpozisyonu varsayımı altında yüksek frekans bölgesinde P nokta saçıcı ile modellenen bir hedefin M frekans örneği ile oluşturulan fazı düzeltilmiş saçılan alan verisi (1.7) eşitliğinden hareketle

$$S_p(f_m) = \sum_{p=1}^P a_p e^{-j \frac{4\pi}{c} f_m x_p}, m = 1, 2, \dots, M \quad (1.46)$$

şeklinde verilmektedir. Denklemden x_p , ve a_p sırasıyla p . saçıcının menzil koordinatını ve saçıcı şiddetini, c ise ışık hızını temsil etmektedir.

İterasyonun ilk adımında M örnek üzerinden ters hızlı Fourier dönüşümü alınarak menzil profili oluşturulur. İkinci adımda menzil profilinin maksimum noktası bulunur ve saçıcı parametreleri olarak saklanır. Bir sonraki adımda kestirilen saçıcı merkezin frekans yanıtı (1.47)'de görüldüğü üzere toplam alandan çıkartılır ve ilk iterasyon adımına geri dönülür [9].

$$S_{p+1}(f_m) = S_p(f_m) - a_p e^{-j \frac{4\pi}{c} f_m x_p}, m = 1, 2, \dots, M \quad (1.47)$$


İterasyon, sayısı önceden bilinen P saçıcı merkez kestirilene veya hata fonksiyonunun değeri önceden belirlenen bir eşik değerinin altına düşene kadar devam eder.

1.3.3 Evrimsel Yöntemler

Bir önceki bölümde verilen klasik CLEAN algoritması yan lobları etkili bir şekilde ortadan kaldırmaktadır, ancak FFT dönüşümüne dayandığından çözünürlük artmamaktadır. Çözünürlüğün artırılması için Bölüm 2’de bahsedilecek evrimsel algoritmalar kullanılabilir. Bu amaçla

$$H_p = \sum_{p=1}^P |S_p(f_m) - a_p e^{-j\frac{4\pi}{c} f_m x_p}|^2 \quad (1.48)$$


şeklinde bir hata fonksiyonu oluşturularak bu fonksiyonunun minimize edilmesine çalışılır. Optimize edilecek (1.48) fonksiyonunda tasarım parametreleri x_p saçıcı menzil uzaklığı ve a_p saçıcı şiddetinden oluşmaktadır. Bu yöneme ilişkin akış şeması Şekil 1.8’de görülmektedir.



Şekil 1.8 : Evrimsel tabanlı CLEAN algoritması akış şeması

Evrimsel tabanlı CLEAN algoritması klasik CLEAN algoritmasına yüksek çözünürlük özelliğini eklemektedir, ancak yüksek çözünürlük işlem sayısının

arttırılması pahasına gerçekleşmektedir [10,11]. İşlem sayısını azaltmak amacıyla optimizasyon başlangıç parametreleri Fourier analiziyle bulunan menzil profilinden yararlanarak belirlenebilir. Bu şekilde hızlı bir yüksek çözünürlüklü karma yöntem oluşturulmuş olmaktadır [12]. Bu karma yönteme ilişkin akış şeması Şekil 1.9’da görülmektedir.



Şekil 1.9 : FFT başlangıç koşullu evrimsel tabanlı CLEAN algoritması akış şeması

1.4 Hedef Tanıma ve Sınıflandırma Yöntemleri

1.4.1 Öznitelik Olarak Saıcı Merkezler

Modern radar sistemlerinin önemli özelliklerinden biri sadece hedef konumunu bulmakla kalmayıp hedef tipini sınıflandırma ve mümkün olması durumunda hedefi doğru olarak teşhis edebilme özelliğine sahip olmalarıdır.

Hedef tanıma ve sınıflandırma süreci alınan işaretin belirli bir hedefe özgü olduğu bilgisi olarak tanımlanmaktadır. İşaret işleme uygulamalarında sınıflandırma süreci arasında keskin çizgiler olmayan üç safhada gerçekleştirilmektedir. Birinci aşamada

farklı işaretlerin bir arada bulunduğu bir ortamda farklılıkların ayrıştırılması işlemi gerçekleştirilir. İkinci aşamada sınıflandırma işlemi ile ilgisiz olan işaretler elimine edilir. Üçüncü aşamada ise farklı işaretlerin ayrı gruplara atanması işlemleri gerçekleştirilir.

Sınıflandırmayı sağlayacak olan bilgi boyut, şekil, zamanlama, konum, manevra gibi çeşitli büyüklüklerin veya bu büyüklüklerinin değişimlerinin gözlenmesinden elde edilmektedir.

Bu bilgiler işaret işleme terminolojisinde *öznitelik* olarak adlandırılmaktadır. Hedefleri temsil edecek birer ‘kimlik kartı’ olduklarından özniteliklerin belirlenmesi hedef tanıma ve sınıflandırma sürecinde kilit bir öneme sahiptir.

Geçerli bir öznitelik ilişkin hedefi doğru biçimde temsil edebilme yeteneğine sahip olmalı, bozucu koşulların etkisi altında da tanınmayı sağlayabilmelidir. Öncelikler uygulamaya göre farklılık göstermektedir. Söz gelimi bazı uygulamalarda yanlış teşhis oranının çok düşük olması istenirken, bazı uygulamalarda sınıflandırma performansının ölçeklenme veya dönüş hareketine göre değişmeyen özellikte olması istenmektedir. Hızın kritik olduğu veya işlem gücü ve belleğin yetersiz olduğu durumlarda ise öznitelik boyutlarının mümkün olduğunca düşük olması tercih edilmektedir. Sonuç olarak uygun özneliğin seçimi sınıflandırma amacından bağımsız bir problem değildir.

Radar hedef tipleri genel olarak toplu ve dağılmış olarak ikiye ayrılmaktadır. Dağılmış hedef tipleri genel olarak bitki örtüsü (orman, deniz gibi), deniz üzerindeki cisimler (büyük gemiler) ve gazları (bulutlar vs.) modellemekte kullanılmaktadır. Toplu hedef tipleri ise sonlu sayıda nokta kullanarak modellenebilecek nokta hedef modeli ile temsil edilebilecek canlıları (insan, kuş gibi) ve insan yapısı cisimleri (füze, uçak, tank gibi) modellemekte kullanılmaktadır.

Hedef sınıflandırma uygulamalarında *çapraz-kesit alanları*, *menzil profilleri* ve *radar görüntüleri* doğrudan öznitelikler olarak kullanılabilir. Ancak bu durumda öznitelik vektörlerinin oluşturduğu öznitelik matrisinin boyutları çok büyüdüğünden işlem zamanı da çok artmaktadır [13].

Nokta hedef modeli ile temsil edilebilecek hedef tiplerini sınıflandırmaya yönelik olarak bir boyutlu menzil profillerinden veya iki boyutlu radar görüntülerinden

yararlanarak bulunan *saçıcı merkezler*den yararlanılarak oluşturulan öznitelikler de kullanılmaktadır [14,15]. Saçıcı merkezlerin kullanılmasının en önemli getirisi öznitelik matrisinin boyutlarının küçültülmesi olmaktadır.

Örneğin 128 noktalı bir menzil profili doğrudan öznitelik olarak kullanıldığında sanal ve gerçel kısımları düşünüldüğünde 256 kelime uzunluklu bir öznitelik vektörü oluşturmaktadır. Bu menzil profilinden en şiddetli 5 nokta saçıcının parametrelerinin öznitelik vektörünü oluşturması durumunda ise saçıcı menzilleri ve saçıcı şiddetlerinin sanal ve gerçel kısımlarından 15 kelime uzunluklu bir öznitelik vektörü oluşmaktadır. Dolayısıyla $(256-15)/256 \approx \% 94$ miktarında bir sıkıştırma elde edilmektedir.

Saçıcı merkezler iki boyutlu görüntülerden yararlanarak kestirildiğinde sıkıştırma oranı da artacaktır. Örneğin 128*128 boyutundaki bir radar görüntüsü 32768 kelime uzunluklu bir öznitelik vektörü oluşturmaktadır. En şiddetli 25 nokta saçıcının parametrelerinin öznitelik vektörünü oluşturması durumunda saçıcı menzilleri ve saçıcı şiddetlerinin sanal ve gerçel kısımlarından 75 kelime uzunluklu bir öznitelik vektörü oluşturulmaktadır. Böylece sıkıştırma oranı $(32768-75)/32768 \approx \% 99,77$ 'ye çıkmaktadır.

Saçıcı merkezlerin kestirimi konusu Bölüm 1.3'te detaylarıyla işlenmişti. Bahsi geçen tekniklerle kestirilen saçıcılardan oluşturulan öznitelik vektörlerinden yararlanılarak yapılacak sınıflandırma için çeşitli sınıflandırma yöntemleri kullanılabilir.

1.4.2 Uyumluluk Derecesi Yöntemi

Sınıflandırmada kullanılabilecek en basit sınıflandırma yolu hangi sınıfa ait olduğu bilinmeyen bir verinin hangi sınıfa ait olduğu bilinen verilerle karşılaştırılarak benzerlik ölçüsünün en yüksek olduğu sınıfa atanmasıdır. Sınıflandırmada kullanılan vektörlerin boyutunun aynı olması durumunda (1.49) ile tanımlanan normalize *ilişki katsayısı* benzerlik ölçüsü olarak kullanılabilir [16].

$$C(\vec{f}, \vec{g}) = \frac{\sum_{p=1}^P f[p]g^*[p]}{\sum_{p=1}^P |f[p]|^2 \sum_{p=1}^P |g[p]|^2} \quad (1.49)$$

Denklemden görülen $g^*[p]$, $g[p]$ vektörünün karmaşık eşleniğidir. Uyumluluk derecesi yönteminde iki öznitelik vektörü arasındaki bütün doğrusal kaydırmalar için ilişki katsayıları hesaplanır. Hesaplanan katsayılardan en yüksek değerde olanı iki vektörün *uyumluluk derecesi* adını alarak saklanır. Bu tanımdan yola çıkarak uyumluluk derecesi iki öznitelik vektörü arasındaki benzerliğin bir ölçüsüdür ve öznitelik vektörlerinin doğrusal kaydırmalarıyla değişmez niteliğe sahiptir.

Sınıflandırma aşamasında ilk olarak hangi sınıfa ait olduğu bilinen $g_{ij}[p]$ özniteliklerinden yararlanarak $\mathbf{G}$ matrisi oluşturulur. $g_{ij}[p]$ i . sınıfa ait j . öznitelik vektörünü ifade etmektedir. Bütün $g_{ij}[p]$ öznitelik vektörleri için $C(\mathbf{f}, \mathbf{g}_{ij})$ uyumluluk dereceleri hesaplanır. Uyumluluk derecesinin en büyük değerini gerçekleyen matris elemanının i indisi $\mathbf{f}$ vektörünün sınıfı olarak belirlenir.

Bu yol izlenerek bir boyutlu menzil profillerinden yararlanarak hedef sınıflandırılması şu şekilde gerçekleştirilmektedir: İlk aşamada $f[p]$ öznitelik vektörünü yaratan saçılan alanın menzil doğrultusuna göre hangi açı aralığında bulunduğu kestirilir. İkinci aşamada bu açı aralığındaki veri tabanında bulunan öznitelik vektörleri kullanılarak uyumluluk dereceleri hesaplanır. Hangi sınıfa ait olduğu bilinmeyen hedef en büyük uyumluluk derecesini gösterdiği sınıfa atanır.

1.4.3 Bayes Sınıflandırması

Bayes sınıflandırması literatürdeki temel sınıflandırma yöntemidir. Yöntem sınıflandırma problemini istatistiksel olarak modellemekte ve ilişkin olasılık değerlerinin ve olasılık dağılımlarının bilindiğini varsaymaktadır. Bu durum için Bayes sınıflandırıcısı en küçük hatalı sınıflandırıcıdır. Bayes sınıflandırıcısında sınıflama $g_i(\mathbf{x})$ *diskriminant fonksiyonları* yardımıyla yapılmaktadır [17].

Diskriminant fonksiyonları çok çeşitli biçimlerde oluşturulabilmekle beraber yaygın olarak kullanılan şekli (1.50)'deki gibidir.

$$g_i(\vec{x}) = \ln p(x | \omega_i) + \ln P(\omega_i) \quad (1.50)$$

Denklemden görülen ω_i değerleri her sınıfın ortaya çıkma durumudur. Ortaya çıkma olasılıkları eşit alınırsa $\omega = \omega_i$ yazılabilir. Sınıflandırıcıda $\mathbf{x}$ giriş vektörü için bütün $g(\mathbf{x})$ diskriminant fonksiyonları hesaplanır. $g_i(\mathbf{x})$ fonksiyon değeri bütün diğer $g_i(\mathbf{x})$ değerlerinden büyükse $\mathbf{x}$ vektörünün ω_i sınıfına ait olduğu kararı verilir. Bu şekilde

oluşturulan sınıflandırıcı *en büyük sonsal olasılık* (Maximum a posteriori probability, MAP) adını almaktadır.

Sonsal olasılığın hesaplanması için

$$p(\omega_i | \vec{x}) = \frac{p(\vec{x} | \omega_i) p(\omega_i)}{p(\vec{x})} \quad (1.51)$$

şeklinde verilen Bayes kuralı kullanılır. (1.51)'de görünen $p(\mathbf{x}|\omega_i)$ olasılığı *benzerlik fonksiyonu* adını almaktadır.

Karar verme kuralı benzerlik fonksiyonu notasyonu kullanılarak da oluşturulabilir.

$$p(\vec{x} | \omega_i) p(\omega_i) > p(\vec{x} | \omega_j) p(\omega_j) \quad j \neq i \quad (1.52)$$

(1.52) ile verilen durumun gerçekleşmesi durumunda $\mathbf{x}$ vektörünün ω_i sınıfına ait olduğu kararı verilir. Bu şekilde oluşturulan sınıflandırıcı *en büyük benzerlik* (Maximum likelihood, ML) adını almaktadır.

Bayes sınıflandırmasında olasılıkların modellenmesi için çok kullanılan bir dağılım türü çok değişkenli Gauss dağılımıdır. Bu dağılım

$$p(\vec{x}) = \frac{1}{\sqrt{(2\pi)^d |\mathbf{C}|}} e^{-\frac{1}{2}(\vec{x}-\vec{\mu})^T \mathbf{C}^{-1}(\vec{x}-\vec{\mu})} \quad (1.53)$$

eşitliği ile tanımlanmaktadır.

Denklemden görülmekte olan $\vec{\mu}$, d boyutunda ortalama vektörü, $\mathbf{C}$ ise $d \times d$ boyutundaki kovaryans matrisidir. (1.53) ile verilen çok değişkenli Gauss olasılık yoğunluk fonksiyonu (1.50) denkleminde yerleştirilirse diskriminant fonksiyonu

$$g_i(\vec{x}) = -\frac{1}{2}(\vec{x} - \vec{\mu}_i)^T \mathbf{C}_i^{-1}(\vec{x} - \vec{\mu}_i) - \frac{d}{2} \ln 2\pi - \frac{1}{2} \ln |\mathbf{C}_i| + \ln P(\omega_i) \quad (1.54)$$

olarak bulunur.

Bu şekilde tasarlanan bir Bayes sınıflandırması giriş örneklerinin normal dağılımlı olması durumunda optimal sınıflandırmayı yapacak, ancak diğer durumlarda sağlıklı sonuçlar vermeyecektir. Dolayısıyla sınıflandırıcının tasarlanırken kullanılan

öznitelik vektörlerinin mümkün olduğunca normal dağılıma uygun hale getirilmesi gerekmektedir.

1.4.4 Yapay Sinir Ağları

Sınıflandırma Bölüm 2.2’de ayrıntılarıyla anlatılacak olan yapay sinir ağlarının en önemli uygulama alanlarından biridir [18]. Bir önceki bölümde görüldüğü üzere Bayes sınıflandırıcısı test verilerine ilişkin tüm olasılık değerlerinin bilinmesini gerektirmektedir. MAP sınıflandırıcı modelinde diskriminant fonksiyonlarının maksimize edilmesine çalışılmakta, ML modelde ise önsel dağılım ve benzerlik fonksiyonunun çarpımı maksimize edilmeye çalışılmaktadır.

YSA konusu incelenirken görüleceği üzere bu iki farklı yaklaşım için iki farklı ağ modeli geliştirilmiştir. MAP yaklaşımını temel alan çok katmanlı perseptron ağlarında doğrudan bir diskriminant fonksiyonu aranmaktadır. ML yaklaşımını temel alan radyal tabanlı ağlarda ise diskriminant fonksiyonu önceden belirlenen bir fonksiyonun (Gauss fonksiyonu) ölçeklenmiş ve kaydırılmış hallerinin toplamı şeklinde modellenerek belirlenen fonksiyonun parametrelerini bulma işlemine indirgenmektedir.

2. EVRİMSEL ALGORİTMALAR VE YAPAY SİNİR AĞLARI

2.1 Evrimsel Algoritmalar

Evrimsel algoritmalar kökenlerini Charles Darwin'in evrim kuramından alan optimizasyon tekniklerinin genel ismidir. Evrim kuramı, en basit haliyle genç bireylerin yaşlı bireylerin yerini aldığı yaşamın zamanla değiştiği fikri üzerine kuruludur. Evrim fikrinin, Darwin'in zamanından çok daha önceden var olmasına rağmen kuram, 1859'da *Canlıların Kökeni (On the Origin of Species)* isimli kitabın yayınlanmasıyla birlikte, bilim camiası tarafından kabul edilmiş bir olgudur. İngiliz bilim adamı bu eserinde, çeşitli bitki ve hayvan türlerinin başka türlerden türemiş olduğunu, dinlerin veya yaratılışla ilgili efsanelerin belirttiği gibi çok eskiden ve birden bire yaratılmadığını ortaya koymuştur. Ernest Mayr'a göre evrim kuramı aşağıdaki beş temel fikri içermektedir [19]:

- Canlı dünyası durağan değildir, evrimsel değişim mevcuttur.
- Evrimsel değişim ağaç yapısındadır. Yapı içindeki herhangi bir canlı bir (veya bir kaç) atadan evrimleşmiştir.
- Yeni türler bir popülasyonun yalıtılmış parçalarının ayrışmasıyla ortaya çıkmaktadır.
- Evrimsel değişim aşamalı bir şekilde gerçekleşmektedir. Ebeveynlerden farklılık arttıkça yaşama şansı azalmaktadır.
- Uyarlamalı değişimi sağlayan olay doğal ayıklanmadır.

Günümüzde en sık kullanılmakta olan evrimsel algoritmalar genetik algoritmalar (GA'lar), evrimsel stratejiler (ES'ler) ve evrimsel programlama (EP) olarak adlandırılmaktadır. GA'lar 1975'te Holland tarafından, ES'ler 1973'te Rechenberg ve Schwefel tarafından, EP 1966'da Fogel, Owens ve Walsh tarafından

birbirlerinden bağımsız olarak geliştirilmiştir. Bütün bu yöntemler bugün yapay sinir ağlarını da içeren biyolojik fikirlerin bilgisayar bilimlerinde kullanımını öngören bir bilimsel disiplinin birer parçalarıdır.

Bu doğrultuda evrimsel algoritmaların genel olarak iki amaca hizmet ettikleri söylenebilir: canlıların doğaya uyum süreçlerini açıklayan bir matematiksel model çıkarmak ve bu model yardımıyla canlı sistemlerine öykünen yapay sistemler tasarlamak.

Evrimsel algoritmalar optimize edilecek problemin olası çözümlerini belirli sayıda canlı içeren bir nesil oluşturacak kromozomlara eşdeğer şekilde kodlar. DNA kopyalaması gibi biyolojik işlevler belirli matematiksel dönüşümlerle gerçekleştirilir. Uygun şekilde tanımlanmış bir hata fonksiyonu yardımıyla çaprazlama ve mutasyon işlemleri sonucunda yeni bir nesil oluşturulur.

2.1.1 Genetik Algoritmalar

1970’li yılların başlarında Michigan Üniversitesi’nde John Holland ve çalışma arkadaşları tarafından geliştirilen genetik algoritma tekniği, evrimsel algoritma türlerinin en çok bilinen türüdür [20]. Evrimsel algoritmalar arasında ilk olarak bu teknikle fiziksel problemlerin çözümünde başarılı sonuçlar elde edilmiştir. Holland’ın öğrencilerinden, GA’ların bir optimizasyon yöntemi olarak popülerleşmesinde büyük katkısı olan Goldberg, GA’ların klasik optimizasyon yöntemlerine göre (tüm evrimsel algoritmalar için genelleştirebileceğimiz) şu avantajlarının bulunduğunu ortaya koymaktadır [21]:

- GA’lar sürekli, ayrık veya karma değişken kümeleriyle çalışabilmektedir.
- GA’lar değişkenlerin kendileri değil, kodlanmış halleri olan kromozomlar üzerinden çalışmaktadır.
- GA’lar aynı anda tek bir noktada değil, aynı nesil içindeki bütün noktalarda optimizasyon gerçekleştirilmektedir.
- GA’lar optimizasyon için sadece hata fonksiyonu değerlerini kullanmaktadır, türevlenebilirlik, süreklilik gibi bilgilere ihtiyaç duymamaktadır.
- GA’larda deterministik değil, rastlantısal geçiş kuralları geçerlidir.

Genetik bilimi GA'ların temelini oluşturduğundan GA terminolojisi bu bilim dalından alınmış bir çok terim içermektedir. Bu terimlerin bazılarının açıklanması GA'ların daha iyi anlaşılması için yararlı olacaktır.

Genetik bilimi uyarınca bir organizmayı oluşturan hücrelerin her biri aynı *kromozom* setinden (DNA zincirleri) oluşmaktadır. Bir kromozom her biri belirli bir proteini kodlayan *gen*lerden meydana gelir. Kabaca bir genin ait olduğu canlının bir karakter veya fiziksel özelliğini (göz rengi gibi) temsil ettiği söylenebilir. Bu özelliğin olası değerleri (kahverengi, ela, mavi vs.) *alel* ismini almaktadır.

GA'larda *kromozom* optimize edilecek problemin olası bir çözümünü temsil eder. *Gen*ler her bir parametrenin kodlanmış şekilde temsil edildiği yapıdır. Holland'ın önerdiği GA yapısında genler ikilik tabanda bitlerden oluşan bir dizi olarak kodlanmaktadır. İkili kodlamada bir *alel* 0 veya 1 değerlerinden birini alabilmekteyen sürekli kodlamada gerçel sayı kümesinin herhangi bir elemanı olabilmektedir. En çok kullanılan bu iki algoritma türü ikili genetik algoritmalar (İGA) ve sürekli genetik algoritmalar (SGA) olarak adlandırılmaktadır.

GA'larda ilk aşamada tasarım probleminin içerdiği değişkenler N_{kr} uzunluğunda bir kromozom oluşturacak şekilde kodlanır. İlk nesil bir rasgele sayı üretici tarafından oluşturulur. Kromozom uzunluğu N_{kr} , birey sayısı N_{bir} ile belirlenirse oluşacak nesil için ($N_{kr} * N_{bir}$) elemanlı, satırların kromozomları ifade ettiği bir matris oluşturulması gerekecektir.

İlk neslin oluşturulmasını takiben, İGA kullanılıyorsa ikilik düzende ifade edilmiş satırlar tasarım değişkenlerini oluşturacak şekilde 10'luk düzene çevrilir ve hata fonksiyonun değeri hesaplanır, SGA kullanılması durumunda her gen bir tasarım değişkenine karşılık düştüğünden hata fonksiyonuna doğrudan yerleştirilebilir. Hata fonksiyonunun aldığı değerlerin hesaplanmasının ardından hangi bireylerin bir sonraki nesle aktarılacağı belirlenmesi gerekir. Evrim teorisinde bu durum *doğal ayıklanma* olarak adlandırılır. En sağlıklı bireyin yaşamını sürdürmesi prensibine dayanan doğal ayıklanma, canlıların hastalıklara, avcılara ve diğer olumsuz faktörlere karşı hayatta kalabilme becerisiyle ifade edilir. Genetik algoritmada ise değişkenlerin kodlanmış halleri olan 'canlıların' yaşamasına veya ölüp gitmesine hata fonksiyonu yardımıyla karar verilir. Hangi bireylerin bir sonraki nesle aktarılacağı sorunu değişik algoritmik yöntemlerle belirlenebilir. Bu yöntemlerin en kolay anlaşılabilir olanlarından biri ağırlıklı rulet çarkı yöntemidir. Bu yöntemde her

birey rulet çarkı üzerinde hata fonksiyonun aldığı değer ile orantılı büyüklükte bir parçayı kaplar. Bireylerin rulet çarkında alacağı paylar ilişkin hata fonksiyonu değerinin tüm hata fonksiyon değerlerinin toplamına bölünmesiyle bulunur.

Rulet çarkının hazırlanmasının ardından yeni neslin oluşturulması için N_{yn} adet bireyin seçilmesi gerekecektir. Bu amaçla rulet N_{yn} kez çevrilir ve hangi bireylerin bir sonraki nesle aktarılacağı belirlenir. Bu şekilde seçilen yeni bireyler ikinci neslin gen havuzunu oluşturur.

Yeni gen havuzunun oluşturulmasının ardından üremeyi sağlayacak çiftlerin seçilmesi gereklidir. Eş seçimi açıkta bir birey kalmayacak bir şekilde rastlantısal olarak yapılarak çiftler oluşturulur.


Üremeyi sağlayacak çiftlerin seçilmesiyle DNA replikasyonuna benzeyen bir şekilde çaprazlama işleminin gerçekleştirilmesi gerekecektir. Bu amaçla kromozom üzerinde rasgele bir gen pozisyonu seçilerek bu pozisyondan itibaren birinci eş ile ikinci eşin tüm genleri yer değiştirir. Böylece iki yeni birey oluşmuş olur.

Yeni neslin oluşturulmasında son olarak uygulanacak olan işlem mutasyondur. Mutasyon işleminin hem doğal genetikte hem de genetik algoritmada oynadığı rolün önemi hakkında kesin bir görüş birliği yoktur. Ancak önemi ne olursa olsun mutasyona ihtiyaç olduğu kaçınılmazdır, çünkü çaprazlama sonucunda oluşan bireyler ne de olsa bir önceki neslin genetik bilgisini taşımaktadırlar. Sadece mutasyon işlemi sonucunda (olumlu veya olumsuz) yeni genetik bilgi oluşturulabilir. İkili genetik algoritma için mutasyon işleminin basit bir gerçekleştirme yolu gen havuzu içindeki bazı genlerin tersini almak olacaktır. Bu amaçla İGA'da mutasyona uğrıtılacak gen 0 bilgisini taşıyor ise 1'e, 1 bilgisini taşıyor ise 0'a dönüştürülecektir. SGA'da ise genin değeri tanım aralığı içersinde rasgele bir değerle değiştirilir.

2.1.1.1 Sürekli Genetik Algoritma

Bir önceki bölümde görüldüğü gibi ikili genetik algoritma tasarım değişkenlerinin ikilik düzende kodlanmasını gerektirir. Bu da kuantalama hatasına yol açar. Kuantalama hatasının azaltılması için bit sayısı arttırılabilir, ancak bu da işlem zamanını arttıracaktır. Tasarım değişkenlerinin doğal olarak ayırık değerler aldığı problemler için ikili genetik algoritma (İGA) uygun olmaktadır. Değişkenler sürekli değerler alıyorsa kodlamanın gerçel sayılarla gerçekleştirildiği SGA, kuantalama

hatasını işlemcinin kelime uzunluğundan dolayı gerçekleşen kuantalama hatasına minimize eder. SGA'nın bir diğer avantajı da İGA'ya göre genlerin saklanması için daha az bellek gerektirmesidir [22]. Genel olarak sürekli parametrelili genetik algoritmanın optimizasyon başarımının ikili genetik algoritmaya göre daha yüksek olduğu söylenebilir. Sürekli genetik algoritmanın işleyişi Şekil 2.1'deki akış şeması ile temsil edilebilir.



Şekil 2.1: SGA akış şeması

Kromozom uzunluğunu N_{kr} , parametrelerin çözüm aralığının alt sınırı N_{as} , üst sınırı $N_{üs}$, birey sayısı N_{bir} parametreleriyle temsil edilmek üzere ilk nesil

$$İlknesil = (N_{üs} - N_{as}) * \text{rand}(N_{bir}, N_{kr}) + N_{as} \quad (2.1)$$

şeklinde oluşturulmaktadır. Bir sonraki aşamada hangi bireylerin bir sonraki nesle aktarılacağı probleminin çözülmesi gerekecektir. Ağırlıklı rulet yönteminin kullanılması durumunda her neslin oluşturulması için çark N_{bir} kez çevrilir. Çiftler ikiye ikiye gruplandırılarak çaprazlama işlemi tanımlanır.

SGA'da çaprazlama işleminin gerçekleştirilmesi için değişik yöntemler geliştirilmiştir. En çok kullanılan yöntemlerden biri kromozomlar üzerinde rasgele bir genin seçilerek $[0,1]$ arasında rasgele oluşturulan bir N_{cap} değeri yardımıyla anne ve babanın genlerinin karıştırılıp üremenin sağlanmasıdır.

Rasgele seçilmiş olan gen N_{yer} , çaprazlama işleminin uygulanacağı genlerdeki değişken değerleri N_{anne} ve N_{baba} , yeni oluşturulan bireylerin genleri $N_{çocuk1}$ ve $N_{çocuk2}$ olarak isimlendirilirse yeni bireyler

$$N_{çocuk1} = N_{anne} - N_{yer} * (N_{anne} - N_{baba}) \quad (2.2)$$

$$N_{çocuk2} = N_{anne} + N_{yer} * (N_{anne} - N_{baba}) \quad (2.3)$$

uyarınca oluşturulur.

Mutasyon işleminin her gen için ayrı ayrı uygulandığı durum ele alınırsa her gen için $[0,1]$ aralığında rasgele seçilen bir N_{ras} sayısının önceden seçilmiş bir N_{min} değerinden küçük olması durumunda, o genin değeri değişkenlerin izinli sınırları arasında N_{mut} sayısı ile değiştirilir.

$$N_{mut} = (N_{üs} - N_{as}) * \text{rand} + N_{as} \quad (2.4)$$

2.1.2 Evrimsel Programlama

Genetik algoritmalar, günümüzde elektromanyetik problemlerin optimizasyonunda yaygın olarak kullanılmaktadır. Ancak, literatürde hata fonksiyonunun yüksek derecede epistatik (tasarım parametrelerinin istatistiksel olarak ilintili) olması durumunda optimizasyon performansının yetersiz kaldığını gösteren çalışmalar bulunmaktadır [23].

Evrimsel programlamanın genetik algoritmalarından en büyük farklılığı GA’larda görülen çaprazlama ve mutasyon operatörlerinin işlevlerinin tek bir operatör yardımıyla gerçekleştirilmesidir. Evrimsel programlamanın sürekli parametrelili optimizasyon problemleri için uygulanmasında ilk aşamada ilk nesil SGA’ya benzer şekilde oluşturulur. SGA’dan farklı olarak kromozomlar tasarım parametreleri x_i ve tasarım parametrelerinin standart sapmaları S_i kullanılarak kodlanır. Mutasyon operatörü esnasında N_{bir} bireyden her biri strateji parametresi $S_{i'}$ ve tasarım parametreleri $x_{i'}$ ile verilen şekilde yeni bir birey oluşturmaktadır.

$$\begin{aligned} S_{i'} &= S_i e^{\left(\frac{1}{\sqrt{2n}} rand + \frac{1}{\sqrt{2n}} rand \right)} \\ x_{i'} &= x_i + S_{i'} rand \end{aligned} \quad (2.5)$$

Böylece gen havuzundaki eleman sayısı iki katına çıkmış olmaktadır. Bu bireylerin arasından hata fonksiyonu yardımıyla iyi performans gösteren yarısı seçilerek, kalan yarı ise öldürülerek bir sonraki iterasyon adımına geçilir.

2.2 Yapay Sinir Ağları

Yapay sinir ağları insan sinir sisteminden esinlenerek oluşturulmuş bilgi işleme elemanlarından (nöronlar) ve bu elemanlar arasındaki bağlantılardan oluşan bir yapı ve bu yapıda gerçekleşen öğrenme ve hatırlama algoritmalarından oluşan bir işlemsel modeldir [19].

YSA’nın hedefi problem çözme ve bilgi işleme görevini daha ‘insancıl’ bir şekilde gerçekleştirmektir. İnsan beyni YSA’lara göre çok daha karmaşıktır, dahası beyinde gerçekleşen fonksiyonlar hakkında detaylı bilgi sahibi de değiliz. Bu nedenle YSA’lar birebir insan beynini modellemek amacıyla değil, insan beynine özgü aşağıdaki karakteristik özelliklerini gerçekleştirme amacıyla oluşturulur:

- **Öğrenme ve adaptasyon:** İnsan beyninin karmaşık problemleri analiz edebilme yeteneği daha önceden sakladığı bilgiyi kullanarak karar verebilme ve yeni durumlara adapte yeteneğinden dolayıdır. Öğrenme sonucunda kazanılan bilgi sinapslarda (nöronlar arasındaki bağlantılar) saklanmaktadır.
- **Genelleme:** Beynin bir diğer yeteneği de geçmiş bilgileri kullanarak daha önce karşılaşılmayan yeni durumlar için de anlamlı cevaplar verebilmesidir.

- Paralel işleme: İnsan sinir sistemi 10^{14} m mertebesinde sinaptik bağlantılar oluşturmaktadır. Bu kadar çok bağlantıyı bir arada yürütebilme özelliği de beynin özelliklerinden biridir.

Bu kavramlardan yola çıkarak oluşturulan YSA yapıları dört parametre ile karakterize edilmektedir:

- Öğrenme algoritması
- Hatırlama algoritması
- Nöron tipi
- Nöron bağlantı mimarisi

Üç tür öğrenme algoritmasının varlığından bahsedilebilir:

1. Öğreticili

Öğreticili eğitim yönteminde eğitime örnekleri giriş örnekleri x ve istenen çıkış örnekleri y 'lerden oluşmaktadır. Eğitim YSA yapısının giriş örneklerine çıkış örneklerini $y = f(x)$ şeklinde ilişkilendirene kadar devam edecektir.

2. Öğreticisiz


Öğreticisiz eğitimde sadece giriş örnekleri x verilmektedir. YSA yapısı bu giriş örneklerinden oluşan küme üzerinden belirleyici nitelikleri keşfetmeye çalışır.

3. Takviyeli öğrenme

Takviyeli öğrenme öğreticili ve öğreticisiz öğrenimin özelliklerinin bir arada yer aldığı bir öğrenim şeklidir. Öğreticisiz öğrenimde olduğu gibi sadece giriş örnekleri verilmektedir. Ancak çıkışa müdahale edilerek çıkış istenilen şekle yaklaştıysa YSA yapısına 'ödül' verilerek o çıkışı çıkartan durum yapısı teşvik edilmektedir. Benzer şekilde istenmeyen bir çıkış bulundursa 'ceza' verilerek YSA'nın o çıkışı çıkartan yapıdan uzaklaşması sağlanmaktadır.

Hatırlama algoritmaları ise sisteme yeni bir $\mathbf{x}$ giriş vektörü tanıtıldığında giriş vektörünün $\mathbf{y}$ çıkışına yol açtığını ‘bildiği’ bir $\mathbf{x}$ vektörüne benzerliğini fark ettiği anda çıkış olarak $\mathbf{y}$ vektörüne benzeyen bir $\mathbf{y}$ vektörü üretmektedir.

YSA’larda yaygın olarak kullanılan nöron modeli McCulloch ve Pitts tarafından 1943 yılında önerilen modeldir [24]. Bu model Şekil 2.2’de temsil edilmektedir.



Şekil 2.2: McCulloch ve Pitts Nöron Modeli

Şekil 2.2’ye göre her nöron net fonksiyonu ve aktivasyon fonksiyonu olarak isimlendirilen iki bölümden oluşmaktadır. Net fonksiyonu ağ girişindeki işaretlerin nasıl birleştirileceğini belirlemektedir. Şekil 2.2’ye göre girişler w_i girişleri ile çarpılmakta ve toplanmaktadır.

$$u = \sum_{i=1}^N w_i x_i + w_0 \quad (2.6)$$


(2.6) denkleminde görülen w_0 parametresi aktivasyon fonksiyonu için eşik değerini sağlamaktadır.

Nöron çıkışı y ağ girişine doğrusal olmayan bir f fonksiyonu yardımıyla ilişkilendirilmektedir. Bu fonksiyon aktivasyon fonksiyonu olarak isimlendirilmektedir.

Çeşitli yapay sinir ağlarında farklı aktivasyon fonksiyonları kullanılmaktadır. En sık kullanılan aktivasyon fonksiyonları ve grafik gösterimleri Tablo 2.1 ve Şekil 2.3’te görülmektedir.

Tablo 2.1: Aktivasyon Fonksiyonları

Aktivasyon Fonksiyonu	Matematiksel İfade
Sigmoid	$f(u) = \frac{1}{1 + e^{-\frac{u}{T}}}$
Hiperbolik tanjant	$f(u) = \tanh\left(\frac{u}{T}\right)$
Eşik	$f(u) = \begin{cases} 1 & u > 0 \\ -1 & u < 0 \end{cases}$
Gauss	$f(u) = e^{-\frac{(u-m)^2}{\sigma^2}}$
Doğrusal	$f(u) = au + b$


**Şekil 2.3:** Aktivasyon fonksiyonları: (a) Sigmoid (b) Hiperbolik tanjant (c) Eşik (d) Gauss (e) Doğrusal

2.2.1 Çok Katmanlı Perseptron Modeli

Çok Katmanlı Perseptron modeli, 1958 yılında Rosenblatt tarafından geliştirilen Perseptron modelinin gelişmiş bir uyarlamasıdır [25]. Perseptron modelinde Şekil 2.2’de gösterilen doğrusal ağırlıklandırılmış net fonksiyonu ve eşik aktivasyon fonksiyonu ile modellenen tek bir nöron kullanılmaktadır.

Çok katmanlı perseptron yapısı nöronların tek bir yöne ilerleyen şekilde katmanlar oluşturacak şekilde dizilmesiyle oluşturulur. Yapı içindeki her nöron doğrusal olmayan bir aktivasyon fonksiyonu içermektedir. Genel olarak MLP yapısında kullanılan aktivasyon fonksiyonları sigmoid ve hiperbolik tanjant fonksiyonlarıdır. Tipik bir MLP yapısı Şekil 2.4’te gösterilmektedir. MLP yapısı giriş ve çıkışı doğrusal olmayan bir şekilde ilişkilendirmektedir.


Şekil 2.4’deki her daire ayrı bir nöron yapısını temsil etmektedir. Nöronlar katmanlar şeklinde dizilmişlerdir. Her bir katmandaki bir nöron bir sonraki katmandaki diğer bir nöronla bağlantı kurabilmekte, ancak bulunduğu katmandan daha önceki bir katmandaki bir nöronla bağlantı kuramamaktadır. Bu bağlantı şekli çevrimsel olmayan (acyclic) bağlantı olarak nitelendirilmektedir.



Şekil 2.4: Çok katmanlı perseptron yapısı

2.2.2 Radyal Tabanlı Ağ Modeli

Radyal tabanlı ağlar, radyal tabanlı aktivasyon fonksiyonları kullanan yapay sinir ağlarıdır [26]. Radyal tabanlı fonksiyonlar genel olarak $f(x-x_0) = f(r)$ formunda ifade edilebilen fonksiyonlardır. Bu tip fonksiyonlar bir x_0 noktasına göre simetri göstermektedirler. Bazı radyal tabanlı fonksiyon örnekleri Şekil 2.5’de görülmektedir.



Şekil 2.5: Radyal tabanlı aktivasyon fonksiyonları


Herhangi bir fonksiyon radyal tabanlı fonksiyonlar yardımıyla yaklaşık bir şekilde oluşturulabilir. Fonksiyonun yaklaşık ifadesi kullanılan farklı ölçeklerdeki kaydırılmış radyal tabanlı fonksiyonların ağırlıklandırılmış doğrusal birleşimleri şeklinde ifade edilebilir.

$$\hat{F}(x) = \sum_{i=1}^C w_i \phi\left(\frac{x - m_i}{\sigma_i}\right) \quad (2.7)$$

Bu fonksiyon Şekil 2.6’da gösterilen radyal temelli ağ yapısıyla gerçekleştirilebilir. Radyal tabanlı ağlarda eğitim süresince $x(k)$ girişinin istenen çıkış değerleri $d(k)$ ile belirlenmek üzere

$$\sum_{k=1}^K [d(k) - \hat{F}(x(k))]^2 \quad (2.8)$$

şeklinde belirlenen karesel hata fonksiyonunu minimize edilmelidir.



Şekil 2.6: Radyal tabanlı ağ örneği

2.2.2.1 Birinci Tipte Radyal Tabanlı Ağlar

Bu tipteki ağlarda (2.7)'deki radyal tabanlı fonksiyonda $C = k$ ve $m_i = x(i)$ olmak üzere ölçeklenme parametresi her radyal tabanlı fonksiyon için $\sigma_i = \sigma$ olacak şekilde sabit alınmaktadır. (2.8) fonksiyonu vektörlerin iç çarpımı şeklinde yeniden yazılırsa

$$\begin{bmatrix} \phi(\|x(k) - m_1\|) & \phi(\|x(k) - m_2\|) & \dots & \phi(\|x(k) - m_C\|) \end{bmatrix} \begin{bmatrix} w_1 \\ w_2 \\ \vdots \\ w_C \end{bmatrix} = d(k) \quad (2.9)$$

eşitliği elde edilir. K değerlerinin $1 \leq k \leq K$ olmak üzere bilinen bütün değerleri yerine konduğunda

$$\begin{bmatrix} \phi(\|x(1) - m_1\|) & \phi(\|x(1) - m_2\|) & \dots & \phi(\|x(1) - m_C\|) \\ \phi(\|x(2) - m_1\|) & \phi(\|x(2) - m_2\|) & \dots & \phi(\|x(2) - m_C\|) \\ \vdots & \vdots & \ddots & \vdots \\ \phi(\|x(K) - m_1\|) & \phi(\|x(K) - m_2\|) & \dots & \phi(\|x(K) - m_C\|) \end{bmatrix} \begin{bmatrix} w_1 \\ w_2 \\ \vdots \\ w_C \end{bmatrix} = \begin{bmatrix} d(1) \\ d(2) \\ \vdots \\ d(K) \end{bmatrix} \quad (2.10)$$

şeklinde bir matris eşitliği ortaya çıkmaktadır. $\Phi = \mathbf{w} \mathbf{d}$ şeklinde yazılabilecek bu ifadeden ağırlık vektörü $\mathbf{w}$

$$\mathbf{w} = \Phi^{-1} \mathbf{d} \quad (2.11)$$

eşitliği kullanılarak bulunabilir [25].

Uygulamada $x(k)$ örneklerinin birbirlerine yakın olması durumunda Φ tekil bir matris olacaktır. Bu durum ise $\mathbf{w}$ için kararsız bir çözüm ortaya çıkarmaktadır. Bu sorunun üstesinden gelmek için değişik yaklaşımlar bulunmaktadır. Bir yöntemde Φ matrisine küçük değerli bir $\lambda \mathbf{I}$ köşegen matrisi eklenmekte, $\mathbf{w}$ ağırlık katsayıları

$$\mathbf{w} = (\Phi + \lambda \mathbf{I})^{-1} \mathbf{d} \quad (2.12)$$

denkleminde hesaplanmaktadır. Bir diğer yaklaşımda $\|(\Phi \mathbf{w} - \mathbf{d})\|^2$ eşitliğini minimize edecek $\mathbf{w}_{LS}$ en küçük kareler çözümü aranmaktadır. Bu çözümü sağlayacak olan ağırlık katsayıları

$$\mathbf{w} = \Phi^+ \mathbf{d} \quad (2.13)$$

denkleminde hesaplanır. Φ^+ , Φ matrisinin genelleştirilmiş tersi (pseudoinverse) olmaktadır.

2.2.2.2 İkinci Tipte Radyal Tabanlı Ağlar

Bu tipteki ağlarda radyal tabanlı fonksiyon olarak

$$\phi(\|x - m\|) = e^{-\frac{\|x - m\|^2}{2\sigma^2}} \quad (2.14)$$

şeklinde belirlenen Gauss fonksiyonları alınmaktadır. Fonksiyonların ortalama ve varyansı giriş örneklerinin kümelenmesiyle bulunmaktadır. Bu şekilde oluşturulan ağ yapısı

$$\mathbf{G} = \begin{bmatrix} e^{-\frac{\|x(1)-m_1\|^2}{2\sigma_1^2}} & e^{-\frac{\|x(1)-m_2\|^2}{2\sigma_2^2}} & \dots & e^{-\frac{\|x(1)-m_C\|^2}{2\sigma_C^2}} \\ e^{-\frac{\|x(2)-m_1\|^2}{2\sigma_1^2}} & e^{-\frac{\|x(2)-m_2\|^2}{2\sigma_2^2}} & \dots & e^{-\frac{\|x(2)-m_C\|^2}{2\sigma_C^2}} \\ \vdots & \vdots & \ddots & \vdots \\ e^{-\frac{\|x(K)-m_1\|^2}{2\sigma_1^2}} & e^{-\frac{\|x(K)-m_2\|^2}{2\sigma_2^2}} & \dots & e^{-\frac{\|x(K)-m_C\|^2}{2\sigma_C^2}} \end{bmatrix} \quad (2.15)$$

olarak tanımlanmak üzere $\mathbf{w}^T \mathbf{G}_0 \mathbf{w} = \text{sabit}$ olma koşulu altında $\|(\mathbf{G} \mathbf{w} - \mathbf{d})\|^2$

büyükliğini minimize edecek $\mathbf{w}$ çözümü aranmaktadır.

Burada $\mathbf{G}_0$ matrisi $C \times C$ boyutunda olup

$$\mathbf{G}_0 = \begin{bmatrix} \frac{(m_1 - m_1)^2}{2\sigma_1^2} & \frac{(m_1 - m_2)^2}{2\sigma_2^2} & \dots & \frac{(m_1 - m_C)^2}{2\sigma_C^2} \\ e & e & \dots & e \\ \frac{(m_2 - m_1)^2}{2\sigma_1^2} & \frac{(m_2 - m_2)^2}{2\sigma_2^2} & \dots & \frac{(m_2 - m_C)^2}{2\sigma_C^2} \\ e & e & \dots & e \\ \vdots & \vdots & \ddots & \vdots \\ \frac{(m_C - m_1)^2}{2\sigma_1^2} & \frac{(m_C - m_2)^2}{2\sigma_2^2} & \dots & \frac{(m_C - m_C)^2}{2\sigma_C^2} \\ e & e & \dots & e \end{bmatrix} \quad (2.16)$$

olarak tanımlanmaktadır. Optimizasyon probleminin çözümü


$$\mathbf{w} = (\mathbf{G}^T \mathbf{G} + \lambda \mathbf{G}_0)^{-1} \mathbf{G}^T \mathbf{d} \quad (2.17)$$

şeklinde ifade edilebilir. λ parametresinin değeri sıfıra yaklaştıkça (2.17) ifadesindeki çözüm en küçük kareler anlamında çözüme yakınsamaktadır.


3. UYGULAMALAR

3.1 Saçılan Alanların Oluşturulması


Bu bölümde saçıcı merkezlerin öznitelik olarak kullanıldığı sınıflandırma yöntemlerinin sınıflandırma başarıları incelenecektir. Uygulama için ilk olarak saçılan alanların oluşturulması gerekmektedir. Saçılan alanlar fiziksel ölçüm sonucunda elde edilebileceği gibi bilgisayar ortamında yapay olarak da oluşturulabilmektedir. Kritik derecede hassas uygulamalarda yapay veri fırlatılan ve geri dönen ışın (shooting and bouncing ray) ve moment yöntemleri gibi karmaşık elektromanyetik hesaplama yöntemleri kullanılmaktadır. Bu tip yöntemlerle saçılan alanların oluşturulması son derece kapsamlı bir konu olduğundan tez çalışması dışında tutulmuştur. Sözü edilen yöntemlerin dışında nokta hedef modeli de yüksek frekans bölgesinde dar bant genişlikli saçılan alan verisinin oluşturulmasında kullanılabilir. Nokta hedef modelinde hedefin, saçıcılıkları frekanstan ve birbirlerinden bağımsız sonlu sayıda saçıcıdan oluştuğu varsayılmaktadır. Kolaylıkla uygulanabilmesi nedeniyle bu bölümde başarımları incelenen sınıflandırma algoritmalarında saçılan alanların oluşturulmasında nokta hedef modeli kullanılmıştır. Saçılan alanların oluşturulmasında ilk adım görüntülenecek cisim modellerinin elde edilmesidir. Yapay verinin oluşturulması için en uygun seçenek cisimlerin CAD modellerinden faydalanmaktır. Bu modeller, üzerinde yapılacak bazı değişikliklerle saçılan alanların oluşturulmasında kullanılabilecek bir hale getirilebilir. Bu çalışmada da saçılan alanların oluşturulması için CAD modellerinden yararlanılmaktadır. Hedef tipi olarak F-14, F-16, F-117 savaş uçakları ve C-5 kargo uçağı olmak üzere 4 uçak modeli kullanılmaktadır. Şekil 3.1’de sözü edilen hedef tipleri için tel kafes modelleri görülmektedir. C-5 kargo uçağının boyutları diğer uçaklara göre çok daha büyük olduğundan bu uçağın modeli diğer modellerle uyumlu hale gelecek şekilde küçültülmüştür.




(a) F-14



(b) F-16




(c) F-117




(d) C-5

Şekil 3.1: Uçak modelleri (Tel kafes)


Geri saçılan alanlar (1.16) ile verilen denklem üzerinden (1.17) uyarınca çeşitli ayırık frekans ve açı değerleri kullanılarak oluşturulacaktır. Saçıcıların kenar ve köşeler gibi süreksizlik ortamlarında yoğun olarak bulunduğu hareketle Şekil 3.1’de görülen modellerin dış çeperlerinin belirgin bir hale getirilmesi söz konusu olmaktadır. Bu amaçla Şekil 3.1’deki modeller ilk olarak Şekil 3.2’de görüldüğü gibi katı cisimlere çevrilmekte, ardından bir kenar belirleme süzgecinden geçirilmektedir. Bir sonraki aşamada ise süzgeçlenmiş resim 1 bit ile kodlanmaktadır. Bu şekilde elde edilen saçıcıların konumsal dağılımı Şekil 3.3’te görülmektedir.



(a) F-14



(b) F-16



(c) F-117




(d) C-5


Şekil 3.2: Uçak modelleri (Katı cisim)

Şekil 1.2'den görülebileceği gibi cisimlerin bütün olarak görüntülenebilmesi konum destek bölgesi içinde yer almalarını gerektirmektedir. (1.10) uyarınca oluşturulan saçılan alanların konum destek bölgesinin menzil eksenindeki kapladığı alan (1.17) ile verilen menzil çözünürlüğü Δ_x ile frekans örnek sayısı M 'nin çarpımı sonucu bulunur.


Konum destek bölgesinin çapraz menzil eksenindeki kapladığı alan benzer şekilde (1.20) ile verilen çapraz menzil çözünürlüğü Δ_y ile gözlem açısı örnek sayısı N 'nin çarpımı sonucu bulunmaktadır.




(a) F-14



(b) F-16



(c) F-117




(d) C-5


Şekil 3.3: Sařıcıların konumsal dağılımı

Simölasyonlarda frekans örneđ sayısı M ve gözlem açısı örneđ sayısı N 128 olarak alınmıştır. Dolayısıyla sařılan alanlar 128×128 boyutunda bir matris oluşturmaktadır. İlk olarak Şekil 3.3’de verilen sařıcıların konumsal dağılım şeması Şekil 3.4’te görüldüğü üzere 128×128 piksel boyutuna indirilir.

Şekil 3.4 uyarınca oluşturulan dağılımda her piksel bir menzile-çapraz menzile hücrelerine denk gelmektedir. Piksel değeri 1 olması durumunda temsil ettiğı hücrede bir sařıcı vardır, piksel değeri 0 ise sařıcı yoktur. Konumsal dağılım bölgesinin $10m \times 10m$ boyutunda olduğı varsayılmıştır.




(a) F-14



(b) F-16



(c) F-117



(d) C-5

Şekil 3.4: Saçıcıların 128*128 piksel boyutunda konumsal dağılımı

Bu varsayımdan menzil çözünürlüğü Δ_x ve çapraz menzil çözünürlüğü Δ_y

$$\Delta_x = \Delta_y = \frac{10}{128}m \approx 7,81cm \quad (3.1)$$

olarak bulunur. İşaret merkez frekansı $f_C = 10GHz$ olarak varsayıldığında iki saçıcı arasındaki minimum uzaklık işaret dalga boyu $\lambda_C = 3cm$ 'den fazla olduğundan saçıcıların birbirlerinden bağımsız olduğu varsayımı yapılabilir.

(3.1) uyarınca hesaplanan menzil çözünürlüğü sağlayacak işaret bant genişliği B

$$B = \frac{c}{2\Delta_x} \approx 1,92GHz \quad (3.2)$$

olarak hesaplanır. İşaret merkez frekansı $f_C = 10GHz$ olarak varsayıldığında (3.1) ile verilen çapraz menzil çözünürlüğünü sağlayacak gözlem açısı aralığı θ

$$\theta = \frac{c}{2f_C\Delta_y} \approx 0,19rad \approx 11,46^\circ \quad (3.3)$$

olmaktadır. Buradan $\Delta\theta$ açısı artırımı için

$$\Delta\theta = \frac{\theta}{128} \approx 0,09^\circ \quad (3.4)$$

değeri bulunur. Sonuç olarak sınıflandırmada kullanılacak saçılan alanlar (3.1) – (3.4) denklemleri kullanılarak 9,04 - 10,96 GHz frekans bandı ve $-5,73^\circ$ - $5,73^\circ$ açı aralığında 128 frekans ve 128 gözlem açısı örneği kullanarak oluşturulmaktadır.

3.2 Saçıcı Merkez Parametrelerinin Kestirimi

Sınıflandırma sonuçlarına geçilmeden önce çalışmada önerilen FFT başlangıç koşullu genetik tabanlı CLEAN algoritmasının saçıcı merkez parametrelerini yüksek çözünürlükle belirleyebildiği gösterilecektir. Bu amaçla Tablo 3.1’de parametreleri verilen saçıcılardan oluşan bir hedefin saçıcı merkezlerinin kestirilmesi problemi ele alınmıştır. Ölçüm değerlerinin oluşturulmasında kullanılan frekans bandı sınıflandırmada kullanılan saçılan alanların oluşturulmasına benzer şekilde 9,04-10,96 GHz olarak belirlenmiştir. Oluşturulan veriye sıfır ortalamalı, 10 dB’lik işaret gürültü oranı oluşacak şekilde beyaz Gauss gürültüsü eklenmiştir. Menzil çözünürlüğü $\Delta_x = 7,81cm$ olduğundan (3) ve (4) numaralı saçıcıların aynı menzil hücresinde bulunduğu görülmektedir. Bu nedenle FFT analizine dayanan yöntemlerle bu saçıcıların tek bir saçıcı olarak kestirilmesi söz konusu olmaktadır. Yüksek çözünürlüğün sağlanması için Tablo 3.2’de gösterilen sürekli genetik algoritma parametreleri ile SGA-CLEAN algoritması kullanılması durumunda saçıcı merkezler için bulunan değerler Şekil 3.5’de gösterilmiştir.

Tablo 3.1: Saçıcı Parametreleri


Saçıcı	Menzil [m]	Saçıcı Şiddeti
1	2	0,2+0,3j
2	4	0,5+0,5j
3	4,6	1
4	4,67	0,5+0,65j
5	8	0,3+0,4j

Tablo 3.2: SGA Parametreleri

Parametre	Değeri
Kromozom uzunluğu	3
Birey sayısı	250
Mutasyon oranı	%5
Nesil sayısı	150

Şekil 3.5 incelendiğinde SGA-CLEAN yönteminin FFT analizine dayanan yöntemlere göre saçıcı menzillerini daha yüksek çözünürlükle belirleyebildiği görülmektedir. Saçıcı şiddetlerinin kestirimindeki hata ise ölçüm değerlerine eklenen rasgele gürültü sonucu oluşmaktadır. Nesil sayısının arttırılması ile saçıcı şiddetleri de işlem süresinin arttırılması pahasına daha yüksek çözünürlükle kestirilebilir.

SGA-CLEAN yönteminde başlangıç değerleri olarak FFT temelli CLEAN yöntemiyle bulunan parametreler de kullanılabilir. Bu durum için SGA parametrelerinin Tablo 3.3'te gösterilen şekilde alınması durumunda saçıcı merkezler için bulunan değerler Şekil 3.6'da gösterilmektedir.




Şekil 3.5: SGA-CLEAN ile kestirilen saçıcı parametreleri

Tablo 3.3: SGA Parametreleri


Parametre	Değeri
Kromozom uzunluğu	3
Birey sayısı	250
Mutasyon oranı	%5
Nesil sayısı	15

Tablo 3.3’den görüldüğü gibi iterasyon sayısı 150’den 15’e indirilmiş, dolayısıyla işlem sayısında %90 oranında azalma olmuştur. Ancak iterasyon sayısındaki azalma kestirim performansını etkilememiştir. Şekil 3.6’dan FFT başlangıç koşullu SGA-CLEAN yönteminin hem yüksek çözünürlük sağladığı, hem de işlem süresini kısalttığı görülmektedir. Karşılaştırma amacıyla optimizasyon Tablo 3.3’deki SGA parametreleri kullanılarak başlangıç değerleri rasgele değerler verilen SGA-CLEAN yöntemiyle gerçekleştirildiğinde Şekil 3.7’de görüldüğü gibi (1) numaralı saçıcının

menzilin kestirilemediği, menzili kestirilen saçıcıların ise şiddetlerinin kestirimindeki hataların arttığı görülmektedir.




Şekil 3.6: FFT başlangıç koşullu SGA-CLEAN ile kestirilen saçıcı parametreleri




Şekil 3.7: SGA-CLEAN ile kestirilen saçıcı parametreleri

FFT başlangıç koşullu SGA-CLEAN yönteminin yüksek çözünürlük sağladığının gösterildiği bu örneğin ardından sınıflandırmada kullanılan saçılan alanlardan seçilen F-14 uçağının 0° açısındaki menzil profili incelenmiştir.

Şekil 3.8’de F-14 uçağının 0° açısındaki menzil profili ile birlikte FFT başlangıç koşullu SGA-CLEAN algoritması ile kestirilen $P = 16$ adet saçıcı görülmektedir. Şekil 3.9’da ise 10 dB’lik SNR oluşturacak şekilde toplamsal Gauss gürültüsü eklenmiş saçılan alandan yararlanarak oluşturulan menzil profili ile birlikte FFT başlangıç koşullu SGA-CLEAN algoritması ile kestirilen $P = 16$ adet saçıcı görülmektedir. 0,5512m, 0,8661m ve 7,4803m menzillerinde kestirilen zayıf saçıcılar yalancı saçıcılar olarak göze çarpmaktadır. Güçlü saçıcıların ise gürültüsüz duruma benzer şekilde kestirildiği görülmektedir. Buradan güçlü saçıcı merkezlerin rasgele gürültüye karşı görece olarak dayanıklı oldukları görülmektedir.




Şekil 3.8: F-14 uçağının 0° açısındaki menzil profili ve FFT başlangıç SGA-CLEAN algoritması ile kestirilen saçıcı parametreleri (gürültüsüz durum)




Şekil 3.9: F-14 uçağının 0° açısındaki menzil profili ve FFT başlangıç SGA-CLEAN algoritması ile kestirilen saçıcı parametreleri (gürültülü durum)

3.3 Sınıflandırma Sonuçları

Saçılan alanların Bölüm 3.1’de anlatıldığı şekilde oluşturulmasının ardından sınıflandırma işlemi Bölüm 1.4’te bahsedilen yöntemler kullanılarak gerçekleştirilebilir. Uygulama aşamasındaki basitlikten dolayı ilk olarak uyumluluk derecesi yöntemi ile elde edilen sınıflandırma sonuçlarına değinilecektir. İlk örnekte F14 uçağının 0° açısındaki menzil profili ile bütün uçakların $-2,15^\circ - 2,15^\circ$ açı aralığındaki 32 gözlem için $P = 16$ saçıcı merkezden yararlanarak oluşturulan menzil profilleri arasındaki uyumluluk derecesi incelenmiştir. Saçıcı merkezler FFT başlangıç koşullu SGA-CLEAN algoritması kullanılarak kestirilmiştir. Gürültüsüz durumda elde edilen sonuçlar Şekil 3.10’da, SNR = 10dB gürültü düzeyinde elde edilen sonuçlar Şekil 3.11’de görülmektedir. Şekil 3.10 ve Şekil 3.11 birlikte değerlendirildiğinde kestirilen saçıcı parametrelerinden yararlanarak oluşturulan menzil profillerinin hedefin belirli bir gözlem aralığında gürültülü durumda da doğru bir şekilde belirlenmesine olanak verdiği görülmektedir.



Şekil 3.10: F-14 uçağının 0° açısındaki menzil profili ile hedefler arasındaki uyumluluk değerleri sonuçları (gürültüsüz durum)



Şekil 3.11: F-14 uçağının 0° açısındaki menzil profili ile hedefler arasındaki uyumluluk değerleri sonuçları (gürültülü durum)

Şekil 3.10 ve 3.11’den görüldüğü gibi belirli bir açı aralığında tüm menzil profili yerine belirli sayıda kestirilen saçıcı merkez hedefi temsil etmek için yeterli olmaktadır. Bu bilgiden yola çıkarak sınıflandırma yöntemlerinde eğitim vektörleri olarak saçılan alan matrisinin tek sayılı satırlarından yola çıkılarak çekilen saçıcı merkezlerin oluşturduğu öznitelik vektörleri, test olarak saçılan alan matrisinin çift sayılı satırlarından yola çıkılarak çekilen saçıcı merkezlerin oluşturduğu öznitelik vektörleri kullanılmıştır.

Sınıflandırma için kullanılan $\mathbf{f}$ öznitelik vektörü kestirilen P sayıda saçıcı merkezin menzillerinin küçükten büyüğe doğru sıralanmasıyla oluşturulmaktadır. Bu şekilde oluşturulan öznitelik vektörü doğrusal kaydırmayla değişmez niteliğe sahiptir.

$$\vec{f} = [x_1 \quad x_2 \quad \cdots \quad x_P] \quad (3.5)$$

(3.5) ile tanımlanan şekilde oluşturulan öznitelik vektörleri kullanılarak sınıflandırma gerçekleştirilmiştir. YSA ve Bayes yöntemleriyle karşılaştırmalı olarak değerlendirilebilmesi amacıyla uyumluluk derecesi yöntemi tek sayılı satırlarla çift sayılı satırların uyumluluk derecesinin bulunması şeklinde değerlendirilmiştir. Çok katmanlı perseptron ağında gizli katmandaki nöron sayısı ampirik olarak kestirilen saçıcı sayısı P ’nin iki katı olarak alınmıştır. YSA ve Bayes yöntemlerinde girişler 0 ve 1 aralığına normalize edilmiştir. Bu nedenle MLP ağında sigmoid aktivasyon fonksiyonu, RBF ağında Gauss aktivasyon fonksiyonu alınmıştır. RBF ağ tipi olarak ölçeklenme parametresinin sabit olarak alındığı 1.tip ağ kullanılmıştır. YSA yöntemlerinde ortalama karesel hatanın minimize edilmesine çalışılmıştır.

İlk olarak sınıflandırma sonuçlarının kestirilen saçıcı merkez sayısı P ’ye göre değişimi incelenecektir. Saçıcı merkezlerin kestirimi için Prony, MUSIC, ESPRIT ve FFT başlangıç koşullu SGA-CLEAN yöntemleri kullanılmıştır. Model tabanlı yöntemler için model derecesi kestirilen saçıcı merkez sayısına eşit olarak alınmıştır. Sınıflandırma başarıları çok yakın olduğundan uyumluluk derecesi yönteminde sadece FFT başlangıç koşullu SGA-CLEAN yöntemi ile kestirilen saçıcı merkezler sınıflandırma için kullanılmıştır.

Tablo 3.4’te uyumluluk derecesi yöntemi, Tablo 3.5 ve Şekil 3.12’de Bayes sınıflandırıcısı, Tablo 3.6 ve Şekil 3.13’te çok katmanlı perseptron ağ yapısı, Tablo 3.7 ve Şekil 3.14’te radyal tabanlı ağ yapısı kullanılarak elde edilen sınıflandırma sonuçlarının kestirilen saçıcı merkez sayısı P ’ye göre değişimi görülmektedir.

Doğru sınıflandırma yüzdesi P_C (3.6) denklemi ile kullanılarak hesaplanmaktadır.

$$P_C = 100 * \frac{N_C}{N_T N_A} \quad (3.6)$$

Denklemde N_C doğru sınıflandırma sayısını, N_T hedef sayısını ve N_A test gözlem açısı sayısını ifade etmektedir.

Tablo 3.4: Uyumluluk derecesi yöntemi için doğru sınıflandırma yüzdesi P_C (gürültüsüz durum)

P	2	3	4	5	6	7	8
FFT-SGA-CLEAN	77,73	80,86	85,94	88,67	90,63	91,80	94,14


Uyumluluk derecesi yönteminde beklenildiği gibi kestirilen saçıcı sayısının artmasıyla sınıflandırma başarısı yaklaşık olarak doğrusal bir şekilde artmaktadır.

Tablo 3.5: Bayes sınıflandırıcısı için doğru sınıflandırma yüzdesi P_C (gürültüsüz durum)

P	2	3	4	5	6	7	8
Prony	71,09	75,39	87,11	85,55	80,08	85,94	89,45
MUSIC	77,73	87,11	90,63	88,28	86,33	81,64	87,11
ESPRIT	74,61	81,25	89,84	85,55	91,41	88,28	89,45
FFT-SGA-CLEAN	85,55	87,89	91,02	86,33	88,28	88,28	90,63
Ortalama	77,25	82,91	89,65	86,43	86,53	86,04	89,16

Tablo 3.5'ten çıkarılan önemli bir sonuç sınıflandırma başarısının kestirilen saçıcı merkez sayısı ile doğrusal olarak artmadığıdır. Üç yöntemde 4 saçıcı merkez kestirilerek yapılan sınıflandırma en başarılı sonuçları vermiştir.


Kestirim yöntemleri arasında genel olarak en başarısız sonucu Prony yönteminin, en başarılı sonuçları FFT başlangıç koşullu SGA-CLEAN yönteminin verdiği görülmektedir.



Şekil 3.12: Bayes sınıflandırıcısı için doğru sınıflandırma yüzdesi P_C (gürültüsüz durum)

Tablo 3.6: Çok katmanlı perseptron ağı için doğru sınıflandırma yüzdesi P_C (gürültüsüz durum)


P	2	3	4	5	6	7	8
Prony	73,83	79,30	87,11	84,38	83,60	88,67	87,5
MUSIC	82,81	91,02	90,63	91,41	89,84	85,55	88,28
ESPRIT	84,38	87,5	91,02	87,11	91,41	90,23	90,63
FFT-SGA-CLEAN	93,36	91,41	97,27	92,58	96,10	94,53	92,97
Ortalama	83,60	87,31	91,51	88,87	90,24	89,75	89,83



Şekil 3.13: Çok katmanlı perseptron ağı için doğru sınıflandırma yüzdesi P_C (gürültüsüz durum)

Tablo 3.7: Radyal tabanlı ağ için doğru sınıflandırma yüzdesi P_C (gürültüsüz durum)

P	2	3	4	5	6	7	8
Prony	73,05	78,13	86,33	86,72	80,08	91,02	87,5
MUSIC	87,89	89,84	91,41	94,14	89,84	87,11	89,06
ESPRIT	84,77	86,72	89,06	89,45	90,23	91,79	90,23
FFT-SGA-CLEAN	87,11	93,75	91,41	93,75	91,02	85,16	88,28
Ortalama	83,21	87,11	89,55	91,02	87,79	88,77	88,77



Şekil 3.14: Radyal tabanlı ağ için doğru sınıflandırma yüzdesi P_C (gürültüsüz durum)

Çok katmanlı perseptron ağı kullanılarak yapılan sınıflandırma sonuçlarından çıkarılacak en önemli sonuç FFT başlangıç koşullu SGA-CLEAN yönteminde gözlenen performans artışı olmaktadır.

MLP ve RBF ağları kendi içlerinde karşılaştırıldığında MLP ağında daha istikrarlı bir performans artışı olmakta, RBF ağında yüksek performans artışı görülen değerlerle performans artışının düşük kaldığı değerler birlikte bulunmaktadır.

Tablolarda görüldüğü gibi doğru sınıflandırma yüzdesi uyumluluk derecesi yöntemi haricinde kestirilen saçıcı sayısının artmasıyla beraber doğrusal olarak artmamaktadır. Saçılan alanların gürültüsüz değerleri üzerinden yapılan bu sınıflandırmada ortalama olarak en başarılı sonuçları veren yöntemin MLP ağı olduğu görülmüştür. 4 saçıcı merkez kestirilerek yapılan sınıflandırmanın Bayes sınıflandırıcısı ve MLP ağı kullanılması durumunda en başarılı sonuçları verdiği, RBF ağı kullanılması durumunda ise 5 saçıcı merkez kestirilerek yapılan sınıflandırmanın daha başarılı olduğu varılan yargılardan bir diğeridir.

Bir sonraki aşamada sınıflandırma başarısının gürültüye bağlı olarak değişimini izlemek amacıyla farklı düzeylerde işaret gürültü oranı oluşturacak şekilde toplamsal beyaz Gauss gürültüsü saçılan alanlara eklenmiş, sınıflandırma gürültülü veri üzerinden gerçekleştirilmiştir.


Kestirilen saçıcı sayısı $P = 4$ olarak sabit alınmak suretiyle Tablo 3.8’de uyumluluk derecesi yöntemi, Tablo 3.9 ve Şekil 3.15’te Bayes sınıflandırıcısı, Tablo 3.10 ve Şekil 3.16’da çok katmanlı perseptron ağ yapısı, Tablo 3.11 ve Şekil 3.17’de radyal tabanlı ağ yapısı kullanılarak elde edilen sınıflandırma sonuçlarının işaret gürültü oranı SNR’ye göre değişimi görülmektedir.

Tablo 3.8: Uyumluluk derecesi yöntemi için doğru sınıflandırma yüzdesi P_C (gürültülü durum)

$SNR[dB]$	-5	0	5	10	15	20
FFT-SGA-CLEAN	34,38	54,69	69,14	82,03	81,64	88,28

Tablo 3.9: Bayes sınıflandırıcısı için doğru sınıflandırma yüzdesi P_C (gürültülü durum)


$SNR[dB]$	-5	0	5	10	15	20
Prony	38,67	58,98	74,22	79,30	82,42	87,11
MUSIC	39,45	63,28	80,08	87,89	87,11	88,67
ESPRIT	41,80	62,11	78,91	83,60	82,42	87,11
FFT-SGA-CLEAN	59,76	72,65	76,95	82,03	87,11	86,33
Ortalama	44,92	64,26	77,54	83,21	84,77	87,31



Şekil 3.15: Bayes sınıflandırıcısı için doğru sınıflandırma yüzdesi P_C (gürültülü durum)

Tablo 3.10: Çok katmanlı perseptron ağı için doğru sınıflandırma yüzdesi P_C (gürültülü durum)


$SNR[dB]$	-5	0	5	10	15	20
Prony	40,23	55,86	71,10	82,03	82,42	84,77
MUSIC	50,78	69,70	79,30	83,98	87,5	89,84
ESPRIT	42,58	62,89	75,00	90,63	71,09	90,23
FFT-SGA-CLEAN	65,23	81,64	88,67	91,02	92,97	92,58
Ortalama	49,71	67,52	78,52	86,92	83,5	89,36



Şekil 3.16: Çok katmanlı perseptron ağı için doğru sınıflandırma yüzdesi P_C (gürültülü durum)

Tablo 3.11: Radyal tabanlı ağ için doğru sınıflandırma yüzdesi P_C (gürültülü durum)

$SNR[dB]$	-5	0	5	10	15	20
Prony	40,63	54,69	67,97	79,30	83,60	84,38
MUSIC	46,48	66,40	80,47	89,84	89,06	89,45
ESPRIT	43,36	62,5	80,08	84,38	87,89	89,06
FFT-SGA-CLEAN	58,60	82,42	88,28	88,67	89,06	90,23
Ortalama	47,27	66,5	79,2	85,55	87,4	88,28



Şekil 3.17: Radyal tabanlı ağ için doğru sınıflandırma yüzdesi P_C (gürültülü durum)

Tablo ve şekillerin incelenmesinden gürültülü veri için sınıflandırma yöntemlerinin birbirlerine yakın sonuçlar verdiği görülmektedir. Genel olarak Bayes sınıflandırıcısının başarımı diğer sınıflandırıcılara göre bir miktar zayıf kalmakta, MLP sınıflandırıcısının başarımı diğer sınıflandırıcılara göre bir miktar daha üstün olmaktadır. Saçııcı merkez kestirim yöntemleri arasında yapılacak bir sıralamada en kötü başarımı Prony algoritması gerçekleştirmekte, sırasıyla MUSIC ve ESPRIT algoritmaları daha yüksek sınıflandırma başarısı gerçekleştirmektedir. Gürültülü veri için sınıflandırma başarımı en yüksek olan yöntemin FFT başlangıç koşullu SGA-CLEAN yöntemi olduğu görülmektedir. Bu yöntemin kullanılması durumunda 128 uzunluklu menzil profili 4 saçıcı menzil parametresine indirgenmekte, dolayısıyla öznitelik uzayı $(128-4)/128 \approx \%97$ oranında bir sıkıştırmaya tabi olmaktadır. Bu sıkıştırma oranı için işaret-gürültü oranının 0dB mertebelerine düştüğü durumlar için bile etkin sınıflandırma imkânının olması yüksek çözünürlükle belirlenen saçıcı merkez parametrelerinin sınıflandırma için uygun öznitelikler oluşturduğunu göstermektedir.

4. SONUÇ VE ÖNERİLER

Tez çalışmasında saçıcı merkezler kullanarak hedef sınıflandırılması gerçekleştirilmeye çalışılmıştır. Çalışma iki temel alt bölüme ayrılmaktadır. Birinci bölümde saçılan alanlardan saçıcı parametrelerinin yüksek çözünürlükle kestirilmesi üzerinde durulmaktadır.

Saçıcı parametrelerinin kestirilmesi amacıyla saçılan alanları yüksek doğrulukla betimleyen harmonik işaret modeli temel alınmıştır. Bu işaret modeli için yüksek çözünürlük sağlayan yöntemler irdelenmiştir. Model tabanlı spektral kestirim yöntemlerinden Prony, MUSIC ve ESPRIT yöntemleri, iteratif yöntemlerden CLEAN yöntemi ve evrimsel yöntemlerden evrimsel tabanlı CLEAN yöntemi açıklanmış ve değinilen yöntemlerden yararlanarak oluşturulan karma bir yöntem önerilmiştir. Bu yöntemler uygulama bölümünde sonuçlar kestirim doğruluğu ve gürültüye duyarlılık parametreleri cinsinden yorumlanmıştır. Önerilen FFT başlangıç koşullu SGA-CLEAN yönteminin yüksek doğruluklu bir şekilde saçıcı merkez parametrelerini kestirebildiği görülmüştür.

Çalışmanın ikinci bölümünde yüksek çözünürlükle kestirilen saçıcı merkezlerin öznitelik vektörleri olarak belirlenmesiyle bir sınıflandırma problemi tanımlanmıştır. Sınıflandırma yöntemi olarak literatürde yer bulan üç farklı yaklaşım denenmiştir.

İlk olarak özilişki tabanlı uyumluluk derecesi yöntemi açıklanmış, bu yöntem kullanarak saçıcı parametrelerinin öznitelikler olarak belirlenmesi sınıflandırma performansının gürültüye karşılık değişimi incelenmiştir.

İkinci yöntem olarak Bayes sınıflandırma yöntemi açıklanmış, bu yöntemin özniteliklerle ilgili bütün olasılıkların bilinmesi durumunda optimum sınıflandırıcı olduğu ortaya konmuştur.

Üçüncü yöntemde ise yapay sinir ağları sınıflandırma için kullanılmaktadır. Yapay sinir ağ modeli olarak literatürdeki en temel ağlar olan çok katmanlı perseptron ağı ve radyal tabanlı ağlar tanıtılmış, bu yapılar sınıflandırmada kullanılmıştır. YSA’larda sınıflandırma performansı aktivasyon fonksiyonu, katman ve nöron sayısı gibi parametrelere bağlı olarak değişmektedir.

Sınıflandırma nokta hedef modeli kullanılarak saçılan alanlar üzerinden yapılmaktadır. Hedef sayısı üçü savaş uçağı biri kargo uçağı olmak üzere dört adettir. Saçılan alanlar 9,04 - 10,96 GHz frekans bandı ve $-5,73^{\circ}$ - $5,73^{\circ}$ açı aralığında 128 frekans ve 128 gözlem açısı örneği kullanarak oluşturulmaktadır. Eğitim için saçılan alan matrisinin tek sayılı satırları kullanılarak oluşturulan özvektörler, test için saçılan alan matrisinin çift sayılı satırları kullanılarak oluşturulan özvektörler kullanılmaktadır. Böylece özvektör uzayının %50’si eğitim, %50’si test için ayrılmış olmaktadır.

İlk sınıflandırma uygulamasında kestirilen saçıcı sayısı parametre olarak alınmıştır. Uyumluluk derecesi yönteminde sınıflandırma başarımı kestirilen saçıcı sayısı ile beraber artmaktadır. Ancak diğer yöntemlerde bu durum söz konusu değildir. İnceleme sonucu en yüksek sınıflandırma başarısının kestirilen saçıcı sayısının $P = 4$ olduğu durumda elde edildiği görülmüştür.

Optimum kestirilen saçıcı sayısının belirlenmesinin ardından sınıflandırma yöntemlerinin gürültülü durumdaki başarımı hesaplanmıştır. Bu durumda sınıflandırma yöntemleri arasında çok büyük farklılıklar olmamakla birlikte çok katmanlı perseptron ağının nispeten daha yüksek başarımı sağladığı görülmüştür.

Saçıcı merkez kestirim yöntemleri arasında çalışmada önerilen FFT başlangıç koşullu SGA-CLEAN algoritması diğer yöntemlere göre öne çıkmaktadır. Bu yöntemin özellikle gürültülü durumda Prony, MUSIC ve ESPRIT yöntemlerine göre bir üstünlüğü olduğu görülmüştür. Prony yöntemi sınıflandırma başarısı açısından en düşük değerleri vermiş, MUSIC ve ESPRIT algoritmalarının başarılarının birbirlerine yakın oldukları görülmüştür. Ayrıca YSA sınıflandırıcıları FFT başlangıç koşullu SGA-CLEAN yönteminin başarımını Prony, MUSIC ve ESPRIT yöntemlerine göre Bayes sınıflandırıcısından daha fazla arttırmaktadır. Sonuç olarak önerilen FFT başlangıç koşullu SGA-CLEAN yönteminin YSA sınıflandırıcılarıyla birlikte kullanılması durumunda optimum başarımın sağlandığı görülmüştür.

Saçılan alanların oluşturulmasında bilgisayar benzetimlerinde kullanılan nokta hedef modeli, cisimleri yüksek frekans bölgesinde yüksek doğrulukla temsil edebilmekle beraber, kullanılan algoritmaların performanslarının ölçülmüş saçılan alanlar da kullanılarak test edilmesinde yarar vardır.

Çalışmada sınıflandırma bir boyutlu saçıcı merkezler kullanarak gerçekleştirilmiştir. Sınıflandırmanın benzer performans gösterecek şekilde iki ve üç boyutlu saçıcı merkezler kullanarak da gerçekleşmesi ileri düzeyde bir araştırma konusudur.

KAYNAKLAR

- [1] **Soumekh, M.**, 1999. Synthetic Aperture Radar Signal Processing, Wiley, New York.
- [2] **Mensa, D.L.**, 1991. High Resolution Radar Cross-Section Imaging, Artech, Norwood.
- [3] **Chen, Q.**, 1996. Joint Time-Frequency Analysis - Methods and Applications, Prentice-Hall, Englewood Cliffs.
- [4] **Barton, D.K. and Leonov, S.A.**, 1998. Radar Technology Encyclopedia, Artech, Norwood.
- [5] **Marple, S.L.**, 1987. Digital Spectral Analysis, Prentice-Hall, Englewood Cliffs.
- [6] **Schmidt, R.O.**, 1986. Multiple Emitter Location and Signal Parameter Estimation, *IEEE Transactions on Antennas and Propagation*, **34**, 276-280.
- [7] **Manolakis, D., Ingle, V. and Kogon, S.**, 2000. Statistical and Adaptive Signal Processing, McGraw-Hill, Boston.
- [8] **Tsao, J. and Steinberg, R.D.**, 1988. Reduction of Sidelobe and Speckle Artifacts in Microwave Imaging: The CLEAN Technique, *IEEE Transactions on Antennas and Propagation*, **36(4)**, 543-556.
- [9] **Bose, R., Freedman, A. and Steinberg, R.D.**, 2002. Sequence CLEAN: A Modified Deconvolution Technique for Microwave Images of Contiguous Targets, *IEEE Transactions on Aerospace and Electronic Systems*, **38(1)**, 89-97.

- [10] **Choi, I.-S. and Kim, H.-T.,** 2001. One-dimensional Evolutionary Programming-based CLEAN, , *Electronics Letters*, **37(6)**, 400-401.
- [11] **Choi, I.-S. and Kim, H.-T.,** 2003. Two-dimensional Evolutionary Programming-based CLEAN, , *IEEE Transactions on Aerospace and Electronic Systems*, **39(1)**, 373-382.
- [12] **Gültekin, Ö., Erer, I., and Günel, T,** 2004. A New Approach to the CLEAN Algorithm for the Estimation of Scattering Centres in Radar Imaging, *IEEE International Conference of Applied Electronics*, Plzen, September, 52-55
- [13] **Potter L. and Moses, R.L.,** 1997. Attributed Scattering Centers for SAR ATR, *IEEE Transactions on Image Processing*, **6(1)**, 79-91.
- [14] **Kim, K.-T. and Kim, H.-T.,** 1999. One-dimensional Scattering Center Extraction for Efficient Radar Target Classification, *IEE Proceedings on Radar, Sonar and Navigation*, **146(5)**, 147-158.
- [15] **Kim, K.-T., Seo, D.-K. and Kim, H.-T.,** 2001. Radar Target Identification Using One-dimensional Scattering Centers, *IEE Proceedings on Radar, Sonar and Navigation*, **148(5)**, 285-296.
- [16] **Li, H.-J., Chiou, V.,** 1993. Aerospace Target Identification-Comparison Between the Matching Score Approach and the Neural Network Approach , *Journal of Electromagnetic Waves and Applications*, **7(6)**, 873-893.
- [17] **Duda, R.O., Hart, P.E. and Stork, D.G.,** 2001. Pattern Classification, Wiley, New York.
- [18] **Choi, I.-S., Seo, D.-K., Bang, J.-K., Kim, H.-T. and Rothwell, E.J.,** 2003. Radar Target Recognition Using One-Dimensional Evolutionary Programming-Based CLEAN, *Journal of Electromagnetic Waves*,, **17(5)**, 763-784.
- [19] **Wilson, R.A. and Keil, F.C.,** 1999. The MIT Encyclopedia of the Cognitive Sciences, MIT Press, Cambridge.

- [20] **Holland, J.H.**, 1975. Adaptation in Natural and Artificial Systems, The University of Michigan Press, Ann-Arbor.
- [21] **Goldberg, D.E.**, 1989. Genetic Algorithms in Search, Optimization and Machine Learning, Addison-Wesley, Reading.
- [22] **Haupt, R.L. and Haupt, S.L.**, 1998. Practical Genetic Algorithms, Wiley, New York.
- [23] **Chellapilla, K. and Hoorfar, A.**, 1998. Evolutionary Programming: an Efficient Alternative to Genetic Algorithms for Electromagnetic Optimization, *IEEE Antennas and Propagation Society International Symposium*, June, 42-45.
- [24] **Freeman, J.A. and Skapura, D.M.**, 1999. Neural Networks: Algorithms, Applications and Programming Techniques, CRC Press, Boca Raton.
- [25] **Hu, Y.H. and Hwang, J.N.**, 1991. Handbook of Neural Network Signal Processing, Addison-Wesley, Reading.
- [26] **Aşık, U.**, 2003. Cisimlere Ait Bilgilerin Elektromanyetik Veri Yardımıyla Belirlenmesinde Genetik ve Wavelet Tabanlı Yapay Sinir Ağ Yaklaşımı, *Yüksek Lisans Tezi*, İ.T.Ü. Bilişim Enstitüsü, İstanbul.

ÖZGEÇMİŞ

Yazar Aralık 1977 Üsküdar doğumludur. İlköğrenimini Üsküdar Paşakapısı İlkokulu, ortaöğrenimini İstanbul Alman Lisesi'nde tamamlamıştır. Haziran 2003'te İstanbul Teknik Üniversitesi'nden Elektronik ve Haberleşme Mühendisi unvanıyla mezun olmuştur. İyi derecede İngilizce, Almanca, Fransızca, İspanyolca; orta derecede İtalyanca bilmektedir.