




TÜRKİYE BİLİMSEL VE
TEKNİK ARAŞTIRMA KURUMU

THE SCIENTIFIC AND TECHNICAL
RESEARCH COUNCIL OF TURKEY

DuP

2001/63



Elektrik, Elektronik ve Enformatik Araştırma Grubu

Electric, Electronics and Informatics Research
Grant Committee

**UZAKTAN ALGILANAN VERİLERDEN
HEDEF / NESNE TANIMA**

PROJE NO: 197E036 (EEEAG-BİLTEN -241)

TÜBİTAK – BİLTEN GÜDÜMLÜ ARAŞTIRMA PROJESİ

DOÇ. DR. GÖNÜL TURHAN SAYAN

**TEMMUZ 2000
ANKARA**

ÖZET

Uzaktan algılanan elektromanyetik işaretleri kullanarak hedef/nesne tanıma problemi üzerinde çalıştığımız bu projede, Yapay Sinir Ağları, Zaman-Frekans Dönüşüm Teknikleri, Genetik Algoritmalar, elektromanyetik saçınım hesaplama yöntemleri ve elektromanyetik hedeflerin doğal rezonans tepkelerini sönmümlendirme esasına dayalı K-Darbe tasarım teknikleri kullanılmıştır. Projede üretilen sonuçların büyük bir kısmı özgün sonuçlar olup, bir bölümü uluslararası hakemli bir dergide yayınlanmış, diğer bölümleri de uluslararası hakemli konferanslarda sunulmuştur. Proje, Orta Doğu Teknik Üniversitesi, Mühendislik Fakültesi, Elektrik ve Elektronik Mühendisliği Bölümü öğretim üyesi Doç. Dr. Gönül Turhan Sayan tarafından Türkiye Bilimsel ve Teknik Araştırma Kurumu, Elektrik Elektronik ve Enformatik Araştırma Grubu (TÜBİTAK-EEEAG) denetiminde yürütülmüş, Bilgi Teknolojileri ve Elektronik Araştırma Enstitüsü (BİLTEN) bütçesinden desteklenmiştir.

İÇİNDEKİLER

ÖNSÖZ.....	i
İÇİNDEKİLER.....	ii
TABLolar.....	iv
ŞEKİLLER.....	v
ÖZ.....	vii
ABSTRACT.....	viii
1. GİRİŞ.....	1
1.1 Konu.....	1
1.2 Amaç.....	1
1.3 Kapsam.....	1
1.4 Konunun Literatürdeki Yeri, Önceliği ve Önemi.....	2
1.5 İncelenen Parametreler ve İzlenen Yöntem.....	3
1.6 Proje Önerisinde Tanımlanan Çalışma İle Gerçekleştirilen Çalışmaların Karşılaştırılması.....	4
2. GELİŞME.....	5
2.1 Hedef veri tabanlarının oluşturulması.....	5
2.1.1 Mükemmel İletken Küreler İçin Veritabanı Oluşturulması.....	6
2.1.2 Mükemmel İletken Silindirik İnce Tel İçin Veritabanı Oluşturulması.....	6
2.1.3 Mükemmel İletken Model Uçaklar İçin Veritabanı Oluşturulması.....	6
2.1.4 Dielektrik Küreler İçin Veritabanı Oluşturulması.....	7
2.1.5 Dielektrik Kaplı İletken Küreler İçin Veritabanı Oluşturulması.....	9
2.2 Zaman-Frekand Dönüşüm Tekniklerinin Öznitelik Çıkarımında Kullanılması...10	
2.2.1 Wigner Dönüşümü (WD).....	11
2.2.2 WD Hesaplamaları İçinYazılım Çalışmaları ve Uygulamalar.....	12
2.2.3 WD Kullanılarak İletken Küreler İçin Öznitelik Vektörlerinin Çıkarımı.....	15

2.2.4	WD Kullanılarak İletken Model Uçaklar İçin Öznitelik Vektörlerinin Çıkarımı.....	17
2.3	Akıllı Hedef Tanıma Yönteminin Karmaşık İletken Hedeflere Uygulanması.....	20
2.3.1	Benzetim Problemi 1.....	20
2.3.2	Benzetim Problemi 2.....	21
2.3.3	Benzetim Problemi 3.....	22
2.3.4	Yorum.....	26
2.4	Akıllı Hedef Tanıma Yönteminin Karmaşık Şekilli İletken Hedeflere Uygulanması.....	26
2.4.1	Benzetim Problemi 4.....	26
2.4.2	Benzetim Problemi 5.....	28
2.4.3	MLP ve SOM tipi Öznitelik Tabanlı Hedef Tanıyıcıların Karşılaştırılması.....	30
2.4.4	Ana Bileşen Analizi (Principal Component Analysis -PCA) Yöntemi İle Hedef Sınıflandırma.....	30
2.5	K-Darbe Hedef Tanıma Yöntemi.....	33
2.5.1	K-Darbe Yönteminde Ana Fikir ve Tanımlar.....	33
2.5.2	K-Darbe Tasarımında Matematiksel Model, Optimizasyon ve Hedef Tanıma.....	36
2.5.3	K-Darbe Tasarım Örnekleri (Benzetim Problemleri 6, 7 ve 8).....	39
2.5.4	K-Darbe Tasarımında Birden Fazla Görüş Açısı ya da Polarizasyonda Veri Kullanılması.....	48
3.	SONUÇ.....	49
	YARARLANILAN KAYNAKLAR.....	53
	EKLER	
A.	UYGULAMA ÖZETİ.....	55
B.	BİBLİYOGRAFİK BİLGİ FORMU.....	57
C.	PROJE İLE İLGİLİ YAPILAN YAYINLAR.....	58

TABLOLAR

- Tablo 1.** MLP ve SOM Hedef Sınıflandırıcı benzetimlerinde eğitim amacı ile ve sadece test amacı ile kullanılan saçınım sinyallerinin "bistatik" açılı ve polarizasyonları (HP: yatay polarizasyon, VP: dikey polarizasyon).....21
- Tablo 2.** MLP Hedef Sınıflandırıcı, Öznitelik Tabanlı MLP Hedef Sınıflandırıcı ve Öznitelik Tabanlı SOM Hedef Sınıflandırıcı performanslarının çeşitli küre veri tabanları bazında karşılaştırılması.....25
- Tablo 3.** Model uçaklara ait hedef sınıflandırıcı benzetimlerinde eğitim amacı ile ve sadece test amacı ile kullanılan dikey polarizasyonlu geri saçınım sinyallerinin görüş açıları (derece cinsinden ve uçakların burnundan ölçülmek üzere).....27
- Tablo 4.** MLP, SOM ve PCA yöntemleri ile model uçak hedefleri sınıflandırmaya ilişkin performans karşılaştırma tablosu..... 32

ŞEKİLLER

Şekil 1. Dielektrik bir küre.....	7
Şekil 2. Dielektrik bir materyalle kaplı mükemmel iletken bir küre.....	10
Şekil 3. Düz, ince, silindirik iletken telin 30 derece görüş açısındaki gerisaçılmış dürtü tepkesi.....	14
Şekil 4. Şekil 3'de görülen dürtü tepkesine ait Wigner Dönüşümünün zaman bantları üzerinde entegre edilmiş izdüşümsel grafiği (contour plot).....	14
Şekil 5. 10 inç yarıçaplı mükemmel iletken küreden 120 derece "bistatic" açıda hesaplanan saçınım verileri ve bu sinyalden çıkarılan öznelik verileri.....	16
Şekil 6. Hedef A ve Hedef C' ye ait 45 derecede ölçülen geri saçınım verileri.....	18
Şekil 7. Hedef A ve Hedef C' ye ait 45 derecede ölçülmüş geri saçınım verilerinden hesaplanan ve (-4 Ghz , 4 Ghz) ile (3.660ns.-5.856 ns.) zaman-frekans bölgelerine karşılık gelen öznelik vektörleri.....	19
Şekil 8. A, B, C ve D mükemmel iletken kürelerine ilişkin kümeleşme bölgelerini gösteren 10X10' luk SOM Haritası. #: Eğitim veri tabanına ilişkin kazanan nöronlar *: Test veri tabanına ilişkin kazanan nöronlar.....	25
Şekil 9. 225 Nörondan oluşan ve A, B, C, D ve E hedeflerine ait kümelenme bölgeleri ile hiç bir hedefe ait olmayan nötral bölgeleri (taranmış) gösteren SOM haritası. (#) Eğitim aşamasındaki kazanan nöronlar (*) Yeni verilerle test aşamasındaki kazanan nöronlar.....	29
Şekil 10. Yarıçapı 1 metre, kırılma endeksi 2 olan kayıpsız dielektrik küre için elde edilen K-darbe sinyali.....	39
Şekil 11. Kırılma endeksi n=2 olan kürenin 90 derece bistatik görüş açısında hesaplanan dürtü tepkesi ve K-darbe tepkesi.....	40
Şekil 12. Kırılma endeksi n=2 olan kürenin 135 derece bistatik görüş açısında hesaplanan dürtü tepkesi ve K-darbe tepkesi.....	41
Şekil 13. Kırılma endeksi n=2 olan kürenin 135 derece bistatik görüş açısında hesaplanan dürtü tepkesinin ve K-darbe tepkesinin geç-zaman dilimindeki detayları.....	42

Şekil 14. Kırılma indeksi $n = 2$ olan kürede mükemmel iletken kürenin çok küçük olması ya da dielektrik kaplamasının çok ince olduğu özel durumlar.....	43
Şekil 15. Dielektrik kaplı mükemmel iletken küre_ ($n = 2$ ve $r_{in} / r_{out} = 0.5$) için tasarlanan K-darbe sinyali.....	44
Şekil 16. $n=2$ ve $r_{in} / r_{out} = 0.5$ değerlerine sahip kürenin geri saçılım durumu için (0 derece) hesaplanan dürtü tepkisi ve K-darbe tepkisi.....	44
Şekil 17. Dielektrik kaplı mükemmel iletken küre_ ($n = 2$ ve $r_{in} / r_{out} = 0.8$) için tasarlanan K-darbe sinyali.....	45
Şekil 18. $n=2$ ve $r_{in} / r_{out} = 0.8$ değerlerine sahip kürenin geri saçılım durumu için (0 derecede) hesaplanan dürtü tepkisi ve K-darbe tepkisi.....	45
Şekil 19. Dielektrik kaplı mükemmel iletken kürenin_ ($n = 4$ ve $r_{in} / r_{out} = 0.8$) K-darbe sinyali.....	46
Şekil 20. $n=4$ ve $r_{in} / r_{out} = 0.8$ değerlerine sahip kürenin geri saçılım durumu için (0 derece) hesaplanan dürtü tepkisi ve K-darbe tepkisi.....	46

ÖZ

Bu proje kapsamında, kuramsal ve uygulamalı olarak incelenerek geliştirilen iki farklı elektromanyetik hedef / nesne tanıma tekniği üzerinde çalışılmış, gerçekçi hedef tanıma senaryoları bilgisayar ortamında gerçekleştirilen benzetimler yoluyla test edilmiştir. İncelenen tekniklerden ilki olan, Yapay Sinir Ağları yardımı ile hedef tanıma tekniğinde Çok Katlı Perseptron ve Öz Örgütlemeli Harita tipi sinir ağları kullanılmış ve sinir ağlarının eğitiminde kullanılan hedef verilerine ait öznitelik vektörleri Zaman-Frekans Dönüşüm teknikleri kullanılarak elde edilmiştir. İkinci olarak incelenen K-Darbe yardımı ile hedef tanıma tekniğinde ise, ait olduğu elektromanyetik hedefi uyarılma açısı ve polarizasyonundan bağımsız olarak tarifleyebilen, zamanda sınırlı bir K-Darbe uyarım işaretinin Genetik Algoritma teknikleri kullanılarak tasarlanması hedeflenmiştir. Dayandıkları teorik esaslar ve kullandıkları ana yöntemler bakımından birbirinden çok farklı olan bu iki tekniğin ortak üstünlüğü gerçek-zaman hedef-tanıma sistemlerinde kullanılabilme potansiyellerinin yüksek olmasıdır.

Anahtar Sözcükler: Elektromanyetik saçınım, Hedef tanıma, Öznitelik çıkarımı, Zaman-Frekans dönüşümleri, Yapay sinir ağları, Genetik algoritmalar, K-Darbe tekniği.

ABSTRACT

In this project, two different electromagnetic target / object identification techniques have been theoretically studied, developed and applied to realistic problems via computer simulations. The first technique is based on the use of Artificial Neural Networks which are trained by feature vectors extracted from a multi-target database using Time-Frequency transformations. Two different types of neural networks, the Multi Layer Perceptrons and the Self Organizing Maps, are used in this context. The second target identification technique which is based on the K-Pulse method, aims that a time-limited excitation signal is designed for each target in the identification class to represent the target in an aspect and polarization independent manner. This signal, called the K-Pulse signal, is designed by using the Genetic Algorithm approach. These two target identification techniques are quite different from each other in terms of the theory that they are based on and the methods that they use, but they have the common superiority of being compatible with real-time target recognition systems.

Key Words: Electromagnetic scattering, Target identification, Feature extraction, Time-Frequency transformations, Artificial neural networks, Genetic algorithms, K-Pulse technique.

1. GİRİŞ

1.1 KONU: Bu projenin konusu, gerçek zamanda yüksek tanıma hızına sahip iki ayrı elektromanyetik hedef / nesne tanıma yönteminin incelenmesi, kuramsal açıdan geliştirilmesi ve uygulanmasıdır. Yapay Sinir Ağlarının (YSA) kullanıldığı "Akıllı Hedef Tanıma Yöntemi" ve hedef tepkesindeki doğal salınımların sönmümlendirilmesi esasına dayalı "K-Darbe Hedef Tanıma Yöntemi" olarak adlandırdığımız bu yöntemlerin her ikisinde de, elektromanyetik saçınım verileri girdi olarak kullanılmıştır. Bu verilerden hedefe ait ayırıcı özelliklerin, diğer bir deyişle "öznitelikler" in çıkarılması işlemi, görüntü işleme yöntemleri kullanılmaksızın gerçekleştirilmiştir.

1.2 AMAC : Zamanın önemli bir kısıt olmadığı durumlarda, bir elektromanyetik hedef/nesne tanıma sistemini değerlendirirken kullanılan başlıca performans kriteri tanımadaki doğruluk oranıdır. Oysa ki, bir çok askeri ve sivil uygulamada tanıma hızı da en az tanıma doğruluğu kadar önemlidir. Bu projenin ana amacı, gerçek zamanda hızlı hedef tanımayı gerçekleştirebilen ve bölüm 1.1 de tanımlanan belli başlı iki elektromanyetik hedef tanıma yöntemi çerçevesinde

- (i) Elektromanyetik ters problemin modellenmesi,
- (ii) Verilerin uygun biçimlerde işlenip hedef tanımlayıcı özelliklerin çıkarılması,
- (iii) Otomatik hedef tanıma/sınıflandırma işleminin gerçekleştirilmesi

konularında araştırmaların derinleştirilmesidir.

Proje öneri aşamasından bu yana, bu araştırmaların sonucuna ilişkin uluslararası yayınların gerçekleştirilmesi de projenin amaçları arasındaydı. Bu amaç doğrultusunda, elde edilen sonuçlar, literatürde eksikliği gözlenen ve uygulamalara doğrudan etkisi olabilecek bazı problemlere çözüm getirmiş ve uluslararası yayınlar çerçevesinde sunulmuştur.

1.3 KAPSAM : Konu ve amaç bölümlerinde de belirtildiği gibi, akıllı hedef tanıma yöntemleri ve K-darbe hedef tanıma yöntemleri ile ilgili özgün sonuç üretmeye yönelik modelleme ve bilgisayar ortamında benzetim çalışmaları bu projenin kapsamına girmektedir. Araştırma sonuçlarının doğrulanması ve yöntemlerin uygulamaya geçirilebilmesi için gerekli olan veriden özellik çıkarma, YSA eğitime ve test etme programları ile K-darbe sentezleme,

ve K-darbe ile hedef tanıma programları bu kapsamda geliştirilmiştir. Tüm bu programlar, iletken ve/veya dielektrik yapıda çeşitli kanonik geometrilere sahip hedef grafikleri ile daha karmaşık geometrilere sahip iletken hedefler üzerinde denenmişlerdir.

1.4 KONUNUN LİTERATÜRDEKİ YERİ, ÖNCELİĞİ VE ÖNEMİ : Hedef / nesne tanıma problemi, genel olarak, çeşitli disiplinlerden pek çok bilim adamının üzerinde çalıştığı önemli, güncel ve disiplinler arası özellik taşıyan bir konudur. Görüntü tanıma, ses tanıma, örüntü tanıma problemlerine getirilen çözümler yaygın bir şekilde genellikle ilgili alanlarda (parmak izi tanıma uygulamaları, optik okuyucular, önemli binalarda güvenlik sistemleri vb.) ve endüstride üretim hatalarının bilgisayar destekli tayininde kullanılmaktadır. Bu konunun uygulamalarının yaygın olduğu bir diğer alan da tıp alanıdır. Örneğin, varlığı tesbit edilen bir tümörün cinsinin cerrahi müdahale gerektirmeksizin tayini üzerinde yoğun çalışmalar sürdürülmektedir [5].

Hedef / nesne tanıma probleminin gerçek zamanda çözümüne en çok ihtiyaç duyulan uygulama alanı, bilindiği gibi, askeri savunma alanıdır. Mikrodalga ve optik (infrared ve ultraviole) frekanslarda radar ve kamera sistemleri ile hedef tesbiti tüm dünyada ilgi odağı olmayı sürdüren ve üzerinde pek çok araştırma yapılan bir konudur. SAR tipi radarlardan hedef tanıma denildiğinde, problem görüntüleme yöntemleri ile hedef tanımaya dönüşür. Doppler radarlardan hedef tanıma problemi ise, ses sinyallerinden hedef tanıma problemi ile pek çok ortak özellik taşır. Bunların dışında kalan Tek-Darbe radar (Monopulse radar) veya geliştirilme aşamasında olan Çok Geniş Bantlı radar (Ultra Wide-Band radar) uygulamalarında ise, hedef tanıma problemi teorik modelleme açısından çok karmaşık bir hal alır. Bu problemde ham veri, alıcı ve verici antenlerin polarizasyonlarına ve hedefe çarpan ve hedeften saçılan sinyallerin gönderilme ve algılanma yönlerine göre değişen elektromanyetik saçınım (scattered signal) sinyallerinden oluşur. Diğer bir deyişle, polarizasyon parametresi uygun anten seçimleri ile bir faktör olmaktan çıkarılsa bile, böyle bir elektromanyetik hedef tanıma problemi üç boyutlu uzayda tanımlanmalıdır. Dolayısı ile, iki boyutlu örüntü tanıma problemleri ile karşılaştırıldığında, elektromanyetik hedef tanıma problemlerine yüksek tanıma oranlı bir çözüm bulmak çok daha zordur. Mevcut literatürdeki çözüm yöntemlerinin önemli bir kısmı, istatistiksel veri karşılaştırma esasına dayanmaktadır. Bunların dışında ise, 80'li yıllardan bu yana fiziksel model tabanlı (K-pulse tekniği, E-pulse tekniği gibi) hedef

tanıma yöntemleri [10, 12, 14, 16] ve 90'li yıllardan bu yana Yapay Sinir Ağları (YSA) na kullanıldığı hedef tanıma yöntemleri [6, 8] sıklıkla önerilmektedir.

Bu projede gerçekleştirilen çalışmalar, özellikle şu üç alanda mevcut literatüre katkıda bulunmuştur:

- Öz Örgütlemeli Haritaların (Self Organizing Map-SOM) elektromanyetik hedef tanıma probleminde ilk kez kullanılması,
- Doğrusal olmayan Zaman-Frekans Dönüşümlerinin (ZFD) kullanılması ile elde edilen doğal tepke ilişkili öznitelik vektörlerinin hedef tanıma probleminde ilk kez kullanılması,
- K-darbe hedef tanıma tekniğinin dielektrik hedeflere ve dielektrik kaplı iletken hedeflere uygulanabilirliğinin gösterilmesi.

1.5 İNCELENEN PARAMETRELER VE İZLENİLEN YÖNTEM : Bu projede izlenen iki ana yöntem ve bu bağlamda incelenen parametreler aşağıda verildiği şekilde özetlenebilir. Yöntemlerle ilgili teorik detaylar Gelişme Bölümü'nde sunulacaktır.

(i) Akıllı hedef tanıma yöntemi:

Elektromanyetik hedef tanıma/sınıflandırma çalışmalarında ölçülen, simüle edilen (yansız oda ölçümleri ile) veya analitik ve/veya nümerik yollardan elde edilen radar verileri, ya doğrudan doğruya ya da öznitelik çıkarımı yapıldıktan sonra bir YSA'yı eğitmek için kullanılırlar. Bu proje bazında iki tür veri kullanılmıştır: Bir yansız odada, frekans uzayında ölçülen gerçekçi geometrilere sahip, iletken kaplı model uçaklara ait saçınım verileri; ve yine frekans uzayında nümerik hesaplama yöntemleri ile iletken ve/veya dielektrik küre, doğrusal tel ve benzeri temel geometriler için elde edilen saçınım verileri. Zaman veya frekans uzayında elde edilen verilerden özellik çıkarımı (feature extraction or selection) yöntemin doğruluk derecesini büyük ölçüde etkilediği için, hedef tanıma çalışmalarımızda ham veriler yerine verilerden çıkartılan öznitelik vektörleri kullanılmış, öznitelik çıkarımı üzerinde ayrıntılı bir biçimde çalışılmıştır. Bu amaçla çeşitli ZFD teknikleri incelenmiş ve diğerlerine oranla daha iyi sonuç veren tekniklerden biri olan Wigner Dönüşümü (WD) kullanılmıştır. YSA ile hedef tanıma konusunda literatürde genellikle MLP (Multilayer Perceptron) kullanımı üzerine örnekler [6,8] görülmektedir. Bu projede ise, yapılan ön çalışmalarda daha iyi sonuçlar verdiği

görülen (ve daha önce elde edilen sonuçlarla da bu kapasiteyi gösterilen) SOM türü YSA'lar üzerinde gerçekleştirilmiştir.

(ii) K-darbe hedef tanıma yöntemi:

Zamanda sınırlı olan özel bir uyarı sinyali (K-darbe sinyali) ile hedefin doğal salınımlarını sönümlendirme ve böylece bütün uyarı açılarında zamanda sınırlı hedef tepkeleri yaratma esasına dayalı bir yöntemdir. Literatürde görülen [13, 15, 16] K-darbe (veya E-darbe) uygulamalarında K-darbe sinyalinin kapsadığı zaman () ya önceden biliniyor kabul edilmiş, ya da deneme yanılma yöntemleri ile bulunmaya çalışılmıştır. Bu yöntemin çok kritik bir parametresi olan τ 'nın doğru tayini, genetik algoritmaların kullanıldığı bir optimizasyon probleminin çözümü ile mümkündür [18]. Bu projede yapılan çalışmalarda sadece K-darbe sinyalinin açıldığı baz fonksiyonlarının katsayıları değil, aynı zamanda K-darbe süresi de optimizasyonun değişken parametreleri olarak modellenmiş ve çözülmüştür.

Yukarıda özetlenen her iki yöntem için de kişisel bilgisayarlarda çalıştırılabilecek sentez ve simülasyon programları yazılmıştır. Ayrıca, yöntemlerin denenmesi aşamasında, teorik öneme sahip kanonik hedefler için veri üretilmesi konusunda sayısal çözüm yöntemlerinden de büyük ölçüde yararlanılmıştır.

1.6 PROJE ÖNERİSİNDE TANIMLANAN ÇALIŞMA İLE GERÇEKLEŞTİRİLEN

ÇALIŞMALARIN KARŞILAŞTIRILMASI: Proje önerisinde tanımlanan çalışma ile proje süresince gerçekleştirilen çalışmalar amaç, kapsam ve yöntem bakımından bire bir uyumludur. Öneri de sözü edilen proje aşamalarının tümü 18 aylık proje süresi içerisinde gerçekleştirilmiştir.

2. GELİŞME

Giriş bölümünde de belirtildiği gibi, projemizin amacı nümerik yöntemlerle hesaplanmış ve/veya yansız oda ölçümlerinden elde edilmiş elektromanyetik saçınım verilerini kullanarak çeşitli geometrik zorluk derecelerindeki hedef tanıma/sınıflandırma problemlerini çözecek yöntemler geliştirmek ve uygulamaktır. Proje planında belirtilen elektromanyetik hedef tanıma çalışmaları iki ana başlık altında toplanmaktadır:

- Akıllı Hedef Tanıma Yöntemleri
- K-Darbe Hedef Tanıma Yöntemi

Hem teorileri hem de kullanıldıkları sinyal işleme araçları bakımından büyük farklılıklar gösteren bu iki yöntemden birincisi Yapay Sinir Ağları (YSA) ve Zaman-Frekans Dönüşüm (ZFD) tekniklerinin uygulamaları üzerinde yoğunlaşırken, ikincisi daha çok elektromanyetik teori ve sistem modelleme konularına odaklanmış ve problemin çözümünde optimizasyon tekniklerini kullanılmıştır. Proje kapsamında gerçekleştirilen çalışmalar, ilgili oldukları temel teoriler üzerine verilen açıklamalarla birlikte aşağıda anlatılmıştır.

2.1 HEDEF VERİ TABANLARININ OLUSTURULMASI: Hedef tanıma çalışmalarında, sınıflandırılacak hedeflere ilişkin geniş kapsamlı ve güvenilir bir veri tabanının oluşturulması yapılması gereken işlerin başında gelir. Gerçek hayattaki uygulamalarda bu hedeflerin büyük bir bölümünü karmaşık geometrili hedefler oluşturmakla birlikte, küre, silindir, disk, ince silindirik tel ve benzeri kanonik geometrili hedeflerin de ön incelemelerde (modelleme ve modellerin test edilmesi aşamalarında) kullanılması gereklidir. Bu nedenle, proje çalışmalarımızın ilk aşamasında, bilgisayar benzetimlerinde kullanılmaya uygun hedef veritabanları oluşturulurken,

- farklı büyüklüklerde mükemmel iletken küreler,
- mükemmel iletken ince silindirik teller,
- mükemmel iletken kaplı farklı tiplerde model uçaklar,

- dielektrik küreler ve
- dielektrik kaplı iletken küreler.

için çeşitli görüş açılarında ve/veya farklı polarizasyonlarda elektromanyetik saçınım verileri ölçüm veya nümerik hesaplama kaynaklı olarak elde edilmiştir.

2.1.1. Mükemmel İletken Küreler İçin Veritabanı Oluşturulması

Çapları 7.5, 10, 15 ve 20 inç (sırasıyla, 19.05 cm, 25.4 cm, 38.1 cm ve 50.8 cm) olan dört adet farklı büyüklükte mükemmel iletken küreye ait *monostatik* (sinyalin aynı bakış açısından gönderilip toplandığı durum) ve *bistatik* (aralarında konum farkı olan iki ayrı antenle hedefin uyarıldıldığı ve saçınımın toplandığı durum) saçınım sinyalleri 0.05-10 Ghz frekans bölgesinde, 50 Mhz aralıklı örneklemelemlerle, sayısal olarak (seri açılımları hesaplayan bir bilgisayar kodu yardımı ile) elde edilmiştir. Her bir hedef küre için yeterli sayıdaki farklı açı/polarizasyon kombinasyonunu içeren bir veri tabanı oluşturulmuştur.

2.1.2. Mükemmel İletken Silindirik İnce Tel İçin Veritabanı Oluşturulması

Çeşitli uzunluk ve yarıçap değerlerine sahip, mükemmel iletken, silindirik ince tel geometrisine sahip kanonik hedefler için veri tabanı oluşturmak amacı ile *Moment Metod* 'a dayalı bir saçınım hesaplama programı [12] kullanılmıştır. Örneğin, boyu 12 metre, boyunun çapına oranı 2000 olan bir düz iletken tel için, 2-256 MHz frekans bölgesinde, 2 MHz örnekleme aralığı ile bir veri tabanı oluşturulmuştur. Tel eksenini referans alındığında, sıfır derece, 60 derece ve 90 derece bakış açıları monostatik (*geri saçınım*) sinyalleri üretilmiştir.

2.1.3. Mükemmel İletken Model Uçaklar İçin Veritabanı Oluşturulması

Geliştirilen hedef tanıma yöntemlerinin karmaşık geometrili hedefler üzerindeki performansını test etmek için, çeşitli açı ve polarizasyon şartlarında yansız oda ölçümlerinden elde edilmiş, iletken model uçaklardan geri saçınım verileri, kullanılması planlanan veritabanı formatında yeniden düzenlenip, ileri sinyal işlemeye hazır hale


getirilmiştir. (Bu veriler, Dr. Mustafa Turhan Sayan' ın doktora tezinde [14] de kullandığı, Ohio State Üniversitesi, Fizik Bilim Laboratuvarı' nda ölçülmüş verilerdir.) Uçak hedef sınıfı aşağıdaki tip modelleri kapsar:

- Boeing-707
- Boeing-727
- Boeing-747
- Concorde
- DC-10

Ölçümlerde, bu modellere ait, geometrik detaylar muhafaza edilerek yapılmış, küçük ölçekli iletken hedefler kullanılmıştır. Yansımaz oda ölçümlerinde elde edilen ve pratik olarak gürültüsüz sayılabilecek orijinal saçınım verileri 1-8 GHz frekans bölgesinde ve 50 Mhz örnekleme aralıkları ile mevcuttur. Her bir hedef için, farklı açı/polarizasyon kombinasyonlarında ve hedef tanıma uygulamaları için yararlı olabilecek çeşitlilikte veri bulunmaktadır.

2.1.4. Dielektrik Küreler İçin Veritabanı Oluşturulması

Çalışmaların bu bölümünde, materyal özellikleri verilmiş bir dielektrik küre için elektromanyetik saçılma hesapları yapılmıştır ve MATLAB ortamında çalışan bir bilgisayar kodu yazılmıştır. Bu analiz sırasında incelenen problem aşağıdaki şekilde gösterilmiştir:



Şekil 1. Dielektrik bir küre

Bu şekilde m_1 ve m_2 dielektrik kürenin ve dış ortamın göreceli kırılma indislerini göstermektedir. a parametresi ise kürenin yarıçapını tanımlamaktadır. Bu kürenin merkezine yerleştirilen bir xyz Kartezyen koordinat sistemine göre tanımlanan ve düzlem dalga şeklinde bir elektromanyetik alanın küreye çarptığını düşünelim:

$$\vec{E}^{gelen} = \exp(-ik_2z) \hat{a}_x \quad (1)$$

Bu elektrik alan x -yönünde polarizasyonu olan ve z -yönünde yayılan bir düzlem dalgadır. Bu düzlem dalga küreye çarpınca ortaya çıkan saçılma alan denklemleri aşağıda ifade edilmişlerdir:

$$E_\phi = -\frac{i \exp(-ik_2r)}{k_2r} \sin\phi \sum_{n=1}^{\infty} \frac{2n+1}{n(n+1)} \left\{ a_n \frac{P_n^1(\cos\theta)}{\sin\theta} + b_n \frac{dP_n^1(\cos\theta)}{d\theta} \right\} \quad (2)$$

$$E_\theta = \frac{i \exp(-ik_2r)}{k_2r} \cos\phi \sum_{n=1}^{\infty} \frac{2n+1}{n(n+1)} \left\{ a_n \frac{dP_n^1(\cos\theta)}{d\theta} + b_n \frac{P_n^1(\cos\theta)}{\sin\theta} \right\} \quad (3)$$

Bu ifadeler aslında uzak alandaki elektrik alan bileşenlerini vermektedir. Radyal değişken olan r parametresine göre olan değişim açıkça küresel dalga görünümündedir ve θ açısına bağlı olarak da a_n ve b_n katsayıları ile belirlenen ve $P_n^1(\cos\theta)$ fonksiyonu ve onun türevi cinsinden sonsuz bir seri ile ifade edilen bir değişim söz konusudur. Buradaki katsayıların değerleri aşağıda verilmiştir:

$$a_n = \frac{\psi_n(\alpha)\psi_n'(\beta) - m\psi_n(\beta)\psi_n'(\alpha)}{\zeta_n(\alpha)\psi_n'(\beta) - m\psi_n(\beta)\zeta_n'(\alpha)} \quad (4)$$

$$b_n = \frac{m\psi_n(\alpha)\psi_n'(\beta) - \psi_n(\beta)\psi_n'(\alpha)}{m\zeta_n(\alpha)\psi_n'(\beta) - \psi_n(\beta)\zeta_n'(\alpha)} \quad (5)$$

Bu ifadelerde $m = \frac{m_1}{m_2}$, $\alpha = m_2 k_0 a$ ve $\beta = m_1 k_0 a$ olarak verilmiştir. Bu bağıntılarda yer alan fonksiyonlar da Ricatti-Bessel fonksiyonları olarak bilinirler:

$$\psi_n(kr) = \left(\frac{\pi kr}{2}\right)^{1/2} J_{n+1/2}(kr) \quad (6)$$

$$\chi_n(kr) = -\left(\frac{\pi kr}{2}\right)^{1/2} N_{n+1/2}(kr) \quad (7)$$


$$\zeta_n(kr) = \left(\frac{\pi kr}{2}\right)^{1/2} H^2_{n+1/2}(kr) \quad (8)$$

Burada $J_{n+1/2}(kr)$, $N_{n+1/2}(kr)$ ve $H^2_{n+1/2}(kr)$ fonksiyonları sırasıyla Bessel, Neumann ve Hankel fonksiyonlarıdır. a_n ve b_n katsayılarının ifadelerinde bu fonksiyonların türevleri de yer almaktadır.

Bu çalışma döneminde saçılma alanının hesabı için bir MATLAB kodu hazırlanmış ve bu programda bulunan ve yukarıda belirtilen özel fonksiyonları hesap eden rutinler kullanılarak uzak alanda verilen bir gözlem noktasındaki elektrik alan hesap edilmiştir.

2.1.5. Dielektrik Kaplı İletken Küreler İçin Veritabanı Oluşturulması

Çalışmanın bu kısmında dielektrik sabiti bilinen bir materyalle kaplı mükemmel iletken bir küreye çarpan bir düzlem dalga yarattığı elektromanyetik alanın hesabı gerçekleştirilmiştir. Problem geometrisi aşağıdaki şekilde verilmiştir:



Şekil 2. Dielektrik bir materyalle kaplı mükemmel iletken bir küre

Bu problemde de gelen alan, bir önceki problemde tanımlanan x -yönünde polarizasyonu olan ve z -yönünde yayılan bir düzlem dalgadır. Burada da Bölüm 2.1.4' de anlatılanlara benzer şekilde a_n ve b_n katsayıları ile belirlenen uzak saçılma alanını hesap eden ayrı bir MATLAB yazılımı geliştirilmiştir. Dielektrik katmanın kırılma indeksi havanın kırılma indeksi ile aynı alındığında, bu kod mükemmel iletken bir kürenin saçılım verilerini hesaplayabilmektedir. Bu kod kullanılarak çeşitli büyüklüklerde, dielektrik tabaka kalınlıklarında ve kırılma indeksi değerlerinde saçılma alanları hesaplanmış ve K-darbe tekniği ile ilgili uygulamalarda kullanılmıştır.

2.2 ZAMAN-FREKANS DÖNÜŞÜM TEKNİKLERİNİN ÖZNETELİK

ÇIKARIMINDA KULLANILMASI: Elektromanyetik hedef/nesne tanıma ve sınıflandırma yöntemleri, sınırlı büyüklükteki bir ölçüm veri tabanını kullanarak, algılanan hedefe ait bazı karakteristik bilgileri elde etme ve bu bilgileri daha önceden aynı yöntemlerle elde edilerek saklanmış, aday hedeflere ilişkin karakteristik bilgilerle bir biçimde karşılaştırma esasına dayanırlar. Söz konusu karakteristik bilgilerin niteliği, hedef tanıma yönteminin başarısını doğrudan etkiler.

Fourier Dönüşümleri gibi klasik teknikler hedef tanımadaki kullanılan elektromanyetik geri saçılım sinyallerinin zamana göre değişen frekans içeriğini incelemekte yetersiz kalmaktadır. Bu boşluğu doldurmak üzere, çeşitli *zaman-frekans dönüşümlerinin (ZFD)* kullanılması gereklidir. Temel olarak, bir ZFD, tek boyutlu (zaman veya frekans uzayında tanımlanmış)

bir sinyalden, aynı anda hem zaman hem de frekans üzerinde (yani iki boyutlu bir uzayda) tanımlanan bir dönüşüm sinyali üretir [3, 7]. Bu dönüşüm sinyali, orijinal sinyalin zamana ve frekansa göre değişimlerini detaylı bir şekilde analiz edebilmemizi mümkün kılar. Doğrusal olmayan ZFD' ler kullanıldığında ise, orijinal sinyalin enerji yoğunluğunu, zaman-frekans uzayında yaklaşık anlamda elde etmek mümkün olur. *Wigner Dağılımı (WD)* da bu doğrusal olmayan ZFD'leri sınıfına girmektedir ve aşağıda özetlenen özelliklerinden dolayı çalışmalarımızda kullanılmak üzere seçilmiştir.

2.2.1 Wigner Dönüşümü (WD)

Zamanını sürekli fonksiyonu olan $x(t)$ gibi bir sinyalin oto-Wigner dönüşümü (veya dağılımı) şöyle tanımlanır [3, 7]:

$$W_x(t, f) = \int_{-\infty}^{\infty} e^{-j2\pi f\tau} x(t + \tau/2) x^*(t - \tau/2) d\tau \quad (9)$$

Oto-Wigner dağılımının en önemli özelliklerinden ikisi, verilen bir sinyal için anlık güç, $|x(t)|^2$, ve enerji yoğunluk dağılımı, $|X(f)|^2$, ifadelerinin marjinal adı verilen aşağıdaki integraller vasıtası ile hesaplanabilmesidir:

$$\int W_x(t, f) df = |x(t)|^2 \quad (10)$$

ve

$$\int W_x(t, f) dt = |X(f)|^2 \quad (11)$$

Bu ifadelerde, $W_x(t, f)$ sinyalin verilen bir zaman, t , ve frekans, f , değerinde hesaplanan oto Wigner dağılımını, $X(f)$ ise $x(t)$ zaman sinyalinin Fourier dönüşümünü gösterir.

Yukarıdaki bağıntılardan yararlanılarak, verilen $x(t)$ sinyalinin toplam enerjisi

$$E_x = \iint W_x(t, f) df dt \quad (12)$$

ve belli bir zaman aralığı $[t_1, t_2]$ ve frekans aralığı $[f_1, f_2]$ için sahip olduğu kısmi enerji

$$E_{kism} = \int_{t_1}^{t_2} \int_{f_1}^{f_2} W_x(t, f) df dt \quad (13)$$

kolaylıkla hesaplanabilir.

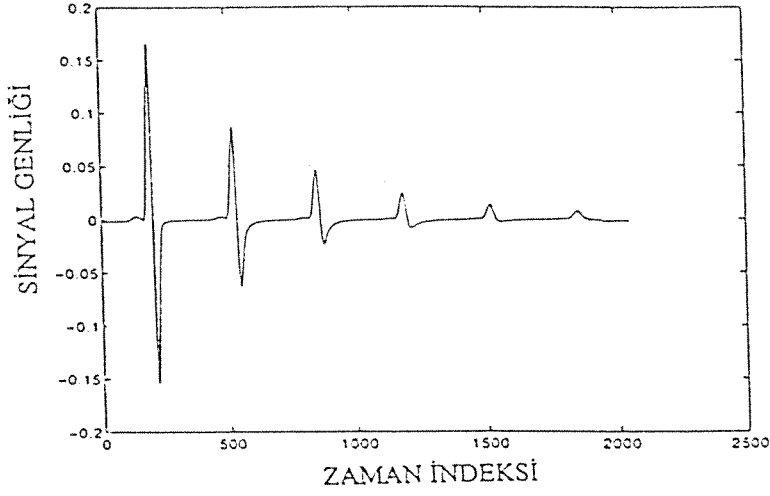
Verilen bir hedefe ait elektromanyetik geri saçılım sinyalinin Wigner dağılımı çeşitli zaman ve frekans değerlerinde hesaplanarak, bir Wigner transform çıktı matrisi elde edilebilir. Bu matrisin elde edilmesinde hedefin belli bir açı/polarizasyon durumuna ait (yaklaşık) dürtü tepkesinin kullanılabilmesi halinde ise, matrisin geç zaman dilimlerine ait kısmını inceleyerek, hedefin sistem kutuplarının dağılımı hakkında bilgi sahibi olmak mümkündür. Bilindiği gibi, bir elektromanyetik hedefe ait sistem kutupları kümesi, o hedefi uyarılma açısı ve sinyal polarizasyonundan bağımsız olarak tarifler [2, 10, 11].

2.2.2. WD Hesaplamaları İçin Yazılım Çalışmaları ve Uygulamalar

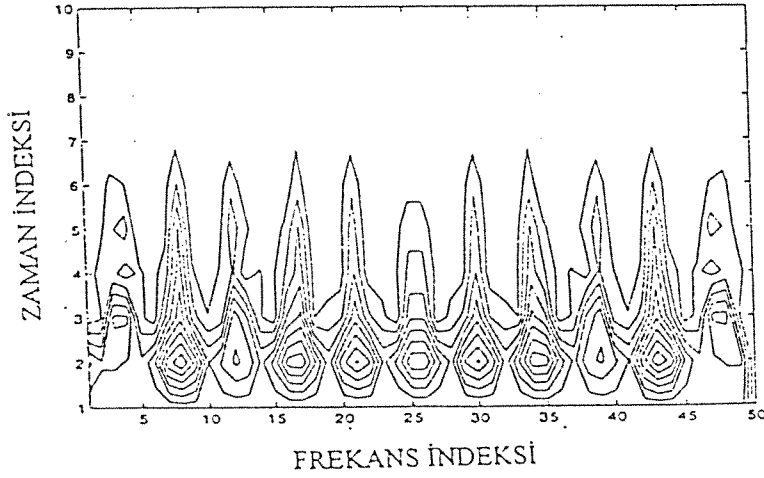
Proje çalışmalarının bir bölümü olarak, verilen bir elektromanyetik saçılım sinyalinin zaman boyutundaki gösteriminden yola çıkarak WD hesaplayan iki bilgisayar programı hazırlanmıştır. Sürekli WD hesaplayan kodlardan biri dönüşümün direkt tanımını (bakınız, denklem 9) kullanıp toplam hesaplarken, diğeri hesaplamalarda Fourier dönüşümünü kullanarak hesaplama hızını arttırmaktadır. Bu programlar MATLAB ile kişisel bilgisayar ortamında çalıştırılmak üzere yazılmıştır. Yazılan WD programlarının işlemesine ve öznetelik çıkarımında kullanılmasına bir örnek olarak mükemmel iletken, ince, doğrusal tel geometrisi aşağıda incelenmiştir.

Örnek:

Boyu 12 metre, boyun çapa oranı 2000 olan ince, silindirik, mükemmel iletken bir telden 30 derece görüş açısında hesaplanmış olan bistatik saçınım sinyali Şekil 3' de görülmektedir. Bu şekilde sinyal 500 nanosaniyelik bir süre için çizilmiştir (2048 inci örnek 500 ns' ye karşı gelmektedir). Bu sinyale ait WD sonucu ise Şekil 4' de sunulmuştur. Bu şekilde, zaman ekseninde her biri 204 örnek içeren ve tümü toplam 500 ns' ye karşılık gelen 10 tane zaman bandı görülmektedir. Frekans ekseninde ise, [-64 Mhz, 64 Mhz] bandını kapsayan 50 adet frekans örnekleme noktası vardır. Diğer bir deyişle, bu sonucun alınması için önce 50X2048 boyutunda bir WD matrisi hesaplanmış, daha sonra zaman ekseninde kısmi ortalamalar alınarak hem problemin boyutu küçültülmüş hem de WD' nin yapısından kaynaklanan ara etkileşim terimleri bir miktar bastırılmıştır. Bu sonuçların yorumundaki en önemli nokta, WD matrisinin gerçekten de iki boyutlu zaman-frekans düzleminde, yaklaşık olarak, bir enerji yoğunluk fonksiyonu özelliğini göstermesidir. Bu sonucu destekleyen en belirgin kanıt, Şekil 4'de gözlenen enerji yoğunlaşmalarının, hedefin sistem kutup değerlerine denk düşmesidir. Örneğin, bu hedef için baskın kutuplar yaklaşık olarak ± 13 Mhz civarında hesaplanmaktadır ki, bu da Şekil 4'de 21 ve 30 numaralı frekans indekslerine karşılık gelmektedir. Yaklaşık sıfır frekansa karşılık gelen 25 numaralı indeks civarında gözlenen yoğunlaşma en güçlü ara etkileşim terimine aittir. Bunun dışında kalan diğer yoğunlaşma bölgeleri iletken telin [-64 Mhz, 64 Mhz] frekans bandında etkili olan diğer sistem kutuplarına yani doğal titreşim frekanslarına karşılık gelmektedir. (Verilen hedef geometrisi için, ilk dört çift sistem kutubunun yaklaşık olarak 13, 26, 39, 52 Mhz değerlerinde olduğu bilinmektedir [14]. Bu önemli gözlem, WD ile çıkartılan hedef özellik matrislerinin hedef tanıma yöntemlerindeki başarıyı büyük ölçüde etkileyeceğini göstermektedir.



Şekil 3. Düz, ince, silindirik iletken telin 30 derece görüş açısındaki gerisaçılmış dürtü tepkesi




Şekil 4. Şekil 3'de görülen dürtü tepkesine ait Wigner Dönüşümünün zaman bantları üzerinde entgre edilmiş izdüşümsel grafiği (contour plot).

2.2.3. WD Kullanılarak İletken Küreler İçin Öznitelik Vektörlerinin Çıkarımı


Bu konudaki ilk uygulama için, 7.5, 10, 15 ve 20 inç çaplarındaki dört mükemmel iletken küreye ait ortak veri tabanındaki sinyaller, geliştirilmiş olan WD hesaplama algoritmaları ile işlendi. Bunun sonucunda, her bir saçınım sinyaline karşılık gelen enerji öznitelik matrisleri elde edildi. Küre biçimli hedefleri tanıyacak yapay sinir ağlarını daha da rafine verilerle eğitebilmek amacıyla, öznitelik çıkarımı bir adım daha ileriye götürüldü: Enerji öznitelik matrislerinde her bir örnekleme frekansına karşılık gelen kolonlar önce 10 eşit zaman dilimine ayrılıp, her bir dilim zaman üzerinde entegre edildi. Daha sonra 5, 6 ve 7 numaralı (geç tepke zamanlarına karşılık gelen ve dolayısı ile hedeflerin doğal rezonans tepkeleri ile yakından ilişkili olan) zaman dilimlerine ait WD değerleri peşpeşe eklenerek enerji öznitelik vektörleri elde edildi.

Örnek:


Çapı 10 inç olan mükemmel iletken bir kürenin 120 derece "bistatic" açıda (uyarı sinyalinin küreye gönderildiği ve saçınım sinyalinin geri alındığı yönler arasındaki açının 120 derece olması hali) hesaplanmış saçınım verileri ve bundan elde edilen enerji öznitelik matris ve vektörleri Şekil 5'de verilmiştir. Frekans uzayında hesaplanan geri saçınım verilerinden pencereleme ve Ters Fourier Dönüşümü (IFFT) kullanılarak elde edilmiş zaman uzayındaki saçınım verileri (ki bu veriler 0-10 Ghz gibi yeterince geniş bir frekans bandına karşılık geldikleri için kürenin "impulse" tepkisi olarak değerlendirilebilir) , Şekil 5.a' da görülmektedir. Bu şekilde, 2048 numaralı zaman endeksi 20 nano-saniyeye (ns) karşılık gelmektedir. WD hesaplamaları yapılırken, hesaplamaları hızlandırmak için, bu zaman sinyali toplam 512 tane eşit aralıklı örnekleme noktası olacak şekilde 1/4 oranında seyreltilmiştir. 20 ns. lık toplam zaman aralığının, her biri 2 ns. lik 10 banda bölünüp, yukarıda açıklanan entegrasyon işleminin uygulanmasından sonra elde edilen, üç boyutta çizilmiş WD sonuçları Şekil 5.b'de verilmiştir. Bu enerji öznitelik matrisinden elde edilen doğal rezonanslarla ilişkili enerji öznitelik vektörü ise Sekil 5.c ' de görülmektedir.



(a) Kürenin 0-20 ns. üzerinde hesaplanmış saçınım verileri



(b) WD kullanılarak elde edilen ve (-2.5 Ghz , 2.5 Ghz) ile (0-20 ns) aralıklarına karşılık gelen öznelik matris değerleri



(c) (-2.5 Ghz , 2.5 Ghz) ile (8ns.-14 ns.) arasına karşılık gelen öznelik vektörü

Şekil 5. 10 inç yarıçaplı mükemmel iletken küreden 120 derece "bistatic" açıda hesaplanan saçınım verileri ve bu sinyalden çıkarılan öznelik verileri.


2.2.4. WD Kullanılarak İletken Model Uçaklar İçin Öznitelik Vektörlerinin Çıkarımı

Daha önce küre veritabanına uygulanan öznitelik çıkarma işlemi, çalışmalarımızı bu bölümünde karmaşık geometrili hedeflere uygulanmıştır. Bunun için, önceki çalışma dönemlerinde ham veritabanı hazırlanmış olan beş adet iletken kaplı model uçaktan (Boeing 707-Hedef A, Boeing 727-Hedef B, Boeing 747-Hedef C, Concorde-Hedef D ve DC-10-Hedef E) oluşan bir hedef grubu kullanılmıştır. Bu hedefler için yapılacak tanıma çalışmaları, geometrilerinin çok karmaşık olması ve uçakların paylaştığı bir çok ortak ya da benzer özellik bulunması nedeniyle, kürelerden hedef tanıma problemine oranla çok daha zordur. Bu problemde başarıyı sağlamak için gerek öznitelik çıkarımının gerekse YSA eğitiminin çok daha özenli yapılması gerektiği ön çalışmalarımız sırasında ortaya çıkmıştır.


Bilindiği gibi, hedef tanıma probleminin ilk önemli aşaması, eldeki verilerden hedeflere ait belirleyici özniteliklerin çıkarılmasıdır ve bu proje kapsamında kullandığımız öznitelik çıkarma yöntemi Wigner Dağılımı (WD) kullanarak hedeflerden geri saçılan sinyallerin zaman-frekans uzayındaki yaklaşık enerji dağılımlarının bulunması esasına dayanmaktadır. WD'nin matematiksel tanımı ve belli başlı özellikleri Bölüm 2.2.1'de verilmişti. Bu bölümde, A, B, C, D ve E model uçak hedeflerine ait veri tabanındaki sinyaller, aynı WD hesaplama algoritmaları ile işlenmiştir. Bunun sonucunda, her bir saçınım sinyaline karşılık gelen enerji öznitelik matrisleri elde edilmiştir. Hedefleri tanıyacak yapay sinir ağlarını daha da rafine verilerle eğitebilmek amacıyla (küre probleminde de olduğu gibi), öznitelik çıkarımı bir adım daha ileriye götürülmüş ve enerji öznitelik matrislerinde her bir örnekleme frekansına karşılık gelen kolonlar 10 eşit zaman dilimine ayrılıp, her bir dilim zaman üzerinde integre edilmiş ve daha sonra 6, 7 ve 8 numaralı (geç tepke zamanlarına karşılık gelen ve dolayısı ile hedeflerin doğal rezonans tepkeleri ile yakından ilişkili olan) zaman dilimlerine ait WD sonuçları peşpeşe eklenerek enerji öznitelik vektörleri elde edilmiştir.

Bu çalışmalara örnek olarak, Hedef A ve Hedef C' nin 45 derece "monostatik" açıda (uyarı sinyalinin hedefe gönderildiği ve saçınım sinyalinin geri alındığı yönlerin aynı olması hali) elde edilmiş saçınım verileri Şekil 6'da ve bunlardan elde edilen enerji öznitelik vektörleri Şekil 7'de verilmiştir. Frekans uzayında hesaplanan geri saçınım verilerinden Ters Fourier Dönüşümü (IFFT) kullanılarak elde edilmiş olan zaman uzayındaki saçınım verilerinin (ki bu veriler yeterince geniş bir frekans bandına karşılık geldikleri için hedeflerin "impulse"

tepkeleri olarak değerlendirilebilir) sunulduğu çekimlerde 1500 numaralı sonuncu zaman aralığı 7.32 nano-saniyeye (ns) karşılık gelmektedir. Analiz sırasında toplam zaman aralığının ona bölünmesiyle, her biri 0.732 ns. lik 10 adet eşit uzunluklu zaman bantları elde edilmiştir. Bu bantlar içerisinde yukarıda açıklanan entegrasyon işleminin uygulanmasından ve 6., 7. ve 8. bant sonuçlarının seçilmesiyle elde edilen enerji öznitelik vektörleri Şekil 7’de görülmektedir. Hedeflerin doğal rezonans davranışları ile ilişkili olan bu enerji öznitelik vektörlerinin elde edilmesi için $[-4, 4 \text{ GHz}]$ aralığında 50 frekansda örnekleme kullanıldığından, vektörlerin her biri $3 \times 50 = 150$ örnekleme uzunluğundadır.




(a) Hedef A




b) Hedef C

Şekil 6. Hedef A ve Hedef C' ye ait 45 derecede ölçülen geri saçılım verileri



a) Hedef A



b) Hedef C

Şekil 7. Hedef A ve Hedef C' ye ait 45 derecede ölçülmüş geri saçınım verilerinden hesaplanan ve (-4 Ghz , 4 Ghz) ile (3.660ns.-5.856 ns.) zaman-frekans bölgelerine karşılık gelen öznelilik vektörleri.

2.3. AKILLI HEDEF TANIMA YÖNTEMİNİN KÜRESEL İLETKEN HEDEFLERE UYGULANMASI:

Giriş bölümünde de belirtildiği gibi, bu hedef tanıma yönteminde Yapay Sinir Ağları (YSA) kullanılmıştır. Başlıca iki tip YSA üzerinde çalışılmış, Çok Katlı Perseptron (Multi Layer Perceptron-MLP) tipi YSA'lar kontrol metodu olarak kullanılıp daha çok, literatürde ilk kez bu tip bir çalışma kapsamında kullanılan, Öz Örgütlemeli Harita (Self Organizing Map-SOM) tipi YSA'ların uygulanması üzerinde durulmuştur. YSA'lar ile elektromanyetik hedef tanıma probleminde öznelik çıkarımının önemini vurgulamak ve ayrıca MLP ve SOM tipi YSA'ların tanıma performansını karşılaştırmak amacı ile aşağıdaki üç adet benzetim problemi tasarlanmış ve küresel hedefler üzerinde test edilmiştir. Hedef grubu olarak 7.5, 10, 15 ve 20 inç çaplarındaki dört adet mükemmel iletken küre seçilmiş ve sırasıyla A, B, C ve D küreleri olarak adlandırılmışlardır. Bu kürelere ait veritabanı Tablo 1'de görülen *bistatik* açılar ve polarizasyonlardaki saçınım verilerinden oluşmaktadır. Eldeki veritabanının bir kısmı YSA'nı eğitmek için kullanılırken (Eğitim Veritabanı), geri kalan kısmı (Test Veritabanı) tanıma tekniğinin genelleme ve doğru sonuç üretme yeteneğini test etmek için kullanılmıştır.

2.3.1. Benzetim Problemi 1

İlk olarak, bir MLP tipi YSA'nın kürelere ait işlenmemiş veri tabanındaki saçınım sinyalleri ile eğitilmesi sonucu bir *MLP Hedef Sınıflandırıcı* tasarlandı.

Bu MLP tasarımında 512 nörondan oluşan bir giriş katı, her biri bir küreye ilişkin 4 nörondan oluşan bir çıkış katı ve bu iki katın arasında iki tane ara kat kullanıldı. Birinci ara katta 250, ikinci ara katta ise 75 nöron bulunmaktaydı. Kürelere ait, her biri 512 eşit zaman aralıklı (0-20 nanosaniye içerisinde) örnekten oluşan saçınım sinyallerinin sırası ile her bir örneği giriş katının bir nöronuna karşılık gelmek üzere eğitici sinyaller MLP ye uygulandı. Momentum sabiti 0.1, öğrenme hızının ilk değeri ise 0.2 olarak alındı.

Tablo 1. MLP ve SOM Hedef Sınıflandırıcı benzetimlerinde eğitim amacı ile ve sadece test amacı ile kullanılan saçınım sinyallerinin "bistatik" açığı ve polarizasyonları. (HP: yatay polarizasyon, VP: dikey polarizasyon)

	A Küresi	B Küresi	C Küresi	D Küresi
Eğitim Veri Tabanı	45/VP, 100/VP 150/VP	0, 60/HP, 135/VP, 180/VP	0, 150/HP	0, 180/HP
Test Veri Tabanı	0, 120/VP	30/HP, 45/VP, 90/VP, 120/HP	30/VP, 120/VP	30/VP, 120/VP

Eğitim sonunda, eğitim amacı ile kullanılan veri tabanı içerisinde doğru tanıma oranı yaklaşık 91% (11 de 1 yanlış) olarak bulundu. Tamamen yeni verilerle yapılan yapılan tanıma testlerinde ise, doğruluk oranı ancak 40% (10 da 6 yanlış) olarak bulundu. Tüm veri tabanı baz alındığında, doğruluk oranı 66.7% (21 de 7 yanlış) gibi oldukça düşük bir seviyede kaldı.

2.3.2. Benzetim Problemi 2

MLP tipi bir YSA' nın kürelere ait öznitelik vektörleri ile eğitilmesi sonucu bir **Öznitelik Tabanlı MLP Hedef Sınıflandırıcı** tasarlandı.

Bu MLP tasarımında ise, 150 nörondan oluşan bir giriş katı, her biri bir küreye ilişkin 4 nörondan oluşan bir çıkış katı ve bu iki katın arasında yine iki tane ara kat kullanıldı. Birinci ara katta 75, ikinci ara katta ise 25 nöron bulunmaktaydı. Kürelere ait, her biri 150 örnekten oluşan öznitelik vektörlerinin sırası ile her bir örneği giriş katının bir nöronuna karşılık gelmek üzere eğitici sinyaller MLP ye uygulandı. Bu süreçte kullanılan öznitelik vektörleri Tablo 1 de adı geçen saçınım sinyallerinden elde edilmiş olup, zaman uzayında 8-14 nanosaniyelik pencereye, frekans uzayında ise, -2.5 Ghz ile +2.5 Ghz arasında kalan pencereye karşılık gelmekte ve bu bölgelere sınırlı zaman-frekans uzayında saçınım verilerinin enerji dağılımı bilgisini taşımaktaydılar. MLP nin eğitimi sırasında, momentum sabiti ve öğrenme hızının ilk değeri bir önceki MLP nin tasarımında kullanılan değerlerle aynı alındı. Burada amaç, her iki hedef sınıflandırıcının performanslarını mümkün olduğunca eşit koşullarda karşılaştırabilmektir.

Eđitim sonunda, eđitimi sonucu ile kullanılan veri tabanı içerisinde doğru tanıma oranı 100 % (11 de sıfır yanlış) olarak bulundu. Tamamen yeni verilerle yapılan yapılan tanıma testlerinde ise, doğruluk oranı 70 % (10 da 3 yanlış) olarak bulundu. Tüm veri tabanı baz alındığında, doğruluk oranı 85.7 % (21 de 3 yanlış) olarak hesaplandı.

Bu iki MLP Hedef Sınıflandırıcının performanslarının Tablo 2 de özetlenen karşılaştırmaları, verilerden öznitelik çıkarımının hedef tanımada doğruluk oranını önemli ölçüde arttırdığını göstermektedir. Bu nedenle, bundan sonraki YSA Hedef Sınıflandırıcı tasarımlarında öznitelik çıkarma basamağının standart olarak kullanılmasına karar verildi. Ayrıca, Tablo 2 de görülen değerler, öznitelik çıkarımına dayalı MLP Hedef Sınıflandırıcıların çok daha iyi bir doğruluk oranına ulaştığını ancak yaklaşık iki kat daha yavaş olduklarını gösterdi. Bu yavaşlama büyük ölçüde WD hesapları nedeniyle ortaya çıkmaktadır. Bir test için harcanan toplam CPU zamanı sadece 270 milisaniyeye yükseldiği için, öznitelik çıkarımına bağlı tanıma yavaşlaması bir sorun olarak görülmemelidir. Öte yandan, 85.7 % değerinde bir doğruluk oranının tam anlamıyla yeterli olduğu söylenemez. Bu nedenle, Öznitelik Tabanlı SOM Hedef Sınıflandırıcıların da incelenmesi gerekli bulundu.

2.3.3. Benzetim Problemi 3

SOM tipi bir YSA' nın kürelere ait öznitelik vektörleri ile eğitilmesi sonucu bir **Öznitelik Tabanlı SOM Hedef Sınıflandırıcı** tasarlandı. SOM sınıflandırıcının eğitimi için kullanılan öznitelik vektörleri her bakımdan MLP sınıflandırıcının eğitiminde kullanılanlar ile (Bkz. Tablo 1) aynı seçildi. Burada amacımız, farklı Yapay Sinir Ağları kullanılarak tasarlanan bu iki hedef sınıflandırıcının performanslarını mümkün olduğunca eşit koşullarda karşılaştırabilmektir.

Bu sınıflandırma benzetiminde kullanılan Öznitelik Tabanlı SOM Hedef Sınıflandırıcı, 10X10 luk tek katmandan oluşan ve 100 adet nöron içeren bir yapay sinir ağı olarak tasarlandı. Standart matris gösterimi ile birbirinden ayırdedebileceğimiz her bir nöronu için SOM girdi vektörleri () ile aynı boyutta olan bir ağırlık vektörü tanımlandı. SOM sınıflandırıcının eğitimi sırasında, her biri 150 örnek uzunluğunda olan (50 frekans noktasında örnekleme) peşpeşe 3 ayrı geç zaman bantı üzerinde tanımlanmış) 11 ayrı enerji

öznitelik vektör girdisi, değişikleri bir sırada ve pek çok kez aynı üzere her bir nöronun ağırlık vektörü ile karşılaştırıldı. Her bir iterasyonda, aşağıda belirtilen kurallara göre “kazanan nöron” belirlendi ve bu nöronun etrafında, verilen bir “komşuluk fonksiyonu” vasıtası ile belirlenen bir bölgeye düşen nöronların ağırlık vektörleri yeniden hesaplandı.

$$\bar{\mathbf{u}} \in \mathbf{R}^k \quad \text{ve} \quad \bar{\mathbf{w}}_{i,j} \in \mathbf{R}^k \quad ; \quad i = 1, 2, \dots, I \quad \text{and} \quad j = 1, 2, \dots, J \quad (14.a)$$

olarak verildiğinde ve norm tanımı

$$\| \bar{\mathbf{u}}(t) - \bar{\mathbf{w}}_{i,j}(t) \| = \left\{ \sum_k [u_k(t) - w_{i,j,k}(t)]^2 \right\}^{1/2} \quad (14.b)$$

olarak yapıldığında i^*, j^* indekslerini öyle seçelim ki, bütün i, j indeksleri için

$$\| \bar{\mathbf{u}}(t) - \bar{\mathbf{w}}_{i^*,j^*}(t) \| \leq \| \bar{\mathbf{u}}(t) - \bar{\mathbf{w}}_{i,j}(t) \| \quad (14.c)$$

olsun (k , kullanılan vektör boyutu ve t , iterasyon indeksi olmak üzere). SOM ağındaki nöronların ağırlık vektörleri de,

$$\bar{\mathbf{w}}_{i,j}(t+1) = \bar{\mathbf{w}}_{i,j}(t) + N_{i^*,j^*}(t) \eta(t) [\bar{\mathbf{u}}(t) - \bar{\mathbf{w}}_{i,j}(t)] \quad (15)$$

kuralına göre değiştirilsin. Bu işlemlerde kullanılan parametrelerden $\eta(t)$ “öğrenme katsayısı”, $N_{i^*,j^*}(t)$ ise “komşuluk fonksiyonu” olarak adlandırılır. Çalışmalarımız sırasında

$$N_{i^*,j^*}(i, j, t) = \begin{cases} 1 & |i - i^*| \leq r_N(t) \quad \text{ve} \quad |j - j^*| \leq r_N(t) \quad \text{için} \\ 0 & \text{için} \end{cases} \quad (16)$$

ifadesiyle belirlenebilen ve yarı genişliği $r_N(t)$ sembolü ile gösterilen basit bir komşuluk fonksiyone kullanıldı. Eğitim iterasyonları sırasında, η ve r_N parametreleri yavaş yavaş azaltılarak daha hassas öğrenme sağlandı. İncelenen problemde, yaklaşık üç bin iterasyondan sonra, bütün nöronlara ait ağırlık vektörlerinin dengeli değerlere ulaşmış, bir iterasyondan diğerine artık değişmediği zaman problemin çözümüne ulaşılmış oldu. Bu durumda, 10X10 luk SOM haritasında her bir hedefe ait ayrı bir kümelenme bölgesi oluştu. Bu bölgeler, yöntem gereği, birbirleri ile kesişmemeli ve ait oldukları hedefe ait farklı açı/polarizasyon kombinasyonlarındaki öznitelik vektörlerinin karşılık geldiği bütün “kazanan nöron” ları içermeli idi. Daha sonra, aktif sınıflandırma (test) sırasında, hangi hedefe ait olduğu bilinmeyen bir saçınım sinyali algılandığında, ilk iş olarak o sinyalin enerji öznitelik vektörü elde edildi ve SOM haritasındaki herbir nöronun ağırlık vektörü ile karşılaştırılarak, buna karşılık gelen “kazanan test nöronu” bulundu. Bu nöronun içine düştüğü kümelenme bölgesi ise bize hedef sınıflandırma sonucunu direkt olarak verdi.

Yukarıda özetlenen yöntemin kürelerden oluşan hedef grubuna uygulanması ile elde edilen sonuçlar Şekil 8'de verilen **SOM Haritası** üzerinde gösterilmektedir. Bu şekildeki 100 nörondan oluşan haritada eğitim safhasında bulunan kazanan nöronlar “#”sembolü ile, test aşamasında bulunan kazanan nöronlar ise “*” sembolü ile işaretlenmiştir. Görüldüğü gibi, SOM haritası üzerinde her bir küreye karşılık gelen ve birbiri ile kesişmeyen kümeleşme bölgeleri (SOM eğitimi sırasında) oluşmuş ve test aşamasında tesbit edilen kazanan nöronların hepsi test edilen “bilinmeyen hedef”lerin aslında ait oldukları kümelere düşmüşlerdir. Bir başka deyişle, tasarlanan Öznitelik Tabanlı SOM Hedef Sınıflandırıcı, söz konusu küre tanıma problemi için, sadece eğitim veri tabanı içerisinde değil, test veri tabanı içerisinde de % 100 doğru tanıma oranına ulaşmıştır. Bir test için harcanan toplam CPU zamanı ise yaklaşık 230 milisaniyedir. Elde edilen bu sonuçlar, Tablo 2 de görülmektedir.

Tablo 2. MLP Hedef Sınıflandırıcı, Öznitelik Tabanlı MLP Hedef Sınıflandırıcı ve Öznitelik Tabanlı SOM Hedef Sınıflandırıcı performanslarının çeşitli küre veri tabanları bazında karşılaştırılması.

	Eğitim Veri Tabanı İçerisinde (toplam 11 sinyal)	Deneme Veri Tabanı İçerisinde (toplam 10 sinyal)	Toplam Veri Tabanı İçerisinde (toplam 21 sinyal)
MLP Hedef Sınıflandırıcı (120 ms./test)	91 %	40 %	66.7 %
Öznitelik Tabanlı MLP Hedef Sınıflandırıcı (270 ms./test)	100 %	70 %	85.7 %
Öznitelik Tabanlı SOM Hedef Sınıflandırıcı (230 ms./test)	100 %	100 %	100 %

B (#) Backscat	B (*) 30/HP	B (#) 60/HP					D (*) 30/VP	
B (*) 45/VP								D (#) Backscat
B (#) 135/VP							D (#) 180/HP	
		B (*) 90/VP						
B (*) 120/HP	B (#) 180/VP		B	D				D (*) 120/VP
			A	C				
A (*) 120/VP		A (#) 150/VP						C (#) 150/HP
A (#) 100/VP								C (*) 30/VP
	A (#) 45/VP	A (*) Backscat					C (*) 120/VP	C (#) Backscat

Şekil 8. A, B, C ve D mükemmel iletken kürelerine ilişkin kümeleşme bölgelerini gösteren 10X10' luk SOM Haritası.

#: Eğitim veri tabanına ilişkin kazanan nöronlar

*: Test veri tabanına ilişkin kazanan nöronlar

2.3.4. Yorum: Yukarıda detaylı olarak anlatılan benzetim problemlerinden elde edilen sonuçlar bizi şu genel yoruma götürmektedir: Elektromanyetik hedef tanıma/sınıflandırma probleminde, Yapay Sinir Ağları uygun öznitelik çıkarma yöntemleri ile birlikte kullanıldıklarında etkili olmaktadır. Özellikle de, Öznitelik Tabanlı SOM Hedef Sınıflandırıcılar'ın performansı MLP tipi sınıflandırıcılara göre çok daha üstün bulunmuştur. Mükemmel iletken, farklı büyüklükte dört küreden oluşan kanonik hedef grubu için tasarlanan Öznitelik Tabanlı SOM Hedef Sınıflandırıcı %100 doğruluk oranına ve bir saniyenin çok altında bir tanıma süresine ulaşmıştır. Proje çalışmalarımızın bundan sonraki aşamasında, aynı Akıllı Hedef Tanıma Yönteminin karmaşık geometrili hedef gruplarına uygulanabilirliği test edilmiştir.

2.4. AKILLI HEDEF TANIMA YÖNTEMİNİN KARMAŞIK ŞEKLİ İLETKEN

HEDEFLERE UYGULANMASI: Öznitelik tabanlı MLP ve SOM elektromanyetik hedef sınıflandırıcıları karmaşık geometrik yapıdaki hedef gruplarına uygulamak amacı ile başlattığımız çalışmaların ilk basamağı olarak, çeşitli uçak modelleri için daha önce oluşturulmuş olan (bakınız, Bölüm 2.1.3) veritabanındaki saçınım sinyalleri işlenerek WD tabanlı enerji öznitelik vektörleri elde edilmiştir (bakınız, Bölüm 2.2.4) Verilerden öznitelik çıkarma çalışmalarının tamamlanmasından sonra, elde edilen öznitelik vektörleri ile YSA tabanlı hedef sınıflandırıcıların tasarımına geçilmiş ve aşağıdaki benzetim problemleri üzerinde çalışılmıştır.

2.4.1. Benzetim Problemi 4

Çalışmaların bu bölümünde, beş adet gerçeğe uygun geometrik özelliklere sahip, iletken yapıya sahip model uçağı tanımaya yönelik bir **Öznitelik Tabanlı MLP Hedef Sınıflandırıcı** tasarlanmıştır. Bu MLP tasarımında, 150 nörondan oluşan bir giriş katı, her biri bir uçağı ait 5 nörondan oluşan bir çıkış katı ve bu iki katın arasında iki tane ara kat kullanılmıştır. 1. Ara katta 100, 2. ara katta ise 30 nöron bulunmaktadır. Hedeflere ait her biri 150 örneklemeden oluşan öznitelik vektörlerinin eğitim için rastgele seçilen bir bölümü (her bir vektör için, sırası ile her bir vektör elemanı giriş katının bir nöronuna karşılık gelmek üzere) MLP ye uygulanmıştır. Bu süreçte kullanılan 17 adet öznitelik vektörü Tablo 3'de listelenen saçınım

sinyallerinden elde edilmiş olup, zaman uzayında (3.660-5.850) nanosaniyelik pencereye, frekans uzayında ise, -4 Ghz ile +4 Ghz arasında kalan pencereye karşılık gelmekte ve bu bölgelere sınırlı zaman-frekans uzayında saçınım verilerinin enerji dağılımı bilgisini taşımaktadırlar. MLP nin eğitimi sırasında, momentum sabiti 0.1, ve öğrenme hızının ilk değeri 0.35 olarak alınmıştır.

Eğitim sonunda, eğitim amacı ile kullanılan veri tabanı içerisinde doğru tanıma oranı %100 (17 de sıfır yanlış) olarak bulunmuştur. Tamamen yeni verilerle yapılan yapılan tanıma testlerinde ise, doğruluk oranı %64 (14 de 5 yanlış) olarak belirlenmiştir. Tüm veri tabanı baz alındığında, doğruluk oranı yaklaşık %84 (31 de 5 yanlış) olarak hesaplanmıştır.

Tablo 3. Model uçaklara ait hedef sınıflandırıcı benzetimlerinde eğitim amacı ile ve sadece test amacı ile kullanılan dikey polarizasyonlu geri saçınım sinyallerinin görüş açıları (derece cinsinden ve uçakların burnundan ölçülmek üzere).

	Hedef A	Hedef B	Hedef C	Hedef D	Hedef E
Eğitim Veri Tabanı	45, 120, 180	30, 60, 150, 180	0, 90	0, 30, 90, 180	0, 30, 90, 180
Test Veri Tabanı	60, 90, 150	45, 90, 120	45	45, 60, 120	45, 60, 120, 150

Yukarıda özetlenen sonuçlardan da anlaşılacağı gibi, MLP tipi YSA eğitimde kullanılan verilerden tanımayı hatasız başarmakta, ancak eğitim sırasında kullanılmayan tamamen yeni verilerle test edildiğinde 64 % seviyesinde kalan yetersiz bir performans göstermektedir. Diğer bir deyişle, bu problemde YSA kendisine direkt verilen bilgileri ezberleyebilmekte ancak yeni verilerle karşılaştığında doğru kararlara ulaşmakta zorlanmaktadır. Bu da MLP tipi YSA' ların mevcut komplike problemi çözmeye yeteri kadar uygun olmadığını (problemin kuvvetli derecede hedef bakış açısına bağımlılık göstermesi nedeniyle), alternatif YSA' ların denenmesi gerektiği sonucunu getirmektedir. Aynı problem basit geometri küre hedef grubunda da (ancak daha hafif bir ölçüde) yaşanmış ve SOM tipi bir YSA' nın kullanılması ile çözülmüştü. Uçaklardan hedef tanıma probleminde de aynı çözümün denenmesi gerektiği ortaya çıkmıştır. Bu nedenle çalışmalarımızın bir sonraki aşaması iletken

model uçaklardan oluşan hedef grubu içerisinde SOM tipi bir YSA kullanarak hedef tanıma problemine odaklanmıştır:

2.4.2. Benzetim Problemi 5

Çalışmaların bu bölümünde, yukarıda sözü edilen beş adet gerçeğe uygun geometrik özelliklere ve iletken yapıya sahip model uçağı tanımaya yönelik bir **Öznelik Tabanlı SOM Hedef Sınıflandırıcı** tasarlanmıştır. SOM tipi YSA' ların temel tasarım prensipleri Bölüm 2.3.3'de detaylı bir şekilde anlatılmıştı. O nedenle, aynı detaylar tekrar verilmeden, aşağıda sadece algoritmada yapılan önemli değişikliklerden söz edilecek ve uygulamalar sunulacaktır.

Çalışmalar sırasında ilk olarak, uçaklardan oluşan hedef grubunun veri tabanına standart SOM algoritması uygulanmıştır. Bu uygulama sırasında, önceden elde edilen öznelik vektörleri ile SOM eğitime çalışıldığında, ciddi bir yakınsama problemi ortaya çıkmış, her bir uçak hedefe ait kümelenme bölgelerinin birbiri ile kesişmeden yaratılabilmesi mümkün olmamıştır. Bu duruma bir çözüm getirmek amacı ile, standart yönlendirmesiz SOM algoritması yerine eğitim fazının başlangıcında kazanan nöronların yaklaşık yer bilgisinin verildiği bir çeşit "Yarı-Yönlendirmeli SOM" (YYSOM) algoritması yazıldı ve benzetimlerde kullanıldı. Yönlendirme sadece eğitimin ilk kaba aşamasına sınırlandırılıp, hassas eğitim ve test aşamalarında ise standart SOM kurallarına uyuldu.

Benzetim probleminde kullanılan Öznelik Tabanlı YYSOM Hedef Sınıflandırıcı 15X15 ' lik tek katmandan oluşan ve 225 adet nöron içeren bir yapay sinir ağı olarak tasarlandı ve yukarıda Tablo 3 de görülen 17 adet farklı veri kullanılarak eğitildi. Bu tabloda görülen eğitim ve test veri tabanları hem MLP probleminde ve hem de SOM probleminde ortak kullanılarak, her iki yöntemin sonuçlar bazında uçak tanıma probleminde karşılaştırılabilir olması hedeflendi.

SOM eğitiminde, kümelenme bölgelerinin kabaca oluşturulmasını hedefleyen birinci aşamada, öğrenme hızı 0.2 olarak ve komşuluk bölgesi yarı genişliği de 15 nöron olarak(başlangıçta bütün nöronları kapsayacak şekilde) belirlendi. Daha sonra, iterasyonlar sırasında her iki parametre de azaltıldı. Yaklaşık 3000 iterasyonda, yukarıda anlatılan YYSOM algoritması ile kümeleşme bölgeleri kabaca oluştu. Yaklaşık 30 000 iterasyon süren

incelikli tasarım aşamasında ise standart SOM algoritması (başlangıçtaki öğrenme hızı 0.05 ve konvergenlik bölgesi yarı genişliği de 3 nöron olacak ve zaman içerisinde azaltılacak şekilde) kullanıldı. Eğitim aşamasının tamamlanmasından sonra, test aşamasına geçildi. Eğitim ve test

(#) A-45		(*) A-60							(*) D-60	(*) D-45		(#) D-30
		(#) A-180							(#) D-90			(#) D-0
			(*) A-150									(#) D-180
		<u>A</u>							<u>D</u>			
(#) A-120	(*) A-90											
					(#) C-0							
		<u>C</u>				(*) C-45				(*) D-120		
					(#) C-90							
(#) B-180		(*) B-90							<u>E</u>			(*) E-120
									(*) E-60	(*) E-45		
	(#) B-60	<u>B</u>										(#) E-90
	(*) B-45											(*) E-150
	(#) B-30	(#) B-150	(*) B-120						(#) E-0	(#) E-30		(#) E-180

Şekil 9. 225 Nörondan oluşan ve A, B, C, D ve E hedeflerine ait kümelenme bölgeleri ile hiç bir hedefe ait olmayan nötral bölgeleri (taranmış) gösteren SOM haritası.

(#) Eğitim aşamasındaki kazanan nöronlar
 (*) Yeni verilerle test aşamasındaki kazanan nöronlar

sonuçları Şekil 9'da verilen SOM haritasında özetlenmektedir. Bu şekilde, eğitim aşaması kazanan nöronları “*” sembolü ile, yeni test verileri ile elde edilen kazanan nöronları ise “+” sembolü kullanılarak işaretlenmiştir. Şekil incelendiğinde, tasarlanan SOM tipi YSA'nın çok iyi bir tanıma performansı gösterdiği, eğitim sırasında kullanılmayan 14 yeni veri ile test edildiğinde hiç yanlış sonuç üretmediği, sadece bir tane (Hedef D-120 derece verisi için) belirsiz sonuca ulaştığı görülmüştür. Bu belirsiz durumda, kazanan nöron nötral bir bölgeye düşmüştür. Özet olarak, 14 denemede 13 doğru sonuçla, tasarlanan SOM Tanıyıcı yeni test verileri söz konusu olduğunda yaklaşık 93 % doğruluk oranına ulaşmıştır. Tüm veri tabanını oluşturan toplam 31 veri için bu oran 97 % e (31 de 30 doğru tanıma) ulaşmıştır.

2.4.3. MLP ve SOM tipi Öznitelik Tabanlı Hedef Tanıyıcıların Karşılaştırılması

Aynı hedefler ve aynı veri tabanları kullanıldığında, söz konusu hedef tanıyıcıların ulaştığı doğruluk performansı aşağıda görülen Tablo 4' de özetlenmiştir. Sadece MLP ve SOM hedef sınıflandırma sonuçlarını değil, aynı zamanda bir sonraki bölümde anlatılacak olan PCA ile hedef sınıflandırma sonuçlarını da özetleyen bu tablonun özellikle birinci derecede önem taşıyan orta kolonunda görüldüğü gibi, tasarlanan SOM Sınıflandırıcı sadece MLP Sınıflandırıcıya göre çok üstün bir performans göstermekle kalmayıp, oldukça karmaşık ve gerçeğe uygun geometrilere sahip olan, kendi aralarında da büyük benzerlikler gösteren bu uçak hedef grubu için mutlak anlamda da mükemmel denilebilecek hedef tanıma sonuçları üretmiştir.

2.4.4. Ana Bileşen Analizi (Principal Component Analysis -PCA) Yöntemi İle Hedef Sınıflandırma

Yukarıda özetlenmiş olan MLP ve SOM tipi YSA'lar ile hedef tanıma sonuçlarının ayrıca YSA türü dışında bir hedef tanıma yöntemiyle de karşılaştırılmasına karar verilmiştir. Bu amaçla, PCA yönteminin kullanıldığı bir hedef sınıflandırıcı tasarlanmıştır.

PCA uzun yıllardır bilinen bir veri analiz yöntemidir. Doğrusal transformasyon tekniklerinin geçerli olduğu bu yöntemde, verilen bir giriş sinyalinin izdüşümünün maksimize edileceği bir alt uzay ve bu uzayı tanımlayan “eigenvector” ler bulunur. Bu nedenle, verilerden öznitelik

çıkarma, veri sıkıştırma ve benzeri işlemlerin PCA yöntemiyle gerçekleştirilmesinde giriş sinyalinin uçuşu olduğu bilgi kaybı minimize edilebilir.

Bu projede uygulanan PCA ile hedef tanımının ana basamakları şöyle özetlenebilir:

- Sınıflandırılması istenen hedeflere ait geri saçılmış sinyallerden oluşan veri tabanındaki her bir (zamanda değişen) sinyal için, önceki gelişme raporunda detaylı olarak anlatıldığı biçimde, ayrı bir WD (Wigner Dağılımı) tabanlı (zaman-frekans uzayında tanımlanan) enerji dağılım matrisi hesaplanır. Başka bir deyişle, PCA ile hedef tanımada kullanılan öznelik çıkarım yöntemi MLP ve SOM ile hedef tanımada kullandığımız yöntemle başlangıçta aynıdır.
- İlk basamakta hesaplanan WD matrisine PCA yöntemi uygulanır. Bunun için, önce WD matrisinin “covariance” matrisi hesaplanır. Daha sonra da, bu “covariance” matrisinin “eigenvalue” ve onlara karşılık gelen “eigenvector” değerleri hesaplanır.
- Bulunan “eigenvalue” değerleri büyükten küçüğe doğru sıralandığında, karşılık geldikleri “eigenvector” ler de önem sıralı bir “orthogonal basis” oluştururlar. Büyük “eigenvalue” değerlerine karşılık gelen “eigenvector” ler, giriş sinyalindeki değişimlerin önemli bir kısmını karakterize ederler.
- Bizim uygulamamızda, veri tabanındaki her bir geri saçılım sinyali sadece ilişkili olduğu en büyük “eigenvalue” değerine karşılık gelen en baskın “eigenvector” ile karakterize edildi. Diğer bir deyişle, bu en baskın “eigenvector” o sinyale karşılık gelen öznelik vektörü olarak alındı.
- Sınıflandırıcı, kaynağı bilinmeyen yeni bir geri saçılım sinyali ile karşı karşıya kaldığında, bu sinyale ait baskın “eigenvector” bulunarak matematiksel norm bazında eğitim kümesindeki diğer baskın “eigenvector” ler ile karşılaştırılarak sinyalin kaynağının tahmini amaçlandı.

Sınıflandırmada model uçak hedeflere ait ortak eğitim ve test veri tabanları kullanıldığında (Bkz. Tablo 3) ve WD öznelik matrisleri her üç yöntem için de aynı biçimde hesaplandığında, aşağıdaki karşılaştırmalı hedef sınıflandırma performans tablosu (Bkz. Tablo 4) elde edilmiştir.

Tablo 4. MLP, SOM ve PCA yöntemleri ile model uçak hedefleri sınıflandırmaya ilişkin performans karşılaştırma tablosu

	Eğitim Veri Tabanı İçerisinde (toplam 17 sinyal)	Deneme Veri Tabanı İçerisinde (toplam 14 sinyal)	Toplam Veri Tabanı İçerisinde (toplam 31 sinyal)
Öznitelik Tabanlı MLP Hedef Sınıflandırıcı	100 %	64 %	84 %
Öznitelik Tabanlı SOM Hedef Sınıflandırıcı	100 %	93 %	97 %
WD Enerji Matriksine Dayalı PCA Hedef Sınıflandırıcı	100 %	79 %	90 %

Tablo 4’de görüleceği gibi, tanıma doğruluğu açısından PCA sınıflandırıcısı MLP sınıflandırıcıdan çok daha iyi ancak SOM sınıflandırıcıya göre ise oldukça zayıf bulunmuştur.

2.5 K-DARBE HEDEF TANIMA YÖNTEMİ

Bilindiği gibi, bu proje kapsamında gerçekleştirilmesi gereken hedef tanıma çalışmalarının ikinci ana bölümü K-Darbe tekniğine dayanmaktadır. Proje kapsamında yapılan işlerin anlatımına geçmeden önce, K-Darbe tekniğine ilişkin kısa bir giriş yapılacaktır. Konunun detayları için referans bölümünde listelenen kaynaklara başvurulabilir.

2.5.1. K-Darbe Yönteminde Ana Fikir ve Tanımlar

Tanım: Sonlu büyüklükteki bir elektromanyetik hedefin **K-darbe sinyali**, $k(t)$, ideal durumda şu şartları sağlamalıdır [10]:

- $k(t)$ zamanın bir fonksiyonu olup, zaman ekseninde sınırlı bir tanım bölgesine (süreeye) sahip olmalıdır,
- Söz konusu hedef $k(t)$ ile uyarıldığında, yaratılacak saçınım sinyali (yani hedefin K-darbe tepkisi) uyarının ve tepkenin açıları ve polarizasyonları ne olursa olsun zamanda sınırlı olmalıdır. Bu şart söz konusu tepkenin Laplace dönüşümünde hiç bir kutup olmaması anlamına gelir. Bu durum ise, K-Darbe spektrumunun kompleks sıfırları ile hedefin sistem fonksiyonunun kompleks kutuplarının bire bir aynı setten oluşarak birbirlerini yok etmeleri ile mümkündür.
- Hedefin k-darbe spektrum sıfırları, o hedefin kompleks rezonans frekanslarını (yani kutuplarını) verir.
- $k(t)$ ' nin süresi ancak minimal olarak seçildiğinde k-darbe sinyalinin tekliğinden (uniqueness) söz edilebilir. (Pratik problemlerde sınırlı frekans bantları ile çalışmak zorunluluğu ve k-darbe süresinin hassas tayinindeki zorluklar teklik şartının sağlanmasına engel olur.)
- Bir hedefin her türlü açı ve polarizasyon şartı altında zamanda sınırlı tepkeler vermesi ancak kendine ait k-darbe sinyali ile uyarılması durumunda mümkündür. Bu durum k-darbe yöntemi ile hedef tanıma/sınıflandırma uygulamalarını mümkün kılar.

Sentez: K-darbe sinyalinin sentezi iki yolla mümkündür:

- Hedefin kompleks rezonans frekansları biliniyorsa, bu frekanslarda kutuplara sahip ve bazı özel değişim şartlarını sağlayan bir “entire” (kompleks frekans uzayının her noktasında analitik olan) fonksiyon, $K(s)$, sentezlenebilir. Daha sonra $k(t)$, $K(s)$ ’ in ters Laplace dönüşümü hesaplanarak bulunabilir. Ancak, bir çok pratik hedef için sistem kutuplarının eldeki gürültü içeren verilerden Prony vb. yöntemlerle çıkarılması oldukça hatalı sonuçlar verir. Genelde, eldeki verilerden direkt yöntemlerle kutupların çıkarılmasında [19] karşılaşılan zorluklar, k-darbe sentezinin bu yolla gerçekleştirilmesini pratikte imkansız hale getirir.
- K-darbe sinyali sabit ya da değişken bir zaman aralığında uygun baz fonksiyonları (basis functions) cinsinden ifade edilir [13, 15, 16]. K-darbe sinyalinin yaratacağı tepkelerin zamanda sınırlı olması şartı kullanılarak, k-darbe açılımındaki bilinmeyen katsayılar bulunur. Diğer bir deyişle, bu bir optimizasyon problemidir ve burada minimize edilen fonksiyon hedef tepkesinin geç-zamanlara yayılmış toplam enerjisidir. Bu problemde “geç-zaman” dan kasıt hedef tepkesinde sadece doğal rezonansların etkisinin görülmeye başladığı andan sonsuza kadar olan zaman aralığıdır. Pratikte kullanılan K-darbe sentez yöntemleri hemen hemen her zaman optimizasyona dayalıdır.

Optimizasyon ile k-darbe tasarımı:

Bu amaçla kullanılacak optimizasyon yöntemi problemdeki bilinmeyen sayısına ve daha da önemlisi k-darbe süresinin bilinip bilinmediğine göre seçilir:

- Eğer K-darbe süresi biliniyorsa (ince metal tel, metal silindir veya metal küre gibi basit geometri ve metalik yapıda kanonik hedefler için bu mümkündür), “steepest-descent” yöntemleri başarı ile ve hızlı bir şekilde kullanılabilir. Bilinmeyen sayısının çok olduğu durumlarda da bu yöntem yararlıdır [10, 13, 15, 16].
- Bir çok pratik problemde, hedef geometrisi ve/veya materyal yapısı nedeniyle k-darbe süresinin tahmini çok zordur. O nedenle, K-darbe süresi de bir optimizasyon değişkeni olarak alınmalıdır. Bu durumda, problemin çok sayıda lokal çözümü ortaya çıkar ve “steepest-descent” yönteminin başarısı optimizasyon probleminde seçilen başlangıç değerlerine aşırı duyarlı hale gelir. Bu tür problemlerde, optimizasyon problemine global

kaldığı geçmiş çalışmalarımızda görülmüştü. Bu nedenle de çalışmalarımız Genetik Algoritmaların kullanımı yönüne kaydırılmıştı. Bu nedenle, bu proje kapsamında MATLAB ortamında GA kod yazım/geliştirme çalışmaları yapıldı ve daha sonra da deneme niteliğinde K-darbe tasarım çalışmaları gerçekleştirildi. Bu tasarım çalışmaları için gerekli olan kürelere ait elektromanyetik saçınım sinyalleri ise Bölüm 2.1.4'de anlatıldığı gibi geliştirilen MATLAB kodları ile hesaplandı.

2.5.2. K-Darbe Tasarımında Matematiksel Model, Optimizasyon ve Hedef Tanıma

Teori:

K-darbe sinyalini tasarlamak istediğimiz sonlu büyüklükteki herhangi bir elektromanyetik hedefi, verilen "i" endeksli görüş açısı ve polarizasyon kombinasyonunda geçerli olan bir sistem fonksiyonu, $H^i(s)$, ile (kompleks frekans, $s = \sigma \pm j 2\pi f$, uzayında) ya da onun ters Laplace dönüşümünü hesaplayarak bulabileceğimiz dürtü tepkisi, $h^i(t)$, ile (zaman uzayında) modelleyebiliriz. Bu modellemenin arkasında "linear, time-invariant" sistem varsayımı (yaklaşık anlamda) yatmaktadır [9]. Hedefi söz konusu açı/polarizasyon şartlarına uygun olarak uyarıcı herhangi bir $x(t)$ sinyaline hedefin verdiği tepki, $r^i(t)$, uyarıcı sinyalle hedefin dürtü tepkesinin konvolüsyonunu alarak bulunur:

$$r^i(t) = x(t) * h^i(t) \quad (17)$$

Bu problemde bizi ilgilendiren, uyarıcı sinyalinin k-darbe sinyali, $k(t)$, olması halidir. Tasarımın başında, hangi uzunlukta ve nasıl bir şekilde olduğunu bilmediğimiz bu özel uyarıcı sinyali $[0, T_k]$ zaman aralığına transform edilmiş Legendre polinomlarından oluşan bir baz cinsinden matematiksel olarak modelleyebiliriz [14, 17]:

$$k(t) = A \delta(t) + \sum_{n=0}^{\infty} D_n \bar{P}_n(t) \quad (18)$$

Bu gösterimde Legendre polinomları

$$\bar{P}_n(t) = \sum_{m=0}^n \alpha_{nm} \left(\frac{2}{T_k}t - 1\right)^m \quad (19)$$

şeklinde, orijinal Legendre polinomlarının yapısal sabitleri, α_{nm} ve k-darbe süresi, T_k , cinsinden ifade edilebilirler. T_k ve D_n katsayıları, problemin bilinmeyenleri olup, aşağıda verilen optimizasyon problemini çözerek elde edilirler:

$$\text{Minimize } J(T_k, D_0, D_1, \dots) = \sum_{i=1}^I W_i J_i \quad (20)$$

Bu bedel fonksiyonunda I tane farklı açıl/polarizasyon kombinasyonu kullanılarak tasarım doğruluğu arttırılabilir [16]. Yukarıdaki ifadede W_i ağırlık katsayılarını, J_i ise her bir kombinasyondaki hedefin rezonatif doğal tepkesine ilişkin geç-zaman enerjisini verir:

$$J_i = \int_{\frac{L_i}{c} + T_k}^{\infty} [r^i(t, T_k, D_0, \dots)]^2 dt \quad (21)$$

K-darbe teorisindeki ana fikir gereği

$$t \geq T_{L_i} = \frac{L_i}{c} + T_k \quad \text{için} \quad r_k^i(t) = 0 \quad (22)$$

olması gerekir, burada T_{L_i} geç-zaman (late-time) olarak adlandırılmaktadır ve hedef tepkesinde zorlanmış tepkenin (forced response) sona erip sadece doğal tepkenin (natural response) var olmaya başladığı zamanı göstermektedir. L_i ise, uyarı açısında hedefin görünür dogrusal boyutudur. Ayrıca, 18 numaralı eşitlikte görüldüğü gibi, k-darbe ifadesine bir dürtü fonksiyonu (impulse function) da, yakınsamayı hızlandırmak amacıyla, katılabilir.

Genetik Algoritmanın (GA) Uygulanması

Bilindiği gibi GA'lar, global çözüm bulma konusunda başarılı olan, türev hesaplamaları ve uygun başlangıç değerleri gerektirmeyen ve "Fitness" diye adlandırılan performans fonksiyonunu maksimize eden evrimsel optimizasyon algoritmalarıdır [4, 20]. Bizim çözdüğümüz K-darbe tasarım probleminde (1/J) yani 20, 21 ve 22 numaralı ifadelerde tanımlanan bedel fonksiyonunun tersi "fitness" olarak tanımlanmış, böylece J'nin (yani

hedefin geç-zamanlarda tek başına var olan rezonans (doğal tepkesinin) minimize edilmesi sağlanmıştır. Çözülen örnek problemlerde bir tek "bistatik" açıda tasarım yapılması yeterli bulunmuş, yani $I=1$ alınmıştır.

GA uygulamasında, k-darbe sinyalinin tanımlayan 7 değişken (k-darbe süresi ve ilk 6 Legendre polinom katsayısı) optimize edilmiş ve bunların herbiri 8 "bit" ile gösterilmiştir. 56 "bit" uzunluğunda 100 adet kromozomdan oluşan GA nüfus kümesi 100-150 iterasyonda evrimden geçirilmiş, Roulette Wheel ebeveyn kromozom seçme yöntemi, "Crossover" (bir sonraki jenerasyondaki kromozomların üretilmesi işlemi), "Mutation" (mutasyon), "Elitism" (en iyi kromozomu bir sonraki jenerasyona taşıma işlemi) ve benzeri bilinen GA işlemleri uygulanarak sonuçlar elde edilmiştir.

K-darbe tekniği ile hedef tanıma


Bilindiği gibi, K-darbe tekniğinde esas, hedefin sistem kutuplarının hedef tepkesinde yarattığı rezonans yapısını ortadan kaldırarak, her uyarı açısı ve polarizasyonda zamanda sınırlı tepkeler yaratacak özel bir uyarı sinyali tasarlamaktır. Zamanda sınırlı olan bu sinyal, yani hedefe ait K-darbe sinyali, hedefi görüş açısı ve polarizasyondan bağımsız bir şekilde tarif eden bir öznelik sinyalidir. Tanınması /sınıflandırılması istenen hedeflerden her biri için, o hedefe özel K-darbe sinyalleri tasarlandıktan sonra bu sinyaller bilgisayar hafızasında depolanan birer sayısal filtre gösterimi olarak düşünülebilirler. Sınıflandırılması gereken, ne olduğu bilinmeyen bir hedeften daha sonra gelen elektromanyetik saçınım sinyali, önceden tasarlanmış olan bu filtrelerin her birinden paralel olarak geçirilir ve çıkış tepkesi göreceli olarak en kısa zaman dilimine yayılmış olan ve rezonans davranış göstermeyen filtrenin ait olduğu hedef sınıflandırma sonucu olarak belirlenir [10, 15, 16]. Bu hedef tanıma yönteminin en büyük avantajı büyük veritabanları gerektirmemesi ve gerçek-zamandaki hızıdır. Sınıflandırma işlemi çıkış sinyallerinin normalize edilmiş enerji eğrileri kullanılarak yapıldığında, gürültü performansının da oldukça iyi olduğu bilinmektedir [14].

2.5.3. K-Darbe Tasarım Örnekleri (Benzetim Problemleri 6, 7 ve 8)

Yukarıdaki bölümlerde özetlenen yöntemler, daha önce literatürde üzerinde çalışılmamış olan bir hedef grubuna, dielektrik küreler ve dielektrik kaplı iletken kürelere uygulandı. Bu uygulamalarda, tek açıda tasarım yapıldı, K-darbe süresi değişken olarak alındı. Kürelerin dielektrik kırılma indeksine ve dielektrik kaplama kalınlığına göre K-darbe süresinin değişimi incelendi. Üzerinde çalışılan hedefler şunlardı:


- $r_{out}=1$ metre yarıçapında, kırılma endeksi $n=(4)^{1/2}=2$ olan kayıpsız dielektrik küre,
- $r_{out}=1$ metre yarıçapında, kırılma endeksi $n=(10)^{1/2} \approx 3.16$ olan kayıpsız dielektrik küre (K-darbe sinyalinden hedef kutuplarının elde edilmesi için incelendi.),
- $r_{out}=1$ metre dış yarıçapında kayıpsız dielektrik kaplı mükemmel iletken küreler: (r_{in} : içteki mükemmel iletken kürenin yarıçapı olmak üzere)
 - $r_{in}/r_{out} = 0.05, 0.5, 0.8, 0.95$
 - $n = 2$ ve 4

Benzetim Problemi 6: Kırılma endeksi $n = 2$ değerinde ($\epsilon_r = 4$) olan kayıpsız dielektrik kürenin K-darbe sinyali GA kullanılarak tasarlandı. K-darbe süresi [10, 60 ns] sınırları içinde optimize edildi ve $T_K = 51.57$ ns bulundu. Elde edilen K-darbe sinyali aşağıda görülmektedir.




Şekil 10. Yarıçapı 1 metre, kırılma endeksi 2 olan kayıpsız dielektrik küre için elde edilen K-darbe sinyali.

Bu küreye ait 90 derece bistatik açıdaki dürtü tepkisi ve K-darbe tepkisi (hedefin kendine ait K-darbe sinyali ile uyarıldığı zaman verdiği tepke) Şekil 11' de verilmektedir.




(a) Dürtü tepkisi




(b) K-darbe tepkisi

Şekil 11. Kırılma endeksi $n=2$ olan kürenin 90 derece bistatik görüş açısında hesaplanan dürtü tepkisi ve K-darbe tepkisi.

Aynı kürenin başka bir bistatik açıda, 135 derecede hesaplanan tepkeleri de aşağıda Şekil 12' de görülmektedir.




(a) Dürtü tepkisi




(b) K-darbe tepkisi

Şekil 12. Kırılma endeksi $n=2$ olan kürenin 135 derece bistatik görüş açısında hesaplanan dürtü tepkisi ve K-darbe tepkisi.

Şekil 11 ve 12 de görüldüğü gibi, teğarlanan K-darbe sinyali her iki test açısında da kürenin doğal rezonanslarını önemli ölçüde yok etmiştir. Bu durumu daha net gözleyebilmek için 135 derecedeki tepkelerin geç-zaman değişimleri daha büyük bir ölçekte çizilmiş olarak Şekil 13 de tekrar verilmiştir:




(a) Dürtü tepkesi




(b) K-darbe tepkesi

Şekil 13. Kırılma endeksi $n=2$ olan kürenin 135 derece bistatik görüş açısında hesaplanan dürtü tepkesinin ve K-darbe tepkesinin geç-zaman dilimindeki detayları.

Benzetim Problemi 7: Kırılma endeksi $n = 2$ olan ($\epsilon_r = 4$) kayıpsız bir dielektrik materyalle kaplanmış mükemmel iletken bir kürenin K-darbe sinyali, farklı kaplama kalınlıkları için GA kullanılarak, tasarlandı ve aşağıdaki sonuçlar elde edildi:



(a) içteki mükemmel iletken kürenin çok küçük olması durumu



(b) dielektrik kaplamanın çok ince olması durumu

Şekil 14. Kırılma endeksi $n = 2$ olan kürede mükemmel iletken kürenin çok küçük olması ya da dielektrik kaplamanın çok ince olduğu özel durumlar

(i) İçteki mükemmel iletken kürenin çok küçük olması durumu:


$r_{in} / r_{out} = 0.05$ ve $n = 2$ değerleri için elde edilen sonuçlar, $n = 2$ değerli kayıpsız dielektrik küre sonuçlarına çok yakın bulundu. Diğer bir deyişle, içteki küçük iletken kürenin etkisinin ihmal edilebilir düzeyde olduğu gözlemlendi.

(ii) Dielektrik kaplamanın çok ince olması durumu:

$r_{in} / r_{out} = 0.95$ ve $n = 2$ değerleri için elde edilen sonuçlar, mükemmel iletken bir küre için elde edilen sonuçlara çok yakın bulundu. Diğer bir deyişle, çok ince dielektrik kaplamanın etkisinin ihmal edilebilir düzeyde olduğu gözlemlendi.

(iii) Dielektrik Kaplı Mükemmel İletken Küre ($n=2$ ve $r_{in} / r_{out} = 0.5$ durumu)


- K-pulse tasarımında GA kullanıldı,
- T_k süresi [10, 100] ns aralığında arandı,
- $T_k \cong 52$ ns bulundu.




Şekil 15. Dielektrik kaplı mükemmel iletken küre

($n=2$ ve $r_{in} / r_{out} = 0.5$) için tasarlanan K-darbe sinyali

Bu hedef için 0 derece bistatik açıda (geri saçılım durumu) hesaplanan dürtü tepesi ve K-darbe tepkeleri de Şekil 16'da görülmektedir:



(a) Dürtü tepesi




(b) K-darbe tepesi

Şekil 16. $n=2$ ve $r_{in} / r_{out} = 0.5$ değerlerine sahip kürenin geri saçılım durumu için (0 derece) hesaplanan dürtü tepesi ve K-darbe tepesi.


(iv) Dielektrik Kaplı Mükemmel İletken Küre ($n=2$ ve $r_{in} / r_{out} = 0.8$ durumu)

- K-pulse tasarımında GA kullanıldı,
- T_k süresi [10, 100] ns aralığında arandı,
- $T_k \cong 52$ ns bulundu.




Şekil 17. Dielektrik kaplı mükemmel iletken küre ($n=2$ ve $r_{in} / r_{out} = 0.8$) için tasarlanan K-darbe sinyali

Bu yeni hedef için 0 derece bistatik açıda (geri saçılım durumu) hesaplanan dürtü tepkisi ve K-darbe tepkeleri de Şekil 18'de görülmektedir:



(a) Dürtü tepkisi




(b) K-darbe tepkisi

Şekil 18. $n=2$ ve $r_{in} / r_{out} = 0.8$ değerlerine sahip kürenin geri saçılım durumu için (0 derecede) hesaplanan dürtü tepkisi ve K-darbe tepkisi.

(v) Dielektrik Kaplı Mükemmel İletken Küre ($n=4$ ve $r_{in} / r_{out} = 0.8$ durumu)


- K-pulse tasarımında GA kullanıldı,
- T_k süresi [20, 130] ns aralığında arandı,
- $T_k \cong 116$ ns bulundu.




Şekil 19. Dielektrik kaplı mükemmel iletken kürenin

($n=4$ ve $r_{in} / r_{out} = 0.8$) K-darbe sinyali

Kırılma indeksinin daha yüksek olduğu bu yeni hedef için 0 derece bistatik açıda (geri saçılım durumu) hesaplanan dürtü tepkisi ve K-darbe tepkeleri de Şekil 20'de görülmektedir:



(a) Dürtü tepkisi



(b) K-darbe tepkisi

Şekil 20. $n=4$ ve $r_{in} / r_{out} = 0.8$ değerlerine sahip kürenin geri saçılım durumu için (0 derece) hesaplanan dürtü tepkisi ve K-darbe tepkisi.

Son üç örnekte elde edilen sonuçlar incelendiğinde, K-darbe süresinin dielektrik kaplama kalınlığındaki değişikliklere hassas olmadığı ancak dielektrik tabakanın kırılma endeksi ile değiştiği görülmektedir. Ancak, literatürde ilk kez incelenen bu problem, K-darbe sinyalinin tek bir çözümü olmadığı da göz önünde tutularak, ilerideki araştırma programlarında daha detaylı bir şekilde incelenmeye devam edilmelidir.

Benzetim Problemi 8: Tasarlanan K-darbe sinyalinden hedef kutuplarının elde edilmesi

K-darbe yönteminin önemli yan uygulamalarından biri de tasarlanan K-darbe sinyalinden hedef kutuplarının elde edilmesidir. Proje çalışmalarımızın bir bölümü de bu amaçla bir MATLAB kodunun yazılmasını ve uygulanmasını içermiştir. Söz konusu uygulamada kullanılan hedef 1 metre yarıçapında ve $n=3.16$ kırılma endeksine sahip olan kayıpsız dielektrik küredir. Bu hedefe ait analitik yöntemlerle elde edilmiş kutup sonuçları Aly et.al tarafından [1] yazılan makalede (grafikler halinde) verilmiş ve elde ettiğimiz sonuçlarla karşılaştırılmıştır. Çalışmanın ara basamaklarını şöyle özetlemek mümkündür:

- Öncelikle Genetik Algoritma (GA) yöntemi kullanılarak kürenin K-darbe sinyali sentezlendi.
- GA uygulanırken K-darbe süresi [10, 100] nanosaniye aralığında optimize edildi ve sonuçta $T_k=95.4$ ns olarak elde edildi.
- Daha sonra, elde edilen K-darbe sinyalinin Laplace dönüşümünün sıfır olduğu kompleks frekans değerleri nümerik olarak (yazılan MATLAB kodu ile) hesaplandı. Aşağıda ilk dört tanesi listelenen bu frekanslar, yukarıda sözü edilen referansta da tartışıldığı gibi dielektrik kürenin iç kutuplarına (inner poles) karşılık gelmektedir.

$-0.0476 \pm i0.9455$ (referanstaki (1,1) indeksli kutup)

$-0.0760 \pm i2.0679$ (referanstaki (1,2) indeksli kutup)

$-0.0935 \pm i2.9569$ (referanstaki (1,3) indeksli kutup)

$-0.1100 \pm i4.0643$ (referanstaki (1,4) indeksli kutup)

Not: s: kompleks frekans, r: küre yarıçapı, c: ışık hızı olmak üzere, kutup değerleri sr/c ölçeğinde listelenmiştir.

Diğer bir deyişle, bu kutuplar elektromanyetik dalgaların dielektrik küre içindeki davranışlarından kaynaklanan ve hedef tepkesinde kısa sürede sönümlenmeyecek biçimde

kendini gösteren rezonanslarla ilişkilidirler. Bulunan bu değerler, yukarıda verilen referansta analitik yöntemlerle hesaplanan kutup değerleri ile de karşılaştırılmış ve iyi bir uyum içerisinde oldukları görülmüştür. Ayrıca, K-darbe sinyalinde elde edilen bu hedef kutuplarının, (göreceli olarak) kuvvetli bir biçimde uyarılan kutuplar olduğuna da işaret etmek gerekir.

2.5.4. K-Darbe Tasarımında Birden Fazla Görüş Açısı ya da Polarizasyonda Veri

Kullanılması

Proje çalışmalarımızın son bölümünde, K-darbe tasarımının birden fazla açı ya da polarizasyon değerinde elde edilmiş verilerle gerçekleştirilmesi üzerine ön çalışmalar yapıldı. Proje teklifimizde yer almadığı halde fazladan yapılan bu çalışmanın motivasyonu şöyle açıklanabilir: Hedef kutuplarının değerleri açı ve polarizasyon seçimlerinden bağımsız olduğu halde, bu kutupların uyarılma seviyeleri (yani tepkenin kutup açılımı içerisinde kutupların ilişkili oldukları ağırlıklar-residues in singularity expansions) açı ve polarizasyona karşı çok duyarlıdır [2]. Bu nedenle, k-darbe tasarımında tek bir açı/polarizasyon kombinasyonunda saçınım verisi kullanılması halinde, ancak bu kombinasyonda güçlü bir şekilde kendini gösteren kutuplar k-darbe tasarımında etkili olabilirler. Sonuçta elde edilen k-darbe sinyali başka bir açı/polarizasyon kombinasyonunda uyarıcı olarak kullanıldığında, tasarım kombinasyonunda zayıf kalıp bu yeni kombinasyonda etkili olan farklı kutupların rezonatif etkisini yok etmekte başarısız kalır. Dolayısı ile, dominant kutupların farklılık gösterdiği birden fazla açı/polarizasyon kombinasyonunda ölçülen verilerle yapılan K-darbe tasarımında başarı oranı daha yüksek olacaktır. Bu amaçla, daha önce yazılmış olan GA ile K-darbe tasarım kodu bu amaca uyacak biçimde geliştirildi. Yapılan pilot tasarımlarda, bu şekilde elde edilen K-darbe sinyallerinde K-darbe süresinin daha kısa olma eğilimi gösterdiği görüldü. Teorik olarak, K-darbe sinyalinin teklik şartı darbe süresinin minimal olması ile tanımlandığı için, bu sonuç olumlu değerlendirildi. Örneğin, kırılma endeksi $n = 2$ olan 1 metre yarıçapındaki kayıpsız dielektrik küre için 0, 45 ve 90 derece bistatik açılardaki veriler kullanılarak tasarlanan K-darbe sinyalinin süresi 37 nano saniye olarak optimize edildi. Daha önceki tek açıda yapılan tasarım sonuçlarında bu süre 52 nanosaniye civarında bulunmuştu. Özet olarak, dielektrik küreler ve dielektrik kaplı iletken küreler için tek ya da birden fazla açıda gerçekleştirilen K-darbe tasarım çalışmaları ilginç sonuçlar üretmiştir, ancak bu sonuçları çeşitlendirme ve yorumlama konusunda çalışmalar henüz başlangıç aşamasındadır ve ileride başka bir proje kapsamında daha detaylı bir şekilde sürdürülmelidir.

3. SONUÇ

Uzaktan Algılanan Verilerden Hedef / Nesne Tanıma isimli projemizin amacı nümerik yöntemlerle hesaplanmış ve/veya yansız oda ölçümlerinden elde edilmiş elektromanyetik saçınım verilerini kullanarak çeşitli geometrik zorluk derecelerindeki hedef tanıma/sınıflandırma problemlerini çözecek yöntemler geliştirmek ve uygulamaktır. Proje planında belirtilen elektromanyetik hedef tanıma çalışmaları iki ana başlık altında toplanmaktaydı:

- Akıllı Hedef Tanıma Yöntemleri,
- K-Darbe Hedef Tanıma Yöntemi,

Bu çerçevede projede yapılan çalışmalar ve elde edilen sonuçlar kısaca şöyle sıralanabilir:

- Mükemmel iletken hedefler olan küreler, düz silindirik teller ve küçük ölçekli iletken model uçaklar için elektromanyetik saçınım sinyallerinden oluşan veritabanları oluşturuldu. Kürelere ve tellere ait veriler mevcut bazı kodlar kullanılarak nümerik olarak hesaplandı. Model uçak verileri ise daha önceden bir yansız odada ölçülmüş verilerdi.
- Dielektrik kürelerden ve küresel dielektrik bir tabaka ile kaplanmış mükemmel iletken kürelerden saçınmış elektromanyetik alanların hesaplanmasına yönelik teorik çalışmalar ve kod yazılım çalışmaları gerçekleştirildi. Söz konusu hedeflerden çeşitli açı ve polarizasyon şartlarında saçınım sinyallerinin hesabını mümkün kılan bu çalışmanın sonucunda, dielektrik küreler ve küresel dielektrik bir tabaka ile kaplanmış mükemmel iletken küreler için veritabanları oluşturuldu.
- Bir Zaman-Frekans Dönüşüm tekniği olan Wigner Dağılımı (WD) kullanılarak, çeşitli hedef gruplarına ait işlenmemiş veri tabanlarından öznelik veri tabanları oluşturmak için gerekli bilgisayar kodları geliştirildi, öznelik vektörleri çıkarıldı.

- Çok Katlı Perseptron (Multi Layer Perceptron-MLP) tipi ve Öz Örgütlemeli Harita (Self Organizing Map-SOM) tipi Yapay Sinir Ağlarının hedef tanımadaki kullanılabilirliği için gerekli bilgisayar kodları oluşturuldu. SOM ağlarının elektromanyetik hedef tanımadaki kullanılması konusunda literatürde mevcut ilk çalışmalar bu proje çerçevesinde gerçekleştirildi.
- WD, MLP ve SOM algoritmaları kullanılarak çeşitli yarıçaplardaki dört mükemmel iletken küreden oluşan bir hedef grubu için (**Akıllı Hedef Tanıma** tekniğiyle) hedef sınıflandırma çalışmaları başarıyla sonuçlandırıldı. WD tekniği ile oluşturulan öznitelik veritabanları ile eğitilen yapay sinir ağlarının çok daha başarılı olduğu gösterildi. WD ve SOM tekniklerinin birlikte kullanıldığı sınıflandırma uygulamasında yüzde yüz (100 %) varan bir doğru tanıma oranı elde edildi. Bu sonuçlar, Nisan 1999' da uluslararası hakemli bir dergide yayınlandı.
- WD ile elde edilmiş öznitelik veritabanının kullanıldığı MLP ve SOM hedef sınıflandırıcıları karmaşık geometrik yapıdaki beş adet iletken model uçaktan oluşan hedef grubuna da başarıyla uygulandı. Elde edilen sonuçlar ayrıca PCA yöntemi ile elde edilen hedef tanıma sonuçları ile de karşılaştırıldı. WD ve SOM tekniklerinin birlikte kullanıldığı uçak sınıflandırma probleminde yüzde doksan üç (93 %) mertebesinde çok yüksek bir doğru tanıma oranına ulaşıldı. Sonuçlar, Temmuz 1999' da uluslararası hakemli bir sempozyumda sunulup, sempozyum kitabında basıldı.
- **K-Darbe Hedef Tanıma** yönteminde darbe süresinin bilinmediği ve bir optimizasyon değişkeni olarak bulunması gerektiği durumlar üzerinde çalışıldı. Bu amaçla, Genetik Algoritmaların kullanıldığı optimizasyon problemleri çözüldü. K-darbe tekniği, literatürde ilk defa olarak, dielektrik yapılara ve dielektrik kaplı mükemmel iletken yapılara uygulandı. Hedef geometrisi olarak küreler kullanıldı. Dielektrik materyalin kırılma indeksinin ve kaplama kalınlığının K-darbe süresini nasıl etkilediği incelendi. Sonuçlar, Temmuz 1999'

da uluslararası hakemli bir sempozyumda sunulup, makale özeti sempozyum kitabında basıldı.

- K-darbe sinyalinin Laplace transformundan hedef kutuplarının hesaplanmasını mümkün kılan bir bilgisayar kodu geliştirildi ve bir dielektrik küreye uygulanarak başarılı sonuçlar elde edildi.
- K-Darbe Hedef Tanıma yöntemi çerçevesinde, birden fazla bakış açısında ölçülmüş ya da hesaplanmış saçınım verilerinden K-darbe sinyalinin tasarımı üzerinde bir ön çalışma gerçekleştirildi ve sonuçlar Temmuz 2000' de uluslararası hakemli bir sempozyumda sunulup, makale özeti sempozyum kitabında basıldı.

Tüm bu sonuçlar proje önerisinde verilen çalışma planı ile karşılaştırıldığında, projenin öneri formunda belirtilen amaç ve kapsama uygun olarak, eksiksiz sonuçlandığı görülmektedir. Ayrıca, proje önerisinde belirtilmeyen, PCA uygulamaları, birden fazla bakış açısında K-darbe tasarımı gibi konularda da ek çalışmaların yapıldığı belirtilmelidir.

Sonuçların uluslararası bilimsel literatüre katkısı yayınlanan bir adet dergi makalesi ve üç adet sempozyum bildirisi ile büyük ölçüde sağlanmıştır. Sonuçların uygulamalara katkısı ise, geliştirilen yöntemlerin entegre edileceği, gerçek hayat senaryolarını ve gerçek-zaman ölçümlerini içeren daha büyük ölçekli proje çalışmalarının başlatılması ile mümkün olacaktır. Projede incelenen ve çözümler üretilen elektromanyetik hedef tanıma problemi gerçek hayata uygulandığında ortaya çıkacak olan, atmosferik gürültü, aynı anda birbirini etkileyen birden fazla hedefin varlığı, kamuflaj ve geri plandaki çeşitli objelerin varlığından kaynaklanan "clutter" tipi gürültüler hedef tanıma problemini çok daha karmaşık hale getirecektir. Bu konuların her biri başlı başına birer proje konusu olabilecek zorlukta ve kapsamdadır. Ayrıca belirtilmesi gereken bir husus da, projede incelediğimiz iki hedef tanıma yönteminden ikincisinin, yani K-darbe tekniği ile hedef tanıma yönteminin, çok geniş bantlı (Ultra Wide Band-UWB) radarların hayata geçirilmesinden sonra daha önem kazanacağıdır. Günümüzde yaygın olarak kullanılan dar bantlı radar sistemleri bu yöntemin kullanılmasına uygun değildir. Ancak UWB Radar konusunda dünyada çalışmalar sürmektedir. Mevcut şartlarda, K-darbe tekniği radar uygulamalarından çok, tıp ve jeoloji konularındaki geniş bantlı anten dizinlerinin kullanılmasını içeren uygulamalarda daha ümit verici

gözükmektedir. Yer altına gömüldü insan yapısı veya doğal cisimlerin tanınması, tümörlerin sınıflandırılması gibi konularda K-darbe tekniğini kullanan arařtırmalar başlatılabilir. Akıllı hedef tanıma yönteminin uygulamaları ise daha yaygın olup günümüzün radar sistemleri ile hedef tanıma problemlerine doğrudan uygulanabilir, ayrıca yukarıda sözü edilen sivil amaçlı arařtırmalarda da kullanılabilir.

YARARLANILAN KAYNAKLAR

1. Aly M.S. and Wong T.T.Y., "Root Nature of the Transverse Electric Characteristic Equation for a Dissipative Sphere" IEEE Trans. Anten. Propagat., volume 37, no.1, p.71-77, (1989).
2. Baum C. E., Singularity Expansion Method, Transient Electromagnetic Fields, Ed: Felsen L. B., Springer-Verlag, New York, (1975).
3. Cohen L., Time-Frequency Analysis , Prentice Hall PTR, Prentice Hall Inc., NJ, (1995).
4. Goldberg, D. E., Genetic Algorithms in Search, Optimization and Machine Learning Reading, Addison-Wesley, MA: (1989).
5. Hagness S. C., Taflove A. and Bridges J. E., "Two-Dimensional FDTD Analysis of a Pulsed Microwave Confocal System for Breast Cancer Detection: Fixed-Focus and Antenna Array Sensors" IEEE Trans. Biomed. Eng., volume 45, p.1470-1479, (1998).
6. Haykin S. and Deng C., "Classification of Radar Clutter Using Neural Networks" IEEE Trans. on Neural Networks, volume 2, no. 6, p. 589-600, (1991).
7. Hlawatsch F. and Boudreaux-Bartels G.F., "Linear and Quadratic Time-Frequency Signal Representations" IEEE Signal Processing Magazine, p.21-67, (1992).
8. Jouni I., Garber F. D. and Ahalt S. C., "Classification of Radar Targets Using Synthetic Neural Networks" IEEE Trans. on Aerospace and Electronic Systems, volume 29, no. 2, p. 336-343, (1993).
9. Kennaugh E. M. and Moffatt D. L., "Transient and Impulse Response Approximations" Proc. IEEE, volume 53, no. 8, p. 893-901, (1965).
10. Kennaugh E. M., "The K-pulse concept" IEEE Trans. on Antennas and Propagat., volume 29, no.2, p. 327-331, (1981).
11. Marin L., "Natural-Mode Representations of Transient Scattering Fields" IEEE Trans. Antennas and Propagat. Volume 21, no:6, p. 809-815, (1973).
12. Richmond J. H., "Computer Program for Thin Wire Structures in a Homogeneous Conducting Medium" Project Report, NASA-CR-2399, (1974).
13. Rothwell E., et.al., "Radar Target Discrimination Using the Extinction Pulse Technique" IEEE Trans. on Antennas and Propagat., volume 33, no.9 p. 929-936, (1985).
14. Sayan G. T., "K-Pulse Estimation and Target Identification", Ph.D. Dissertation, Ohio State University, 1988, Columbus, Ohio, USA.

15. Sayan G. T. and Moffatt D. L., "K-pulse Estimation and Target Identification of Low-Q Radar Targets" *Wave Motion*, no. 11, p. 453-461, (1989).
16. Sayan G. T. and Moffatt D. L., "K-pulse Estimation and Target Identification for Geometrically Complicated Low-Q Scatterers, Ultra-Wideband Radar, Ed: Noel B. W., CRC Press, Boca Raton, (1991).
17. Sayan, G. T. and Moffatt, D.L., "K-Pulse Estimation Using Legendre Polynomial Expansions and Target Discrimination" *Journal of Electromagnetic Waves and Applications*, volume 4, p.113-128, (1990).
18. Sayan G. T., Leblebicioglu K. and Inan S., "Input Signal Shaping for Target Identification Using Genetic Algorithms" *Microwave and Optical Technology Letters*, volume 17, p.128-132, (1998).
19. Van Blaricum M. L. and Mittra R., "A Technique for Extracting the Poles and Residues of a System Directly from Its Transient Response" *IEEE Trans. on Antennas and Propagat.*, volume 23, no. 6, p. 777-781, (1975).
20. Weile D. and Michielssen E., "Genetic Algorithm Optimization Applied to Electromagnetics: A Review" *IEEE Trans. Antennas Propagat.*, volume 45, p.343-353, (1997).

EK-A

UYGULAMA ÖZETİ

Bu proje kapsamında yapılan ve bu raporda sunulan çalışmalar, incelenen/geliştirilen elektromanyetik hedef/nesne tanıma yöntemlerinin temel teorisini ve uygulamaları ile ilgili ana hatları vermektedir. Projenin sonuç bölümünde de belirtildiği gibi, projede elde edilen sonuçların gerçek hayatta uygulamaya dönüştürülebilmesi için, konuyla ilgili yeni projelerin başlatılması ve bu projelerde gerçek hedef tanıma senaryoları üzerinde gerçek verilerle çalışılması gereklidir. Çözülmesi amaçlanan bir hedef tanıma probleminin zorluğu, elektromanyetik saçınım verilerinin ölçüldüğü frekans bölgesine ve frekans bandının ne kadar geniş olduğuna çok bağlıdır. Farklı frekans bölgelerinde çıkarılması gereken öznelik bilgileri ve bunları çıkarmakta kullanılacak yöntemler farklılık gösterebilir. Ayrıca, gerçek hayatta ölçülen verilerde gürültü, kaçınılmaz olarak, önemli bir faktördür ve hedef tanıma yöntemlerinin gürültüye hassasiyetlerini en aza indirgeyecek tedbirlerin alınması ön plana çıkabilir. Bunun dışında, kamuflaj, "clutter", aynı anda birden fazla hedefin algılanması gibi radarla hedef tanımayı çok zorlaştıran durumların herbiri ise neredeyse ayrı birer araştırma ve uygulama projesi olabilecek kadar kapsamlı konulardır.

Projede incelenen hedef/nesne tanıma teknikleri, başta askeri savunma ve tıbbi teşhis alanları olmak üzere, çeşitli alanlarda kullanılma potansiyeli taşımaktadır. Bu konulardaki uygulamalarla ilgilenen kuruluşların destekleyebileceği yeni projelerin hayata geçirilmesi ve bu bağlamda beklentileri belirlerken, incelenen problemin çok karmaşık, çözümü çok zor açık bir problem olduğunun unutulmaması yerinde olacaktır. Yurt dışındaki pek çok üniversite, askeri, resmi veya sivil araştırma kuruluşunda, hedef tanıma ile ilgili çalışmalar büyük bütçelerle ve kalabalık araştırmacı grupları tarafında sürdürülmektedir. Çeşitli algılayıcılara uygulanabilecek farklı hedef tanıma yöntemlerinin paralel kullanılması ve karar mekanizmasında her bir yöntemden gelen kararların kaynaştırılması son yıllarda önem kazanmıştır. Örneğin, bir gemiye ait radar ve infrared işaretlerinin paralel değerlendirilmesi gibi. Dolayısı ile, ileriye yönelik araştırmalarda bu konunun da göz ardı edilmemesi gerekmektedir.

Özet olarak, bu proje söz konusu hedef tanıma tekniklerini tanımlamak, modellemek ve yapılabirliklerini göstermek konusunda başarılı sonuçlarla tamamlanmış, bu konuda uluslararası literatüre de katkılar yapabilecek bir orijinallik düzeyini yakalamıştır. Bundan sonra, aynı konuda gerçekleştirilebilecek yeni çalışmalar ve gerçek hayata geçirilebilecek uygulamalar için birbirini tamamlayıcı nitelikte bir dizi yeni proje çalışmasına ihtiyaç vardır.

1. A. Dreher and R. Pregla, Analysis of planar waveguides with the method of lines and absorbing boundary conditions, IEEE Microwave Guided Wave Lett 1 (1991), 138-143.
2. H.Q. Zhu, Y. Long, and D.G. Fang, Analysis of open planar structures using the method of lines with periodic boundary conditions, Dig IEEE AP-S, 1995, pp. 786-789.

© 1999 John Wiley & Sons, Inc.
 CC 0895-2477/99

ELECTROMAGNETIC TARGET CLASSIFICATION USING TIME-FREQUENCY ANALYSIS AND NEURAL NETWORKS

Önül Turhan-Sayan,¹ Kemal Leblebicioğlu,¹ and Türker Ince¹
 Department of Electrical and Electronics Engineering
 Middle East Technical University
 6531 Ankara, Turkey

Received 25 August 1998

ABSTRACT: This paper demonstrates the feasibility and advantages of using a self-organizing map (SOM)-type neural network classifier for electromagnetic target recognition. The classifier is supported by a novel feature extraction unit in which the Wigner distribution (WD), a time-frequency representation, is utilized for the extraction of natural-resonance-related energy feature vectors from scattered fields. The proposed target classification technique is tested for a set of canonical targets, displaying an excellent performance in terms of both real-time classification speed and accuracy, even in the presence of noisy data.
 © 1999 John Wiley & Sons, Inc. Microwave Opt Technol Lett 21: 63-69, 1999.

Key words: electromagnetic target classification; neural networks; self-organizing maps; feature extraction; Wigner distributions

1. INTRODUCTION

Recognition of radar targets from their scattered signals has been a major area of interest in applied electromagnetics [1]. It is well known that all of the characteristic information about the size, shape, and electrical properties of a target is contained inherently in the electromagnetic field scattered by the object. However, recognition of an object from its scattered field data is a complicated task because of the strong dependence of the data on aspect angle and polarization of transmission and reception. The database needed by a target classification system must, therefore, involve scattered information at many combinations of aspect angle and polarization for each candidate target to provide sufficient characterization. Unless a sophisticated signal preprocessing scheme is used to extract some sort of useful information from this huge database, the resulting target classification procedure may be too slow to be applicable in real time. In this context, the artificial neural networks (NNs) are very useful signal processing tools, due to their ability to learn and generalize, in addition to their substantial data-handling capacity by parallel processing. These remarkable properties of NNs have made them very attractive for numerous engineering applications [2, 3] such as pattern recognition, speech processing, control system design, microwave and millimeter-wave circuit design, and electromagnetic target recognition.

In this paper, the feasibility of using self-organizing map (SOM)-type NNs in target classification problems will be

discussed. In particular, a novel radar target classification technique is introduced with a SOM-type classifier which is trained and tested by target feature vectors extracted from scattered data using Wigner distributions (WD). The performance of the proposed target classifier is tested for a target group of four perfectly conducting spheres of varying sizes. It needs to be emphasized that, despite the simplicity of the chosen target geometry, the resulting test problem is a challenging one because of the following facts. First of all, these four targets have many similarities, i.e., the same material properties and the same geometrical shape. Obviously, increased similarity within a classification group leads to increased difficulty in making correct decisions. Second, extraction of the natural-resonance-related energy feature vectors (by the novel feature extraction approach proposed in this paper) becomes especially difficult for this test problem due to the extremely low- Q nature of the perfectly conducting spheres.

In addition to the SOM classifier with the WD feature extraction unit, an MLP classifier is also designed and applied to the same group of test targets, with and without the WD-based feature extraction unit, to demonstrate the advantages of using the SOM and the WD tools for this electromagnetic target classification problem. Noisy data effects are also demonstrated for a SOM-with-WD classifier with quite satisfactory simulation results.

2. METHOD

The target classifier proposed in this paper is composed of two main units: an artificial neural network unit, and a feature extraction unit as shown in Figure 1. The NN unit may be an MLP or a SOM network, in general. However, as will be demonstrated later, due to its clustering abilities, the SOM network turns out to be superior to the MLP network in this electromagnetic target classification problem.

2.1. The SOM-Type Neural Network Classifier. An artificial neural network is a signal processing device which is composed of a large number of interconnected parallel processing elements called *neurons* [4]. The most important features of NNs are their learning and adaptation abilities. Learning in NNs is accomplished by exposing the network to randomly selected training inputs. During this process, the NN adapts itself to the information environment to be learned by updating its parameters, which are the weight vectors associated with neurons. The network topology, neuron characteristics, and learning rules determine the type of a NN. According to their learning strategies, NNs can be classified as *supervised* and *unsupervised* networks. In supervised learning, each time the NN is exposed to a training input, the related class information (i.e., the desired NN output) is provided as well. The multilayer perceptron (MLP), or the feedforward NN as it is also called, has been the most popular example to the supervised neural networks. The well-known backpropagation algorithm used for training MLPs is an iterative gradient descent technique based on the minimization of error between the actual and the desired network outputs [5]. The self-organizing map (SOM)-type NN, on the other hand, is an unsupervised neural network which does not need any class information for learning, but which acquires that knowledge by itself during the training phase through cluster formation [6].

As the main emphasis of this paper is on the use of a SOM-with-WD type classifier in electromagnetic target




Figure 1 Block diagram of the electromagnetic target classifier

ognition, the basic steps of the SOM algorithm are outlined in this section. The MLP-type NN, on the other hand, is implemented in two simulation examples only to generate comparable classification results to judge the performance of SOM-with-WD classifier. Details about the MLP algorithm will not be given here, but can be found in [4-6].

As introduced by Kohonen [7], the unsupervised SOM algorithm creates a mapping from a high-dimensional input vector space onto a two-dimensional output lattice. The SOM network is basically composed of a single, two-dimensional layer of neurons. Each neuron $n_{i,j}$ of this layer is associated with a weight vector $w_{i,j}$ that is of the same dimension as the input vector x . The SOM algorithm is initialized by assigning all random values to all of the weight vector elements. At each iteration of the SOM training phase, a randomly selected input feature vector is applied to each and every neuron of the output lattice. Then, the neuron at the lattice location (i^*, j^*) , whose weight vector w_{i^*,j^*} most closely approximates that specific input vector, is chosen as the *winning neuron*. This selection procedure can be explained in mathematical terms as follows.

$$\text{Minimize } \|\mathbf{x}(t) - \mathbf{w}_{i,j}(t)\| \quad (1a)$$

where $\mathbf{x}(t) \in R^k$ and $\mathbf{w}_{i,j} \in R^k$,
for $i = 1, 2, \dots, I$ and $j = 1, 2, \dots, J$ (1b)

and the norm is computed as

$$\|\mathbf{x}(t) - \mathbf{w}_{i,j}(t)\| = \sqrt{\sum_k [x_k(t) - w_{i,j,k}(t)]^2} \quad (1c)$$

with R^k representing the k -dimensional real space and t being the iteration index. Then, the weight vectors of the neurons are updated to be used in the next iteration as

$$\mathbf{w}_{i,j}(t+1) = \mathbf{w}_{i,j}(t) + N_{i,j}(t)\eta(t)[\mathbf{x}(t) - \mathbf{w}_{i,j}(t)] \quad (2)$$

where $\eta(t)$ is the learning rate and $N_{i,j}(t)$ is a neighborhood function centered around the winning neuron n_{i^*,j^*} of that particular iteration. In this study, the neighborhood function is selected as a two-dimensional pulse function for its simplicity, and is defined as

$$N_{i,j}(i, j, t) = \begin{cases} 1, & \text{for } |i - i^*| \leq r_N(t) \\ & \text{and } |j - j^*| \leq r_N(t) \\ 0, & \text{elsewhere} \end{cases} \quad (3)$$

where $r_N(t)$ is the half width of the neighborhood function.

At the beginning of the SOM training procedure, η and r_N are initialized, and as learning continues, both of these parameters are gradually reduced to provide better learning

with finer tuning. Iterations are continued until all of the weight vectors are stabilized, and hence cluster regions for each candidate target are properly established on the SOM output lattice. The output lattice is also called the *SOM output map*.

2.2. Feature Extraction by Wigner Distribution. Classical signal processing tools such as the Fourier transform can provide valuable information about the energy content of a signal, either in the time or the frequency domain, but not in both simultaneously. Time-frequency representations (TFRs) such as the short-time Fourier transform (STFT), Gabor expansion, wavelet transform, and Wigner distribution (WD), on the other hand, have the ability to analyze a signal over the two-dimensional domain of time and frequency [8, 9]. In this study, we have chosen the WD to use for feature extraction since this real-valued, quadratic TFR is subject to no time-frequency resolution tradeoff, preserves time shifts and frequency shifts of the signal, has the same frequency and time spans as the original signal, and can be interpreted as a two-dimensional distribution of signal energy over the time-frequency plane up to a good approximation [10, 11]. In particular, the WD satisfies two important expressions called *time-frequency marginals* as follows:

$$\int W_x(t, f) df = |x(t)|^2 \quad (4a)$$

and

$$\int W_x(t, f) dt = |X(f)|^2 \quad (4b)$$

where $x(t)$ is the time signal with $X(f)$ being its spectrum, $|x(t)|^2$ is the instantaneous power of the signal at a given time t , $|X(f)|^2$ is the spectral energy density of the signal at a given frequency f , and $W_x(t, f)$ is the continuous auto WD of the signal defined as

$$W_x(t, f) = \int_{-\infty}^{\infty} e^{-j2\pi f\tau} x(t + \tau/2)x^*(t - \tau/2) d\tau \quad (5)$$

The total energy E_x of the signal can then be computed from

$$E_x = \iint W_x(t, f) df dt \quad (6)$$

Similarly, the energy contribution of the spectral terms in the frequency range $[f_1, f_2]$ to the time interval $[t_1, t_2]$ can be estimated from

$$E_{\text{partial}} = \int_{t_1}^{t_2} \int_{f_1}^{f_2} W_x(t, f) df dt \quad (7)$$

The feature extraction procedure implemented in this paper assumes a database of scattered signals measured in or

transformed into (using IFFT) the discrete time domain. As the first step of this process, an individual WD matrix of size $M \times N$ is computed using Eq. (5) for each signal in the database at M frequency points and N time points. Then, the complete time span is divided into, say, Q time bands, and the integrals of the WD are taken within each of these time bands to obtain energy feature vectors $E_q(f_m)$ as

$$E_q(f_m) = \int_{t_{in} + (q-1)\Delta}^{t_{in} + q\Delta} W_x(t, f_m) dt, \quad \text{for } m = 1, 2, \dots, M \text{ and } q = 1, 2, \dots, Q \quad (8a)$$

where

$$\Delta = (t_{fin} - t_{in})/Q \quad (8b)$$

is the width of each time band, with t_{in} and t_{fin} being the initial and final times, respectively, for the overall time span of the input signal $x(t)$. Despite the existence of cross terms (stemming from the quadratic nature of the WD) in these energy vectors, the concentration of signal energy around the target's natural-resonance frequencies conveys valuable information to be used for target characterization [6]. Using these energy feature vectors instead of the WD matrices has two advantages. First of all, for each input signal, a reduction in the size of the feature matrix from $M \times N$ to $M \times Q$ (where $Q \ll N$) leads to a smaller and less complicated neural network structure, and hence shorter computing times while training and testing the NN. Second, this procedure also helps to suppress the noise terms and the undesired effects of highly oscillatory WD cross terms to some extent. It should be kept in mind, however, that there is always a tradeoff between the useful energy interpretation of the WD and the cross-term reduction. At this point, either all of these energy feature vectors are used altogether to train and test the NN unit or further selection in target features is carried on, depending upon the frequency span of the original database. When the available scattered data contain the resonance region information, for instance, the natural-resonance-related energy content of the target can be emphasized by choosing only a few sufficiently late-time energy feature vectors. Then, these vectors coming from successive late-time bands are joined end to end to form a feature string representing the associated scattered signal. This procedure is repeated for all signals in the database, and the resulting feature strings are used as inputs to the NN unit. It is important to construct these feature strings over a proper common time interval for all candidate targets so that the early-time intervals associated with the forced components of the scattered signals can be avoided, even for the largest size target. Consequently, the resulting feature strings will carry information only about the natural responses of the targets [12].

3. APPLICATIONS

In this section, the performance of the proposed target classification scheme is tested using a canonical target group of four perfectly conducting spheres as stated earlier. In the rest of the paper, these test targets are referred to as spheres *A*, *B*, *C*, and *D* whose diameters are 7.5, 10, 15, and 20 in, respectively. The database for these canonical test targets is composed of scattered discrete time-domain signals at various bistatic angles and polarizations. Obviously, for the highly

symmetrical sphere geometry, the backscattered (monostatic) data are aspect independent. However, in the bistatic case for which the angle between the transmission and reception directions is different from zero, the scattered field strongly depends on this bistatic aspect angle α . For our simulation problems, the bistatic time-domain database signals for the spherical targets are obtained over a total time span of 20 ns by computing the 2048-point IFFT of the frequency-domain scattered data which are computed using the Mie solution.

Three simulation problems are designed to demonstrate the advantages of using the SOM-with-WD classifier as compared to using an MLP classifier with or without the WD-based feature extraction. In the first simulation problem, an MLP classifier is trained and tested by the scattered time-domain signals without using any feature extraction. The WD-based feature extraction technique explained in Section 2.2 is utilized in the second simulation problem together with the MLP classifier to demonstrate the effectiveness of the proposed feature extraction technique. Finally, in the third simulation problem, a modified SOM classifier is trained and tested by feature strings extracted from the sphere database using the WD technique. The noise behavior of the SOM clustering algorithm is also demonstrated in an additional simulation problem at the end of this section.

3.1. Simulation of an MLP Classifier Without Any Feature Extraction. In this simulation problem, an MLP network with four layers (the input layer, two hidden layers, and the output layer) of neurons has been trained by the backpropagation algorithm to be used as a target classifier. The time-domain database signals are down-sampled from 2048 to 512 points (with practically no loss of information) to avoid an extremely large NN. Then, the input layer of the MLP is designed to have 512 neurons, each accepting one sample value of the applied input signal simultaneously. The first and second hidden layers are chosen to have 250 and 75 neurons, respectively. The class labels are provided at the output layer of the MLP, which has a total of four neurons corresponding to four spheres to be classified. Table 1 shows the bistatic angles and the polarization types of the training and testing database signals used in all the simulation problems to follow.

In this simulation problem, the learning rate is set to 0.2 at the beginning of the training phase, and is decreased gradually as iterations continue. The momentum constant is chosen as 0.1. After about 10,000 iterations, convergence is obtained in the MLP training phase during which the network is exposed to 11 training signals over and over again in a random order. After training is completed, the classifier is tested using the complete sphere database of 21 input signals. The correct classification rate within the training data set is found to be 90.9% with one failing decision out of 11 trials. For the entirely new test data which have not been used in training, the performance of the classifier is found to be very poor, with a correct decision rate of 40% (four correct decisions out of ten test trials), which is obviously far from being acceptable for a practical classification system. The overall correct decision rate was 66.7% with a total of only 14 correct decisions out of 21 trials.

For this MLP-only classification scheme, the total CPU time spent for a typical test cycle is about 120 ms on a Sun Sparc 4 machine.

3.2. Simulation for an MLP Classifier with WD-Based Feature Extraction. This simulation problem aims to demonstrate the

TABLE 1 Training and Testing Database Used in Simulation Problems of Sections 3.1 – 3.3 (Where VP and HP Denote Vertical Polarization and Horizontal Polarization, Respectively, and the Bistatic Aspect Angles are Measured in Degrees)

	Sphere A	Sphere B	Sphere C	Sphere D
Training data set	45/VP, 100/VP 150/VP	Backscattered, 60/HP, 135/VP, 180/VP	Backscattered, 150/HP	Backscattered, 180/HP
Testing only data set	Backscattered, 120/VP	30/HP, 45/VP, 90/VP, 120/HP	30/VP, 120/VP	30/VP, 120/VP

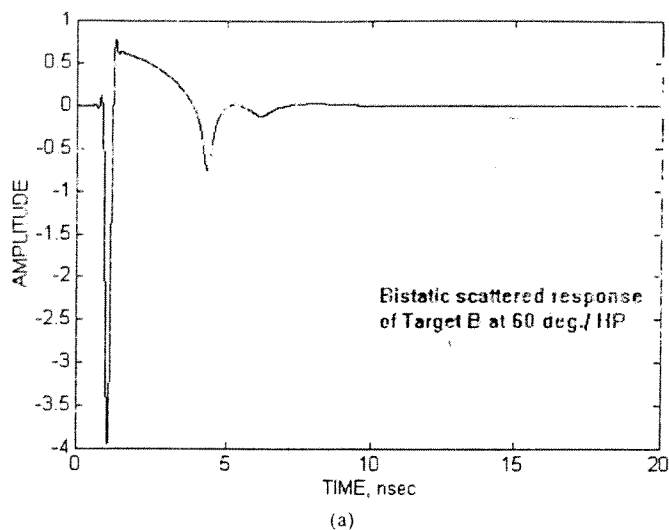
lower of the proposed feature extraction procedure in improving the accuracy of classification. The MLP implemented in this simulation is again a four-level network which has been trained and tested by the data set specified in Table 1. This time, however, input layer neurons of the MLP have been exposed to the elements of feature strings obtained by the procedure which is outlined in general terms in Section 3.2. Accordingly, for each scattered database signal, a WD matrix is computed at $J = 50$ equally spaced frequency values over the interval $[-2.5 \text{ GHz}, 2.5 \text{ GHz}]$ and at $I = 512$ equally spaced time values over the interval $[0, 20 \text{ ns}]$. Next, this overall time span of 20 ns is divided into $Q = 10$ time bands of 2 ns each. Then, the WD values are integrated over time within each band at all 50 sample frequencies, resulting in energy feature vectors $E_q(f_j)$, with $q = 1, 2, \dots, 10$ and $j = 1, 2, \dots, 50$. Finally, the feature vectors for $q = 5, 6$, and 7 are selected and joined end to end to form a feature string at length 150. Essentially, this string represents the natural-resonance-related energy distribution of the associated database signal in the joint time-frequency domain over the intersection of the frequency range $[-2.5 \text{ GHz}, 2.5 \text{ GHz}]$ and the time range $[8, 14 \text{ ns}]$. The choice of the time window is quite arbitrary as long as the lower bound remains larger than the summation of the maximum transit time for the largest size target and a time offset in the data, if there is any. This lower bound is about 3.7 ns for the present example, and 1.7 ns for the transit time through the 20 in diameter sphere plus about 2 ns for the time offset in the data. (The first return from the target shows up around 2 ns.) As an example of the extracted feature strings, Figure 2 shows the scattered signal for test target B (the perfectly conducting sphere with a diameter of 10 in) at 60° bistatic angle/horizontal polarization in part (a), and the corresponding feature string in part (b). The decay of natural response energy with increasing time is clearly observed in Figure 2(b), being consistent with the decaying nature of the natural modes.

Since the dimension of the feature strings is 150 in this application, only 150 neurons are needed at the input layer of the MLP now. The number of neurons of the hidden MLP layers was also reduced, and chosen as 75 neurons at the first hidden layer and 25 neurons at the second hidden layer. The output layer still has four neurons. To make the results of the first and second MLP simulation examples comparable, the same training parameter values (for the learning rate, momentum constant, maximum number of iterations, etc.) are used in both simulations. It is observed, after a training phase of about 10,000 iterations, that the MLP network is successfully trained with a correct decision rate of 100%. In other words, when the trained classifier is tested with the previously used training data again, 11 correct target classifications are made out of 11 cases. However, when the classifier is tested with the completely new test data, three out of ten of the


trials yield incorrect or ambiguous results, leading to a correct decision rate of 70%. The overall correct decision rate is computed to be 85.7% with 18 correct decisions out of a total of 21 tests. Although the classification results of this MLP-with-WD classifier are hardly satisfactory, it has a drastically improved performance as compared to the MLP-only classifier. Due to the additional feature extraction alone, the correct decision rate is increased from 40 to 70% within the test-only database and from 66.7 to 85.7% within the entire database.

For this MLP-with-WD classifier, a typical test cycle is completed in approximately 270 ms (190 ms for feature extraction and 80 ms for MLP classification stage) on a Sun Sparc 4 machine.

3.3. Simulation for a SOM Classifier with WD-Based Feature Extraction. This third simulation example is intended to demonstrate the substantial improvement achieved by using a SOM network as the target classifier instead of an MLP network. The inputs of this SOM-with-WD classifier are the same feature strings obtained for the previous example in Section 3.2. The SOM output map is designed as a 10×10 matrix having 100 neurons all together. Training the SOM network is achieved in two phases. In the first phase, which provides a coarse clustering, the initial learning rate is set to 0.1, and the initial half width of the neighborhood function is chosen to be 10. Both of these parameters are decreased as iterations continue. A maximum number of 1000 iterations is allowed in this phase for the formation of four cluster regions, one for each sphere, on the output map. Then, in the fine clustering phase of at most 10,000 iterations, the initial learning rate is chosen to be 0.03, and the initial half width of neighborhood function is set to 2. At the end of the training phase, the weight vectors associated with a total of 100 neurons are all stabilized to be used later in the real-time test phase. At this point, the training phase winning neurons are marked on the SOM output map, and their distribution provides the necessary information to determine appropriate borders of the cluster region regions for the targets A, B, C, and D. Although it is not a unique way of deciding the borders of the individual cluster regions, it is reasonable for this specific example to divide the whole map into equal quadrants, one for each target as shown in Figure 3, where the training phase winning neurons are denoted by the symbol "#." After the cluster borders are determined based on the examination of the training phase results, the next step is to test the SOM classifier with the completely new test data specified in Table 1. The winning neuron locations obtained for the test data are marked in Figure 3 by the symbol "*." It is observed that all of the testing phase winning neurons fall in proper cluster regions matched with the type of test data. In other words, the 100% correct decision rate is achieved



(a)



(b)

Figure 2 Time-domain scattered signal and the corresponding energy feature string for test target *B* at 60° bistatic angle with horizontal polarization. (a) Bistatic scattered signal. (b) Natural-resonance-related energy feature string for the signal shown in part (a)

not only within the training database, but also within the entire database.

A typical test cycle in this simulation is completed in about 230 ms (190 ms for feature extraction and 40 ms for SOM classification stage) on a Sun Sparc 4 machine.

3.4. Noise Effects in SOM-with-WD Classifier. To demonstrate the noise effects in the SOM-with-WD classifier designed in Section 3.3, the backscattered (i.e., $\alpha = 0$) time signal for sphere *B* is contaminated by Gaussian noise at signal-to-noise (SNR) levels of 15, 10, and 5 dB, while the original noise-free signal has an infinite SNR. The testing phase winning neurons corresponding to these three noisy signals are found and marked on the SOM output map given in Figure 4. To provide a detailed view, this figure shows the enlarged target *B*-cluster region only. It is observed that as the noise level of the test data increases, the resulting winning neuron deviates

from its noise-free location farther away. For the moderate SNR level of 15 dB, deviation is only one cell. In the 10 dB SNR case, deviation becomes two cells. Finally, for the extremely contaminated signal of 5 dB SNR, deviation increases to three cells. Very impressively, however, the noisy input winning neurons remain in the proper cluster region, even in the worst case of 5 dB SNR.

4. CONCLUSIONS

Introduced in this paper is a novel electromagnetic target classification scheme based on the joint use of the SOM network and a special feature extraction technique. The feasibility and advantages of the proposed SOM-with-WD target classifier are successfully demonstrated by four simulation examples.

Use of the novel feature extraction technique (based on the computation of natural-resonance-related energy distri-

B (#) 30/HP	B (*) 60/HP								
									D (#) Backscat.
									D (*) 180/HP
			B (*) 90/VP						
B (*) 120/HP	B (#) 180/VP			B	D				D (*) 120/VP
				A	C				
									C (#) 150/HP
A (*) 120/VP			A (#) 150/VP						C (*) 30/VP
A (#) 100/VP									C (#) Backscat.
	A (#) 45/VP	A (*) Backscat.						C (*) 120/VP	

Figure 3 10 × 10 SOM output map of 100 neurons with cluster regions for the spherical targets A, B, C, and D. The winning neurons for the training data are indicated by the symbol "#," and those for the testing data are designated by the symbol "*".

B (#) Backscattered SNR=∞			B (*) Backscattered SNR=5 dB	
B (*) Backscattered SNR=15 dB				
B (*) Backscattered SNR=10 dB			B	

Figure 4 Cluster-B region of the SOM output map (designed in Section 3.3) tested against the noisy backscattered data for target B at SNR levels of infinity, 15, 10, and 5 dB.

Contributions by WD) is shown to increase the correct decision rate of an MLP classifier from 40 to 70% within the test-only database and from 66.7 to 85.7% within the overall database according to the results of the first two simulation examples. Next, the use of the SOM-with-WD classifier instead of the MLP-with-WD classifier is found to lead to another big jump in the correct classification rate. Specifically, the correct decision rate is increased from 70 to 100% within the test-only database and from 85.7 to 100% within the overall database according to the results of the second and third simulation examples. These results certainly demonstrate the power of the proposed SOM-with-WD classifier in this electromagnetic target classification problem.

It also has been demonstrated that the proposed SOM-with-WD classifier is promising for real-time applications as reflected by the typical classification duration of only 230 ms CPU time measured on a Sun Sparc 4 machine for this test

problem. Finally, as demonstrated in the last simulation example, the proposed classifier has a satisfactory noise performance. The robustness of the classifier against noise is expected to improve for a SOM output map of larger size that is likely to have built-in neutral safety margins between the individual target cluster regions.

ACKNOWLEDGMENT

The work reported in this paper was supported in part by a grant from the Information Technologies and Electronics Research Institute of the Turkish Scientific and Technical Research Council (TUBITAK-BILTEN).

REFERENCES

1. D.L. Moffatt, J.D. Young, A.A. Ksienski, H. Lin, and C.M. Rhoads, Transient response characteristics in identification and imaging, IEEE Trans Antennas Propagat AP-29 (1981), 192-205.

2. A.B. Bulsari and S. Kallio (Editors). Proc 1997 Int Conf Engineering Applications of Neural Networks. Stockholm, Sweden, June 1997.
3. M.W. Roth. Survey of neural network technology for automatic target recognition. IEEE Trans Neural Networks 1 (1990). 28-41.
4. S. Haykin. Neural networks: A comprehensive foundation, Macmillan College Publishing, New York, 1994.
5. J. Freeman and D.M. Skapura, Neural networks: Algorithms, applications, and programming techniques, Addison-Wesley, Reading, MA, 1991.
6. T. Ince. Electromagnetic target classification by using time-frequency analysis and neural networks, Master's thesis, Middle East Technical University, 1996.
7. T. Kohonen. Self-organization and associative memory, Springer-Verlag, Berlin, 1989.
8. F. Hlawatsch and G.F. Boudreaux-Bartels. Linear and quadratic time-frequency signal representations. IEEE Signal Processing Mag (1992). 21-67.
9. L. Cohen. Time-frequency analysis. Prentice-Hall PTR, Englewood Cliffs, NJ, 1995.
10. T.A.C.M. Claasen and W.F.G. Mecklenbrauker, The Wigner distribution—A tool for time-frequency signal analysis—Part I: Continuous time signals. Phillips J Res 35 (1980), 217-250.
11. T.A.C.M. Claasen and W.F.G. Mecklenbrauker, The Wigner distribution—A tool for time-frequency signal analysis—Part II: Discrete time signals. Phillips J Res 35 (1980), 276-300.
12. E.M. Kennaugh. Opening remark—Special issue on inverse methods in electromagnetics. IEEE Trans Antennas Propagat AP-29 (1981), 190-191.

© 1999 John Wiley & Sons, Inc.
 CCC 0895-2477/99

A SIMPLE RECIPROCI- TATION PROCEDURE FOR THE DERIVATION OF SCATTERING PARAMETERS USING ELECTROMAGNETIC SIMULATORS

C. Seguinot,¹ F. Huret,¹ E. Paleczny,¹ J. F. Legier,¹ and P. Kennis¹

¹Institut d'Electronique et de Microelectronique du Nord IEMN. Cité Scientifique 59655 Villeneuve d'Ascq Cedex, France

Received 2 September 1998

ABSTRACT: We report a simple and helpful procedure which yields the derivation of reciprocity normalized scattering parameters without the need for field normalization. The algorithm can be easily implemented in any electromagnetic simulator to reduce the CPU time and memory requirements. Two examples involving a lossy single-mode two-port and a multimode network are presented. © 1999 John Wiley & Sons, Inc. Microwave Opt Technol Lett 21: 69-72, 1999.

Key words: scattering parameters; reciprocity; multimode; networks

I. INTRODUCTION

Electromagnetic simulators today are common tools of microwave engineers. Calculating the S -parameters using such software generally requires the derivation of reference waves, reference voltages, or reference currents [1, 2]. In some simulators, the electromagnetic fields of each mode are calculated in the reference plane waveguide cross section prior to computing scattering parameters so that normalizing fields is straightforward. When using moment methods, electromagnetic solutions are found as a weighting of basis functions. These basis functions approximate the electric or magnetic

currents existing on metallic strips. Meanwhile, defining reference waves requires knowledge of the electromagnetic fields of each mode in the whole cross section of the ports. This is not given as the problem's solution, but requires an additional computational effort. Furthermore, if one reference plane propagates multiple modes, depending on the numerical method used, separating and normalizing fields of individual modes can be a difficult task. In order to facilitate the derivation of S -parameters, we propose a simple normalization procedure.

Our presentation will be organized as follows. First, in order to point out where the problem lies, we will present a simple example for which computing S -parameters may cause difficulties. Then we will introduce what we call unnormalized wave amplitudes and corresponding unnormalized S -parameters. Using the S -matrix symmetry of a reciprocal network, the normalization procedure is then straightforward. While our concept can be easily extended to multiports, in our presentation, we will consider multimode two-ports. All results are demonstrated in the multimode case. When necessary, single-mode two-port examples will be also considered and discussed for the sake of clarity. Finally, two examples involving experimental and theoretical characterizations will be presented in order to highlight the usefulness of the method.

II. THE ORIGIN OF THE PROBLEM

In order to point out when additional postprocessing is needed to compute S -parameters, we will consider the simple impedance step presented in Figure 1 [3]. The two corresponding ports are lossy waveguides. They are assumed to propagate in only one mode. Let us suppose that this network was simulated using an FDTD method. As a result, in each reference plane, some incident ($E_{inc,i}$) and reflected ($E_{ref,i}$) electrical fields can be calculated. Using these fields, assuming that port 2 has been loaded with a matched load, we derive port reflection coefficients with

$$\Gamma_i = S_{ii} = \frac{E_{ref,i}}{E_{inc,i}} \quad (1)$$

Furthermore, if both ports exhibits identical cross section (for example, ports 1 and 2 in Fig. 1), it will be demonstrated that the S_{21} -parameter is simply given by

$$S_{21} = \frac{E_{ref,2}}{E_{inc,1}} \quad (2)$$

For this reason, structures are generally simulated so that all ports are identical. As soon as different characteristic impedances are used on each port (reference planes 1 and 3 of Fig. 1), Eq. (2) is no longer valid. In fact, in (2), electrical fields might have been normalized with respect to different reference fields. Such normalized fields or reference fields refer to the fields of an incident mode whose reaction integral is equal to 1 [3] (unit power mode in the lossless case only):

$$\frac{1}{2} \int_V (\vec{e} \times \vec{h}) \cdot d\vec{s} = 1 \quad (3)$$

As the reflection coefficient only involves an incident mode and the corresponding reflected mode, no normalization is required in (1). For the same reason, (2) is correct as long as

Neural Network Techniques in Electromagnetic Target Classification: A Comparison Study

* Gönül Turhan-Sayan^{1,2} and Türker Ince^{1,3}

- (1) Middle East Technical University, Dept. of Electrical and Electronics Eng.,
(2) TÜBİTAK-BİLTEN (Information Technologies and Electronics Research Inst. of the
Turkish Scientific and Technical Research Council)
Ankara, TURKEY
(3) Univ. of Massachusetts, Microwave Remote Sensing Lab., Amherst, MA, USA

1. Introduction

Electromagnetic target classification is known to be a challenging problem due to the highly variant nature of scattered responses from a target with respect to aspect angle and polarization of the incident and the scattered fields. The classification algorithms to be used in this problem should be able to handle a large volume of data to establish the basic guidelines of comparison between the candidate targets. The artificial neural networks perfectly comply with this requirement due to their ability to learn and generalize in addition to their substantial data handling capacity by parallel processing [1].

Applications of neural networks to automatic target identification problems have become popular since late 80's [2]. Multilayer perceptron (MLP) has been the first type of neural network being used in such applications long before the introduction of self-organizing map (SOM) type neural networks as potential electromagnetic target identifiers [3]. It has been established in recent studies [4,5] that the SOM algorithm attains a higher correct classification rate as compared to the MLP algorithm, due to the fact that the clustering nature of SOM conforms very well with the aspect dependent nature of the electromagnetic target classification problem.

In this paper, performances of a SOM classifier, an MLP classifier and a conventional classifier, based on the well-known principal component analysis (PCA) technique, will be compared in classifying a group of model aircraft, according to their accuracy and their real-time classification speed.

2. Methods

In all target classification techniques, the first step of application is the extraction of some target features from the available database of electromagnetic scattered signals. The target feature vectors to be fed to the target classifiers in this paper are obtained using the Wigner distribution (WD) which is a well-known time-frequency representation (TFR) technique [6].

First of all, in this process, the discrete energy distribution of a given database signal (i.e. the scattered signal received from a target at a specific aspect

angle/polarization combination) is computed over a specified joint time-frequency domain in the form of an energy feature matrix corresponding to discrete values of time and frequency. Then, some sort of partial time averaging may be applied at each sample frequency to reduce the problem size and to reduce the cross terms and noise to some extent. Finally, a late time portion of this energy distribution matrix may be selected, if desired, to emphasize the energy content of the natural response components. Either the energy distribution matrix itself or its individual rows or columns can be used as target features in the rest of the classification procedure. Use of this feature extraction technique has been demonstrated to be quite effective in electromagnetic target classification problems studied so far [5], and hence the same approach is preferred in this paper. In other words, the input data used to train and test the neural network classifiers are the late-time energy feature vectors (rows of the final feature matrix corresponding to different time slots) and the input data used for the PCA classifier is the original feature matrix itself.

The generalized block diagram for the process of target classification is given in Figure 1 below, which applies to both training and testing phases of the classifiers.




Figure 1. Block diagram for the SOM, MLP and PCA classifiers.

3. Simulations

In the simulations to follow, five electroplated model aircraft; the Boeing 707 (target A), Boeing 727 (target B), Boeing 747 (target C), Concorde (target D) and DC-10 (target E) are used as the candidate targets. Their backscattered signals at various aspect angles (all in vertical/vertical polarization) were measured in a compact range over 1 to 4 GHz frequency band.

Simulation with a SOM classifier:

A SOM output map of size 15X15 (i.e., a total of 225 neurons) is trained by using the training data sets specified in Table 1 starting with an initial learning rate of 0.2 in the course training phase, and that of 0.05 in the fine clustering phase. The neighbourhood function used in the algorithm was a two-dimensional unit pulse function whose initial half width was chosen to be 15 in the course phase and only 3 in the fine phase. After about 30 thousand iterations, the weight coefficients of the SOM are all stabilized and next, in the testing phase, the SOM classifier attained the classification performance summarized in Table 2.

Table 1. Aspect angles for vertically polarized aircraft scattered data

	Target A	Target B	Target C	Target D	Target E
Training Data	45, 120, 180	30,60,150, 180	0, 90	0,30,90, 180	0, 30, 90, 180
Testing-only Data	60, 90, 150	45, 90,120	45	45, 60, 120	45, 60, 120, 150

Simulation with an MLP classifier:

A four-layer MLP network with 150, 100, 30 and 5 neurons in the input layer, first hidden layer, second hidden layer and the output layer, respectively was trained by the same late-time energy feature vectors corresponding to the training data set indicated in Table 1. The initial value of the learning rate was chosen as 0.35 while the momentum constant was set to 0.1. After about 20 thousand iterations, the MLP network was ready for tests. The classification performance of this classifier is also indicated in Table 2.

Simulation with a PCA classifier:

Principal component analysis is a well-known statistical data analysis technique based on the computation of eigenvectors of the covariance matrix for a given data matrix of random nature. It is also an effective method for feature enhancement especially when the input data consists of a few clusters which can be separated well by the major principal axis found by PCA. In most applications, use of one or two dominant eigenvalues for eigenfunction computations is found sufficient. In our problem, the PCA is applied to each energy feature matrix (computed for a given classification database signal) to find the major eigenvector of the PCA problem corresponding to the most dominant eigenvalue. The aim here is to decompose the data represented by this specific feature matrix into a simpler data set by using the largest principal component that explains most of the variance in the original data. This process is repeated for all the signals in the available database to compute the corresponding major eigenvectors. Later, during the real-time classification, the major eigenvector for a given test signal is computed in the same way. Then, for decision, the Euclidian distances between the test eigenvector and each one of the previously computed known eigenvectors are determined. The criteria of the smallest Euclidian distance is used to finalize the classification decision.

In the simulation results summarized in Table 2, the training data set specified in Table 1 were utilized to compute the known major eigenvectors. The rest of the data were used for testing purposes.

Table 2. Simulation results for the SOM, MLP and PCA classifiers as applied to the model aircraft targets, based on the same training and testing databases specified in Table 1.

	Correct Decision Rate (within the test-only database, as a percentage)	Real-time Decision Period (on a Sun Sparc 4 machine, including 190 msec for WD matrix computations)
SOM Classifier	93 %	250 msec
MLP Classifier	64 %	270 msec
PCA Classifier	79 %	620 msec

4. Conclusions

As presented in Table 2 above, the SOM type neural network classifier was found to be highly superior to both MLP type neural network classifier and the PCA type statistical classifier, in terms of not only its correct decision rate but also its real time classification speed. As the correct decision rate of the MLP classifier turned around to be intolerably low, the PCA classifier resulted in a barely acceptable accuracy level with a relatively low classification speed.

REFERENCES

1. S. Haykin, Neural Networks: A Comprehensive Foundation , Macmillan Collage Publishing Company, New York , 1994.
2. M.W. Roth, " Survey of Neural Network Technology for Automatic Target Recognition," *IEEE Trans. Neural Networks*, Vol.1, No.1, pp.28-41, March 1990.
3. T. Ince, Electromagnetic Target Classification by Using Time-Frequency Analysis and Neural Networks, Master Thesis, Middle East Technical University, August 1996.
4. G. Turhan-Sayan, S. Inan, T. Ince and K. Lelebicioglu, "Applications of Artificial Neural Networks and Genetic Algorithms to Electromagnetic Target Classification," NATO RTO-SCI Symposium Proceedings, RTO-MP-3, pp.23-1 till 23-10, November 1998.
5. G. Turhan-Sayan, K. Lelebicioglu and T. Ince, "Electromagnetic Target Classification Using Time-Frequency analysis and Neural Networks," to appear in *Microwave and Optical Technology Letters*, April 1999 issue.
6. L. Cohen, Time-Frequency Analysis , Prentice Hall PTR, Prentice Hall Inc., NJ, 1995.

Investigation of the K-Pulse Concept as Applied to Dielectric Coated Conducting Targets

Gönül Turhan-Sayan (*) and Mustafa Kuzuoğlu

Middle East Technical University, Dept. of Electrical and Electronics Eng., and TÜBİTAK-BİLTEN (Information Technologies and Electronics Research Inst. of the Turkish Scientific and Technical Research Council), Ankara, TURKEY

David L. Moffatt

Professor Emeritus, The Ohio State University, ElectroScience Lab.,
43210 Columbus, Ohio, USA

Since the introduction of the "Kill pulse" concept by E. M. Kennaugh in early 80's, a considerable number of papers have been published on the applications of natural-response annihilation techniques in electromagnetic target identification. Considering the fact that many targets of practical importance (such as aircraft, missiles, ship, tanks, etc.) are basically made of conducting materials, the majority of these studies have been concentrated on the problems concerning perfectly conducting scatterers. Depending upon the target geometry, these conductors may behave either as a high-Q target (e.g. a straight thin conducting wire) or as a low-Q target (e.g. a conductor sphere) or behave somewhere in between. So far, different signal shaping techniques have been demonstrated to synthesize specially tailored pulse waveforms for various target geometries with the basic requirement that the Laplace transform zeros of a synthesized Kill pulse (or, K-pulse as also called) must coincide with the target's system poles within a specified operational bandwidth. As discussed by Kennaugh, this requirement is equivalent to the annihilation of the target's natural resonances in response to K-pulse excitation at all possible aspects and polarizations.

The purpose of this paper is to extend the applications of the K-pulse concept to dielectric scatterers and to dielectric coated conductors, in particular. The genetic algorithm techniques as well as the conventional optimization algorithms will be implemented for K-pulse synthesis. Also, the target poles will be estimated from the synthesized K-pulse waveforms. The effects of a dielectric coating on the natural resonances of a target will be studied using conducting spheres, dielectric spheres and dielectric coated conducting spheres as canonical targets. The pole loci as a function of coating permittivity and coating layer thickness will also be investigated.

Use of Time-Frequency Distributions and Genetic Algorithms in Electromagnetic Target Feature Extraction and K-Pulse Shaping

Gönül Turhan-Sayan

Middle East Technical University, Electrical and Electronics Eng. Dept. &
TÜBİTAK-BİLTEN (Information Technologies and Electronics Research Inst. of the
Turkish Scientific and Technical Research Council), Ankara, TURKEY

Target recognition from measured data either in microwave or optical frequencies has been an important problem of applied electromagnetics. The most critical step in the solution of this general problem is to extract a proper set of target features for effective characterization. These features should represent the target in a unique way if possible, or otherwise should strongly emphasize the differences of that target from the other candidate targets. In addition to being physically meaningful, the extracted features should be compatible with the rest of the computational process and with the specific methods (statistical methods, neural network methods, natural response annihilation methods, etc.) to be used in target recognition.

Feature extraction from available data needs intensive use of signal processing techniques. Therefore, target recognition can be considered as an interdisciplinary area making use of both electromagnetics and signal processing.

The conventional signal processing techniques, such as the Fourier transform, are useful for the analysis of stationary signals but not for that of non-stationary signals. Time-frequency representation (TFR) techniques must be utilized in the latter case to see the distribution of total signal energy with respect to time and frequency, simultaneously. In case of target recognition from scattered electromagnetic data, target pole strings on the complex frequency plane play a very important role in characterizing the target in an aspect and polarization independent manner. In our previous research which was focused on the design of Neural Network target classifiers by the help of TFR techniques (Turhan-Sayan, et.al., "Electromagnetic Target Classification Using....," *Microwave and Optical Tech. Lett.*, vol.21, no.1, pp.63-69, 1999) the Wigner Distribution, a well-known TFR technique, is found quite useful to locate the poles and to extract feature vectors related to the distribution of signal energy in two-dimensional time-frequency plane.

The purpose of this paper is to extend the use of TFR's to target recognition techniques which are based on the natural response annihilation method, such as the K-Pulse technique. In the problem of multi-aspect K-Pulse shaping by Genetic Algorithms, selection of design aspects will be accomplished by using TFR analysis to ensure that almost all the target poles within the frequency band of the measurements will be properly represented by the design data. That approach will improve the results obtained in our previous K-Pulse design research (Turhan-Sayan, et.al., "Input Signal Shaping for Target Identification Using Genetic Algorithms," *Microwave and Optical Tech. Lett.*, vol.17, no.2, pp.128-132, 1998). The TFR analysis will also be used to check the validity of the designed K-pulse waveforms. Demonstrations involving both canonical and complicated target geometries will be presented.

EK-B: Bibliyografik Bilgi Formu

BİBLİYOGRAFİK BİLGİ FORMU	
1- Proje No: 197E036	2- Rapor Tarihi: 31.07. 2000
3- Projenin Başlangıç ve Bitiş Tarihleri: 01.09.1998 - 01.03.2000	
4- Projenin Adı: UZAKTAN ALGILANAN VERİLERDEN HEDEF / NESNE TANIMA	
5- Proje Yürütücüsü ve Yardımcı Araştırmacılar: Proje Yürütücüsü: Doç. Dr. Gönül TURHAN SAYAN Yardımcı Araştırmacılar: Prof. Dr. Mustafa KUZUOĞLU Prof. Dr. Kemal LEBLEBİCİOĞLU	
6- Projenin Yürütüldüğü Kuruluş ve Adresi: ORTA DOĞU TEKNİK ÜNİVERSİTESİ Elektrik ve Elektronik Mühendisliği Bölümü 06531 Ankara	
7- Destekleyen Kuruluş(ların) Adı ve Adresi: TÜBİTAK Elektrik-Elektronik ve Enformatik Araştırma Grubu Atatürk Bulvarı No: 221, Kavaklıdere, 06100 Ankara TÜBİTAK-BİLTEN, ODTÜ, 06531 Ankara	
8- ÖZ Bu proje kapsamında, kuramsal ve uygulamalı olarak incelenerek geliştirilen iki farklı elektromanyetik hedef / nesne tanıma tekniği üzerinde çalışılmış, gerçekçi hedef tanıma senaryoları bilgisayar ortamında gerçekleştirilen benzetimler yoluyla test edilmiştir. İncelenen tekniklerden ilki olan, Yapay Sinir Ağları yardımı ile hedef tanıma tekniğinde Çok Katlı Perseptron ve Öz Örgütlemeli Harita tipi sinir ağları kullanılmış ve sinir ağlarının eğitiminde kullanılan hedef verilerine ait öznitelik vektörleri Zaman-Frekans Dönüşüm teknikleri kullanılarak elde edilmiştir. İkinci olarak incelenen K-Darbe yardımı ile hedef tanıma tekniğinde ise, ait olduğu elektromanyetik hedefi uyarılma açısı ve polarizasyonundan bağımsız olarak tarifleyebilen, zamanda sınırlı bir K-Darbe uyarım işaretinin Genetik Algoritma teknikleri kullanılarak tasarlanması hedeflenmiştir. Dayandıkları teorik esaslar ve kullandıkları ana yöntemler bakımından birbirinden çok farklı olan bu iki tekniğin ortak üstünlüğü gerçek-zaman hedef-tanıma sistemlerinde kullanılabilir potansiyellerinin yüksek olmasıdır. Anahtar Kelimeler: Elektromanyetik saçınım, Hedef tanıma, Öznitelik çıkarımı, Zaman-Frekans dönüşümleri, Yapay sinir ağları, Genetik algoritmalar, K-Darbe tekniği.	
9- Proje ile ilgili Yayın/Tebliğlerle ilgili Bilgiler Projede yapılan çalışmalarla ilgili olarak biri dergi makalesi, üçü sempozyum bildirisi olmak üzere aşağıda belirtilen toplam dört adet uluslararası yayın yapılmıştır:	

1. G. Turhan-Sayan, K. Leblebicioğlu and T. İnce, "Electromagnetic Target Classification Using Time-Frequency Analysis and Neural Networks," *Microwave and Optical Technology Letters*, Vol.21, No. 1, pp. 63-69, April 1999.
2. G. Turhan-Sayan and T. İnce, "Neural Network techniques in Electromagnetic Target Classification: A Comparison Study," *1999 IEEE AP-S International Symposium and UNSC/URSI National Radio Science Meeting*, July 1999, Orlando, Florida, USA (published in the AP proceedings, Vol.3, pp. 2222-2225).
3. G. Turhan-Sayan, M. Kuzuoğlu and D. L. Moffatt, "Investigation of the K-Pulse Concept as Applied to Dielectric Coated Conducting Targets," *1999 IEEE AP-S International Symposium and UNSC/URSI National Radio Science Meeting*, July 1999, Orlando, Florida, USA (published in the URSI proceedings, pp.353).
4. G. Turhan-Sayan, "Use of Time-Frequency Distributions and Genetic Algorithms in Electromagnetic Target Feature Extraction and K-Pulse Shaping," *2000 IEEE AP-S International Symposium and UNSC/URSI National Radio Science Meeting*, July 2000, Salt Lake City, Utah, USA (published in the URSI proceedings).

10- Bilim Dalı

Doçentlik B. Dalı Kodu:

ISIC Kodu:

Uzmanlık Alanı Kodu:

11- Dağıtım(*):

Sınırlı

Sınırsız

12- Raporun Gizlilik Durumu:

Gizli

Gizli Değil

(*) Projenizin Sonuç Raporunun ulaştırılmasını istediğiniz kurum ve kuruluşları ayrıca belirtiniz.

EK-C : Proje ile ilgili yayınlar (yayınların fotokopileri, takip eden sayfalarda, ektedir).