

## DARBELİ RADARLARDA HEDEF SINIFLAMA İÇİN AR MODELİNİN GÜÇ SPEKTRUMU VE YAPAY SİNİR AĞI TEMELLİ ÖZELLİK ÇIKARMA YÖNTEMİ

İbrahim TÜRKOĞLU\*, Ahmet ARSLAN\*\*

\*Fırat Üniversitesi, Teknik Eğitim Fakültesi, Elektronik ve Bilgisayar Eğitimi Bölümü, ELAZIĞ

\*\*Fırat Üniversitesi, Mühendislik Fakültesi, Bilgisayar Bölümü, 23119 ELAZIĞ

### ÖZET

Bu çalışmada, örüntü tanımının en önemli kısmı olan özellik çıkarma için geliştirilmiş etkili bir yöntem sunulmuştur. Darbeli radarlarda hedef sınıflama için AR modelinin güç spektrumu ve yapay sinir ağı temelli, yeni bir özellik çıkarma yöntemi geliştirilmiştir. Bu yöntemle ölçülen darbeli radar işaretlerinin AR modeli güç spektrumundan elde edilen 512 adet özellik kullanılarak sınıflama yapılmaktadır. Özelliklerin frekans bölgesinden elde edilmesi ve özellik sayısının fazla oluşu yöntemin güvenilirliğini ve etkinliğini yükseltmektedir. Sınıflama yapısı ileri beslemeli ve geri yayılım öğrenme algoritmali yapay sinir ağı üzerine kurulmuştur. Böylelikle akıllı ve otomatik bir sınıflama gerçekleşmesi sağlanmıştır.

**Anahtar Kelimeler :** Özellik çıkarma, hedef sınıflama, AR modeli, Darbeli Radar, Örüntü Tanıma.

## FEATURE EXTRACTION METHOD BASED ON POWER SPECTRUM OF AR MODEL AND ARTIFICIAL NEURAL NETWORK FOR TARGET CLASSIFICATION IN THE PULSE RADARS

### ABSTRACT

In this study, we present an efficient method for feature extraction, which is the most important stage of pattern recognition. We develop a new feature extraction procedure based on power spectrum of AR models and artificial neural network for target classification in the pulse radars. This method makes classification using 512 features obtained from power spectrum of AR models of measured pulse radar signals. Efficiency and reliability of the method is high because the features are obtained in the frequency domain and the number of the features is high. Structure of classification is set up based on artificial neural network of feed forward and the back propagation-learning algorithm. In this way, an automatic and intelligent classification is realised.

**Keywords:** Feature Extraction, Target Classification, AR model, Pulsed Radar, Pattern Recognition.

### 1. GİRİŞ

Radar, nesnelere bulmak ve bunlarla ilgili bilgileri belirlemek için kullanılan bir mikrodalga sistemidir. Günümüzde radarlar pek çok yerde kullanılmaktadır: hava trafik kontrolünde, hava savunma, marina çarpışma önleme sistemi, füze ve akış kontrolü, uzay araç radarı ve meteoroloji radarı bu farklı kullanım alanlarına birer örnektir (1).

Radar doppler işaretleri ile geleneksel şekil analizi ve yapay sinir ağı yaklaşımı kullanılarak hedef tanıma ve sınıflama çalışmaları yapılmaktadır (2-6). Bununla birlikte, radar işaretlerine örüntü tanıma uygulanarak erken uyarı sistemleri (7), düşük genlikli radar işaretlerini iyileştirme (8), radar işaretlerine işaret işleme yöntemleri uygulanarak analizi ve hedef türü tanıma (9,10), modüle edilmiş radar işaretleri ile hedef tanıma ve analizi (11-13), yansıyan radar işaretleri ile çevre hak-

kında bilgi edinme (14) çalışmalarına da literatürde rastlanmaktadır. Son yıllarda sağlanan gelişmeler sonucu radarlarda ilgi alanı kapsama alanı içindeki hedeflerin varlığını belirlemenin yanı sıra hedefle ilgili özel bilgilerin ilave olarak elde edilmesi beklenmektedir. Diğer bir deyişle konum, hız ve toplam radar saçılma yüzeyi değerleri bir çok uygulama için yeterli görülmektedir. Bazı durumlarda hedef sınıfı ve hatta kimlik bilgisi ayrıntısı gerekmektedir (15). Bu çalışmada hedef kimlik bilgisi için önemli olan hedef türü belirleme problemi için hedef ile ilgili etkili bir özellik çıkarma metodu sunulmuştur.

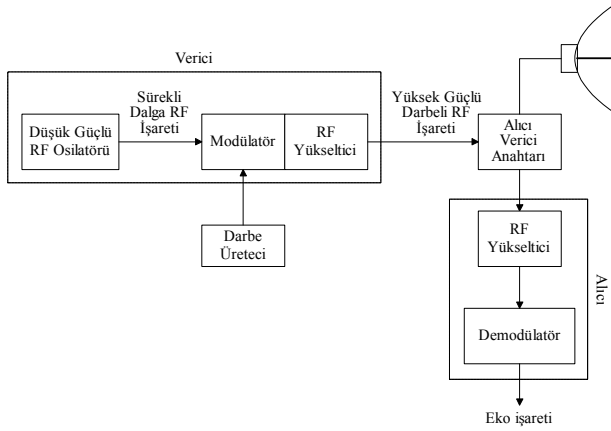
### 2. TEORİK BAKIŞ

Bu bölümde darbeli radar sistemlerinin yapısı sunulup, örüntü tanımaya ilişkin temel kavram ve yöntemler genel bir yaklaşım içinde verilerek, geliştirilen sistem için gerekli teorik alt yapı oluşturulmuştur.

## 2.1.Darbeleri Radar

Radarların temel olarak iki türü vardır: Darbeleri radar, sürekli dalga radar. Darbeleri radar genellikle belirli bir alandaki hedeflerin ve her bir hedefin mesafe ve duruşunu, bazı durumlarda da hızını belirlemek için kullanılır. Ancak pek çok radar uygulamasında hedef kimlik bilgisi önemli olmayıp hedef hızı ve hedef mesafesi ile ilgilenilir. Bu gibi durumlarda darbeleri radar sistemleri tarafından sağlanan bütün bilgiler gerek olmayıp, sürekli dalga radarı kullanılır (16).

Bir darbeleri radar sisteminde (Şekil 1), iletim için radyo frekans (RF) enerjisinin kısa patlamaları kullanılır. Bunun için öncelikle düşük güçlü sürekli dalga RF işareti üretilir ve bu işaret ile dikdörtgen şekilli darbeler genlik modülasyonuna tabii tutularak modüleli RF darbeleri elde edilir. Bu darbeleri RF işareti anten tarafından iletilir. Eğer işaret bir hedefe çarparsa, işaretin bir bölümü radar antenine eko (echo) olarak geri yansır. Alınan bu eko darbeleri daha sonra de-modüle edilerek elde edilen işaret ile hedef hakkında bilgi edinilir (15,16).



Şekil 1. Darbeleri bir radarın blok diyagramı.

Anten tarafından yakalanan eko işaretinin gücü, denklem (1) ile bulunabilir;

$$P = \frac{P_t \cdot G \cdot \sigma \cdot A_e}{(4\pi)^2 \cdot R^4} \quad (1)$$

Burada; P alınan eko işaretinin gücü,  $P_t$  ortalama radar verici gücü, G anten kazancı,  $\sigma$  hedefin alanı,  $A_e$  antenin etki alanı ve R hedef mesafesidir.

## 2.2. Örüntü Tanıma

Örüntü tanıma; aslında bilimin, mühendisliğin ve günlük hayatın geniş bir alanındaki etkinlikleri kapsamaktadır. Örüntü tanıma askeri uygulamalarda uzun ve saygın bir tarihe sahiptir (17). Bununla birlikte gerekli veriyi (görüntü ve işaret algılayıcısı) elde etme süreci uzun yıllar donanımın pahalılığından dolayı geniş uygulama alanını sınırlamıştır. Günümüzde, güçlü otomatik örüntü tanıma sistemini tasarlamak ve test etmek mümkündür.

Örüntü tanıma şu şekilde tanımlanabilir : Aralarında ortak özellik bulunan ve aralarında bir ilişki kurulabilen karmaşık işaret örneklerini veya nesnelere bazı tespit edilmiş özellikler veya karakterler vasıtası ile tanımlama veya sınıflandırma olayıdır (18,19).

Örüntü tanıma uygulamaları insanların yaşantısında da görülür : Hava değişiminin algılanması, binlerce çiçek, bitki, hayvan türünü tanımlama, yüz ve ses tanıma gibi. İnsan örüntü tanıması öğrenme esaslıdır. Belirli bir sesi tanımak için kullanılan kuralları tanımlamak mümkün değildir. İnsanlar bu işlemlerin bir çoğunu oldukça iyi yapmalarına rağmen, bu işlemleri daha ucuz, iyi, hızlı ve otomatik olarak makinaların yapmasını arzularlar. Örüntü tanıma böyle makinaları gerçekleştirmek için bir mühendislik disiplini (20).

Örüntü tanıma işleminde kullanılan en yaygın blok diyagram Şekil 2 'de gösterilmiştir (18). Sistemin yapısı iki önemli aşamadan oluşmaktadır : Özellik çıkarma, sınıflandırıcı. Sınıflandırıcı tasarımında en önemli gösterge doğru özellikleri seçmektir. Başka bir deyişle ileri örüntü tanıma tekniklerinde daha karmaşık sınıflandırıcı tasarlamak yerine, daha iyi özellik çıkarımı ön plandadır (19).



Şekil 2. Örüntü tanıma sistemi

## 2.3. Özellik Çıkarma

Özellik çıkarma örüntü tanımının en önemli kısmı olup, bir anlamda doğru örüntü sınıflandırmanın anahtarıdır. İşaretten özellik çıkarmanın üç ana amacı; sınıflama süresini azaltarak sınıflandı-

ricının başarımını artırmak, işlenecek bilgi miktarını en aza indirmek ve tanıma sisteminin güvenilirliğini sağlamaktır. Çıkarılan özelliklerin sistemdeki kontrolsüz parametrelerden etkilenmemesi kararlı olmasını sağlayacaktır. Böylece özellikler genelleştirilebilir ve sistemin doğru karar verme güvenilirliği artırılabilir (21). Kararsız işaretlerin özelliklerinin çıkarımı ile ilgilenildiğinde, özellik çıkarımı için genelde zaman ve frekans bölgesinin bileşimi ile ilgilenilir. Böylece hem geçici ve hem de frekans değişimlerini içeren tanımlayıcı bilgiler çıkarılabilir. Kararsız verilerin zaman-frekans analizi için iki yaklaşım vardır : Parametrik ve parametrik olmayan. Parametrik metotlar belirli bir modelin parametrelerinin belirlenmesini gerektirir. Örneğin verilen bir modeldeki veriye uygun bir model oluşturmak için sinüzoidallerin toplamı gibi. Parametrik olmayan metotlar, veriler hakkında birkaç kabul yaparak zaman serilerine geniş bir dizi ile doğrudan uygulanabilir (20).

Parametrik analizde önemli olan model ve derecesinin (sinüzoidallerin sayısı) seçimidir. Uygun olmayan model ve derece seçimi verinin uygun modelin üstünde veya altında modellenmesine sebep olacaktır ve o ardışık analiz ile büyük bir hataya yol açabilir. Parametrik metotlar veriyi kararlı kabul eder. Böylece kararsız zaman serileri kararlı olarak değerlendirilebilmesi için bölümlere ayrılmalıdır.

En yaygın olarak kullanılan parametrik metot AR (autoregressive) modelidir. AR modelinde belirli bir zaman aralığı için verilen veri değeri bir gürültü terimi ve  $p$  ön veri değeri ile tahmin edilebildiği kabul edilir. Bu metodun bir avantajı herhangi bir güç spektrumu, yaklaşık bir  $p$  derecesi ile bir AR süreci kullanılarak modellenenebilir olmasıdır. Bununla birlikte,  $p$  nin değeri zaman serisinin uzunluğunu aşabilir. AR modeli denklem (2) ile verilmiştir :

$$x_t = \sum_{k=1}^p a_k \cdot x_{t-k} + n_t; \quad t \geq 1 \quad (2)$$

Burada  $x_t$  zaman örneklerini,  $a_k$  AR sürecinin katsayılarını,  $p$  model derecesini ve  $n_t$  kararlı beyaz gürültü sürecinin örneklerini gösterir. AR sistemi aynı zamanda güç spektrumu olarak denklem (3) ile tanımlanabilir :

$$\frac{\sigma_p^2 \Delta t}{\left| 1 - \sum_{k=1}^p a_k \cdot e^{-j2\pi f k \Delta t} \right|^2} \quad (3)$$

Burada  $\sigma_p^2$ ,  $n_t$  gürültü teriminin değişimi,  $f$  frekans,  $\Delta t$  iki örnek arası zamandır (22).

#### 2.4. Yapay Sinir Ağları ile Sınıflandırma

Yapay sinir ağları biyolojik beyin hücrelerinden geliştirilmiş olup, örüntü tanımada çok kuvvetli sınıflandırıcılardır. En yaygın ve en güçlü tanımlayıcı yapay sinir ağı, çok katmanlı ileri beslemeli ağ olup, tüm yapay sinir ağı uygulamalarının %90'ını kaplamaktadır (17). Yapay sinir ağları aşağıdaki karakteristiklere sahip paralel bilgi işleme yapılarıdır :

- Biyolojik bir nöronun esinlenerek matematiksel modeli ortaya konmuştur.
- Birbirine bağlanan çok geniş sayıdaki işlem elemanlarından oluşur.
- Bağlantı ağırlıkları ile bilgiyi tutar.
- Bir işlem elemanı giriş uyarılarına dinamik olarak tepki verebilir ve tepki tamamen yerel bilgilere bağlıdır (ilgili işlem elemanını etkileyen bağlantılar ve bağlantı ağırlıkları yoluyla gelen giriş sinyali).
- Eğitim verisi ile ayarlanan bağlantı ağırlıkları sayesinde öğrenme, hatırlama ve genelleme yeteneklerine sahiptir.

Bu üstün özellikleri, yapay sinir ağlarının karmaşık problemleri çözebilme yeteneğini göstermektedir (23). Şekil 3 'de biyolojik nöronun esinlenerek ortaya konmuş işlem elemanının basit bir matematiksel modeli verilmiştir. Bu modelde  $i$ . işlem elemanının çıkışı denklem (4) de verilmiştir.


$$y(t+1) = a \left( \sum_{j=1}^m w_{ij} x_j(t) - \theta_i \right) \quad (4)$$

Burada  $a(\cdot)$  etkinleştirme fonksiyonu,  $\theta_i$  ise  $i$ . işlem elemanının eşik değeridir. İşlem elemanlarının bilgi işlemleri iki kısımdan oluşur : giriş ve çıkış. Bir işlem elemanı dışardan almış olduğu  $x_j$  giriş bilgilerini bağlı oldukları  $w_{ij}$  ağırlıkları üzerinden birleştirerek bir  $net$  değeri üretir.

$i$ . işlem elemanının net değeri denklem (5) ile hesaplanır.

$$f_i \triangleq \text{net}_i = \sum_{j=1}^m w_{ij} x_j - \theta_i \quad (5)$$

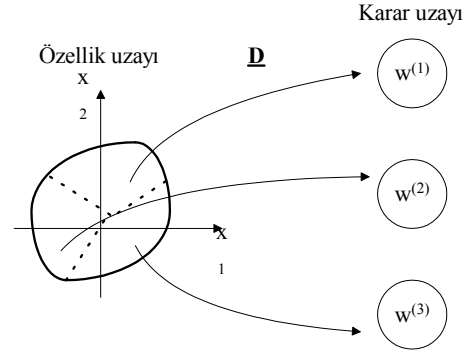
Her bir işlem elemanının ikinci süreci, net değerini bir  $a(\cdot)$  etkinleştirme fonksiyonundan geçirerek çıkış değerini bulmaktır. Etkinleştirme fonksiyonları işlem elemanlarının çok geniş aralıktaki çıkışını belli aralıklara çekmektedir. Böylece her bir işlem elemanının tepkisi yumuşak olmaktadır ve bağlantı ağırlıklarının değişimleri de daha küçük değerlerde olması sağlanır. Dolayısıyla yapay sinir ağının eğitimi sırasında, hata değişiminin iraksaması engellenerek kararlılığa ulaşmasına yardımcı olunur. Yapay sinir ağ modelleri ve öğrenme algoritmaları daha detaylı olarak (24) kaynağında bulunabilir.



Şekil 3. Bir nöron hücresinin matematiksel modeli

### 3. GELİŞTİRİLEN YÖNTEM


Örüntü tanıma sisteminin biçimsel amacı, gerçek giriş uzayındaki gözlemleri  $x \in X \subset \mathbb{R}^M$  birkaç sınıftan  $y \in Y \equiv \{w^{(1)}, w^{(2)}, \dots, w^{(K)}\}$  birine ayırmaktır. Sınıfsal çıkış karar uzayındaki her bir  $w^{(k)}$  sınıfı temsil eder.  $\underline{D}$  operatörü Şekil 4 'de bir harita olarak gösterilen veya her bir ayrıma bir sınıf etiketi atayarak özellik uzayının ayrı bölümlere ayrılmasını sağlayan bir sınıflayıcıyı tanımlar. Sistemde önemli olan ayrımın belirgin bir şekilde gerçekleşmesidir. Bunu sağlayacak olan en önemli kısım anahtar özelliklerdir.



Şekil 4. Karar yüzeyinin özellik uzayının haritası olarak gösterimi


Bu çalışmada gerçek giriş uzayı olarak darbeli radar işaretleri kullanılıp, Şekil 5 'de gösterilen altı adet hedef nesnenin birbirinden ayrımını keskin bir şekilde sağlayacak özellik seçimi için etkili bir özellik çıkarımı yöntemi geliştirilmiştir. Deneysel uygulama, eğitim amaçlı ve çok fonksiyonlu 9620/21 Model Lab-Volt radar deney seti üzerinde gerçekleştirilmiştir. Darbe eko işaretleri 1 Khz örnekleme frekansı ile data kartı aracılığıyla bilgisayar ortamına alındı. Darbeli Radar Sisteminin parametreleri aşağıdaki gibi ayarlandı :

- Darbe genişliği : 1ns
- RF Osilatör : 9.4 Ghz
- Darbe Tekrar Frekansı (PRF) :216 Hz
- Sabit Hedef Mesafesi : 75 cm



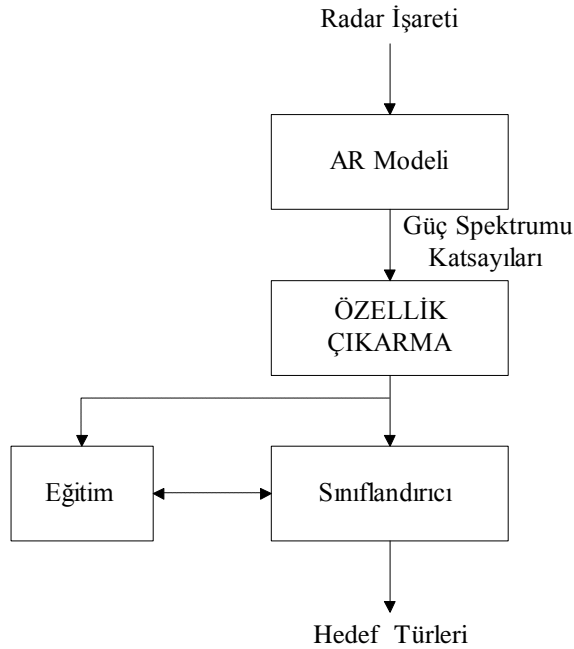
Küçük metal plaka

Büyük metal plaka



Şekil 5. Radar hedefleri.

Sistemin yapısı ve hesaplama şeması Şekil 6 'da verilmiştir. Görüleceği üzere sistemin önem arz eden ve sınıflayıcının doğrudan başarımını etkileyen nokta özellik çıkarımıdır.



Şekil 6. Radar işaretlerinin ayrımı için geliştirilen örüntü tanıma sistemi.

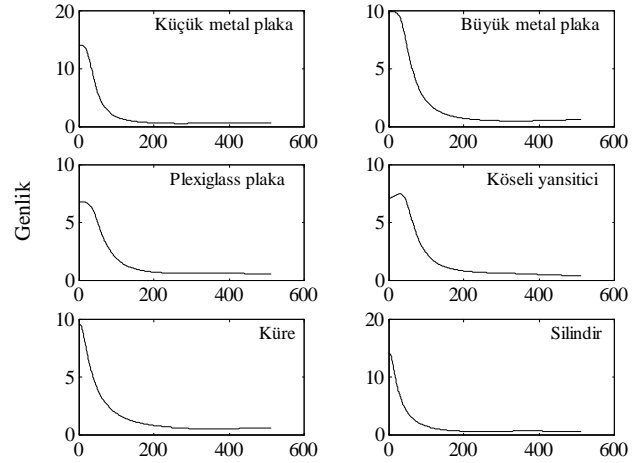
### 3.1. Hedef Özellik Seçimi

Radar işaretlerinin güç spektrum katsayılarını bularak özellik çıkarımını elde etmek için öncelikle AR model parametrelerinin hesaplanması gerekmektedir.

AR model parametrelerinin hesaplanması için ya doğrudan spektral analizi yapılacak olan bilgi alanı örnekleri kullanılır ya da bu bilgi alanına ait öz ilişki fonksiyonu örnekleri kullanılır. Literatürde her iki metoda da ait algoritmalar bulunmakla birlikte, bunların en önemlileri Levinson ve Burg metotlarıdır (25). Burg algoritması Levinson algoritmasına kıyasla daha çok işlem sayısı gerektiren bir algoritma olmasına rağmen AR model parametrelerinin hesaplanmasında kullanılan algoritmalar arasında performansı en yüksek algoritmalarından biridir (26).

AR model parametreleri, her bir hedef türünün radar işaretlerinden model derecesi  $p = 4$  alınarak Burg metoduyla hesaplanmıştır. Her bir hedefin radar işaretinin AR modelinin 512 noktalı güç spektrumu elde edilmiştir (Şekil 7). Bu değerlerle öznitelik vektörü denklem (6) deki gibi çıkarıldı :

$$V = [1, x_2, x_3, \dots, x_{512}] \quad (6)$$

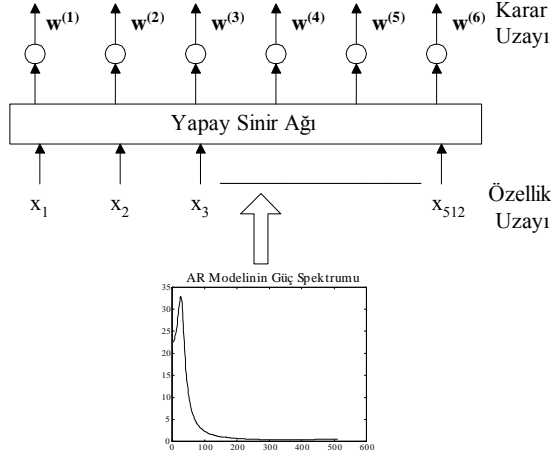


Şekil 7. Duran hedeflerin darbeli radar işaretlerinin AR modellerinin güç spektrumları

### 3.2. Yapay Sinir Ağı Sınıflandırıcısı

Geliştirilen yöntemin sınıflandırıcı aşaması için, çok katmanlı ileri beslemeli yapay sinir ağı kullanıldı (24). Şekil 8 'de kullanılan sınıflandırıcının giriş çıkış ikilisi görülmektedir. Yapay sinir ağının seçilen parametreleri :


Katman sayısı : 3  
 Katmanlardaki (giriş, ara, çıkış) nöron sayısı : 512, 50, 6  
 Öğrenme algoritması : Uyarlamalı öğrenme oranlı geri- yayılım  
 Öğrenme oranı : 0.05  
 Momentum katsayısı : 0.98  
 Toplam mutlak hata : 0.005  
 Etkinleştirme fonksiyonu : Tanjant sigmoid.



Şekil 8. Sınıflandırıcı sisteminin giriş/çıkış ikilisi.

Karar Uzayı = {Küçük metal plaka, Büyük metal plaka, Plexiglass plaka, Köşeli yansıtıcı, Küre, Silindir}

Şekil 9 'da gösterilen sürekli dalga radar alıcından elde edilen işaretlere geliştirilen özellik çıkarma algoritması uygulandı. Elde edilen özellikler yapay sinir ağına uygulanarak sınıflandırıcının eğitimi sağlandı. Eğitim için hedef nesnelerin her biri için 5 adet işaret örüntüsü kullanılmıştır. Bir örüntü tanıma sınıflandırıcısından beklenen, özellik uzayındaki her bir grup özellik için ayırım fonksiyonlarını oluşturmasıdır (27). Bu bağlamda, her bir hedef nesne için kullanılan 5 adet işaret örüntüsü ile sınıflandırıcı test edilmiş olup, geliştirilen yöntem ile elde edilen özelliklerin yapay sinir ağı sınıflandırıcısı tarafından doğru bir şekilde ayırt edilebilmelerinin ortalama yüzdeleri Tablo 1'de verilmiştir.



Şekil 9. Küçük metal plaka hedefine ait darbeli radar işaret örüntüsü.

Tablo 1. Seçilen Özelliklere Göre Yapay Sinir Ağı Sınıflandırıcısının Başarımı (%)

Hedef Nesne	Küçük Metal Plaka	Büyük Metal Plaka	Plexiglass Plaka	Köşeli Yansıtıcı	Küre	Silindir
Küçük Metal Plaka	97.49	0.03	0.04	0.01	0.04	0.00
Büyük Metal Plaka	0.05	97.46	0.01	0.05	0.01	0.00
Plexiglass Plaka	0.00	0.02	97.23	0.08	0.02	0.01
Köşeli Yansıtıcı	0.03	0.05	0.03	97.41	0.03	0.00
Küre	0.00	0.01	0.04	0.03	97.99	0.03
Silindir	0.01	0.01	0.02	0.00	0.03	97.81

#### 4. SONUÇ VE DEĞERLENDİRME

Geliştirilen özellik çıkarma yöntemi, darbeli radar işaretlerine uygulanarak %100 doğru bir şekilde ayırım fonksiyonlarının oluşmasını yapay sinir ağı sınıflandırıcısı aracılığı ile sağlamıştır. Ayrıca Tablo 1 'de görüleceği üzere, ayırım fonksiyonları arasında oldukça belirgin farklar olduğu tanıma yüzdelerinden anlaşılmaktadır. Bu göstergeler doğal girişlerden çıkarılan özelliklerin ne kadar etkili ve güçlü olduğunu betimlemektedir. Yine sistemin karar uzayındaki ayırım fonksiyonlarının çok belirgin oluşu, özellik vektörü için seçilen özelliklerin başka bir işleme gerek kalmadan sistemi en iyi bir biçimde özetlediğini ve seçilen özelliklerin güvenilirliğinin ispatı olmakla birlikte sınıflandırıcı olarak yapay sinir ağının kullanımı sisteme öğrenme ve öğrendiklerinden karar çıkarma özelliği katmaktadır. Bu yöntem sayesinde gerçekleştirilebilecek basit yapıya sahip akıllı tanı sistemleri, çok geniş bir sahada uygulama alanı bulabilir. Bu sistem geliştirilerek, çıkarılan özelliklerin çevre ve gürültüden kararlı hale gelmesiyle, radar

sistemlerinde hedef kimliği hakkında bilgi edinme çalışmalarında etkili bir yöntem olabilecektir.

#### KAYNAKLAR

1. Ahern J., Delisle G. Y., etc. Radar, Lab-Volt Ltd., vol. 1, Canada, 1989.
2. Madrid J.J. M., Corredera J. R. C., Vela G. M., A neural network approach to Doppler-based target classification, Radar 92. International Conference, pp. 450–453, Brighton, England, 1992.
3. Swiatnicki Z., Semklo R., The artificial intelligence tools utilization in radar signal processing, 12th International Conference on Microwaves and Radar (MIKON '98), vol. 3, pp. 799–803, Krakow, Poland, 1998.
4. Jakubiak A., Arabas J., Grabczak K., etc., Radar clutter classification using Kohonen neural network, Radar 97 (Conf. Publ. No. 449), pp. 185–188, Edinburgh, UK, 1997.
5. Tang B., Jiang W., Ke Y., Radar signal classification by projection onto wavelet packet subspaces, CIE International Conference of Radar Proceedings, pp. 124–126, Beijing, China, 1996.
6. Beastall W. D., Recognition of radar signals by neural network, First IEE International Conference on Artificial Neural Networks, (Conf. Publ. No. 313), pp.139-142, London, UK, 1989.
7. Application of pattern recognition techniques for early warning radar, Nasa Technical Reports, AD-A299735, Mar 29, 1995.
8. Guangyi C., Applications of wavelet transforms in pattern recognition and denoising, Concordia University (Canada), 1999.
9. Sowelam S.M., Tewfik A.H., Waveform selection in radar target classification, IEEE Transactions on Information Theory, vol. 46, pp. 1014–1029, 2000
10. Kempen L.V., Sahli H., Nyssen E., etc., Signal processing and pattern recognition methods for radar AP mine detection and identification, Second International Conference on the Detection of Abandoned Land Mines, (Conf. Publ. No. 458), pp. 81–85, Edinburgh, UK, 1998.
11. Noone G.P., A neural approach to automatic pulse repetition interval modulation recognition, Information Decision and Control, IDC 99 Proceedings, pp.213-218, Adelaide, Australia 1999.
12. Zyweck A., Bogner R.E, Radar target recognition using range profiles, IEEE International Conference on Acoustics, Speech, and Signal Processing, ICASSP-94., vol. 2, pp. II/373 -II/376, Adelaide, Australia, 1994.
13. Roome S.J., Classification of radar signals in modulation domain, Electronics Letters, vol. 28, pp.704–705, 1992.
14. Liu J., Gao S., Luo Z.Q., etc., The minimum description length criterion applied to emitter number detection and pulse classification, Statistical Signal and Array Processing, Proceedings., Ninth IEEE SP Workshop on, p.172–175, Portland, Oregon, Usa, 1998.
15. Richards M. A., Fundamentals of Radar Signal Processing, Georgia Institute of Technology, 2000.
16. Ahern J., Delisle G. Y., etc. Radar, Lab-Volt Ltd., vol. 2, Canada, 1990.
17. Rothe H., Approaches to Pattern Recognition, Advanced Pattern Recognition Techniques, NATO-RTO Lecture Series 214, pp.1-1, 1-29. Lisbon Portugal, 1998.
18. Duda R.O., Hart P.E., Pattern Classification and Scene Analysis, Stanford Research Institute, 1989.
19. Bishop C.M., Neural Networks for Pattern Recognition, Clarendon Press, Oxford, 1996.
20. Kil D.H., Shin F.B., Pattern Recognition and Prediction with Applications to Signal Characterization, AIP Press, USA, 1996.
21. Türkoğlu İ., Arslan A., Hardalaç F., Yapay Sinir Ağları ile Kalp Doppler Ses İşaretlerine Tanı Koyma. Biyomut 2000 Biyomedikal Mühendisliği Ulusal Toplantısı Bildiriler Kitabı, s.152-156. İstanbul. 2000.
22. Percival D. B., Walden A. T., Spectral analysis for physical applications: Multitaper and conventional univariate techniques. New York: Cambridge University Press. 1993.

23. Lin C. T., Lee C.S.G., Neural Fuzzy Systems, Prentice-Hall, 1996.
24. M.J. Zurada, Introduction to Artificial Neural Systems, West Publishing Company Inc., New York, 1992
25. Kara S., Doppler cihazı ve autoregresif spektral analiz metoduyla mitral ve triküspit kapaklardaki kan akışının incelenmesi, Erciyes Üniversitesi Fen Bilimleri Enstitüsü, Doktora tezi, s:15-20, 1994.
26. Yüksel M. E., Ultrasonik Doppler İşaretlerinin Bilgisayar Destekli Analizi, Erciyes Üniversitesi Fen Bilimleri Enstitüsü, Y. Lisans tezi, s:25-43, 1993.
27. Türkoğlu İ., Arslan A., Optimisation of the Performance of Neural Network Based Pattern Recognition Classifiers with Distributed Systems, IEEE Computer Society, 2001 International Conference on Parallel and Distributed Systems (ICPADS'2001), pp. 379 –3 82, Kyong Ju, Korea, Jun. 26-29, 2001