

Sonar Sinyallerinin Yapay Sinir Ağları ile İşlenmesine Dayalı Hedef Sınıflandırması *

Birsel Ayrulu ve Billur Barshan

Bilkent Üniversitesi, Elektrik-Elektronik Mühendisliği Bölümü, Bilkent, 06533, Ankara
ayrulu@ee.bilkent.edu.tr billur@ee.bilkent.edu.tr

Özetçe

Yapay sinir ağlarının kullanımı hareketli robot ortamlarında sıklıkla karşılaşılan ve hedef ilkel-leri olarak adlandırılan yüzeylerin tanınmasına ve konum kestirimine uygulandı. Akustik yankı verilerinden çıkarılan zaman-sıklık bilgisinden çok yüzeylerin tanınmasında ve konum kestiriminde yardımcı olan genlik ve uçuş süresi bilgileri kullanıldı. Ayrıca, sonar sinyalleri için dört ayrı uçuş süresi kestirim yöntemi, yanlılık, standart sapma ve karmaşıklık bakımından karşılaştırıldı.

1 Giriş

Hareketli robotlar bir çok uygulamada, içinde buldukları ortamın modeline gereksinim duyarlar. Kullandıkları modelin tamamını veya bir kısmını çoğunlukla birden fazla algılayıcı kullanarak elde ederler. Bu iş için, robotun düzlem (duvar), köşe, kenar ve silindir gibi sıklıkla karşılaşılan yüzeyleri ayırdedebilmesi gerekmektedir. Güvenilir bir sınıflandırma son derece önemli olup kullanılan yöntem ve algılayıcı türü ile yakından ilgilidir.

Akustik algılayıcılar kullanımı kolay, hafif, dayanıklı ve ucuz oldukları için hareketli robot uygulamalarında sıkça kullanılmaktadır [8]. Sinyal genliğinin çevresel koşullara karşı oldukça duyarlı olması ve mevcut sistemlerin çoğunlukla yankı genliğini doğrudan sağlayamamaları nedeniyle, en yaygın olarak kullanılan sonar erim düzenekleri bir dürtünün gönderimi ile alımı arasında geçen sürenin ölçümüne dayanmaktadır. Bu nedenle sonar erim düzeneklerinde doğru konum bilgisi için güvenilir bir uçuş süresi kestirimine gereksinim duyulur. Bu çalışma paralelinde, sonar sinyalleri için dört ayrı uçuş süresi kestirim yöntemi, yanlılık, standart sapma ve karmaşıklık bakımından karşılaştırılmıştır [4]. Bu yöntemler eşikleme, eğri yerleştirme, kayan pencere, ve uyumlu süzgeç yöntemleridir. Uyumlu süzgeç yöntemi eniyi ilinti sezim yöntemi olmasına rağmen diğer yöntemlerle karşılaştırıldığında işlem süresi ve karmaşıklığı daha fazladır. Ayrıca, hedeflerin daha iyi sınıflandırılması için hem genlik hem de uçuş süresi verilerini ya da sinyalin tamamını işleyen çok algılayıcı dürtü/yankı sistemlerinin kullanılması gerekmektedir.

Günümüzde, yapay sinir ağları örüntü sınıflandırıcı olarak yaygın kullanım alanına sahiptirler [9]. Örüntü sınıflandırıcıların temel amacı giriş verilerinin çıkışta var olan bir sınıfa eşlenmesidir. Yapay sinir ağlarının sonar sistemlerindeki kullanımının arkasında yatan en belirgin motivasyon ise, insan ve hayvanlarda bulunan çarpıcı algılama ve örüntü tanıma yeteneğidir. Örneğin, yunuslar ve yarasalar içinde buldukları çevreye ait ayrıntıları akustik yankı verilerinden çıkarabilme yeteneğine sahiptirler [10]. Bir çok çalışmada akustik yankı verilerinden çıkarılan zaman-sıklık bilgilerinin yapay sinir ağlarına öğretilmesi ile küre, koni, silindir gibi çeşitli hedefler sınıflandırılmaya çalışılmıştır [1, 6].

Bilkent Üniversitesi Robotbilim ve Algılama Laboratuvarı'nda yapmış olduğumuz çalışmada yapay sinir ağlarının kullanımını hareketli robot ortamlarında sıklıkla karşılaşılan ve hedef ilkelleri olarak adlandırılan yüzeylerin tanınmasına ve konum kestirimine taşıdık. Yapmış olduğumuz çalışmada, akustik yankı verilerinden elde edilen zaman-sıklık bilgisinden çok yüzeylerin tanınmasında ve konum kestiriminde yardımcı olan genlik ve uçuş süresi bilgilerini kullandık.


*Bu çalışma TÜBİTAK tarafından EEEAG-92, EEEAG-116, ve 197E051 sayılı projeler kapsamında desteklenmiştir.

2 Sonarla Algılama

En yaygın olarak kullanılan sonar erim düzenekleri bir dürtünün gönderimi ile alımı arasında geçen süre olarak tanımlanan uçuş süresi verilerine dayanmaktadır. Bu sistemlerde gönderilen dürtü bir cisim ile karşılaştığı zaman yankı üretilir ve yankı genliğinden uçuş süresi t_o kestirilerek bir erim değeri bulunur:

$$r = \frac{ct_o}{2} \quad (1)$$

Bu eşitlikteki c , sesin havadaki hızını göstermektedir.




Şekil 1: (a) Bir sesötesi dönüştürücünün duyarlılık bölgesi. (b) Yaklaşık olarak iki dönüştürücünün duyarlılık bölgesinin kesişiminden oluşan birleşik duyarlılık bölgesi.

Bu çalışmada, dairesel açıklığa sahip piston tipi dönüştürücülerin uzak alan modelleri kullanılmıştır [12]. Yankı genliği, dik gelişten sapma açısı olarak tanımlanan eğim açısı θ 'ya bağlı olarak azalmaktadır (Şekil 1(a)). Eğim açısı θ_o 'dan büyük olduğu zaman yankı genliği eşik değerinin altına düşmektedir. Buradaki θ_o ile dönüştürücünün açıklık yarıçapı (a) ve çınlama sıklığı (f_o) arasındaki ilişki aşağıda verilmiştir:

$$\theta_o = \sin^{-1} \left(\frac{0.61c}{af_o} \right) \quad (2)$$

Bir tek algılayıcı ile hedefin bulunduğu açısal konumu sonarın açısal çözünürlüğü olan $2\theta_o$ 'dan daha iyi kestirmek mümkün değildir. Bu nedenle, bu çalışmada açısal çözünürlüğü artırmak için aralarında d kadar uzaklık bulunan aynı özelliklere sahip iki dönüştürücü kullanılmıştır (Şekil 1(b)). Her bir dönüştürücü hem göndermeç hem de almaç olarak çalışabilmektedir. Tek bir sesötesi dönüştürücünün ve bu çalışmada kullanılan dönüştürücü çiftinin duyarlılık bölgesi Şekil 1'de sırasıyla gösterilmiştir.



Şekil 2: Bu çalışmada modellenip sınıflandırılan hedeflerin yatay kesitleri.

Bu çalışmada modellenen hedeflerin yatay kesitleri Şekil 2'de gösterilmiştir. Kullanılan akustik dalga boyu ($f_o = 40.0$ kHz'de $\lambda \cong 8.6$ mm) laboratuvar ortamında karşılaşılan herhangi bir cisim yüzeyindeki girinti çıkıntılardan çok daha büyük olduğu için, bu tür nesnelere akustik dalgaları ayna gibi

yansıtırlar. Böylece, hem göndermeç hem de almaç olarak kullanılan dönüştürücüler ayrı göndermeç T ve hayali almaç R gibi incelenebilir [7].

Bu hedeflerin fiziksel yansıma modelleri ve bunlara bağlı yankı sinyal modelleri [2]'de ayrıntılı olarak verilmiştir.

3 Sonar Sinyalleri için Uçuş Süresi Kestirimi

Bu çalışmada dört ayrı uçuş süresi kestirim yöntemi, yanlılık, standart sapma ve karmaşıklık bakımından karşılaştırılmıştır.

Uygulamaya geçirilmesi çok kolay olan ve sonar erim düzeneklerinde sıklıkla kullanılan eşikleme yönteminde, uçuş süresi yankı genliğinin önceden belirlenen eşik değerini ilk geçtiği an olarak alınır. Bu nedenle, elde edilen uçuş süresi her zaman sinyalin başlangıcı olarak tanımlanan gerçek değerinden daha büyüktür.

Uçuş süresi kestiriminde pratikte kullanılan diğer bir yöntem eğri uyarlama yöntemidir. Sinyal başlangıcına doğrusal olmayan dürümsel en küçük karekök yöntemi kullanılarak bir parabol uyarlanır ve bu parabolun tepe noktası uçuş süresi olarak alınır. Bu süre genellikle eşikleme yöntemi ile elde edilen süreden daha küçüktür [5].

Üçüncü bir uçuş süresi kestirim yöntemi olarak, daha önce sonar sinyalleri için kullanılmamış olan kayan pencere yöntemi incelendi. Bu yöntem, radar sinyalleri için uygulanan $N - m$ çift eşikleme sezim yönteminden esinlenerek kullanılmıştır. N uzunluğunda bir pencere sinyal boyunca birer örnek kaydırılır ve her bir pencere konumunda önceden belirlenen eşik değerini geçen örnekler sayılır. Eğer bu sayı ikinci bir eşik değeri olan m 'i geçiyorsa, hedefin sezildiği varsayılır ve sinyalin uçuş süresi kestirilir. Bu yöntemle, uçuş süresi kestirimi (i) pencere içerisinde eşik değerini geçen ilk örnek (ii) pencerenin ortasında bulunan örnek ve (iii) pencerenin $(N - m)$ 'inci örneği olarak alınan üç değişik şekilde ele alındı. Ayrıca, kayan pencere yönteminin başarımı, pencere uzunluğu N , ikinci eşik değeri m , ve pencere içinde hangi örneğin uçuş süresi olarak alındığına göre değişmektedir.

Son olarak uçuş süresi kestirimi için sinyal-gürültü oranını (SGO) enbüyüten ve yanlılığı olmayan klasik eniyi ilinti sezim yöntemi olan uyumlu süzgeç yöntemi kullanıldı.

Benzetim çalışmalarında kullanılan ve değişik hedef türleri ve konumlarından elde edilen sinyalleri temsil eden bir sinyal modeli aşağıda verilmiştir:

$$s_{r,\theta}(t) = k(r) e^{-\frac{\theta^2}{2\sigma_\theta^2}} e^{-\frac{(t-t_0-\frac{18}{f_0})^2}{\sigma_t^2}} \sin[2\pi f_0(t-t_0)] \quad (3)$$

İlk olarak, kayan pencere yöntemi için uygun olan N ve m değerlerini bulmak amacıyla değişik erim ve eğim açısı değerleri için $5 \leq N \leq 50$ ve $1 \leq m \leq N$ değerleri arasında değişen N ve m değerleri denendi. $N = 40$ ve $m = N/4$ değerlerinin birçok durum için en küçük yanlılık değerini verdiği görüldü ve çalışma boyunca bu değerler kullanıldı.

Benzetim çalışmalarında $r = 0.3, 0.5, 0.7, 1.0$ m, $\theta = 0^\circ, \pm 10^\circ, \pm 20^\circ$, $f_0 = 40$ kHz, $c = 343.5$ m/s, $\sigma_\theta = 27^\circ$, ve $\sigma_t = 3 \times 10^{-4}$ s değerleri kullanıldı. Yanlılık ve standart sapma kestirimi için, sinyal modeline ortalama değeri sıfır olan Gauss-dağılımlı gürültü eklenerek 100 ayrı gerçekleştirim oluşturuldu. Yukarıdaki eşitlikte verilen işlenmemiş zaman sinyali (İ) ve bu sinyalin zarfı (Z) için $r = 0.5$ m, $\theta = 0^\circ$ ve SGO = 20 dB değerlerinde elde edilen yanlılık ve standart sapma değerleri Tablo 1'de gösterilmiştir.

İlk üç yöntemde, sinyal zarfı işlendiği zaman en küçük yanlılık eğri uyarlama yöntemi ile elde edildi. Fakat, bu yöntemdeki standart sapma en büyük çıktı. Tahmin edildiği gibi, sinyal başlangıcındaki dalgalanmalardan dolayı bu yöntemin yanlılık başarımı işlenmemiş sinyal kullanıldığı zaman düşmektedir. Standart sapma açısından bakıldığı zaman, kayan pencere yöntemi her zaman eşikleme ve eğri uyarlama yöntemlerinden daha iyi sonuç vermektedir. Ele alınan yöntemlerin uygulamaya geçirilmelerindeki karmaşıklık sırası ise küçükten büyüğe doğru: eşikleme, kayan pencere, eğri uyarlama, ve uyumlu süzgeç yöntemidir.

DeneySEL çalışmalarda, $r = 0.5$ m ve $\theta = 0^\circ$ 'ye yerleştirilen düzlemsel hedeften, $f_0 = 40$ kHz'lik bir dönüştürücü ile alınan 100 ayrı sinyal kullanıldı. Bu sinyaller üzerinden yapılan yanlılık ve standart sapma kestirimleri dört yöntem için Tablo 1'de verilmiştir. Tablo 1'e bakılarak benzetimsel ve deneysel sonuçların birbirleriyle uyum içinde oldukları görülebilir.

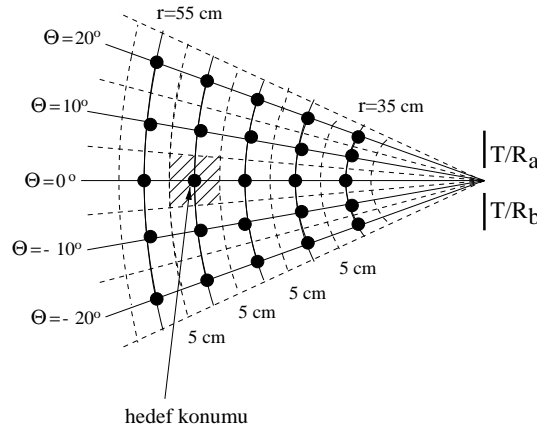
Yöntem		Benzetim		Deney	
		Yanlılık (s)	$\sigma_{\hat{t}_o}$ (s)	Yanlılık (s)	$\sigma_{\hat{t}_o}$ (s)
EŞM	İ	1.81×10^{-4}	3.07×10^{-5}	1.82×10^{-4}	2.49×10^{-5}
	Z	1.41×10^{-4}	2.77×10^{-5}	1.41×10^{-4}	2.40×10^{-5}
KP (i)	İ	1.70×10^{-4}	1.59×10^{-5}	1.67×10^{-4}	1.73×10^{-5}
	Z	1.57×10^{-4}	1.84×10^{-5}	1.54×10^{-4}	1.74×10^{-5}
KP (ii)	İ	1.71×10^{-4}	1.59×10^{-5}	1.69×10^{-4}	1.73×10^{-5}
	Z	1.65×10^{-4}	2.22×10^{-5}	1.60×10^{-4}	2.04×10^{-5}
KP (iii)	İ	2.09×10^{-4}	1.59×10^{-5}	2.07×10^{-4}	1.73×10^{-5}
	Z	1.97×10^{-4}	1.84×10^{-5}	1.94×10^{-4}	1.74×10^{-5}
EU	İ	2.14×10^{-4}	1.49×10^{-4}	2.02×10^{-4}	1.53×10^{-4}
	Z	1.34×10^{-4}	2.98×10^{-5}	1.34×10^{-4}	2.50×10^{-5}
USY	İ	9.04×10^{-7}	2.62×10^{-18}	1.19×10^{-5}	1.71×10^{-5}
	Z	2.36×10^{-6}	2.62×10^{-6}	4.96×10^{-6}	1.37×10^{-6}

EŞM: eşikleme, KP: kayan pencere, EU: eğri uyarlama, USY: uyumlu süzgeç yöntemi, İ: işlenmemiş, Z: zarf

Tablo 1: $r = 0.5$ m, $\theta = 0^\circ$ ve SGO = 20 dB için benzetimsel ve deneysel sonuçlar.

4 Yapay Sinir Ağları ile Hedef Sınıflandırma

Yapmış olduğumuz çalışmada, herbiri yüksekliği 1.2 m olan düzlem, köşe, kenar, 60° 'lik dar açılı köşe ve 2.5, 5.0 ve 7.5 cm yarıçaplı üç adet silindir kullanıldı. Bu yüzeylerin her biri Şekil 3'te gösterilen 25 ayrıık konuma yerleştirilerek bir sonar algılayıcı tarafından -52° 'den 52° 'lik tarama açısına kadar 1.8° 'lik adımlarla tarandı. Tarama açısı hedef konumundan bağımsız olarak $\theta = 0^\circ$ 'ye göre ölçülmektedir. Bu tarama esnasında alınan genlik ve uçuş süresi verileri üç katmanlı bir yapay sinir ağına geri-iletmişim (back-propagation) algoritması kullanılarak öğretildi. Yapay sinir ağlarının uygulamaya geçirilmeleri oldukça karmaşık olduğu için burada uçuş süresi kestirimi için en hızlı yöntem olan eşikleme yöntemi kullanıldı. Yapay sinir ağının çıktısı, hedef türü ve hedefin algılayıcıdan uzaklığı ve eğim açısı olarak alınmaktadır. Daha sonra, aynı şekilde alınan farklı veri kümesi ile bu yapay sinir ağı denendi ve % 95 doğru sınıflandırma başarımı elde edildi. Bunun yanında, % 74 doğru erim ve % 89 doğru eğim açısı kestirim başarımları sağlanmıştır (Tablo 2).



Şekil 3: Ayrıık hedef konumları.

Ayrıca, bu hedeflerin sınıflandırılması ve algılayıcıya göre konumlarının kestirilmesi için daha fazla genelleme kapasitesine ve öğrenme hızına sahip olduğu bilinen modüler yapay sinir ağları kullanıldı ve % 96 doğru sınıflandırma elde edildi. Doğru erim ve doğru eğim açısı kestirim başarımları ise sırasıyla % 77 ve % 90'dır (Tablo 3).

hedef türü	doğru sınıf. (%)	doğru erim kestirimi (%)				doğru eğim açısı kestirimi (%)			
		hata toleransı ϵ_r				hata toleransı ϵ_θ			
		± 0.125 cm	± 1 cm	± 5 cm	± 10 cm	$\pm 0.25^\circ$	$\pm 2^\circ$	$\pm 10^\circ$	$\pm 20^\circ$
düzlem	% 100	% 62	% 66	% 78	% 88	% 91	% 96	% 98	% 99
köşe	% 99	% 90	% 90	% 92	% 95	% 88	% 90	% 92	% 93
kenar ($\theta_e = 90^\circ$)	% 99	% 51	% 59	% 82	% 92	% 72	% 77	% 89	% 97
dar açılı köşe ($\theta_c = 60^\circ$)	% 98	% 81	% 83	% 91	% 95	% 85	% 87	% 93	% 97
silindir ($r_c = 2.5$ cm)	% 90	% 77	% 80	% 89	% 94	% 97	% 97	% 97	% 98
silindir ($r_c = 5.0$ cm)	% 89	% 75	% 77	% 82	% 89	% 98	% 98	% 99	% 99
silindir ($r_c = 7.5$ cm)	% 92	% 82	% 86	% 92	% 98	% 95	% 97	% 99	% 99
ortalama	% 95	% 74	% 77	% 87	% 93	% 89	% 92	% 95	% 97

Tablo 2: Hedef türlerine göre doğru sınıflandırma ve doğru erim ve eğim açısı kestirim yüzdeleri.

hedef türü	doğru sınıf. (%)	doğru erim kestirimi (%)				doğru eğim açısı kestirimi (%)			
		hata toleransı ϵ_r				hata toleransı ϵ_θ			
		± 0.125 cm	± 1 cm	± 5 cm	± 10 cm	$\pm 0.25^\circ$	$\pm 2^\circ$	$\pm 10^\circ$	$\pm 20^\circ$
düzlem	% 99	% 85	% 88	% 93	% 98	% 94	% 97	% 99	% 99
köşe	% 99	% 90	% 93	% 95	% 99	% 94	% 94	% 95	% 97
kenar ($\theta_e = 90^\circ$)	% 99	% 55	% 59	% 79	% 91	% 73	% 76	% 90	% 96
dar açılı köşe ($\theta_c = 60^\circ$)	% 97	% 83	% 83	% 89	% 93	% 85	% 88	% 91	% 97
silindir ($r_c = 2.5$ cm)	% 94	% 78	% 82	% 92	% 99	% 97	% 97	% 97	% 98
silindir ($r_c = 5.0$ cm)	% 95	% 75	% 81	% 87	% 94	% 97	% 97	% 99	% 99
silindir ($r_c = 7.5$ cm)	% 89	% 75	% 83	% 90	% 96	% 93	% 97	% 98	% 99
ortalama	% 96	% 77	% 81	% 89	% 96	% 90	% 95	% 96	% 98

Tablo 3: Hedef türlerine göre doğru sınıflandırma ve doğru erim ve eğim açısı kestirim yüzdeleri.

5 Karşılaştırmalı Analiz

Daha önce yazarlar tarafından genlik ve uçuş süresi verilerine dayanan bir hedef sınıflandırma algoritması geliştirilmiştir [3]. Bu algoritma beş ayrı hedef ilkelini (düzlem, köşe, kenar, silindir, dar açılı köşe) kuramsal olarak sınıflandırabilmesine rağmen, sinyaller üzerindeki gürültüden dolayı pratikte ancak üç tanesi (düzlem, köşe ve dar açılı köşe) % 61’lik doğruluk yüzdesi ile sınıflandırılabilir. Ayrıca, sınıflandırma işlemindeki başarımlarını yükseltmek için Dempster-Shafer kanıtsal akıl yürütme ve basit oylama yöntemleri ile çoklu sonarlardan alınan kararlar tümleştirilmiştir [11]. Söz konusu çalışmada, bu algoritmaya bağlı olarak her bir algılayıcı düzlem, köşe ve dar açılı köşeye Dempster-Shafer kanıtsal akıl yürütme kuramına göre olabirlik kütlesi atamaktadır. Daha sonra, 15 ayrı algılayıcının görüşleri Dempster tümleşim kuralına göre birleştirilerek bu oran % 87’ye ulaşmıştır. Aynı sistemde, algılayıcı görüşlerinin basit oylama yöntemi ile tümleştirilmesinden elde edilen sonuç ise % 88’dir. Ayrıca, basit oylama yönteminde değişik sıralama stratejilerinin kullanımı ile bu oran % 90’a çıkmıştır [11].

Bu çalışmada ise yapay sinir ağlarıyla, dört duyucudan oluşan bir algılayıcı düzeneği kullanılarak yedi ayrı hedef ilkelinin sınıflandırılması ve konum kestirimi oldukça yüksek bir yüzdeyle gerçekleştirilmiştir (% 95 ve % 96). Yapay sinir ağları ile elde edilen başarımlar, sonar sinyallerinin bu yedi ayrı hedef ilkelini sınıflandırmak için gerekli olan tüm bilgileri taşımasına rağmen daha önce kullanılan yöntemlerin bu belirleyici bilgiyi çözümleyemediğini göstermektedir.

6 Sonuç

Bu çalışmada, belli başlı hedef ilkeleri akustik yankı verilerinden elde edilen genlik ve uçuş süresi bilgisinin yapay sinir ağları ile işlenmesi sonucu yüksek başarımla ayırdedildi. Ayrıca, sonar sinyalleri için dört ayrı uçuş süresi kestirim yöntemi, yanlılık, standart sapma ve karmaşıklık bakımından karşılaştırıldı.

Elde edilen sonuçlar, yapay sinir ağlarının dayanıklı örüntü sınıflayıcı olarak algılayıcı-tabanlı robot-bilimde, özellikle sonar sinyallerine dayalı hedef sınıflandırılması ve konum kestiriminde, daha geniş kullanım alanlarına sahip olacağını göstermektedir.

İleriki çalışmalarda, denetçisiz öğrenme algoritmalarının kullanımı ile sınıflandırma işleminin çevresel koşullardaki değişikliklere karşı duyarlılığının azaltılmasına çalışılıp geliştirilen sınıflandırma algoritmaları hareketli robotların buldukları ortamların modellenmesinde ve harita çıkarımında kullanılacaktır.

Kaynakça

- [1] Au W. W. L., Andersen L. N., Rasmussen A. R., Roitblat H. L., ve Nachtigall P. E., “Neural network modeling of a dolphin’s sonar discrimination capabilities,” *The Journal of the Acoustical Society of America*, cilt. 98, s. 43–50, 1995.
- [2] Ayrulu B., *Classification of target primitives with sonar using two non-parametric data fusion methods*. Yüksek Lisans Tezi, Elektrik Mühendisliği Bölümü, Bilkent Üniversitesi, Ankara, Temmuz 1996.
- [3] Ayrulu B. ve Barshan B., “Identification of target primitives with multiple decision-making sonars using evidential reasoning,” *The International Journal of Robotics Research*, cilt. 17, s. 598–623, Haziran 1998.
- [4] Barshan B. ve Ayrulu B., “Performance comparison of four methods of time-of-flight estimation for sonar waveforms,” *Electronics Letters*, cilt. 34, s. 1616–1617, 6 Ağustos 1998.
- [5] Barshan B. ve Kuc R., “A bat-like sonar system for obstacle localization,” *IEEE Transactions on Systems, Man and Cybernetics*, cilt. 22, s. 636–646, Temmuz/Ağustos 1992.
- [6] Gorman R. P. ve Sejnowski T. J., “Learned classification of sonar targets using a massively parallel network,” *IEEE Transactions on Acoustic, Speech and Signal Processing*, cilt. 36, s. 1135–1140, Temmuz 1988.
- [7] Kuc R. ve Siegel M. W., “Physically-based simulation model for acoustic sensor robot navigation,” *IEEE Transactions on Pattern Analysis and Machine Intelligence*, cilt. PAMI-9, s. 766–778, Kasım 1987.
- [8] Leonard J. J. ve Durrant-Whyte H. F., “Mobile robot localization by tracking geometric beacons,” *IEEE Transactions on Robotics and Automation*, cilt. 7, s. 376–382, 1991.
- [9] Lippman R. P., “An introduction to computing with neural nets,” *IEEE ASSP Magazine*, s. 4–22, Nisan 1987.
- [10] Moore P. W. B., Roitblat H. L., Penner R. H., ve Nachtigall P. E., “Recognizing successive dolphin echoes with an integrator gateway network,” *Neural Networks*, cilt. 4, s. 701–709, 1991.
- [11] Utete S. W., Barshan B., ve Ayrulu B., “Voting as validation in robot programming,” *The International Journal of Robotics Research*, cilt. 18, sayı 4, s. 401–413, Nisan 1999.
- [12] Zemanek J., “Beam behaviour within the nearfield of a vibrating piston,” *The Journal of the Acoustical Society of America*, cilt. 49, s. 181–191, Ocak 1971.