

# Yapay Sinir Ağlarıyla Hedef Ayırdetmede Farklı Sonar Girdi Sinyallerinin Başarım Üzerindeki Etkisi \*

Birsel Ayrulu ve Billur Barshan

Elektrik ve Elektronik Mühendisliği Bölümü

Bilkent Üniversitesi, Bilkent 06533 Ankara

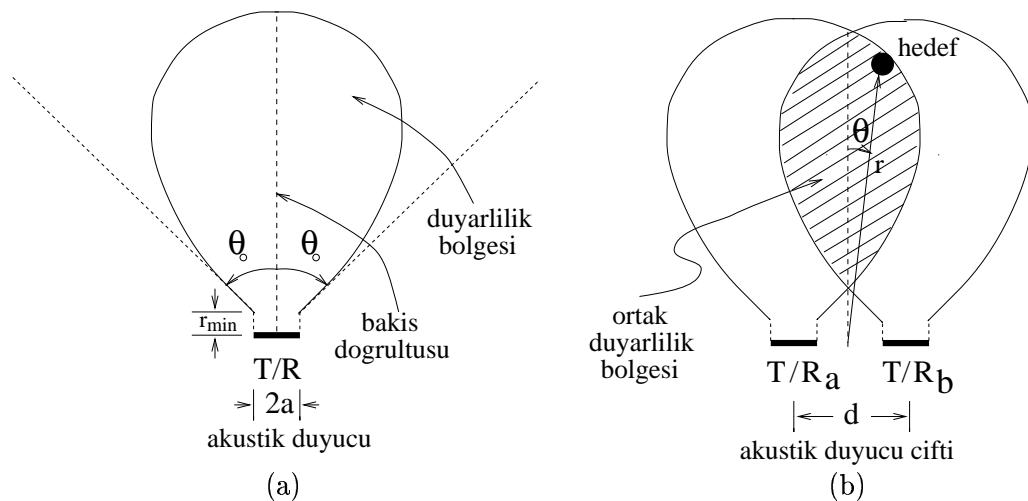
E-posta: billur@ee.bilkent.edu.tr

## Özetçe

Bu çalışmada yapay sinir ağlarına verilen girdi sinyallerinin değişik yöntemlerle önişlenmesinin başarım üzerindeki etkisi incelenmektedir. Önişleme yöntemleri arasında geleneksel ve kesirli Fourier dönüşümü, ayrik dalgacık dönüşümü ve kendinden örgütlü öznitelik haritası yer almaktadır. Gerçek sonar sinyalleri işlenerek hedef ayırdetme ve konum belirleme problemi ele alınmıştır. En iyi sonuç kesirli Fourier dönüşümü önişlemesi ile elde edilmektedir.

## 1 Giriş

Bu çalışmada sonar sinyalleri hedef ayırdetme amacıyla yapay sinir ağlarına girdi olarak verilmekte ve değişik girdi önişleme yöntemlerinin karşılaştırılması yapılmaktadır. Akıllı sistemler birçok uygulamada, bulundukları ortamın modelinin tamamını veya bir kısmını duyuculardan yararlanarak elde ederler. Bulundukları ortamdaki düzlem (duvar), köşe, kenar ve silindir gibi sıkılıkla karşılaşılan hedef ilkellerini ayırdedebilmeleri gereklidir. Güvenilir bir sınıflandırma, kullanılan yöntem ve duyucu türleri ile yakından ilgilidir. Sonar duyucuları ile yapay sinir ağları birlikte kullanılarak hedef ayırdetme amaçlı deneyel çalışmalar yapılmıştır. Birden fazla sonar duyucusu kullanılarak tipik bir ortamda sıkılıkla karşılaşılan cisimlerin yapay sinir ağları ile birbirinden ayırdetme ve konumlarını kestirmekdeki doğruluk oranları belirlenmiştir.



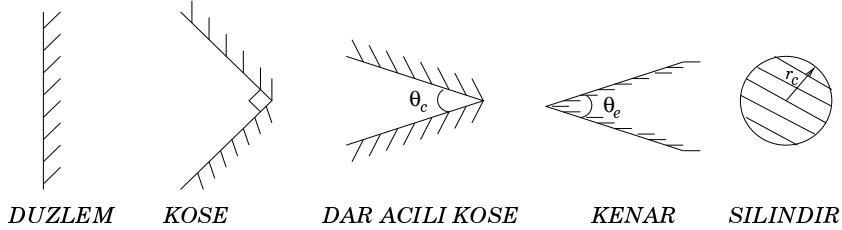
Şekil 1: (a) Bir sesötesi dönüştürücünün duyarlılık bölgesi, (b) iki dönüştürücünün ortak duyarlılık bölgesi.

\*Bu çalışma TÜBİTAK 197E051 projesi tarafından desteklenmiştir. Haldun M. Özaktaş'a kesirli Fourier dönüşümlerinin kullanımını önerdiği için, Çağatay Candan'a kesirli Fourier dönüşümü kodunu sağladığı için teşekkür ederiz.

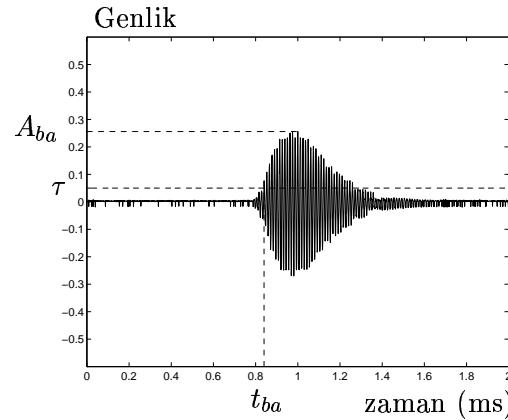
## 2 Akustik Algılama

Akustik algılayıcılar kullanımı kolay, hafif, dayanıklı ve ucuz oldukları için sıkılıkla kullanılmaktadır. En yaygın olarak kullanılan sonar erim düzenekleri, uçuş süresi verilerine dayanmaktadır. Bu tür sistemlerde, gönderilen dürtü bir cisim ile karşılaşıldığı zaman yankı üretir ve bu üretilen yankı genliğinin önceden belirlenen eşik değerini ilk geçtiği  $t_0$  anında bir erim değeri  $r = \frac{ct_0}{2}$  bulunur. Bu eşitlikteki  $c$  sesin havadaki hızını göstermektedir. Hedeflerin daha iyi sınıflandırılması için hem genlik hem de uçuş süresi verilerini veya sinyalin tamamını işleyen çok algılayıcılı dürtü/yankı sistemlerinin kullanılması gerekmektedir. Bu çalışmada, sıkılıkla karşılaşılan hedef türlerinin sınıflandırılması ve konum kestiriminde hem genlik hem de uçuş süresi verilerini işleyen sonar duyucuları kullanılmış ve hedef ayırdetme ve konum kestirimindeki doğruluk oranları belirlenmiştir. Açısal çözünürlüğü artırmak için aralarında  $d$  kadar uzaklık bulunan, aynı özelliklere sahip, hem göndermeye hem de almaç olarak çalışabilen iki dönüştürücü kullanılmıştır (Şekil 1).

Çalışmada kullanılan hedeflerin yatay kesitleri Şekil 2'de gösterilmiştir. Kullanılan akustik dalga boyu (8.6 mm) laboratuvar ortamında karşılaşılan tipik bir cisim yüzeyindeki girinti çıkışlarından çok daha büyük olduğu için, bu tür nesneler akustik dalgaları ayna gibi yansıtırlar. Hedeflerin fiziksel yansıtma modelleri ve bunlara bağlı yankı sinyal modelleri [1]’de ayrıntılı olarak verilmiştir. Aşağıda  $A_{aa}$ ,  $A_{bb}$ ,  $A_{ab}$  ve  $A_{ba}$  herbir yankı sinyalinin en büyük genlik değerini,  $t_{aa}$ ,  $t_{bb}$ ,  $t_{ab}$  ve  $t_{ba}$  ise bu sinyallerden eşikleme ile elde edilen uçuş süresi değerlerini göstermektedir. Gösterimlerdeki birinci altsıngle göndermeyece, ikincisi ise almaça karşılık gelmektedir. Örnek bir yansıtma sinyali Şekil 3’té gösterilmektedir.



Şekil 2: Bu çalışmada sınıflandırılan hedef ilkellerinin yatay kesitleri.



Şekil 3:  $r = 60$  cm ve  $\theta = 0^\circ$ ’deki bir düzlemden duyucu  $b$  gönderip  $a$  aldığında elde edilen gerçek sonar sinyali.

## 3 Yapay Sinir Ağları

Yapay sinir ağları örüntü sınıflandırıcı olarak yaygın kullanım alanına sahiptirler [7]. İstatistiksel sınıflandırma yöntemlerine göre veri ve gürültü kümeleri hakkında fazla varsayımlı ve modellemeye dayanmadıkları için

istatistiksel bilgi bulunmadığı veya mevcut veriler doğrusal olmayan bir sistemin çıktıları olduğu durumlarda özellikle tercih edilen bir yaklaşımındır.

### 3.1 Girdi Sinyalleri

Yapay sinir ağları ile hedef türlerinin sınıflandırılmasında girdi sinyallerinin seçimi önemli işlerden biridir. En küçük ağ yapısına ve sınıflandırma hatasına neden olan girdi sinyalleri tercih edilmelidir. Bu özellikleri taşıyan girdileri bulmak amacıyla çeşitli girdi sinyalleri denenmiştir.

Herbiri yüksekliği 1.2 m olan tahtadan yapılmış düzlem, köşe, kenar,  $60^\circ$ 'lik dar açılı köşe ve 2.5, 5.0 ve 7.5 cm yarıçaplı üç adet silindir kullanılmıştır. Bu cisimlerin herbiri Şekil 4'deki 25 ayrık konuma yerleştirilerek sonar algılama ünitesi tarafından  $-52^\circ$ 'den  $52^\circ$ 'ye kadar  $1.8^\circ$ 'lik adımlarla taranmıştır. Herbir hedef türü ve herbir konum için 58 örnekten oluşan dört ayrı genlik ve uçuş süresi sinyali alınarak 700 örüntü setinden oluşan bir öğrenme kümesi oluşturulmuştur. Elde edilen genlik ve uçuş süresi örüntülerini ham haliyle veya çeşitli sinyal önişleme yöntemleriyle işlendikten sonra üç katmanlı bir yapay sinir ağına hata geri-yayılım (error back-propagation) algoritması ile öğretilmiştir. Kullanılan önişleme yöntemleri, geleneksel ve kesirli Fourier dönüşümü (GFD ve KFD) [8], ayrık dalgacık dönüşümü (ADD) [4], kendinden örgütlü öznitelik haritası (KÖÖH) (self-organizing feature map)'dır [6]. Toplam 21 farklı girdi sinyali denenmiştir:

$$I_1 : A_{aa}(\alpha), A_{bb}(\alpha), \frac{A_{ab}(\alpha)+A_{ba}(\alpha)}{2}, t_{aa}(\alpha), t_{bb}(\alpha) \text{ ve } \frac{t_{ab}(\alpha)+t_{ba}(\alpha)}{2}$$

$$I_2 : A_{aa}(\alpha) - A_{ab}(\alpha), A_{bb}(\alpha) - A_{ba}(\alpha), t_{aa}(\alpha) - t_{ab}(\alpha) \text{ ve } t_{bb}(\alpha) - t_{ba}(\alpha)$$

$$I_3 : [A_{aa}(\alpha) - A_{ab}(\alpha)][A_{bb}(\alpha) - A_{ba}(\alpha)], [A_{aa}(\alpha) - A_{ab}(\alpha)] + [A_{bb}(\alpha) - A_{ba}(\alpha)], \\ [t_{aa}(\alpha) - t_{ab}(\alpha)][t_{bb}(\alpha) - t_{ba}(\alpha)], \text{ ve } [t_{aa}(\alpha) - t_{ab}(\alpha)] + [t_{bb}(\alpha) - t_{ba}(\alpha)]$$

$$I_4 - I_6 : \text{geleneksel Fourier dönüşümü, GFD}(I_i)$$

$$I_7 - I_9 : \text{kesirli Fourier dönüşümü, KFD}(I_i)$$

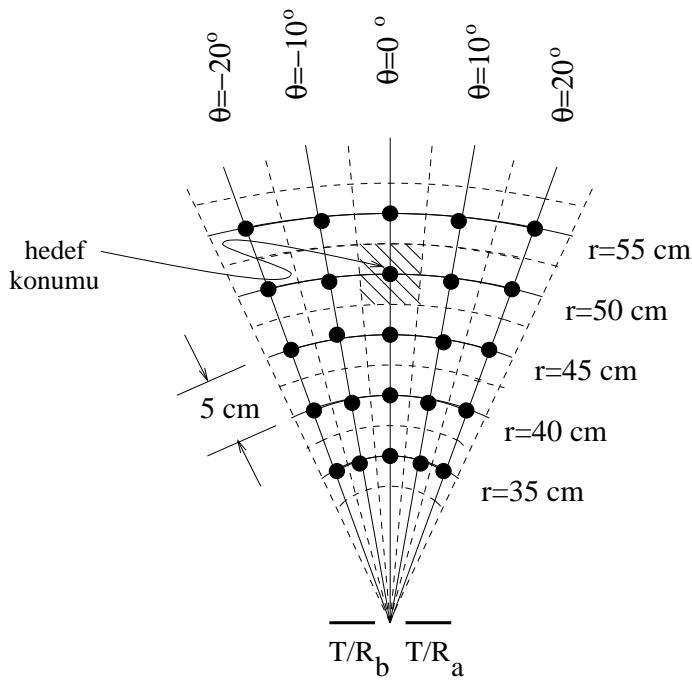
$$I_{10} - I_{18} : \text{farklı katmanlarda ayrık dalgacık dönüşümü, ADD}(I_i)$$

$$I_{19} - I_{21} : \text{kendinden örgütlü öznitelik haritası kullanılarak çıkarılan özellikler, KÖÖH}(I_i)$$

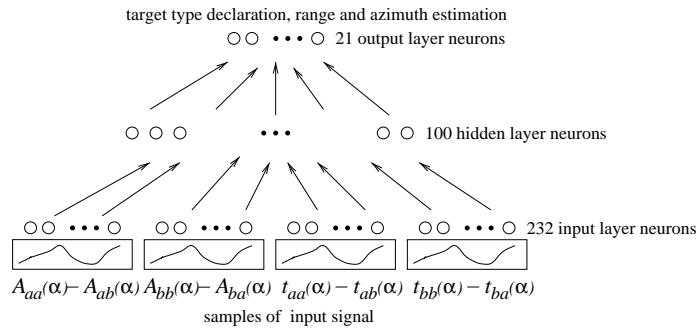
Bu girdilerden ilki olan  $I_1$ 'de sinyaller olduğu gibi kullanılmış, sadece, çapraz terimlerin ideal koşullarda birbirine eşit olması gereğinden bunların ortalaması alınarak her ikisinin yerine de kullanılmıştır. İkinci sinyal  $I_2$  yazarlar tarafından geliştirilen sınıflandırma algoritmasında [1] kullanılan fark sinyalleridir. Üçüncü girdi sinyali  $I_3$  ise önceki bir çalışmada [1] hedef türlerine atanınan inanç değerlerindeki terimlerden esinlenerek fark sinyallerinin toplamı ve çarpımı olarak alınmıştır. GFDnin yanısıra girdi sinyallerinin KFDsının [8] alınmasının hedef ayırdetme ve konum belirlemedeki etkisi de incelenmiştir.  $I_1, I_2$  ve  $I_3$  girdi sinyallerinin  $a$ . dereceden KFDleri alınmış, KFDnin derecesi  $a$  sıfırdan bire kadar 0.05 aralıklarla artırılmıştır. ADD önişleme yönteminde önce her sinyalin birinci katmandaki ADDsi alındı. Daha sonra kullanılan örnek sayısını azaltmak amacıyla birinci ve ikinci katmanlardaki sinyalin kendisine çok benzeyen alçak-sıklık elemanları  $[ASE(ADD(I_i))_j, i = 1, 2, 3; j = 1, 2]$  kullanıldı.

Yapay sinir ağının çıktısı, hedef türü, erimi ve eğim açısındandır. Herbir çıktı yedi nöronla kodlandığı için çıkış katmanı 21 nöron içermektedir. Ara katmandaki nöron sayısı yeterince küçük nöron sayılarından başlanıp öğrenme işlemi tamamlanıncaya kadar nöron ve gerekli bağlantılar eklenerek elde edilmiştir. Ortalama olarak 65 saklı katman nöronu kullanılmıştır.  $I_2$  girdi sinyali ile birlikte kullanılan yapay sinir ağının yapısı Şekil 5'de görülmektedir. Öğrenme aşamasında herbir konum ve herbir hedef türü için dört ayrı veri seti alınarak oluşturulan 700 yankı sinyalinden elde edilen veri kümesi kullanılmıştır. Daha sonra, öğretme kümese benzer şekilde elde edilmiş ikinci bir veri kümlesi (deneme kümlesi) ile geliştirilen ağlar denenmiştir. Deneme sonucunda elde edilen doğru sınıflandırma, erim ve eğim açısı kestirim yüzdesinin hedef türleri üzerinden ortalaması Tablo 1'de verilmiştir. Bu tabloya göre en yüksek sınıflandırma başarımı (%98) ve en yüksek doğru eğim açısı kestirimini (%90) ASE(ADD( $I_1$ ))<sub>2</sub> sinyaliyle, en yüksek doğru erim kestirimini (%79) ise  $I_3$  sinyaliyle elde edildi.

En iyi sonucu KFD verdiği göre bu önişleme yöntemi ile elde edilen sonuçları aşağıda daha ayrıntılı olarak ele alacağız.  $I_1$  girdi sinyali için önişleme yapılmadığı durumda ortalama sınıflandırma hatası %12, GFD önişlemesi ile %3 ve KFD ile %0'dır. Uzaklık ve eğim açısı kestirim hatası hata toleransları  $\epsilon_r$  ve  $\epsilon_\theta$  içinde kalırsa doğru kabul edilmektedir.  $\epsilon_r$  ve  $\epsilon_\theta$ 'nın değişik değerleri için hedefler üzerinden alınan ortalamaya göre erim ve açı hatasının değerleri Şekil 6(a) ve (b)'de gösterilmiştir.



Şekil 4: Ayrık hedef konumları.



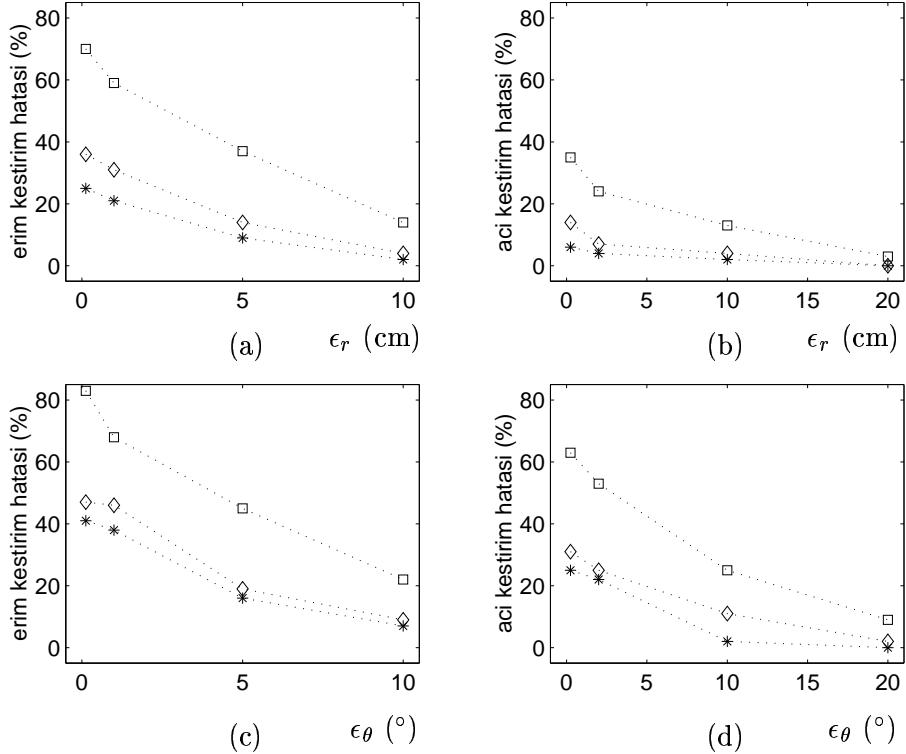
Şekil 5:  $I_2$  sinyali için ağ yapısı.

Beklendiği gibi ortalama hata, tolerans büyülüüğü arttıkça azalmaktadır. Konumlama hatasının KFD önişlemesi ile hiç önişleme yapılmayan duruma göre büyük ölçüde azaldığı görülmektedir (erim kestirimi için ortalama %73 veya 3.6 kat, açı kestirimi için %88 veya 8.3 kat). GFD ile ise hatada daha küçük oranda bir azalma gözlenmektedir (erim kestirimi için ortalama %37 veya 1.6 kat, açı kestirimi için %63 veya 2.7 kat). KFD'nin de hızlı bir algoritması olduğu, dolayısıyla GFD ile işlem yükü aynı olduğu için KFD kullanımı ek bir işlem yükü getirmemektedir.

Yapay sinir ağları Şekil 4'deki 25 noktaya bağlı kalmaksızın sürekli kestirim düzlemi içerisinde rastgele yerlere konularak da denendi.  $I_1$  sinyali için önişleme yapılmadığı durumda ortalama sınıflandırma hatası %12, GFD önişlemesi ile %4 ve KFD ile %0'dır. Bu ikinci deneme kümesiyle elde edilen erim ve açı kestirim sonuçları Şekil 6(c) ve (d)'de gösterilmiştir. Bu durumda da KFD ile çok daha iyi sonuçlar elde edilmektedir. Konumlama hatasının KFD önişlemesi ile hiç önişleme yapılmayan duruma göre büyük ölçüde azaldığı görülmektedir (erim kestirimi için ortalama %57, açı kestirimi için %78). Beklendiği üzere ikinci durumda hatalar birinci kümeye göre bir miktar daha yüksektir (Şekil 6(a),(b) ve 6(c)(d)'deki birbirine karşı gelen noktaları karşılaştırınız). Öğretme işleminin sadece 25 noktada ve 5 cm ve  $10^\circ$ 'lik aralıklarla yapıldığı göz önünde bulundurulursa geliştirilen yapay sinir ağlarının bir miktar interpolasyona yatkın olduğu ortaya çıkmaktadır.

girdi sinyali	doğru sınıfı (%)	doğru erim kestirimi (%)				doğru eğim açısı kestirimi (%)			
		hata toleransı $\epsilon_r$				hata toleransı $\epsilon_\theta$			
		$\pm 0.125$ cm	$\pm 1$ cm	$\pm 5$ cm	$\pm 10$ cm	$\pm 0.25^\circ$	$\pm 2^\circ$	$\pm 10^\circ$	$\pm 20^\circ$
$I_1$	88	30	41	63	86	65	76	87	97
$I_2$	95	74	77	87	93	89	92	95	97
$I_3$	86	79	82	89	94	83	89	95	97
$GFD(I_1)$	97	64	69	86	96	86	93	96	100
$GFD(I_2)$	93	59	64	79	89	76	81	88	93
$GFD(I_3)$	86	54	61	77	89	70	76	85	94
$KFD(I_1)$	100	75	79	89	97	93	96	97	100
$KFD(I_2)$	95	74	77	87	93	89	92	95	97
$KFD(I_3)$	86	79	82	89	94	83	89	95	97
$ADD(I_1)$	82	15	30	59	80	46	58	77	94
$ASE(ADD(I_1))_1$	85	18	28	58	82	54	65	80	95
$ASE(ADD(I_1))_2$	98	71	76	87	95	90	93	97	100
$ADD(I_2)$	92	63	69	84	93	85	88	93	96
$ASE(ADD(I_2))_1$	95	65	70	84	94	87	90	94	97
$ASE(ADD(I_2))_2$	89	28	34	58	84	58	68	86	95
$ADD(I_3)$	86	58	62	76	93	85	88	93	96
$ASE(ADD(I_3))_1$	82	56	60	75	89	73	77	86	93
$ASE(ADD(I_3))_2$	83	29	37	63	83	53	65	78	87
$KÖÖH(I_1)$	75	17	25	49	80	64	67	81	90
$KÖÖH(I_2)$	78	22	28	59	88	69	73	86	92
$KÖÖH(I_3)$	66	24	30	57	84	51	54	78	89

Tablo 1: Ortalama doğru sınıflandırma, erim ve eğim açısı kestirim yüzdeleri.



Şekil 6: Deneme aşamasında (a),(b): öğretme noktaları kullanıldığı, (c),(d): rastgele noktalar kullanıldığı durumlarda erim ve açı kestirim hatasının  $\epsilon_r$  ve  $\epsilon_\theta$ 'ya göre grafikleri. Veri noktaları  $\epsilon_r = 0.125, 1, 5, 10$  cm ve  $\epsilon_\theta = 0.25^\circ, 2^\circ, 10^\circ, 20^\circ$ 'ye, kare, baklava, ve yıldızlar  $a = 0$  (önişlemesiz durum),  $a = 1$  (GFD ile önişleme),  $a = a_{opt}$  (KFD ile önişleme)'ye karşılık gelmektedir.

## 4 Sonuç

Yapay sinir ağlarıyla hedef ilkellerinin sınıflandırılması ve konum kestirimini oldukça yüksek bir yüzdeyle gerçekleştirmiştir. Elde edilen yüksek başarım, sonar sinyallerinin hedef ilkellerini sınıflandırmak için gerekli olan tüm bilgileri taşımamasına rağmen daha önce kullanılan yöntemlerin bu belirleyici bilgiyi çözümleyemediğini göstermektedir. Önişleme yöntemleri arasından en iyi sonuç kesirli Fourier dönüşümü ile elde edilmektedir. Bu durumda %100 doğru hedef ayırdetme, hata toleransının değerine bağlı olarak %75–97 doğruluk oranıyla erim kestirimini ve %93–100 doğruluk oranıyla açı kestirimini elde edilmiştir. Hedef ayırdetmede şimdide kadar kullandığımız yaklaşımın bir karşılaştırması Tablo 2’de özetlenmiştir.

yöntem	ayırdedilen hedef türleri	başarım oranı	öğrenme	öncül bilgi	dağılma özelliği
hedef ayırdetme algoritması [1, 2]	D,K,DK	≤ %57	yok	var	var
kanıtsal akıl yürütme [9]	D,K,DK,{Kr,S,B}	%85	yok	yok	var
basit oylama [9] karmaşık oylama [9]	D,K,DK,{Kr,S,B}	%79 %91	yok yok	yok yok	var olmayabilir
yapay sinir ağları: diferansiyel girdi [3] GFD KFD ADD KÖÖH	D,K,DK,Kr,S	%95 %97 %100 %98 %78	var	yok	—
KÖÖH ve doğrusal sınıflandırıcı bulanık kümelendirme en yakın $k$ komşuluk genelleştirilmiş en yakın $k$ komşuluk parametrik yoğunluk kestirimini (heteroskedastik) parametrik yoğunluk kestirimini (homoskedastik) doğrusal ayırım analizi	D,K,DK,Kr,S	%85 %98 %98 %99 %81 %76 %71	var	yok	—

Tablo 2: Hedef ayırdetmede şimdide kadar kullandığımız yöntemlerin aynı veri seti üzerinden karşılaştırması. Kırık parantez içindeki hedef ilkelleri sadece grup olarak ayırdedilebilmektedir. D: düzlem, K: köşe, DK: dar açılı köşe, Kr: kenar, S: silindir, B: bilinmeyen.

## Kaynakça

- [1] B. Ayrulu ve B. Barshan. Identification of target primitives with multiple decision-making sonars using evidential reasoning. *Int. J. Robot. Res.*, 17(6):598–623, Haziran 1998.
- [2] B. Barshan ve R. Kuc. Differentiating sonar reflections from corners and planes by employing an intelligent sensor. *IEEE Trans. Pattern Anal. Machine Intell.*, 12(6):560–569, Haziran 1990.
- [3] B. Barshan, B. Ayrulu, ve S. W. Utete. Neural network based target differentiation using sonar for robotics applications. *IEEE Trans. Robot. Automat.*, 16(4):435–442, Ağustos 2000.
- [4] C. K. Chui. *An Introduction to Wavelets*. Academic Press, San Diego, CA, 1992.
- [5] S. Cohen. *Time-Frequency Analysis*. Prentice Hall, New Jersey, 1995.
- [6] S. Haykin. *Modern Filters*. MacMillan Publishing Company, New York, NY, 1989.
- [7] R. P. Lippman. An introduction to computing with neural nets. *IEEE ASSP Mag.*, s. 4–22, Nisan 1987.
- [8] H. M. Ozaktas, Z. Zalevsky, ve M. A. Kutay. *The Fractional Fourier Transform with Applications in Optics and Signal Processing*. John Wiley & Sons, New York, 2000.
- [9] S. W. Utete, B. Barshan, ve B. Ayrulu. Voting as validation in robot programming. *Int. J. Robot. Res.*, 18(4):401–413, Nisan 1999.