

YAPAY AÇIKLIKLI RADAR GÖRÜNTÜLERİNDE YAPAY SİNİR AĞLARI İLE HEDEF TANIMLAMA

Okyay KAYNAK

Boğaziçi Üniversitesi
Mühendislik Fakültesi

Elektrik ve Elektronik Mühendisliği A.B.D.
Bebek / İSTANBUL
kaynak@boun.edu.tr

Lokman ÖZÇOBAN

Hava Harp Okulu Komutanlığı
Havacılık ve Uzay Teknolojileri Enstitüsü
Bilgisayar Mühendisliği A.B.D.
Yeşilyurt / İSTANBUL
lozcoban@ttnet.net.tr

ÖZET: Bu makalede YAR görüntülerinin analizi ve görüntü içindeki nesnelerin tanınmasını hedeflenmiştir. Önce, işaret işleme teknikleri kullanımı ile görüntünün hedef içerebilecek bölgeleri bulunmuş, sonra bu bölgelerin moment envaryantlarının hesaplanması sonucunda hedefler modellenmiştir. Bu modelleme sonucunda elde edilen öznelik vektörlerini sınıflandırmak için ise yapay sinir ağları kullanılmıştır. Örnek görüntüler üzerinde elde edilen sonuçlar kullanılan yöntemin etkinliğine işaret etmekte ve yeni çalışmaları teşvik etmektedir.

Anahtar Kelimeler: Yapay açıklıklı radar, yapay sinir ağları, nesne tanıma.

RECOGNITION OF OBJECTS IN SYNTHETIC APERTURE RADAR IMAGES WITH NEURAL NETWORKS

ABSTRACT: This thesis is concerned with the analysis of SAR images and the recognition of objects in the image. Firstly, the regions of the image that may contain a target are established by signal processing techniques. Subsequently, the momentum invariants of these regions are calculated and the targets are modelled to result in characteristic vectors. Finally, a neural network is used for the classification of these vectors. The results obtained on a sample image demonstrate the effectiveness of the approach used and encourage further work.

Keyword:s Synthetic aperture radar, neural networks, pattern recognition.

1. GİRİŞ

Günümüzde kullanılan görüntüleme radarlarıyla yer yüzü her an taranmakta ve dünyada meydana gelen değişiklikler izlenmektedir. Değişikliklerin izlenmesinin yanı sıra, yüzeyde bulunan ağaçlar, dağlar, buzullar ve denizler gibi doğal nesnelere evler, köprüler ve arabalar gibi insan yapımı olan nesnelere de veri toplanmaktadır.

Her hava koşulunda, gece ve gündüz tarama yapabilme kapasitesine sahip olan yapay açıklıklı radarlar, son yıllarda yaygın bir şekilde kullanılmaya başlanmıştır. Yapay açıklıklı radarların kullanılması ile birlikte nesnelere hakkında optik sistemlerle elde edilemeyen yeni veriler toplanarak sinyal ve görüntü işleme algoritmalarının kullanılmasıyla yer yüzünün dijital görüntüleri oluşturulmuştur. Oluşturulan bu

görüntülerin yeşil alan, deniz ve yerleşim alanı olarak sınıflandırılması ya da yeşil alanda ekili olan ürünlerin sınıflandırılması için bir çok yöntem geliştirilmiştir. [1]

Sınıflandırma algoritmalarının dışında görüntüler üzerinde nesne tanıma algoritmaları da uygulanmaktadır. Nesneyi tanımlayabilmek için öncelikle görüntü üzerinde nesne olabilecek bölgeler tespit edilmekte ve bu bölgeler modellenmektedir. Denetimli veya denetimsiz öğrenme tekniklerinin kullanılmasıyla, modelleme sonucu ortaya çıkan öznelik vektörü sınıflandırılarak nesne tanımlanmaktadır.

Tarama sonucu elde edilen verilerin genlik veya faz bilgileri ya da her ikisi de, çeşitli sinyal işleme ve görüntü işleme algoritmalarından geçirilerek hedef

olabilecek olan bölgeler tespit edilir. En yaygın olarak kullanılan hedef tanımlama yönteminde, hedef olabilecek bölgeleri bulabilmek için, görüntü belirli bir eşik değerinden geçirilir ve kenar bulma algoritmalarının uygulanması sonucu; o bölgedeki hedefin sınırları belirlenir.

Nesnelerin sınırları tespit edildikten sonra, o nesnelerin hangi sınıfa ait olduğunun belirlenmesi gereklidir. Nesnenin hangi sınıfa ait olduğunu bulabilmek için, nesneyi özetleyen ve o nesneye ait belirgin özellikleri ihtiva eden öznitelik vektörü hesaplanır. Nesneyi modelleyebilmek için oluşturulan öznitelik vektörü çevresel ya da bölgesel olarak hesaplanabilir. Makalede kullanılan yapay açıklıklı radar görüntülerinde bulunan nesnelerin birbirlerine çok benzemesinden dolayı çevresel öznitelik vektörü hesaplama yöntemlerinden ziyade bölgesel öznitelik vektörü hesaplama yöntemlerinin kullanılması, sınıflandırmanın daha iyi sonuçlar vermesine neden olmaktadır.

Öznitelik vektörü hesaplandıktan sonra, bu öznitelik vektörünün hangi sınıfa ait olduğunun bulunması gerekmektedir. Nesnenin hangi sınıfa ait olduğunu belirleyebilmek için bir sınıflandırıcı kullanılır. Sınıflandırıcıları, denetimli sınıflandırıcılar ve denetimsiz sınıflandırıcılar olarak iki ana gruba ayrılır.

Nesne tanımlama, denetimli sınıflandırıcılarla yakın ilişkilidir. Denetimli sınıflandırıcılarda, farklı nesne sınıflarına ait olan öznitelik vektörleri ile görüntüde ki nesneye ait öznitelik vektörü karşılaştırılır. Yapılan karşılaştırmalar sonucunda, sınıflandırılacak olan öznitelik vektörüne en yakın olan ve veritabanımızda bulunan öznitelik vektörü bulunur. Bulunan öznitelik vektörü hangi sınıfa ait ise görüntüdeki nesne de o sınıfa dahil edilir.


Yapay açıklıklı radarların askeri amaçlar için kullanılmasıyla birlikte, arazi yüzeyinde bulunan nesnelerin yerlerinin tespit edilmesi ve bu nesnelerin hangi tip araca (tank, top, zırhlı personel taşıyıcısı v.s.) ait olduğunun belirlenmesi önem kazanmıştır. Bu makale çalışmasında, elimizde bulunan görüntülerde ki hedeflerin yerleri tespit edilmekte ve tespit edilen hedefin öznitelik vektörünün bulunması için moment envaryantları hesaplanmaktadır.[2] Moment envaryantları, sınıflandırıcı olarak kullanılan yapay sinir ağı için giriş vektörü olarak kullanılmakta ve o hedefin tank, personel taşıyıcı ya da piyade savaş aracı mı olduğu tespit edilmektedir.

2. MATERYAL ve YÖNTEM


Makalede kullanılan veriler Sandia National Laboratory (SNL)'nin YAR sensörü tarafından Eylül 1995'de kaydedilmiştir. Bu verilerin toplanması, hareketli ve sabit hedef elde etme ve tanıma (Moving

and Stationary Target Acquisition and Recognition - MSTAR) programı kapsamında DARPA ve Air Force Research Laboratory (AFRL) tarafından desteklenmiştir. Veriler, X bant aralığında çalışan YAR sisteminin spotlight modunda toplanmıştır. Veriler HH polarizasyonunda toplanmış olup görüntü oluşturmak için hedeften geri yansıyan sinyallerin genlik bilgisi kullanılmıştır.


Verilerde, T-72 tankı, BMP2 piyade savaş aracı (Infantry Fighting Vehicle) ve BTR-70 zırhlı personel taşıyıcısı (Armored Personnel Carrier) olmak üzere üç değişik tipte araç mevcuttur. 3 değişik seri numaralı T-72 tankı, 3 değişik seri numaralı BMP2 piyade savaş aracı ve 1 seri numaralı BTR-70 zırhlı personel taşıyıcısını verileri 15° ve 17° açılarla toplanmıştır. 17° 'lik açıyla toplanan 1622 veri, yapay sinir ağlarını eğitmek için kullanılırken 15° 'lik açıyla toplanan 1365 veri ise test amaçlı kullanılmıştır. Her veri 128×128 piksel büyüklüğünde olup araçlar genelde oluşan görüntünün ortasındadır. Bu görüntüler içerisindeki araçların kapsadığı alan ise yaklaşık olarak 40×40 piksel'dir. Şekil 1, şekil 2 ve şekil 3'de her bir araç modeli için örnek görüntüler verilmiştir.



Şekil 1. BMP2 Piyade savaş aracı



Şekil 2. BTR70 Zırhlı personel taşıyıcı




Şekil 3. T72 Tankı

Daha öncede belirtildiği gibi amacı; görüntü içerisinde hedef olabilecek bölgeleri tespit ederek bu bölgelerde bulunan nesnelere tanımlamaktır. Aynı görüntü içerisinde birkaç hedefin bulunduğu görüntüler, hedefleri gizlenmiş görüntüler ve hedef

olmayıp da hedefmiş gibi görünen bölgeler içeren görüntüler mevcut olmadığı için, sadece 128*128 piksellik veriler kullanılarak uygulamalar gerçekleştirilmiştir.


Görüntüleri tanımlayabilmek için; görüntüde hedef olabilecek bölgeler tespit edilir ve bu bölgeler modellenir. Modelleme sonucunda elde edilen öznitelik vektörü, hedefleri sınıflandırmak amacıyla kullanılır.

Hedef verilerinin kullanılmasıyla şekil 4’de ki gibi bir görüntü elde edilir.



Şekil 4. Orijinal görüntü


YAR görüntülerinde ki benekleri yok edip görüntüyü daha pürüzsüz bir hale getirebilmek için birçok filtreleme algoritması geliştirilmiştir. Makalede yapılan filtrelemelerde, görüntünün standart sapması, görüntü değerinden çıkarılmış ve çıkan sonuç, görüntü ortalamasına bölünmüştür. Filtrelenmiş görüntüde, şekil 5.’de de görüleceği gibi, hedef daha belirgin hale gelmiştir.




Şekil 5. Filtreli görüntü

Görüntü içerisinde hedefin yerini tespit edebilmek için görüntüye bir eşik değeri uygulanır. Makalede her bir görüntüye uygulanacak olan eşik değerinin belirlenmesi için Otsu tarafından geliştirilen yöntem kullanılmaktadır [3]. Eşik değerinin altında kalan noktalara sıfır, eşik değerini geçen noktalara ise bir değeri atanarak görüntü ikili görüntü haline getirilir. Eşiklendirmenin sonucunda elde edilen görüntüde hedefin yeri net bir şekilde belli olmaktadır. (Şekil 6)

Oluşturulan ikili, görüntüde eşik değerini geçmiş fakat hedef olamayacak kadar küçük bölgelerin olma olasılığı vardır. Bu küçük bölgeleri yok edebilmek için ikili görüntü ikinci bir filtremeden geçirilir. Filtreleme sonucunda elde edilen görüntüde hedefin yeri kesin olarak tespit edilmiş olur. (Şekil 7)




Şekil 6. İkili görüntü



Şekil 7. Filtrelenmiş ikili görüntü

Sınıflandırılacak olan hedefin koordinatları şekil 3.8.’de tespit edilir. Aynı koordinatlar kullanılarak filtreli görüntüden (şekil 3.6) 40*40’lık bir matris alınır. Teşkil edilen bu matriste hedefe ait bilgiler vardır. Şekil 3.9.’da örnek bir hedef görüntüsü verilmiştir.



Şekil 8. Hedefin görüntüsü

Görüntü içerisinde ki hedef tespit edildikten sonra, hedefi sınıflandırabilmek için hedefi ifade edecek olan matematiksel modelin oluşturulması gerekir. Sınıflandırma algoritması ne kadar başarılı olursa olsun, hedefin özelliklerini tam olarak yansıtan ve hedefi diğer hedeflerden ayıran bir öznitelik vektörü oluşturulmazsa, sınıflandırma başarısız olur. Öznitelik vektörünün mümkün olduğu kadar küçük olması, hedefi en az veri kaybıyla temsil etmesi ve rotasyon, büyüklük ve ötelemeden bağımsız olması gerekir.

Makalede yapılan uygulamalarda hedefi tanımlayabilmek için bölgesel modelleme yöntemlerinden moment envaryantları kullanılmıştır. Bütün hedeflerin moment envaryantları hesaplanarak hedef sınıflarına ait veritabanı kurulmuştur. Sınıflandırıcı olarak yapay sinir ağları [4] seçilmiş olup öncelikle 1622 elemanlı eğitim setinin moment envaryantları kullanılarak yapay sinir ağları eğitilmiştir. 1365 hedeften oluşan test seti ile de yapay sinir ağlarının performansları değerlendirilmiştir.

Ağdan beklenen çıktı olarak, hedefin ait olduğu sınıfı gösteren nöronun çıkış değeri 1, diğer iki çıkış değeri ise sıfır olarak atanmıştır. Eğitim seti ve tasarlanan çıktılarla ağ eğitilmiş, test seti ile de performans değerlendirmesi yapılmıştır. Performans değerlendirmesinde; hedef, ağı ürettiği çıkışlardan en büyük çıkış değerine sahip olan nöronun temsil ettiği sınıfa dahil edilmiş ve doğruluğu karşılaştırılmıştır.

3. ARAŞTIRMA BULGULARI

Bu çalışmada, yapay açıklıklı radar görüntülerini sınıflandırmak için sınıflandırıcı olarak yapay sinir ağları kullanılmıştır. Değişik yapay sinir ağı modelleri denenmiş ve elde edilen bulgular aşağıya çıkarılmıştır.

Hedefi tanımlayabilmek için kullanılan öznitelik vektörü, yedi moment envaryantının hesaplanmasıyla teşkil edildiğinden, makalede kurulan yapay sinir ağlarının giriş vektörü yedi elemanlıdır. Üç değişik tipte araç sınıflandırılacağı için ağ çıkış vektörü ise üç elemanlıdır. Uygulamalarda kullanılan ağlar, çok katmanlı perceptron ağlar olup, iki gizli katman içermektedirler. Çıkış katmanı için sigmoid aktivasyon fonksiyonu kullanılmış, gizli katmanlar

için sigmoid aktivasyon fonksiyonu ve hiperbolik tanjant aktivasyon fonksiyonu kullanılarak denemeler yapılmıştır. Yapılan denemeler sonucunda, gizli katmanlarda sigmoid aktivasyon fonksiyonunun kullandığı ağların doğruluk yüzdesi hiperbolik tanjant aktivasyon fonksiyonunun kullandığı ağların doğruluk yüzdesinde daha düşük çıkmıştır. Bunun için makale kapsamında kurulan ağların gizli katmanlarında hiperbolik tanjant aktivasyonunun kullanılmıştır.

Yeni bir ağ kurulduğunda, ilk ağırlık parametre değerleri bilgisayar tarafından otomatik olarak atanmaktadır. Yapılan denemelerde ilk ağırlık değerlerinin, ağ performansını etkilediği görülmüştür. Doğru bir yorumun yapılabilmesi için her bir ağ modeli on defa yeniden kurulmuş ve ağ performansları hesaplanmıştır. Performans hesaplanırken, hedef, en yüksek çıktı değerine sahip nöronun sınıfına dahil edilmiştir.

Kabul edilebilir hata toleransı olarak 0,001 atanmıştır. Hiçbir ağı hatası bu değer altına inemediğinden ağ eğitimini durdurma kriteri olarak iterasyon sayısı kullanılmıştır. Ağlar, 500, 1000 ve 2000 iterasyonlar da eğitilmiş ve performansları hesaplanmıştır. 500 ve 1000 iterasyonla eğitilen ağların doğruluk yüzdeleri 2000 iterasyonla eğitilen ağların doğruluk yüzdelere göre daha düşük çıkmıştır. 2000 iterasyondan daha fazla eğitilen ağlarda ise eğitim seti için doğruluk yüzdeleri yüksek çıkarken, test seti için doğruluk yüzdeleri düşmüştür. Ağların, çok yüksek iterasyonlar da genelleme yapabilmek özelliklerini kaybederek ezberlemeye yöneldikleri görülmüştür. Optimum çözümü elde edebilmek için 2000 iterasyonun yeterli olduğuna karar verilmiştir.

5, 10, 20 ve 40 nörondan oluşan gizli katmanların kullandığı dört değişik yapay sinir ağı denenmiştir. 7*20*20*3'lük yapay sinir ağı modelinin 2000 iterasyonda optimum çözümü verdiği görülmüştür.

Çizelge 1'de de görüldüğü gibi, 7*20*20*3 ağ modeli için, 500 iterasyon sayısı ağı eğitiminde yetersiz gelmekte ve ağın performansı düşmektedir. 1000 iterasyonda en yüksek değer olarak %77'lik performansa ulaşılmış olmasına rağmen ortalama performans düşmektedir. 2000 iterasyonun birbirine yakın sonuçlar verdiği görülmüştür. Daha yüksek iterasyonlar da ağlar eğitilmiş fakat ağların ezberlemeye yöneldiği görülmüştür.

Diğer ağ modelleri içinde 500 ve 1000 iterasyonları denenmiştir. Sadece 2000 iterasyonun sonuçları kıyaslanmıştır. Gizli katman nöron sayısı 5'de 10'a çıkarıldığında %1'lik, 10'dan 20'ye çıkarıldığında da %1'lik bir artış sağlanmıştır. Daha yüksek nöron sayısına sahip ağlarda eğitim seti doğruluk oranı çok yükselirken, test seti doğruluk oranı düşmüştür. Optimum çözümün 20 nöron olduğu görülmüş olup

7*20*20*3 ağ modeli sınıflandırıcı olarak kullanılmıştır.

7*20*20*3 ağ modelinde, %77.65'lik doğruluk ortalamasına sahip olan ağ tarafından üretilen sonuçlar çizelge 2. de verilmiştir. 1 numara, BMP2 piyade savaş aracını, 2 numara, BTR70 zırhlı personel taşıyıcısını, 3 numara da T72 tankını temsil etmektedir.

Çizelgeye incelendiğinde, piyade savaş aracına ait 109 adet hedef T72 tankı olarak sınıflandırılmıştır. %82 doğruluk yüzdesi ile T72 tankı en yüksek performansa sahipken, BMP2 piyade savaş aracının %76'sı ve BTR70 zırhlı personel taşıyıcının da %64'ü doğru olarak sınıflandırılmıştır.

4. SONUÇ ve ÖNERİLER

Bu çalışmada yapay açıklıklı radarlardan elde edilen görüntülerde ki hedeflerin tanımlanması yapılmaktadır. YAR sistemleri tarafından toplanan sinyaller YAR veri işleme süreçlerinden geçirilerek, taranan arazinin iki boyutlu dijital görüntüsü oluşturulur. Bu görüntülerde ki hedefler ile daha önceden teşkil edilmiş veritabanında ki hedefler kıyaslanarak, YAR görüntüsünde bulunan hedefin sınıfı belirlenir.

Eğitim seti hedefleri kullanılarak, bir veritabanı oluşturulmuş ve bu veritabanına göre test setini sınıflandırmak için yapay sinir ağı sınıflandırıcısı seçilmiştir. Birbirine çok benzeyen ve insan gözüyle ayırt edilmesi zor olan görüntülerin sınıflandırılması sağlanmıştır.

Çalışmada kullanılan eğitim ve test seti görüntülerde sadece hedefler mevcuttur. Çalışmada kullanılan hedef modellerinin bulunduğu arazi görüntüleri, elde

mevcut olmadığı için otomatik hedef bulma ve tanıma algoritmalarına yönelik çalışmalar yapılamamıştır.

Sonuç olarak; eğitilen bu ağlar kullanılarak, otomatik hedef bulma algoritmalarının geliştirilmesi mümkündür. Bunun için, veritabanındaki hedefler kullanılarak, YAR görüntüleri için bir eşik değeri belirlenir. YAR görüntüsü bu eşığe göre ikili görüntü haline getirilir. Görüntü işleme yöntemleri (kenar bulma v.s.) kullanılarak hedef olabilecek olan bölgeler tespit edilir. Bu bölgeler modellenerek, sınıflandırıcıya tabi tutulur ve o bölgelerde hedeflerin mevcut olup olmadıkları, mevcut ise hangi hedefin olduğu belirlenir.

KAYNAKLAR

- [1] Hellmann, M. 2000. Classification of fully polarimetric SAR data for cartographic application. Ph.D. thesis, DLR research report FB-2000-19, 156, Almanya.
- [2] Hu M.K. 1962. Visual Pattern Recognition by Moment Invariants. IRE Transactions on Information Theory, Volume IT-8,179-187.
- [3] Otsu N. 1979. A Threshold Selection Method from Gray-Level Histograms. IEEE Transactions on Systems, Man, and Cybernetics, Volume. 9(1), 62-66.
- [4] Bishop C.M. 1995. Neural Networks for Pattern Recognition. Clarendon press, 482, İngiltere.

Çizelge 1. Toplu sonuçlar

Ağ	Ortalama Doğruluk	En düşük Doğruluk	En yüksek Doğruluk
7*5*5*3 (2000 İterasyon)	%73.41	%70.47	%76.41
7*10*10*3 (2000 İterasyon)	%74.49	%70.76	%75.82
7*40*40*3 (2000 İterasyon)	%74.15	%70.69	%76.04
7*20*20*3 (500 İterasyon)	%71.88	%67.25	%75.89
7*20*20*3 (1000 İterasyon)	%74.84	%71.35	%77.14
7*20*20*3 (2000 İterasyon)	%75.85	%74.43	%77.65

Çizelge 2. Sınıflandırma sonuçları

		Hesaplanan Sınıf			
		1	2	3	Toplam
Hedeflenen Sınıf	1	455	23	109	587
	2	42	127	27	196
	3	91	13	478	582
	Toplam	588	163	614	1365

ÖZGEÇMİŞ :

Prof.Dr. Okyay KAYNAK

1948 Afyon doğumludur. 1969 yılında Birmingham Üniversitesinden Elektrik-Elektronik Mühendisliği Lisans diplomasını aldı. 1972 yılında yine aynı üniversiteden doktora derecesini aldı. 1979 yılında Boğaziçi Üniversitesi Elektrik-Elektronik Mühendisliği Bölümünde öğretim üyesi olarak göreve başladı. Halen aynı üniversitede görev yapmaktadır. İlgili alanları: akıllı sistemler, İleri hareket kontrolü ve robotik.