

## AN INTELLIGENT TARGET RECOGNITION SYSTEM BASED ON PERIODOGRAM FOR PULSED RADAR SYSTEMS

Engin AVCI\*, İbrahim TURKOĞLU  
Firat University, Department of Electronic and Computer Science, 23119, Elazig, TURKEY,  
e-mail:enginavci@firat.edu.tr

Mustafa POYRAZ  
Firat University, Engineering Faculty, Department of Electric and Electronic, 23119,  
Elazig, TURKEY

### ABSTRACT

In this study, a pattern recognition system is developed for automatic classification of the radar target signals. For feature extraction which is an important subset of the pattern recognition system, a new method which is based on periodogram power spectral density and intelligent classifier is proposed. Artificial neural network and adaptive network based fuzzy inference system were used as an intelligent classifier respectively. Radar signals were obtained from pulse radar system for various targets. According to developed feature extraction method, the classifier performances were evaluated with radar signals on the target recognition.

**Key Words:** Radar target classification, power density, pulsed radar, pattern recognition

## DARBELİ RADAR SİSTEMLERİNDE GELİŞTİRİLEN PERIODOGRAM ÇIKARIMLI AKILLI HEDEF TANIMA

### ÖZET

Bu çalışmada, radar hedef işaretlerini sınıflamak üzere akıllı örüntü tanıma sistemi geliştirilmiştir. Örüntü tanımının önemli bir kısmı olan özellik çıkarma için periodogram güç spektrum yoğunluğu ve akıllı sınıflandırıcı temelli bir yöntem sunulmuştur. Akıllı sınıflandırıcı olarak, yapay sinir ağı ve uyarlamalı yapay sinir ağı temelli bulanık çıkarım sınıflandırıcısı kullanılmıştır. Radar işaretleri, farklı hedefler için darbeli radar sisteminden elde edilmiştir. Her iki sınıflandırıcının başarımları, geliştirilen özellik çıkarma yöntemine göre radar işaretleri ile hedef tanımda değerlendirilmiştir.

**Anahtar Kelimeler:** Radar hedef sınıflandırma, güç spektrumu, darbeli radar, örüntü tanıma

### 1. GİRİŞ

Radar, hedef nesnelere bulmak, bunların hakkında çeşitli parametrelere ulaşmak için kullanılan bir mikrodalga sistemidir (1). Şekil 1.de görüldüğü üzere, basit bir radar; verici, alıcı, verici/alıcı antenler ve bir belirtici içerir. Verici tarafından bir radyo işareti üretilir ve verici anten tarafından yayımlanır. İletilen işaretin bir bölümü yansıtıcı bir nesneye veya hedefe çarpar ve bütün yönlerde dağılır. İşaretin bir bölümü hedeften radara doğru geri yansıtılır.

### 1. INTRODUCTION

Radar is a microwave system for detecting objects and determining their distance, or range (1). In practice, the transmitter and receiver usually share the same antenna, as shown in Figure 1. The antenna usually directs the signal into a narrow beam which is systemically swept through the region where targets are expected. The direction of the target is determined by the direction the antenna is pointing when the echo is received. The range of the target is determined by the time taken for the radar signal to travel to the target and back to the radar

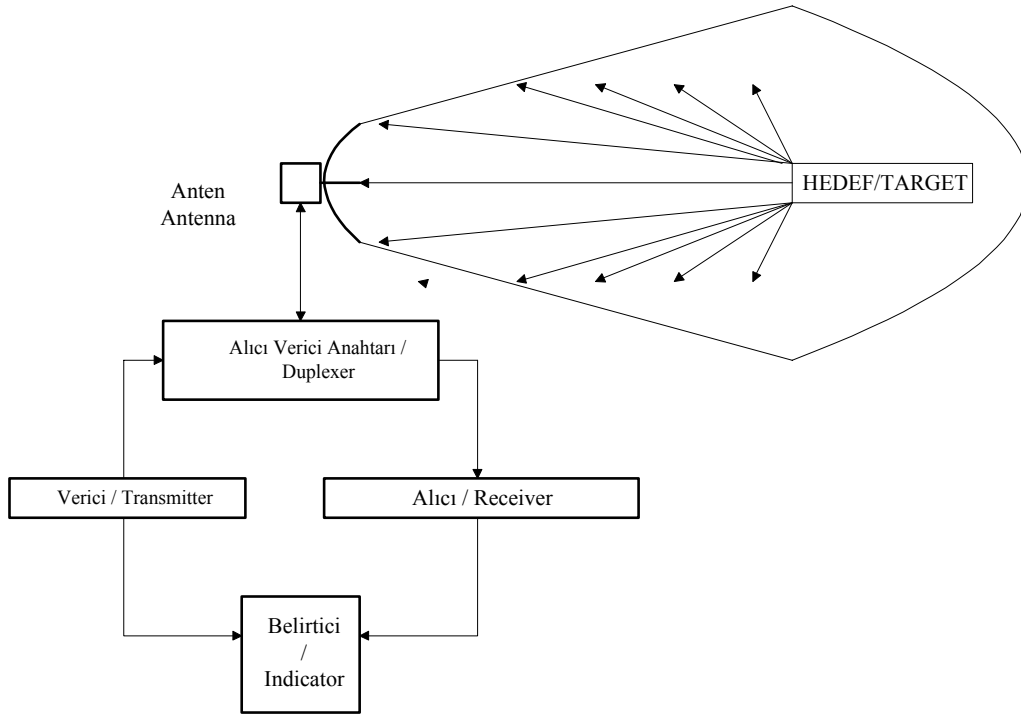


Figure 1. Simplified radar system

Şekil 1. Basit bir radar sisteminin blok diyagramı

Radar Doppler işaretleri ile geleneksel şekil analizi ve yapay sinir ağı ve uyarlamalı ağ tabanlı bulanık çıkarım sistemi yaklaşımı kullanılarak hedef tanıma ve sınıflama çalışmaları yapılmaktadır (3-6). Bununla birlikte, radar işaretlerine örüntü tanıma uygulanarak erken uyarı sistemleri (7), düşük genlikli radar işaretlerini iyileştirme (8), radar işaretlerine işaret işleme yöntemleri uygulayarak analizi ve hedef türü tanıma (9,10), modüle edilmiş radar işaretleri ile hedef tanıma ve analizi (11-13), yansıyan radar işaretleri ile çevre hakkında bilgi edinme (14) çalışmalarına da literatürde rastlanmaktadır.

Son yıllarda sağlanan gelişmeler sonucu radarlarda ilgi, kapsama alanı içindeki hedeflerin varlığını belirlemenin yanı sıra hedefle ilgili özel bilgilerin ilave olarak elde edilmesine kaymıştır. 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 probleminin çözümü için, etkili örüntü tanıma sistemi geliştirilmiştir.

### 1.1. Darbeli Radar Sistemleri

Radarın en çok rastlanan türü darbeli radardır. Bu radarlar özellikle, hava trafik kontrolünde olduğu gibi, belirli bir alandaki hedefleri bulmak ve bunların mesafelerini belirlemek için kullanılır. Darbeli radarda, verici çok kısa patlamalarla enerji iletir. Pek çok tür darbeli radar sistemi mevcuttur. Hava savunma, hava trafik kontrolü, marina çarpışma önleme sistemi, füze ve atış kontrolü, uzay araç radarı ve meteoroloji radarı bu farklı tiplere birer örnektir.

Radars use Doppler frequency to extract target radial velocity (range rate), as well as to distinguish between moving and stationary targets or objects such as clutter (3-6). The Doppler phenomenon describes the shift in the center frequency of an incident waveform due to the target motion with respect to the source of radiation (7-10). Depending on the direction of the target's motion this frequency shift may be positive or negative. A wave from incident on a target has equipages wave fronts separated by  $\lambda$ , the wavelength. A closing target will cause the reflected equipages wave fronts to get closer to each other (smaller wavelength). Alternatively, an opening or receding target (moving away from the radar) will cause the reflected equipages wave fronts to expand (larger wavelength) (11-15).

### 1.1. Pulsed Radar System

In a pulsed radar system, short bursts of radio frequency (RF) energy are generated for transmission. This is usually accomplished by first generating a train narrow, rectangular-shape pulses and using these to amplitude-modulate a sinewave RF carrier. The pulsed RF signal is transmitted by the antenna. If the signal strikes a target, a portion of the signal will be reflected back to the radar as an echo. The antenna captures the echo pulses which are sent to the receiver. The received pulses are then demodulated and converted to a video signal for display.

## 1.2. 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 (16,17). Bununla birlikte gerekli veriyi (görüntü ve işaret algılayıcısı) elde etme süreci uzun yıllar, donanımın pahalılığından dolayı geniş uygulama alanını frenlemiştir. Günümüz teknolojisi ile, 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 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 (19-20).

## 1.2. Pattern Recognition

Pattern recognition is the research area that studies the operation and design of systems that recognize patterns in data. It encloses subdisciplines like discriminant analysis, feature extraction, error estimation, cluster analysis (sometimes called as statistical pattern recognition), grammatical inference and parsing (sometimes called syntactical pattern recognition). These important application areas are radar target recognition, image analysis, character recognition, speech analysis, man and machine diagnostics, person identification and industrial inspection.

Pattern recognition as a field of study is developed significantly in the 1960s. It was very much interdisciplinary subject, covering developments in the areas of statistics, engineering, artificial intelligence, computer science, psychology and physiology, among others (16-17). Some people entered the field with a real problem to solve. The large numbers of applications, ranging from the classical ones such as automatic character recognition and medical diagnosis to the more recent ones in data mining (such as credit scoring, consumer sales analysis and credit card transaction analysis), have attracted considerable research effort, with many methods developed and advances made.

The ability to recognize patterns is fundamental to computer vision. Here, term pattern refers to a quantitative or structural description of an object. In general, one or more descriptors form patterns. The pattern space corresponds to a measurement or an observation space. A pattern vector is referred to as an observation vector. A pattern vector often contains redundant information; hence, the pattern vector is mapped to a feature vector [14-17]. Pattern recognition systems usually consider a feature space onto which feature vectors are mapped first. The feature vector is used to decide the class to which the input sample belongs. The purpose of feature extraction is to reduce data by retaining certain "features" or "properties" that distinguish input patterns(18-20).




Figure 2. Pattern Recognition System.

Şekil 2. Örüntü Tanıma Sistemi

## 2. 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. Sistemde önemli olan ayrımın belirgin bir şekilde gerçekleşmesidir. Bunu sağlayacak olan en önemli kısım anahtar özelliklerdir.

Bu çalışmada gerçek giriş uzayı olarak darbeli radar

## 2. DEVELOPED METHOD

In this study, pulsed radar Doppler signals were used as real input space. An efficiency feature extraction method was developed for six target objects which are shown in Figure 3 to separate one from the others. Experimental application was realized on having educational purpose and multi function 9620/21 Model Lab-Volt radar experiment set. Pulse echo signals were received to computer media by using data accusation card has 1 Khz sample frequency.

işaretleri kullanılıp, Şekil 3' 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** : 1 ns
- **RF Osilatör** : 9.4 GHz
- **Darbe Tekrar Frekansı (PRF)** : 216 Hz
- **Sabit Hedef Mesafesi** : 75 cm

Kullanılan örüntü tanıma mekanizması ve hesaplama şeması Şekil 4' de verilmiştir. Görüleceği üzere sistemin önem arz eden ve sınıflayıcının doğrudan başarımını etkileyen nokta özellik çıkarımıdır.

The pulsed radar system parameters were adjusted as bellow:

- Pulse width: 1 ns
- RF oscillator: 9.4 GHz
- Pulse Repeat Frequency (PRF): 216 Hz
- Fixed Target Distance: 75 cm

The used pattern recognition mechanism and calculated scheme which are given in Figure 2. We can see that the feature extraction is the most important part of pattern recognition system, and directly impresses accomplishment of classifier.


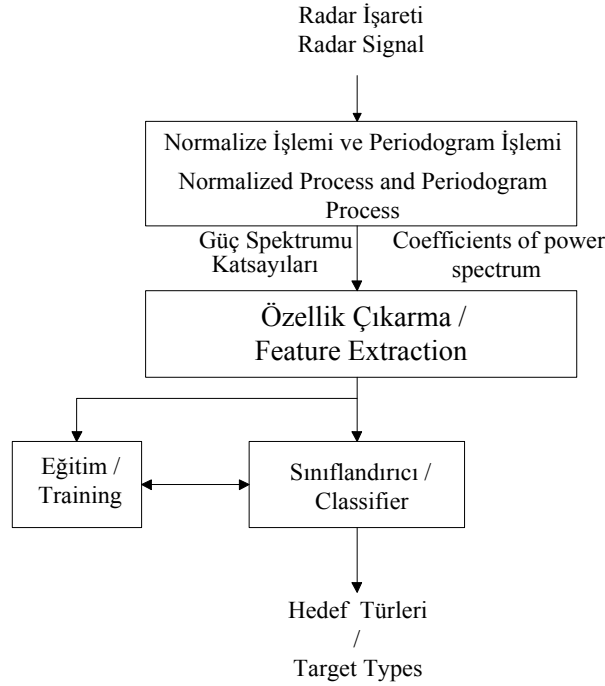


Figure 3. Used Radar Targets

Şekil 3. Kullanılan radar hedefleri



**Figure 4.** Developed pattern recognition system for detecting of radar signals  
**Şekil 4.** Radar işaretlerinin ayrımı için geliştirilen örüntü tanıma sistemi

## 2.1. Özellik Çıkarması

Özellik çıkarma örüntü tanınmanın en önemli kısmı olup, bir anlamda doğru örüntü sınıflandırmanın anahtarıdır. İşaretten özellik çıkarmanın üç ana amacı; sınıflama süresini azaltarak sınıflandırıcının başarımını artırmak, işlenecek bilgi miktarını en aza indirmek ve tanıma sisteminin güvenilirliğini sağlamaktır. Çıkarılan özelliklerin sistemdeki kontrolsüz parametrelerden etkilenmemesi, kararlı olması ile sağlanacaktır. Böylece özellikler geliştirilebilir ve sistemin doğru karar verme güvenilirliği artırılabilir (20). 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.

Burada özellik çıkarımı için radar deney setinden elde edilen farklı her bir hedefe ait Doppler işaretine normalize işlemi uygulanmıştır (Denklem 1). Daha sonra buradan elde edilen sonuç işaretine periodogram denilen ve işaretin ayrık zaman Fourier dönüşümü alındıktan sonra bulunan sonucun genliğinin karesini elde etmeye yönelik bir güç spektral yoğunluk (PSD) yöntemi uygulanmıştır. Bu periodogram yönteminde kullanılan ayrık zaman Fourier dönüşüm denklemi aşağıda Denklem 2' de verilmiştir (21-22).

## 2.1. Feature Extraction

The feature extraction is the most important part of pattern recognition and correct pattern classification key. The purposes of the feature extraction from signals both raise the accomplishment of classifier and reduce the classification time. The other advantages are reduce the processed data to minimum level, and prove safe of recognition system. Therefore extracted features isn't impressed from uncontrolled parameters in system, the extracted features should be determined (19-20). Thus, the features may be generalized and security of systems may be raised. Features extraction of unstable signals is commonly interested in composition of the time-frequency region. Thus, definitely data which includes both transient alteration and frequency alteration can be extracted from radar Doppler signals. In preceding studies, the stochastic modeling methods, namely, AR(p) and ARMA(p,q) have been applied for the classification of radar returns. They are historically well known for resolving the spectral peaks of a short data record, but this only cannot be the basis for classification. The amount of clutter spectral spread is a good indication of the source of clutter.

In there, firstly the normalized process was applied to each of Doppler signals which to be obtained from radar experiment set for all targets (Equation 1). Secondly, the Periodogram was applied to be obtained from there result signals. The Periodogram is to obtain square of amplitude of result which to be obtained after is get discrete time Fourier transform of signal. The Periodogram method is a Power Spectral Density (PSD) method. Used discrete time Fourier transform equation in this Periodogram method is given below at Equation 2 (21-22).

$$x(n+1) = \frac{y(n)}{\sum_{n=0}^{N-1} y(n)} \quad [1]$$

$$X(k+1) = \sum_{n=0}^{N-1} x(n+1)e^{-j\left(\frac{2\pi}{N}\right)} \quad [2]$$

Burada  $y(n)$ = ayrık zamanlı işaret,  
 $N$ = örnek sayısı (bu uygulama için 512 örnek alınmıştır.),  
 $n$ = örnek sayacı ( $n=1, \dots, N$ )  
 $x(n+1)$ = ayrık zamanlı işaretin Denklem 1'e göre normalize edilmiş hali,  
 $X(n+1)$ = ayrık zamanlı işaretin Fourier dönüşümü alınmış halidir.

Buradan elde edilen ayrık fourier dönüşümünün mutlak değerinin karesi alınarak bu sonuç, örnek sayısına bölünür ve güç spektral yoğunluğu (PSD) elde edilir (Denklem 3).

$$\text{PSD} = \frac{1}{N} |X(k+1)|^2 \quad [3]$$

$$x(n+1) = \frac{y(n)}{\sum_{n=0}^{N-1} y(n)} \quad [1]$$

$$X(k+1) = \sum_{n=0}^{N-1} x(n+1)e^{-j\left(\frac{2\pi}{N}\right)} \quad [2]$$

Where  $y(n)$ = discrete time signal,  
 $N$ = example number (512 examples were taken for this application),  
 $n$ = example index ( $n=1, \dots, N$ )  
 $x(n+1)$ = According to Equation 1, normalized state of discrete time signal.  
 $X(n+1)$ = Fourier transform of the discrete time signal.

Firstly, square of absolute value of obtained discrete Fourier transform is divided to example number. Thus PSD is obtained (Equation 3).

$$\text{PSD} = \frac{1}{N} |X(k+1)|^2 \quad [3]$$

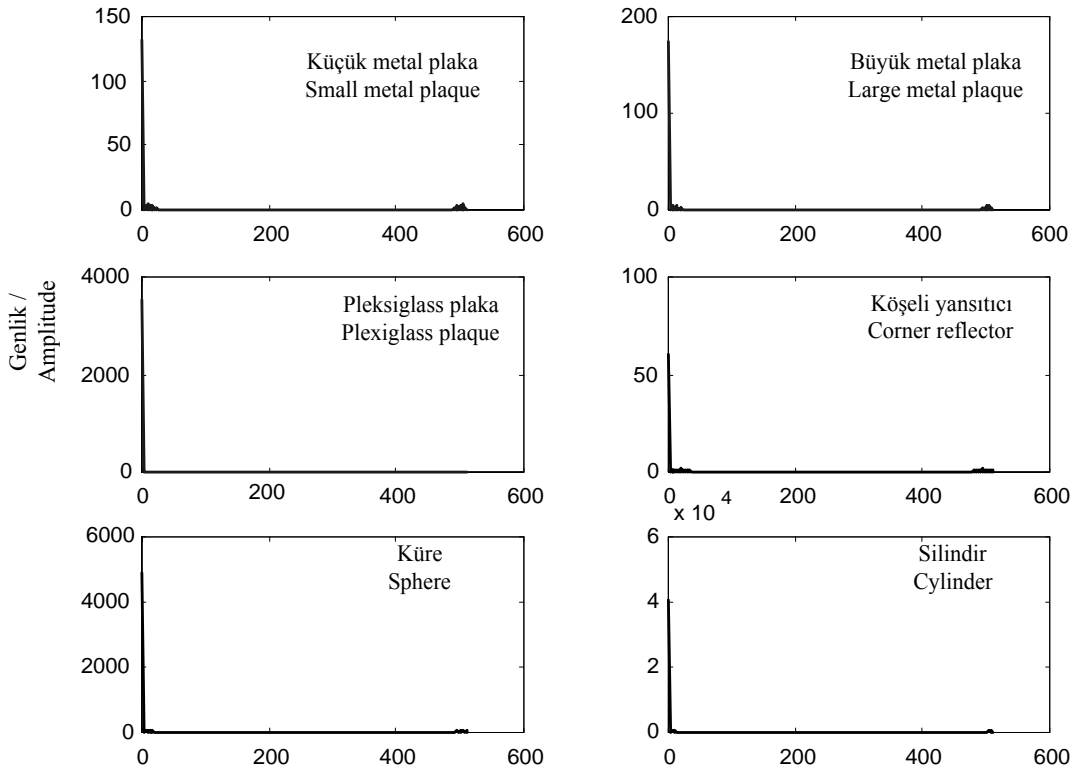


Figure 5. PSDs of fixed targets for obtained Doppler signals of radar targets


Şekil 5. Duran hedeflerin darbeli radar işaretlerinin periodogram yöntemine göre güç spektral yoğunlukları

Şekil 5'de bu çalışmada kullanılan her bir hedefin periodogram güç spektral yoğunluğu yöntemi uygulanması sonucunda elde edilen güç spektrum yoğunlukları verilmiştir. Bu güç spektral yoğunlukları, Bölüm 2'de özellikleri verilen deney setinden elde edilen Doppler işaretlerinin Denklem 1'de gösterildiği gibi normalize işlemine tabi tutulmasından sonra periodogram güç spektral yoğunluk yönteminin uygulanması ile bulunmuştur. Radar deney setinden elde edilen darbeli

The PSDs of fixed targets for obtained Doppler signals of radar targets are given in Figure 5. These PSDs were found after Equation 1-3. For obtain these PSDs, firstly the normalized process was applied to each of Doppler signals which to be obtained from radar experiment set for all targets (Equation 1). Secondly, the Periodogram was applied to be obtained from there result signals. The Periodogram is to obtain square of amplitude of result which to be obtained after is get discrete time Fourier

radar işaret örüntüsü (Doppler) işaretlerinden biri Şekil 6'da görülmektedir.

transform of signal. One of the obtained Doppler signals from radar experimental set is given at Figure 6.



**Figure 6.** Doppler signal of the plexiglass plaque target.

**Şekil 6.** Pleksiglass plaka hedefine ait darbeli radar işaret örüntüsü (doppler işareti).

### 3.SINIFLANDIRMA

Bu çalışmada sırasıyla yapay sinir ağları ve uyarlamalı ağ tabanlı bulanık çıkarım sistemi sınıflandırıcıları kullanarak hedef tanıma yapabilmek için Bölüm 2.1'de gösterilen özellik çıkarım yöntemi kullanılarak örüntü tanıma giriş uzayı elde edilmiştir.

#### 3.1.Yapay Sinir Ağı Sınıflandırıcısı

Yapay sinir ağları biyolojik beyin hücresinden 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 işareti).
- Eğitim verisi ile ayarlanan bağlantı ağırlıkları sayesinde öğrenme, hatırlama ve genelleme yeteneklerine sahiptir.

Bu üstün özellikleri, yapay sinir ağlarının karmaşık problemleri çözebilme yeteneğini göstermektedir (23-26). Şekil 7' de biyolojik nöronun esinlenerek ortaya konmuş

### 3. CLASSIFICATION

In this study, the classification for target recognition was done by using obtained features from Section 2.1 with Artificial Neural Networks (ANN) classifier and Adaptive Network Based Fuzzy Inference System (ANFIS) classifier respectively. For this purpose, by using the feature extraction method showed in Section 2.1 was obtained input space of pattern recognition.

#### 3.1. Artificial Neural Networks

Neural networks (NNs) have been used to model the human vision system. They are biologically inspired and contain a large number of simple processing elements that perform in a manner analogous to the most elementary functions of neurons. Neural networks learn by experience, generalize from previous experiences to new ones, and can make decisions. Neural elements of a human brain have a computing speed of a few milliseconds, whereas the computing speed of electronic circuits is on the order of microseconds. The NNs are parallel process elements which has characteristic in below.

- A NN is a mathematical model of a biological neuron.
- A NN has very process elements which are related another.
- A NN keeps knowledge with connection weights.

Neural network models provide an alternative approach to implementing enhancement techniques. A simple process element of the NNs is given in Figure 7. Output of

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  $a(.)$  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 buldukları  $w_{ij}$  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  $a(.)$  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 değişimlerinin 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 (19) kaynağında bulunabilir.

$i_{th}$  process element at this simple model is given Equation 4.

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

In there,  $a(.)$  is activation function,  $\theta_i$  is threshold value of  $i_{th}$  process element. Knowledge processes of process element compose from two parts: input and output. output of  $i_{th}$  process element is calculated with Equation 5 (19).

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



**Figure 7.** The mathematical model of neuron  
**Şekil-7.** Bir nöron hücresinin matematiksel modeli

Geliştirilen yöntemin sınıflandırıcı aşaması için ilk önce, çok katmanlı ileri beslemeli yapay sinir ağı kullanılmıştır. Şekil 8' de kullanılan sınıflandırıcının giriş çıkış ikilisi görülmektedir.

Yapay sinir ağının seçilen parametreleri :

**Katman sayısı : 3**

Katmanlardaki (giriş, ara, çıkış) nöron sayısı : 512, 25, 6  
Öğrenme algoritması: Uyarlamalı öğrenme oranlı geri-yayınım

Öğrenme oranı : 0.8

Momentum katsayısı : 0.98

Toplam mutlak hata : 0.000005

Etkinleştirme fonksiyonu : Tanjant sigmoid.

Firstly, multi layer neural network was used for classification stage of the developed method (20-25). Input-output of the used classification is showed at Figure 8.

The selected parameters of used artificial neural network:

**Layer number: 3**

Neuron number of Layers (input, hidden, output): 512, 25, 6

Learning algorithm: Adaptive learning rate back propagation

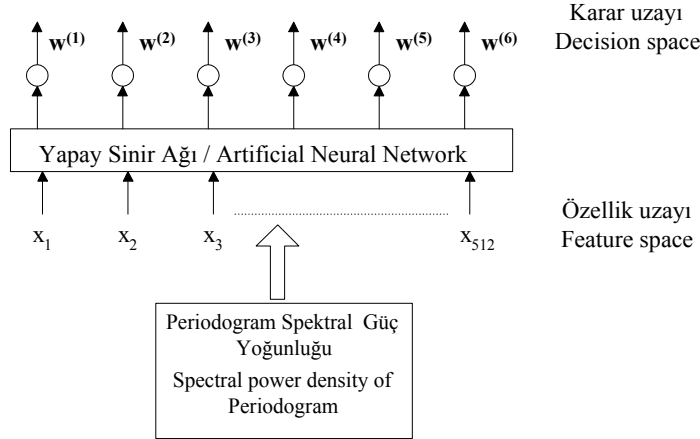
Learning rate: 0.8

Momentum coefficient: 0.98

Mean square error: 0.000005

Activation Function: Tangent sigmoid.





**Figure 8.** Pair of output-input of classification system

**Şekil-8.** Sınıflandırıcı sisteminin giriş/çıkış ikilisi

Burada karar uzayı; küçük metal plaka, büyük metal plaka, pleksiglass plaka, köşeli yansıtıcı, küre ve silindir hedeflerinden oluşmaktadır. Şekil 6' da gösterilen darbeli radar alıcısından elde edilen işaretlere geliştirilen özellik çıkarma algoritması uygulanmıştır. Elde edilen özellikler yapay sinir ağına uygulanarak sınıflandırıcının eğitimi sağlanmıştır. Bir örüntü tanıma sınıflandırıcısından beklenen, özellik uzayıdaki her bir grup özellik için ayırım fonksiyonlarını oluşturmasıdır (27-29). Bu bağlamda, her bir hedef nesne için kullanılan 1 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 Çizelge 1'de verilmiştir. Yapay sinir ağının hedef tanımadaki başarımının yüzde olarak hesaplanmasında her bir hedef için 100 adet gürültülü test verisi kullanılmıştır. Bu gürültülü test verilerini elde etmek amacıyla Gauss beyaz gürültüsü kullanılmıştır. Bu gürültü denklemi Denklem 6'da verilmiştir.

$$c = \sqrt{\frac{\sigma_s^2}{\sigma_w^2 10^{\text{SNR}/10}}} \quad [6]$$

Burada,  $c$  gürültü ölçekleme sabiti,  $\sigma_s^2$  sinyal varyansı,  $\sigma_w^2$  gürültü varyansı, SNR sinyal / gürültü oranıdır. Bu denklem kullanılarak Gauss beyaz gürültü elde etmek amacıyla SNR oranı sırasıyla 1, 2, 3, 4 şeklinde değiştirilmiştir. Elde edilen gürültülü test verileri sırasıyla kullanılan yapay sinir ağları ve uyarlamalı ağ tabanlı bulanık çıkarım sistemi sınıflandırıcılarının sınıflandırma başarımlarını denemek amacıyla kullanılmıştır.

Hundred noisy test data for each of target were used for target recognition achievement of used neural network. Gauss white noise (Equation 6) was used for obtain these noisy test data. SNR ratios of this Gauss white noises were changed 1, 2, 3, 4 respectively (25-26). Outputs of this artificial neural network classifier formed from a decision space = {small metal plaque, large metal plaque, Plexiglas plaque, corner reflector, sphere, cylinder} that represents six numbers different real radar targets.

$$c = \sqrt{\frac{\sigma_s^2}{\sigma_w^2 10^{\text{SNR}/10}}} \quad [6]$$

There,  $\sigma_s^2$  is signal variance,  $\sigma_w^2$  is noise variance, SNR is signal / noise ratio,  $c$  is noise scale constant (27-29). The obtained classification performance results of the ANN classifier are given on Table 1.

**Table 1.** Achievement of ANN classifier (%)**Çizelge 1.** Yapay Sinir Ağı Sınıflandırıcının Başarımı (%)

Target Type/ Hedef Nesne	Small metal plaque/ Küçük Metal Plaka	Large metal plaque/ Büyük Metal Plaka	Plexiglas plaque/ Pleksiglass Plaka	Corner reflector/ Köşeli Yansıtıcı	Sphere/ Küre	Cylinder/ Silindir
Small metal plaque/ Küçük Metal Plaka	98	1	-	-	-	-
Large metal plaque/ Büyük Metal Plaka	1	97	-	2	-	1
Plexiglas plaque/ Pleksiglass Plaka	1	2	99	1	1	1
Corner reflector/ Köşeli Yansıtıcı	-	-	1	97	2	1
Sphere/ Küre	-	-	-	-	97	1
Cylinder/ Silindir	-	-	-	-	-	96

### 3.2. Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi Sınıflandırıcısı

ANFIS (Adaptive Network Based Fuzzy Inference System)'in, yapısında hem yapay sinir ağları hem de bulanık mantık kullanılır (30-32). Yapı bakımından ANFIS, bulanık çıkarım sistemindeki eğer-ise kuralları ve giriş çıkış bilgi çiftlerinden oluşur. Ancak sistem eğitiminde yapay sinir ağı öğrenme algoritmaları kullanılır. Burada ANFIS yapısını basit bir şekilde anlatabilmek için örnek olarak iki girişli ve tek çıkışlı bir ANFIS yapısı verilmiştir. Bu ANFIS yapısı aşağıda da görüldüğü gibi 5 katmandan oluşmaktadır. Burada x ve y giriş, z ise çıkış olarak alınırsa temel kural yapısı şu şekilde yazılabilir:

Eğer x A<sub>1</sub> ve y B<sub>1</sub> ise  $f_1 = p_1x + q_1y + r_1$

Burada p, q ve r lineer çıkış parametreleridir. A<sub>1</sub> ve B<sub>1</sub> ANFIS'in giriş üyelik fonksiyonlarıdır. İki girişli ve bir çıkışlı bir ANFIS'in temel yapısı Şekil 9'da görülmektedir. Bu yapı, 5 katman ve 9 adet eğer-ise kuralı kullanılarak oluşturulmuştur:

**1.Katman:** Bu katmandaki hücre sayısı, iki giriş ve bu iki girişin her birine üç üyelik fonksiyonu tanımlandığına göre altı adettir (i=6'dır). Buna göre,

$$O_{1,i}=\mu_{A_i}(x), i=1,2,3 \text{ için } O_{1,i}=\mu_{B_{i-3}}(y), i=4,5,6 \text{ için} \quad [8]$$

Burada x ve y girişlerdir. Bu katmanın çıkışı kuralların varsayım (eğer) kısımlarının üyelik fonksiyonlarına olan üyelik dereceleridir. Kullanılan üyelik fonksiyonu Denklem 9'da verilmiştir. Buradan da görüldüğü gibi üyelik fonksiyonu olarak Gauss üyelik fonksiyonu kullanılmıştır.

$$\mu_{A_i}(x), \mu_{B_{i-3}}(y) = \exp(-((x_i - c_i)/(a_i))^2) \quad [9]$$

Burada, x ve y giriş, c<sub>i</sub> Gauss üyelik fonksiyonu merkezi ve a<sub>i</sub> Gauss üyelik fonksiyonu genişliğini ifade eder.

### 3.2. Adaptive-Network-Based Fuzzy Inference System

Both artificial neural network and fuzzy logic are used in ANFIS's architecture. ANFIS is consisted of if-then rules and couples of input-output, for ANFIS (Adaptive-Network-Based Fuzzy Inference System) training is used learning algorithms of neural network (30-32).

For simplicity, we assume the fuzzy inference system under consideration has two inputs (x and y) and one output (z). For a first order Sugeno fuzzy model, a typical rule set with base fuzzy if-then rules can be expressed as

If x A<sub>1</sub> ve y B<sub>1</sub> then  $f_1 = p_1x + q_1y + r_1$

Where, p, r, q are linear output parameters. The ANFIS's architecture which has two inputs and one output is showed in Figure 9. This architecture is formed by using five layer and nine if-then rules:

**Layer-1:** Every node i in this layer is a square node with a node function.

$$O_{1,i}=\mu_{A_i}(x), \text{ for } i=1,2,3 \quad O_{1,i}=\mu_{B_{i-3}}(y), \text{ for } i=4,5,6 \quad [8]$$

Where x and y are inputs to node i, and A<sub>i</sub>, B<sub>i</sub> are linguistic label associated with this node function. In order words, O<sub>1,i</sub> is the membership function of A<sub>i</sub> and B<sub>i</sub>. Usually we choose  $\mu_{A_i}(x)$  and  $\mu_{B_{i-3}}(y)$  to be bell-shaped with maximum equal to 1 and minimum equal to 0, such as

$$\mu_{A_i}(x), \mu_{B_{i-3}}(y) = \exp(-((x_i - c_i)/(a_i))^2) \quad [9]$$

Where a<sub>i</sub>, c<sub>i</sub> is the parameter set. These parameters in this layer are referred to as premise parameters.

**2. Katman:** Burada kuralların kesinlik dereceleri cebirsel çarpım kullanılarak bulunur (Denklem 10).

$$O_{2,i} = w_i = \mu_{A_i}(x) * \mu_{B_i}(y), \quad i=1,2,3,\dots,9 \quad [10]$$

Buradaki  $O_i$  sembolü ise her bir katman çıkışlarını göstermektedir.

**3. Katman:** Burada kuralların normalizasyon işlemi yapılmaktadır (Denklem 11).

$$O_{3,i} = \bar{w}_i = w_i / (w_1 + w_2 + \dots + w_9), \quad i=1,2,3,\dots,9 \quad [11]$$

**4. Katman:** Bu katmanda normalize edilmiş her bir kural kendine ait çıkış fonksiyonu ile çarpılır (Denklem 12).

$$O_{4,i} = \bar{w}_i * f_i = w_i * (p_i x + q_i y + r_i) \quad [12]$$

Buradaki  $p$ ,  $q$  ve  $r$  lineer parametreleri sonuç parametreleri olarak adlandırılır.

**5. Katman:** 4. Katman çıkışlarının toplanarak ANFIS çıkışının sayısal değerinin bulunduğu kısımdır.

$$O_{5,i} = \text{toplam çıkış} = \frac{\sum_i w_i f_i}{\sum_i w_i} \quad [13]$$

Şekil 9'da iki girişli ve tek çıkışlı ANFIS'in 5 adet katmanı verilmiştir.

**Layer-2:** Every node in this layer is a circle node labelled  $\Pi$  which multiplies the incoming signals and sends the product out. For instance,

$$O_{2,i} = w_i = \mu_{A_i}(x) * \mu_{B_i}(y), \quad i=1, 2, 3, \dots, 9 \quad [10]$$

Each node output represents the firing strength of a rule. (In fact, other T-norm operators that performs generalized AND can be used as the node function in this layer).

**Layer-3:** Every node in this layer is a circle node labelled  $N$ . The  $i^{\text{th}}$  node calculates the ratio of the  $i^{\text{th}}$  rules firing strength to the sum of all rule's firing strengths:

$$O_{3,i} = \bar{w}_i = w_i / (w_1 + w_2 + \dots + w_9), \quad i=1,2,3,\dots,9 \quad [11]$$

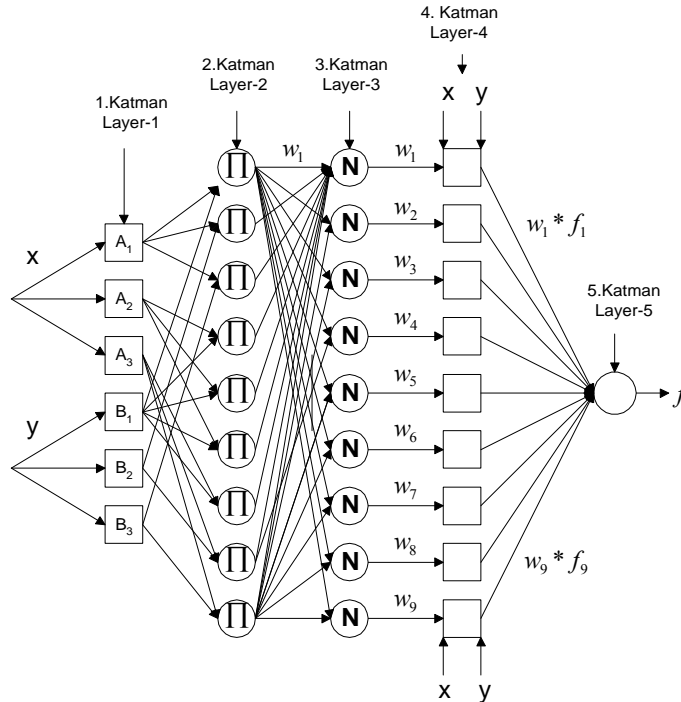
**Layer-4:** Every node  $i$  in this layer is a square node with a node function

$$O_{4,i} = \bar{w}_i * f_i = w_i * (p_i x + q_i y + r_i), \quad i=1,2,3,\dots,9 \quad [12]$$

Where,  $w_i$  is the output of layer 3, and  $\{p_i, q_i, r_i\}$  is the parameter set. Parameters in this layer will be referred to as consequent parameters.

**Layer-5:** The single node in this layer is a circle node labelled  $\Sigma$  that computes the overall output as the summation of all incoming signals:

$$O_{5,i} = \text{overall output} = \frac{\sum_i w_i f_i}{\sum_i w_i} \quad [13]$$




**Figure 9.** ANFIS architecture of 2-inputs and 9-rules.  
**Şekil 9.** 2 girişli 9 kuralı bir ANFIS sınıflandırıcı yapısı

Bu 5 katmandan oluşan bir ANFIS sınıflandırıcısının kullanımı Şekil 10'da görülmektedir.

Bölüm 2'de ayrıntıları verilen özellik çıkarma yöntemi ile elde edilen eğitim verileri ANFIS sınıflandırıcısının girişine verilmiştir. ANFIS'in çıkışına ise Bölüm 2.1'de yapay sinir ağları sınıflandırıcısı çıkışına da verilen Karar Uzayı = {Küçük metal plaka, Büyük metal plaka, Pleksiglass plaka, Köşeli yansıtıcı, Küre, Silindir} verilmiştir. Şekil 10'da ise ANFIS sınıflandırıcı ile sınıflandırma blok diyagramı görülmektedir.

Using of ANFIS in this application is showed at Figure 10.



**Figure 10.** Block diagram of the classification with ANFIS classifier  
**Şekil 10.** ANFIS Sınıflandırıcı İle Sınıflandırma Blok Diyagramı

Giriş eğitim verileri ile eğitilen ANFIS sınıflandırıcı Bölüm 2.1'de yapay sinir ağı sınıflandırıcısının test edildiği, her bir hedef için Denklem 7 kullanılarak elde edilen 100 adet gürültülü test verisi ile test edilerek sınıflandırma performansı yüzde olarak belirlenmiştir. Elde edilen sonuçlar Çizelge 2'de verilmiştir.

Hundred noisy test data for each of target were used for target recognition achievement of used ANFIS. Gauss white noise (Equation 6) was used for obtain these noisy test data. SNR ratios of this Gauss white noises were changed 1, 2, 3, 4 respectively (25-26). Outputs of this artificial neural network classifier formed from a decision space = {small metal plaque, large metal plaque, Plexiglas plaque, corner reflector, sphere, cylinder} that represents six numbers different real radar targets. The obtained classification performance results of the ANFIS classifier are given on Table 2.

**Table 2.** Achievement of ANFIS classifier (%)  
**Çizelge 2.** ANFIS Sınıflandırıcısının Başarımı (%)

Target Type/ Hedef Nesne	Small metal plaque/ Küçük Metal Plaka	Large metal plaque/ Büyük Metal Plaka	Plexiglas plaque/ Pleksiglass Plaka	Corner reflector/ Köşeli Yansıtıcı	Sphere/ Küre	Cylinder/ Silindir
Small metal plaque/ Küçük Metal Plaka	100	-	-	-	-	-
Large metal plaque/ Büyük Metal Plaka	-	98	-	-	-	-
Plexiglas plaque/ Pleksiglass Plaka	-	2	100	1	-	-
Corner reflector/ Köşeli Yansıtıcı	-	-	-	99	-	-
Sphere/ Küre	-	-	-	-	100	1
Cylinder/ Silindir	-	-	-	-	-	99

#### 4. SONUÇ VE DEĞERLENDİRME

Geliştirilen özellik çıkarma yöntemi, darbeli radar işaretlerine uygulanarak %100 doğru bir şekilde ayırım fonksiyonlarının oluşması sırasıyla yapay sinir ağı ve uyarlamalı ağ tabanlı bulanık çıkarım sistemi sınıflandırıcıları aracılığı ile sağlanmıştır. Ayrıca Çizelge

#### 4. RESULTS AND CONCLUSIONS

Improved feature extraction method was applied to pulsed radar signals, and clear differences among differentiation percents. These signs have been described how the extracted from natural inputs are effective and powerful. The differentiation function at the decision

1 ve Çizelge 2’de de görülebileceği üzere, ayırım fonksiyonları arasında oldukça belirgin farklar olduğu tanıma yüzdelilerinden 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 veya uyarlamalı ağ tabanlı bulanık çıkarım sisteminin kullanımı sisteme öğrenme ve öğrendiklerinden karar çıkarma özelliği katmaktadır. Bununla birlikte yapay sinir ağı sınıflandırıcısı ile uyarlamalı ağ tabanlı bulanık çıkarım sistemi sınıflandırıcısı arasındaki en büyük farkın yapı bakımından yapay sinir ağı sınıflandırıcısına göre daha karmaşık olan uyarlamalı ağ tabanlı bulanık çıkarım sistemi sınıflandırıcısının eğitim aşamasının yapay sinir ağı sınıflandırıcısı eğitimine göre biraz daha yavaş olduğudur. Buna karşın tanıma performansı bakımından Çizelge 1 ve Çizelge 2’den de görülebileceği gibi ANFIS’in YSA (Yapay Sinir Ağı) ’ya göre çok az bir üstünlüğünden söz edilebilir. Bu yöntemler sayesinde gerçekleştirilebilecek basit yapıllı akıllı tanı sistemleri, çok geniş bir sahada uygulama alanı bulabilir.

İlerde bu alanda yapılabilecek çalışmalarda, özellik çıkarımına çevre ve gürültüden daha az etkilenen kararlı bir yapı kazandırılmasıyla, radar sistemlerinde hedef kimliği hakkında bilgi edinme çalışmaları pratik şartlar altında kullanılabilir.

#### KAYNAKLAR/ REFERENCES

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*, Brighton, England , 450–453, (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, Krakow, Poland, 799 –803, (1998).
4. Jakubiak A., Arabas J., Grabczak K., etc., “Radar clutter classification using Kohonen neural network”, *Radar 97* (Conf. Publ. No. 449), Edinburgh , UK, 185 –188, (1997).
5. Tang B., Jiang W., Ke Y., “Radar signal classification by projection onto wavelet packet subspaces”, *CIE International Conference of Radar Proceedings*, Beijing, China, 124–126, (1996).
6. Beastall W. D.,” Recognition of radar signals by neural network”, *First IEE International Conference on Artificial Neural Networks*, (Conf. Publ. No. 313), London, UK, 139-142, (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 de-noising”, *Concordia University* (Canada), (1999).
9. Sowelam S.M., Tewfik A.H., “Waveform selection in radar target classification”, *IEEE Transactions on Information Theory*, Vol. 46, 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), Edinburg, UK, 81–85, (1998).

space of the system is very clear.

Therefore the features which are selected for feature vector is summarized very well without using another operations, and yet it proves the reliability of the selected features as a classifier, the use of ANFIS add the features of the learning and the reaching a decision to the system. However the most important difference between ANN classifier and ANFIS classifier is that the training stage of the ANFIS system classifier is shorter than the ANN classifier. However from the point of the view of recognition performance, we can mention just a little superiority of ANFIS than ANN classifier (Table 1 and Table 2). In this way the basic built intelligent diagnosis systems are used in a very big area.

At the future studying about this area, if one can be acquired a structure about feature extraction which is less effected from the environment and noise, the effort of the getting information from the at the practical conditions may be used at the radar system about the target identify.

11. Noone G.P., "A neural approach to automatic pulse repetition interval modulation recognition", *Information Decision and Control, IDC 99 Proceedings*, Adelaide, Australia, 213-218, (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, Adelaide, Australia, II/373 -II/376, (1994).
13. Roome S.J., "Classification of radar signals in modulation domain", *Electronics Letters*, vol.28, 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*, Portland, Oregon, USA, 172 –175, (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*, Lisbon Portugal, 1-1, 1-29. (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. Turkoglu, I., "Automatic Target Distance Recognition by Using Continuous Wave Radar Doppler Signals and Artificial Neural Networks", *DAUM*, 1, 80-87, Elazig, (2002).
22. Turkoglu, I., "An Intelligent Pattern Recognition for Non-stationary Signals Based on The Time – Frequency Entropies", PhD Thesis, *Firat University Graduate School of Natural and Applied Sciences*, Elazig, 40-47, (2002).
23. Percival D. B., Walden A. T., "Spectral analysis for physical applications: Multitaper and conventional univariate techniques", *Cambridge University Press.*, New York (1993).
24. Lin C. T., Lee C.S.G., "Neural Fuzzy Systems", *Prentice-Hall*, (1996).
25. Zurada, M.J., "Introduction to Artificial Neural Systems", *West Publishing Company Inc.*, New York, (1992).
26. Turkoglu, I., Arslan A., "Power spectrum of the AR model and feature extraction method based on artificial neural network for target classification", Gazi University, Technical Education Faculty, *Journal of Polytechnic* , 5(2) , 121-127, May, (2002).
27. Kara S., "Doppler cihazı ve autoregresif spektral analiz metoduyla mitral ve triküspit kapaklardaki kan akışının incelenmesi", Doktora tezi, *Erciyes Üniversitesi Fen Bilimleri Enstitüsü*, 15-20, (1994).
28. Yüksel M. E., "Ultrasonik Doppler İşaretlerinin Bilgisayar Destekli Analizi", Y. Lisans tezi, *Erciyes Üniversitesi Fen Bilimleri Enstitüsü*, 25-43, (1993).
29. Turkoglu I., Arslan A., "Optimisation of the Performance of Neural Network Based Pattern Recognition Classifiers with Distributed Systems", *IEEE Computer Society, International Conference on Parallel and Distributed Systems (ICPADS'2001)*, Kyong Ju, Korea, 379-382 (2001).
30. Kosko, B., Neural Networks and Fuzzy Systems, A Dynamical Systems Approach, Englewood Cliffs., *NJ: Prentice Hall*, (1991).
31. Jang, J. S. R., Sun, C. T., "Neuro-Fuzzy Modeling and Control", *Proceedings of the IEEE*, vol. 83, No. 3, (1995).
32. Jang, J. S. R., May., "ANFIS: Adaptive network-based fuzzy inference systems", *IEEE Trans. Syst., Man. and Cybern.*, vol. 23, 665-685., (1993).