

# Kızılberisi Algılayıcılarla Yapay Sinir Ağlarına Dayalı Hedef Ayırdetme

Tayfun Aytaç ve Billur Barshan

Elektrik ve Elektronik Mühendisliği Bölümü  
Bilkent Üniversitesi, 06800, Bilkent, Ankara  
{taytac, billur}@ee.bilkent.edu.tr

## Özetçe

Düşük maliyetli kızılberisi algılayıcılardan elde edilen açısız yeğnlik sinyalleri kullanarak iç mekanlarda sıkça karşılaşılan hedeflerin geometrik ve yüzey özelliklerini yapay sinir ağlarıyla belirleyen bir yöntem ileri sürüyoruz. Yöntem deneysel olarak alüminyum, beyaz kumaş ve beyaz köpükten ambalaj malzemesiyle kaplı düzlem, 90° köşe ve 90° kenar hedefleriyle doğrulanmıştır. Tüm hedefler için geometri ve yüzey özellikleri ortalama %78 doğru ayırdedilmiştir. Aynı olarak düşündüğümüzde, hedeflerin geometrileri ve yüzey tipleri %99 ve %78 oranlarıyla doğru ayırdedilmişlerdir. Bu durum hedeflerin geometrik özelliklerinin yüzey özelliklerine göre daha baskın olduğunu ve yüzey tipinin sınırlayıcı etken olduğunu göstermektedir. Uygulanan yöntem, basit kızılberisi algılayıcıların, uygun sinyal işlemeyle, bilinen uygulamalarının aksine daha fazla bilgi çıkarımında kullanılabileceğini göstermektedir.

## 1. Giriş

Hedef ayırdetme ve konumlandırma hedeflerin tanınmasının ve ayırdedilmesinin gerektiği akıllı sistemlerde oldukça önemlidir. Ayırdetme ayrıca farklı maddelerin ayırdedilmesinin gerektiği endüstriyel uygulamalarda da önemlidir. Bu çalışmada, ayırdetme ve konumlandırma için bir alıcı ve vericiden oluşan basit bir kızılberisi algılayıcı sistemi kullanıyoruz. Bu algılayıcılar ucuz, kullanımı ve erişimi kolay aygıtlardır. Fakat, yeğnlik sinyalleri yansıtıcı hedefin geometrisine ve yüzey özelliklerine bağlı olduğundan, basit yeğnlik ölçümleri kullanılarak güvenilir erim kestiriminde bulunmak mümkün değildir. Aynı zamanda, hedeflerin özellikleri, hedefin erimi ve açısız konumu bilinmeden basit yeğnlik ölçümlerinden çıkarılamamaktadır. Bu bildiride, hedeflerin geometrik ve yüzey özelliklerini, açısız yeğnlik taramalarını kullanarak yapay sinir ağlarıyla bulan bir yöntem ileri sürüyoruz.

Kızılberisi algılayıcılar robotbilim ve otomasyonda, süreç kontrolünde, uzaktan algılamada ve güvenlik uygulamalarında kullanılmaktadır. Özellikle, bu tip algılayıcılar, yakın hedeflerin saptanmasında, sayma işleminde, erim ve derinlik gözetiminde, zemin algılamada, konum kontrolünde ve engel saptamada kullanılmaktadır. Kızılberisi algılayıcılar gezgin robot yöngüdümünde kapı aralıklarında kenarların yerinin belirlenmesinde [1], bina ve araçlarda kapı ve pencere gözetiminde kullanılmaktadır. [2]'de bilinen bir uzaklıkta konumlanmış düzlemsel hedeflerin yüzey özellikleri Phong

aydınlatma modeli kullanılarak belirlenmiş, böylece kızılberisi algılayıcılar yakın mesafeler için erim ölçer olarak kullanılmıştır. Kızılberisi algılayıcıların kullanımına ilişkin detaylı kaynaklar [3]'ün giriş kısmında verilmiştir. [4]'de, farklı geometrik özelliklere ama benzer yüzey özelliklerine sahip (tahta) hedefler referans sinyallerine dayalı olarak ayırdedilmiştir. [5]'de ise, aynı düzlem geometriye fakat farklı yüzey özelliklerine sahip hedefler benzer yöntemle ayırdedilmiştir. Bu bildiride, [3]'de anlatılan referans sinyallerine dayalı ayırdetme yöntemine alternatif olarak yapay sinir ağları hedef ayırdetmede kullanılmıştır.


## 2. Yapay Sinir Ağları

Yapay sinir ağları hedef ayırdetme ve sınıflandırmada [6], konuşma işlemede [7], sistem tanımada [8], kontrol teorisinde [9], medikal uygulamalarda [10] ve karakter tanımada [11] çokca kullanılmaktadır. Bu çalışmada, yapay sinir ağları, farklı yüzey özelliklerine sahip hedeflerden elde edilen kızılberisi yeğnlik taramalarında gömülü olan parametre ilişkilerini tanımlamada ve çözümlemede kullanılmıştır. İki adımda bu gerçekleştirilmektedir: İlk önce hedef geometrisi, sonrasında ise yüzey türü belirlenmektedir.


Yapay sinir ağları daha fazla anlamlı öznitelik çıkarmak için, farklı sayıda nöronlardan oluşan giriş katmanı, bir ya da daha çok saklı katmandan oluşmaktadır. Her nöron modeli sürekli ve doğrusal olmayan etkinleştirme fonksiyonuna sahiptir. Yapay sinir ağlarının teorik olarak analizi dağınık, doğrusal olmama durumundan ve yüksek dereceden bağlantılılıktan dolayı zordur. Eğitim algoritmaları, bağlantı ağırlıkları ve yanlılık değerlerini kullanarak karar verme bölgelerinin sınırlarını belirlemede kullanılmaktadır. Yapay sinir ağlarının başarımı ağ yapısına, parametre seçimine, öğrenme algoritmalarına, giriş sinyallerine ve parametre ilklendirmesine bağlıdır.

### 2.1. Yapay Sinir Ağ Parametreleri ve Yapısı

Çalışmada kullanılan yapay sinir ağı, giriş, saklı ve çıkış katmanından oluşmaktadır. Katmanlar sırasıyla 160, 10 ve 3 nörondan oluşmaktadır. Hem giriş hem de saklı katmandaki nöronların sayısı 1 yanlılık değerini içermektedir. Yapay sinir ağ yapısı Şekil 1'de verilmiştir. Tüm nöronlar için etkinleştirme fonksiyonu Şekil 2'de verildiği gibi teğet hiperbol ( $\varphi(v) = (1 - e^{-2v}) / (1 + e^{-2v})$ ) seçilmiştir. Çıkış katmanındaki nöronlar -1



Şekil 1: Kullanılan yapay sinir ağı yapısı.




Şekil 2: Etkinleştirme fonksiyonu olarak kullanılan teğet hiperbol fonksiyonu.

ile 1 arasında sürekli değerler almaktadır ve çıkış katmanında kararlar kazanan hepsini alır yaklaşımına göre alınmaktadır.

Ağ karmaşıklığı ve doğru ayırtma oranına göre, en iyi ağ yapısının belirlenmesi önemlidir. Kızılberisi yeğlilik taramaları ağ karmaşıklığını azaltmak için her 10 örnekten biri alınarak örneklendirilmiştir (giriş ve saklı katman arasındaki bağlantı ağırlıklarını azaltmak için). Örnekleme oranı örüntüler şeklini koruyacak şekilde ve ayırtıcı bilgi kaybolmayacak şekilde seçilmiştir. Daha az örnek alma ayırtma oranında bir iyileştirmeye neden olmamaktadır.

Geri yayılım (GY) ve Levenberg-Marquardt (LM) olmak üzere iki farklı eğitim yöntemiyle ağırlar eğitildi. GY yöntemiyle istenen sinyal ile çıkıştaki sinyal arasındaki hata bayer inişi yordamına göre enküçültülmektedir. İki ayarlama parametresi olan öğrenme oranı ve devinirlik sabiti [12] sırasıyla 0.01 ve 0.9 olarak seçilmiştir.

GY ile eğitilen yapay sinir ağlarının eğitim seti üzerindeki sonuçları iyi sonuç vermediğinden, yapay sinir ağlarının eğitimi, GY'ye göre daha kısa sürede yakınsadığından ve daha gürbüz olduğundan, LM yöntemiyle gerçekleştirilmiştir. LM yönteminde düzenleme için ağırlık azalma çarpanı kullanılmıştır. Bu algoritmanın bir dezavantajı yüksek bellek gereksinimidir, fakat bizim küçük eğitim seti için bu sorun değildir. Yöntemde, deste modunda, tüm ağ parametrele-



(a)



(b)

Şekil 3: (a) Kızılberisi algılayıcı ve (b) deney düzeneği.


ri bütün giriş verileri işlendikten sonra güncellenmektedir. Ağırlık azalma çarpanı olarak  $10^{-4}$  seçilmiştir. Bu çarpan değerini oldukça ufak seçerek genelleştirme hatasını azaltmak mümkündür. Eğer bu çarpan çok ufak seçilirse ( $<10^{-4}$ ), istenen doğruluğa ulaşmak daha uzun sürecektir. Diğer taraftan, daha büyük çarpan değerleri için, yapay sinir ağı istenen doğruluğa yakınsamayabilir. LM yönteminde öğrenme oranı uyarlamalı olarak değişmektedir, bu yüzden öğrenme oranının ilk değeri sadece ağı yakınsama hızını değiştirmektedir.

Yapay sinir ağlarının yakınsaması için ortalama karesel ölçütü kullanıldı ve kabul edilebilir hata seviyesi  $10^{-3}$  olarak alındı. Öğrenme süreci ya hata ölçütü sağlandığında ya da döngü sayısına (100,000) ulaştığında bitirilmektedir. İkinci durum oldukça seyrek olmaktadır.

Yapay sinir ağları eğitildikten sonra *budama* adı verilen yöntemle ağ en küçük sayıda ağırlıklara sahip olacak şekilde eğitilmektedir. Budama için *Optimal Brain Surgery* (OBS) tekniği [13] kullanılmıştır. Ağırlıkların %5'i budandığında, en büyük döngü sayısı 50 olacak şekilde ağ tekrar eğitilmektedir. (Tekrar eğitilme bir tane ağırlığın budanmasıyla da yapılabilir ama bu daha uzun sürmektedir.) Her yeni öğrenmede, Yapay sinir ağları test taramalarıyla test edilmektedir ve ilgili hata ve ağırlıklar kaydedilmektedir. En küçük test hatasıyla sonuçlanan budanmış yapay sinir ağı en iyi ağ olarak seçilmektedir ve ağ ağırlık azalma çarpansız en küçük hataya neden olan ağırlıklarla, tekrardan eğitilmektedir. LM ve OBS uygulamasında, yapay sinir ağ tabanlı sistem tanıma programı kullanılmıştır [14].

## 2.2. Geometri Tiplerinin Yapay Sinir Ağıyla ile Belirlenmesi

Çalışmada kullanılan kızılberisi algılayıcı [15] [Şekil 3(a)] bir alıcı-verici çiftinden oluşmakta ve hedeften yansıyan sinyalin yeğliliğiyle orantılı analog gerilim çıkışı sağlamaktadır. Alıcı penceresi ortam aydınlatmasının yeğlilik ölçümle-



Şekil 4: Deney düzeneğinin üstten görünüşü. Tarama açısı  $\alpha$  ve konum açısı  $\theta$  yatay ekseninden saatın dönme yönünün tersi yönünde ölçülmektedir.

rine olan etkisini en aza indirmek için kızılberisi süzgeç ile kaplıdır.

Kullanılan hedefler 120 cm uzunluğunda düzlem, 90° köşe ve 90° kenardır. Bu hedefler alüminyum, beyaz kumaş ve beyaz köpükten ambalaj malzemesiyle kaplanmıştır. Yöntemimiz, her hedefin belli bir açı aralığında taranmasına bağlıdır. Kızılberisi algılayıcı 15,2 cm yarıçapında döner bir platform [16] üzerine yerleştirilmiş ve hedeflerden açısal yeğinlik taramaları elde edilmiştir. Deney düzeneğinin fotoğrafı ve çizimi sırasıyla Şekil 3(b) ve 4'de verilmiştir. Referans yeğinlik taramaları her geometri-yüzey kombinasyonu için 2.5 cm aralıklarla, en yakın gözlenebilir uzaklıktan en büyük gözlenebilir uzaklığında  $\theta = 0^\circ$ 'de yerleştirilerek elde edilmiştir. Elde edilen yeğinlik taramaları Şekil 5'de verilmiştir. Bu yeğinlik taramaları orjinal taramalardır, yapay sinir ağlarına girdi olarak kullanılan taramalar bunların örneklenmiş halidir. Eğitim seti 60 düzlem, 49 köşe ve 38 kenar hedef olmak üzere 147 referans taramasından oluşmaktadır. Her hedef türü için hedef sayısı birbirinden farklıdır. Bunun nedeni her hedefin farklı yansıtıcı özelliklerine sahip olması ve geometri ve yüzey özelliklerinin belirlediği farklı erim aralıklarında gözlenebilir olmasıdır.

Eğitim LM algoritmasıyla gerçekleştirildi. Giriş ağırlıkları rasgele ilklendirildi. Eğitim ve test setinde en yüksek ayırtma oranına sahip yapay sinir ağı 10 saklı katman nöronuna sahiptir. Burada OBS henüz ağı budamak için kullanılmamıştır.

Yapay sinir ağı, hedefleri farklı erim  $r$  ve açılarda  $\theta$  yerleştirilerek elde edilen kızılberisi yeğinlik taramalarıyla test edildi. 82'si düzlem, 64'ü köşe ve 48'i kenar olmak üzere toplam 194 test taraması elde edildi. Hedefler  $-45^\circ$ 'den  $45^\circ$ 'ye en yakın gözlenebilir aralıktan en uzak gözlenebilir aralığa kadar rasgele yerleştirildi. (Dikkat edilmesi gereken diğer hususta, eğitim seti eşit aralıklarla  $\theta = 0^\circ$ 'de toplanmıştır, test taramaları ise rasgele pozisyonlarda ve açısal konumlarda elde edilmiştir.)

Test taraması elde edildiğinde, hedefin açısal konumu ağırlık merkezi ya da en büyük yeğinlik değeri kullanılarak elde edilebilir. Test taramaları açısal konum kestirimi kadar kaydırılmakta, 1'e 10 oranında örneklenmekte ve elde edilen tarama girdi olarak yapay sinir ağına sunulmaktadır. Ağırlık merkezi durumu için ayırtma sonuçları Tablo 1'de parantez içinde verilmiştir. Toplamda %94.3 ayırtma oranı elde edilmiştir. Köşe hedefleri taramaların ayırdedici özelliğinden

Tablo 1: Geometri ayırtma dizeyi: açısal konumu ağırlık merkezine göre kestirildi. Sonuçlar OBS sonrası (öncesi) parantez dışı (içi) (D: Düzlem, KÖ: köşe, K: kenar).

| hedef  | ayırtma sonuçları |        |        | toplam   |
|--------|-------------------|--------|--------|----------|
|        | D                 | KÖ     | K      |          |
| D      | 80(76)            | –      | 2(6)   | 82(82)   |
| KÖ     | –                 | 64(64) | –      | 64(64)   |
| K      | (5)               | –      | 48(43) | 48(48)   |
| toplam | 80(81)            | 64(64) | 50(49) | 194(194) |


dolayı doğru olarak ayırdedilmişlerdir. Düzlemler 82 durum içerisinde 6 kez kenar hedefleriyle karıştırılmıştır, kenar hedefleri ise 48 durumda 5 kez düzlemlerle karıştırılmıştır. Alternatif olarak hedeflerin açısal konumu doyuma ulaşmamış taramalar için en büyük yeğinlik değeri bulunarak hesaplanmıştır. Bu durumda %96.4 doğru ayırtma oranı elde edildi. Ağırlık merkezi durumuna göre daha iyi olmasının nedeni kenar hedeflerinin doğru ayırdedilmesidir. 7 düzlemsel test taramaları dışında, tüm yüzeyler doğru olarak ayırdedilmişlerdir. 7 yanlış ayırdedilen düzlemsel test hedeflerinden 6 tanesi doyuma ulaşmış alüminyum kaplı yüzeylerdir.

Bir sonraki adımda, yapay sinir ağı OBS tekniğiyle budanmaktadır. Eğitim ve test hatalarının, ağ budandıktan sonra ağırlıkların sayısına göre çizimi Şekil 6'da verilmiştir. Bu şekilde, hatalar sağdan sola doğru ilerlemektedir. En küçük hata 263 tane ağırlık kullanıldığında elde edilmektedir. Elenen ağırlıklar sıfır değerini almaktadır. Ağırlıkların sayısı 263'ten öteye azaldığında, eğitim ve test hataları çok fazla ağırlığın elenmesinden dolayı hızlıca artmaktadır. 263 tane ağırlık tutulduğunda, saklı katman nöronları hala 10 olmaktadır.

En küçük test hatasına neden olan ağırlıklar kullanılarak ağ LM algoritması kullanılarak ama sıfır ağırlık azalma çarpanıyla tekrardan eğitilmektedir. Yapay sinir ağı 7 yinelemede 0.00033 hatasına yakınsamaktadır. En iyilenen ağa göre sonuçlar parantez dışında Tablo 1'de ve Şekil 7'de verilmiştir. Ortalama %99.0 doğru ayırtma oranı elde edildi. Bu yüzden ağ yapısını optimize etmek dışında geometri ayırtmada daha iyi sonuç elde edilmiştir.

### 2.3. Yapay Sinir Ağlarıyla Yüzey Tipi Ayırtma

İkinci adımda, hedef geometrilerinin doğru ayırdedildiği varsayılarak, yüzey özellikleri yapay sinir ağlarıyla ayırdedilmektedir. Geometri ayırtmadaki aynı ağ yapısı ve yöntem kullanılmıştır. Eğitim setindeki her yüzey doğru olarak ayırdedilmiştir. 3 geometri ve yüzey için ayırtma dizeyi Tablo 2'de verilmiştir. Düzlem hedefleri ortalama %80.5 doğru olarak ayırdedilmiştir. Alüminyum kaplı yüzeyler %100 doğru ayırdedilmiştir. Köşe hedeflerinin yüzey özellikleri %85.9 oranında doğru ayırdedilmektedir. Ayırdedici özelliklerinden dolayı alüminyum kaplı köşe hedefleri doğru olarak ayırdedilmişlerdir. En kötü ayırtma sonuçları (%64.6) kenar hedefleri için elde edildi. Beyaz kumaş kaplı kenar hedefleri köpük ambalaj malzemesiyle karıştırılmamaktadır. Öte taraftan, %72.2 oranında köpük malzeme kaplı kenar hedefleri beyaz kumaş kaplı olarak yanlış ayırdedilmişlerdir.



Şekil 5: Farklı uzaklıklarda konumlanmış yüzeylerle kaplı (ilk sütun, alüminyum; ikinci sütun, beyaz kumaş; üçüncü sütun, beyaz köpük ambalaj malzemesi) hedefler için yeğinlik taramaları (ilk sıra, düzlem; ikinci sıra, köşe; üçüncü sıra, kenar).


Tüm yüzeyler için ortalama doğru ayırtma oranı %78.4'tür.

### 3. Sonuçlar

Bu çalışmada kızılberisi algılayıcılarla daha iyi hedef ayırtmak için en iyi yapay sinir ağ yapısı ileri sürüldü. Giriş sinyalleri farklı hedeflerden döner bir noktasal algılayıcıyla elde edilmiştir. Yeğinlik sinyalleri ağın işlevsel karmaşıklığını azaltmak için örneklenmiştir. Eğitim algoritmaları olarak GY ve LM yöntemleri kullanıldı. LM ile eğitilen ağ, en iyi ağ yapısı için OBS tekniğiyle budanmıştır. Budama işlemi ayırtma sonuçlarında iyileştirmeye neden olmuştur. İlk önce geometri sonra yüzey tipi belirlenerek modüler bir yaklaşım sergilenmiştir. Hedeflerin geometrileri %99 doğru olarak ayırdedilmiştir. Sadece 2 düzlem hedefi kenar olarak yanlış ayırdedilmiştir. Yüzey ayırtmada, tüm yüzeyler için %78.4 doğru ayırtma oranı elde edildi.

Yüzey ayırtma yeğinlik taramaları benzer özelliklere sahip olduğundan geometri ayırtmaya göre daha az başarılıdır. Sonuçlar hedeflerin geometrik özelliklerinin daha ayırdedici olduğunu ve yüzey ayırtmanın kısıtlayıcı olduğunu göstermektedir.

Referans sinyallerine dayalı ayırtmada [3], geometri ve yüzey için %80 doğru ayırtma oranı elde edildi. Aynı olarak ele alındığında geometri ve yüzey türleri %99 ve %81 oranlarında doğru olarak ayırdedilmişlerdir. Sonuçlar, bu çalışmada elde edilen sonuçlara yakındır. Diğer taraftan, yapay sinir ağları dışındaki yöntemlerle elde ettiğimiz sonuçlara göre burada elde ettiğimiz sonuçlar beklenilenin altındadır. Bunu bir nedeni ağın eğitim setini ezberlediği *genelleştirme* durumudur. Ağ karmaşıklığı arttıkça, ağın eğitim setini ezberleme eğilimi artmaktadır. Karmaşık ağlar gürültüyü öğrenmeye çalıştığı için, aşırı eğitilme durumu ortaya çıkmaktadır. Diğer taraftan, basit ağ modelleri ilgili görevleri yerine getirmekte yetersiz kalmaktadır. Ayrıca en iyi ayırtma oranlarının her zaman eğitim setinde en iyi sonucu veren ağla elde edilmediği gözlemlendi. Bunun ana nedeni küçük ölçekli olan eğitim setidir. Eğitim setini iki küçük sete bölerek, eğitim setinin temsil etme yeteneği azaltılmış oluyor. Bu yüzden, eğitim setindeki orijinal taramalara gürültü ekleyerek taramaların sayısını arttırmaya çalıştık. Gürültü iki türlü eklendi: İlk önce her örneğe beyaz Gauss gürültü eklendi. Alternatif olarak, küçük açısalları (tüm taramalar için sabit) taramalara eklenmiş, böylece açısallı kestirimden sonra  $\theta = 0^\circ$ 'den sapmalı taramaların doğru olarak




Şekil 6: OBS tekniğiyle budanmış yapay sinir ağı test ve eğitim sonuçları.

Tablo 2: Üç geometri ve yüzey için ayırtma dizeyi. (AL: alüminyum, BK: beyaz kumaş, BKÖ: beyaz köpük, B: belirle-nemeyen.)


|                            |    | ayırdedilen |    |     |    |
|----------------------------|----|-------------|----|-----|----|
|                            |    | D           |    |     | B  |
| g<br>e<br>r<br>ç<br>e<br>k | D  | AL          | BK | BKÖ |    |
|                            |    | 24          | –  | –   | –  |
|                            |    | BK          | –  | 23  | 6  |
|                            | KÖ | BKÖ         | –  | 9   | 19 |
|                            |    |             |    |     | 1  |
|                            |    |             |    |     |    |
|                            | K  | AL          | BK | BKÖ |    |
|                            |    | 22          | –  | –   | –  |
|                            |    | BK          | –  | 14  | 8  |
|                            |    | BKÖ         | –  | 1   | 19 |
|                            | K  | AL          | BK | BKÖ |    |
|                            |    | 8           | –  | –   | 2  |
|                            |    | BK          | –  | 19  | –  |
|                            |    | BKÖ         | –  | 13  | 4  |
|                            |    |             |    |     | 1  |

ayırdedilmesi düşünülmüştür. Diğer bir girişimde giriş tarama sinyallerinin örneklenme oranını düşürmekti. Sonuçta, tüm bu deneyler doğru ayırtma oranında iyileştirmeye neden olmadı.


Bu çalışma basit kızılberisi algılayıcıların, uygun işleme ve algılama teknikleriyle, bilinen uygulamalarının aksine daha fazla bilgi çıkarımında kullanılabileceğini göstermektedir. Bu sayede nesnelerin farkına varma, yakınsak algılama, sayma, erim ve derinlik gözetimi, pozisyon ölçümü ve çarpmalardan sakınma gibi basit görevlerin ötesinde kızılberisi algılayıcıların kullanılabileceği görülmüştür. Böylece, ayırtma, sınıflandırma, tanıma, pozisyon kestirimi, harita çıkarma, çevrenin algılanması, otonom yöngüdümlü ve hedef takibi uygulamalarında kızılberisi algılayıcılardan faydalanmak mümkün olacaktır.



(a) düzlem



(b) köşe



(c) kenar

Şekil 7: En iyi ağı için yapay sinir ağı ayırtma sonuçları: (a) düzlem, (b) köşe ve (c) kenar.

## 4. Kaynakça

- [1] A. M. Flynn. Combining sonar and infrared sensors for mobile robot navigation. *Int. J. Robot. Res.*, 7:5–14, Aralık 1988.
- [2] P. M. Novotny ve N. J. Ferrier. Using infrared sensors and the Phong illumination model to measure distances. *Proc. ICRA*, 1644–1649, Detroit, MI, Mayıs 1999.
- [3] T. Aytaç ve B. Barshan. Simultaneous extraction of geometry and surface properties of targets using simple infrared sensors. *Opt. Eng.*, 43:2437–2447, Ekim 2004.
- [4] T. Aytaç ve B. Barshan. Differentiation and localization of targets using infrared sensors. *Opt. Commun.*, 210:25–35, Eylül 2002.
- [5] B. Barshan ve T. Aytaç. Position-invariant surface recognition and localization using infrared sensors. *Opt. Eng.*, 42:3589–3594, Aralık 2003.
- [6] B. C. Bai ve N. H. Farhat. Learning networks for extrapolation and radar target identification. *Neural Networks*, 5:507–529, Mayıs/Haziran 1992.
- [7] M. Cohen, H. Franco, N. Morgan, D. Rumelhart ve V. Abrash. Context-dependent multiple distribution phonetic modelling with MLPs. *Advances in Neural Information Processing Systems*, 649–657, 1993.
- [8] K. S. Narendra ve K. Parthasarathy. Gradient methods for the optimization of dynamic systems containing neu-

ral networks. *IEEE Trans. Neural Networks*, 2:252–262, Mart, 1991.

- [9] M. I. Jordan ve R. A. Jacobs. Learning to control an unstable system with forward modeling. *Advances in Neural Information Processing Systems 2*, 324–331, 1990.
- [10] M. Galicki, H. Witte, J. Dörschel, M. Eiselt ve G. Griessbach. Common optimization of adaptive processing units and a neural network during the learning period: application in EEG pattern recognition. *Neural Networks*, 10: 1153–1163 Ağustos, 1997.
- [11] Y. LeCun, B. Boser, J. S. Denker, D. Henderson, R. E. Howard, W. Hubbard ve L. D. Jackel. Handwritten digit recognition with a back-propagation network. *Advances in Neural Information Processing Systems 2*, 396–404, 1990.
- [12] D. E. Rumelhart, G. E. Hinton ve R. J. Williams. Learning representations by back-propagation errors. *Nature*, 323:533–536, 1986.
- [13] B. Hassibi ve D. G. Stork. Second-order derivatives for network pruning: optimal brain surgeon. *Advances in Neural Information Processing Systems*, 5:164–171, 1993.
- [14] M. Nørgaard. Neural Network Based System Identification Toolbox. *Department of Automation, Technical University of Denmark*, Denmark, 2000.
- [15] Matrix Elektronik, AG, Kirchweg 24 CH-5422 Oberehrendingen, İsviçre, *IRS-U-4A Proximity Switch Datasheet*, 1995.
- [16] Arrick Robotics, P.O. Box 1574, Hurst, Teksas, 76053 URL: [www.robotics.com/rt12.html](http://www.robotics.com/rt12.html), *RT-12 Rotary Positioning Table*, 2002.