

# Uydu Görüntülerinde Betimleme Öğrenme ile Kuru Dok Tespiti

## Dry Dock Detection in Satellite Images with Representation Learning

Ümit Ruşen Aktaş, Orhan Fırat, Fatoş T. Yarman Vural  
Bilgisayar Mühendisliği Bölümü  
Orta Doğu Teknik Üniversitesi  
Ankara, Türkiye  
{rusen, orhan.firat, vural}@ceng.metu.edu.tr

**Özetçe—** Bu çalışmada, betimleme öğrenme kullanılarak tanınması zor bir liman nesnesi olan kuru dokları uydu görüntülerinde tespit edebilen bir yöntem sunulmaktadır. Kuru doklar, liman bölgelerinde bulunan ve gemilerin tamir veya yapım için içinde bulunabildiği, denize komşu yapılardır. Dokları betimleyici iki adet düşük seviyeli öznitelik kullanılarak, arama uzayı küçültülmekte ve kalan bölgelerde betimleme öğrenme yöntemi ile algoritma eğitilmektedir. Yapılan deneyler, alan uzmanı tarafından önerilen özniteliklerle yapılan sınıflandırmalarla, otomatik olarak öğrenilen özniteliklerle çalışanların benzer performanslara sahip olduğunu ortaya koymuştur. Elde edilen sonuçlar, aynı sistemin başka nesnelere uzaktan algılanan görüntülerdeki tespitinde de efor harcamadan uygulanabilirliği konusunda önemli ipuçları vermektedir.

**Anahtar Kelimeler —** betimleme öğrenme, nesne tespiti.

**Abstract—** In this study, we propose a method to detect dry docks, a harbour man-made object which is hard to recognize, using representation learning in satellite images. Dry docks are coastal structures which may include ships for repairing purposes, and they exist in harbour regions. The search space is pruned by making use of two low-level features that invariantly define docks, and remaining samples are used to train a representation learning system. Experimental results suggest that classification methods using learned features have similar performances to those using handcrafted features, which are proposed by the field expert. The results also provide insight on the applicability of the same methodology on detection of different objects in remotely sensed images, without wasting any effort.

**Keywords —** representation learning, object recognition

### I. GİRİŞ

Limanlar, insan gözüyle tanımlanması kolay, ancak klasik anlamda bir nesne tespit etme yöntemiyle bulunması zor yapılardır. Limanların yüksek çözünürlüklü optik uydu görüntülerinde otomatik tespit edilmesi, diğer insan yapımı nesnelere gibi üzerinde çalışılan bir konudur. Limanlar, çeşitli boyutlarda, tiplerde ve şekillerde olabildiği için, limanlara özgü

bir yöntem tanımlamak sahil şeridinden çıkartılan düşük seviyede özniteliklerin ötesine geçememektedir[7,8]. Limanı modellemeye yönelik çalışmalar [9], sadece belli liman tiplerinde başarılı olmaktadır.

Doklar, limanlarda bulunan, denizden açılabilir bir kapak ile ayrılan ve içlerinde gemi tamirlerinin yapıldığı yerlerdir. İçlerinde su bulunup bulunmamasına göre, kuru dok ve ıslak dok olarak iki gruba ayrılırlar. Literatürde dokların tespitine yönelik bir çalışmaya rastlanmamıştır. Bir diğer liman nesnesi olan gemilerin otomatik tespitine yönelik çalışmalar, genel anlamıyla iki yolda ilerlemiştir. İlk olarak, karaya veya başka bir gemiye yanaşmamış gemilerin tespitinden söz edilebilir [17]. Literatürde bulunan ve dokların tespit edilmesine daha yakın olan ikinci tipteki çalışmalar, kızağa çekilmiş / kıyıya yanaşmış gemilerin tespitine yönelik araştırmalardır. Jiang ve diğerleri[10], gemilerin uçlarındaki eğimli yapıyı kullanarak kıyıdaki gemileri bulmuşlardır. Wang ve Weixing[18] ise, kıyıya çokgen oturtma yöntemiyle, denize doğru çıkıntı yapan gemileri tespit etmişlerdir. Dokların önemli bir kısmının içerisinde gemi olduğu için, kıyıdaki gemilerin tespit edilmesi dokları tespitine yönelik önemli bir ipucu vermektedir. Ancak, dokların içindeki gemilerin tamamen karanın içinde olması, şekil tabanlı yöntemlerin kullanımını güçleştirmektedir. Buna ek olarak, bazı dokların içinde gemi bulunmadığı için, daha farklı bir yaklaşım geliştirmek zorunlu olmuştur.

Limanlarda bulunan doklar, görünüşte pek çok açıdan birbirlerinden farklı olmasına rağmen, kendi içinde değişmeyen iki adet öznitelik barındırmaktadır. Bu öznitelikler, aşağıda verilmiştir.

#### A. Denize Diklik

Dokların büyük bir kısmının karanın içine doğru uzanan, deniz-kara ayrımına dik bir dikdörtgenel alan olarak tanımlanabildiği görülmektedir. Bu bilgi, deniz-kara ayrımına dik olarak karaya yerleştirilen dikdörtgenler aracılığıyla aday dok bölgelerinin elde edilebileceği varsayımını doğurmuştur.

#### B. Biçimsel Öznitelikler


Veri seti incelendiğinde, halihazırda iki tür dok olduğu tespit edilmiştir. Birinci tür olan küçük doklar, 25 metre

genişliğinde ve 150 metre uzunluğunda olup, küçük gemileri içine alabilmektedir. 55 metre genişlik ve 330 metre uzunluğa sahip olan büyük doklar ise, büyük yolcu gemilerini ve tankerleri içine alabilmektedir. Bu iki dok tipini biçimsel özniteliklerle ifade edebilmek için iki farklı boyutta dikkörtgensel alanlar kullanılmaktadır.

Bu çalışmada, çok-bantlı uydu görüntülerinde kuru dokların tespitine yönelik bir öğrenme algoritması sunulmaktadır. İlk safhada arama uzayını küçültmek amacıyla (tüm kıyı şeridinde arama yapmaktan ziyade), dokların bulunabileceği aday çokgenler çıkartılmaktadır. Ardından, aday bölgelerden öznitelik çıkarma ve bu bölgeleri sınıflandırma adımları gelmektedir. Önerilen algoritma mevcut yaklaşımlardan, kullanılacak özniteliklerin verisetinden öğreticisiz olarak öğrenilmesi bakımından ayrılmaktadır. Öğreticisiz öznitelik öğrenme maksadıyla seyrek oto-kodlayıcılar kullanılmış ve öğrenilen öznitelik seti bir sınıflandırıcıya verilerek önerilen yaklaşımın başarımı ölçülmüştür. Elle tasarlanan zaman-yoğun ve/veya alan uzmanı tarafından belirlenmiş saha tecrübesi gerektiren öznitelik belirleme safhası tamamen bir makina öğrenme algoritmasıyla yer değiştirilmiştir. Algoritmanın başarımı, bu şekilde çıkarılmış olan özniteliklerle yapılan sınıflandırmalara göre daha üst düzeydedir.

## II. VERİ SETİ

Hazırlanan veri seti, GeoEye ve Ikonos uydularından alınmış 17 adet R-G-B-NIR bantlarına ve 0.5 metre çözünürlüğe sahip liman görüntüsünden oluşmaktadır. Veri setinin zorluğu, içerdiği örnek sayısının azlığından (25 adet) ve bu dokların çeşitlilik arz etmesinden kaynaklanmaktadır. Veri sayısının azlığı sebebiyle, her dokun farklı bölgelerinden 4-5 adet pozitif (dok içeren) örnek otomatik olarak toplanmaktadır. Bu sayede, pozitif örneklerin sayısı 127'ye çıkartılmıştır. Negatif örnekler ise, pozitif örneklerle aynı yöntemle çıkartılan 452 adet dok içermeyen çokgenden oluşmaktadır. Veri setinde bulunan bazı dok örnekleri ve etiketlenmiş bir görüntü Şekil 1'de görülebilir.




Şekil 1. Dok örnekleri ve örnek görüntü

## III. ADAY DOK ÇOKGENLERİNİN TESPİTİ

Limanlardaki dokların tespit edilmesi amacıyla, öncelikle su-kara çizgisi(kıyı şeridi) belirlenmektedir. Su-kara ayrımı, GeoEye görüntüleri için Normalize Fark Su İndisi kullanılarak [11], Ikonos görüntüleri içinse görüntüdeki piksellerin NIR yansıma değerleri üzerinde Otsu'nun eşiği [5] uygulanarak bulunmaktadır. Bulunan piksel tabanlı su çıktısı, alanı 2000

$m^2$ 'den küçük su bölgelerinin elenmesi yöntemiyle görüntülerden temizlenmektedir.

Su çıktıları bulunduktan sonra, kıyı şeridi üzerinde Doğru Parçası Tespit Edicisi [6] yardımıyla kıyı çizgisi üzerindeki doğru parçaları bulunmaktadır. Elde edilen doğru parçalarının eğimleri, kıyının o bölgedeki eğimini bize vermektedir. Örnek görüntüye ait su çıktısı ve kıyı şeridini tanımlayan doğru parçaları, Şekil 2'te görülebilir.



Şekil 2. Örnek görüntüye ait su çıktısı ve doğru parçaları (solda), kıyıya oturtulan dikkörtgenler (sağda)

Kıyıdaki çizgiler bulunduktan sonra, bu çizgiler üzerine, karanın içine uzanacak şekilde dikkörtgenler yerleştirilmektedir. Dikkörtgen yerleştirme işlemi, Şekil 2'teki örneklerde görüldüğü üzere, iki varsayıma dayanmaktadır.

- 1) Dikkörtgenin boy/en oranı: 7
- 2) Dikkörtgenin kısa kenarı: 20 veya 55 metre

Eğer doğru parçasının uzunluğu 20 metre'den küçük ise, bu doğru parçası üzerine dikkörtgen oturtulmamaktadır. Her bir doğru parçası üzerinde oturtulabilecek dikkörtgenlerin sayısı (1)'deki gibidir.

$$N_{DP} = (u_{DP} - en_{Dok}) / adım \quad (1)$$

$N_{DP}$  doğru parçası üzerindeki dikkörtgen sayısını,  $u_{DP}$  doğru parçasının uzunluğunu,  $en_{Dok}$  aranılan dokların enini (20 veya 55 metre),  $adım$  ise, doğru parçasına dikkörtgenlerin kaç metre aralıklarla yerleştirileceğini göstermektedir.  $adım$  parametresi, bu çalışmada 10 metre olarak seçilmiştir.

Her bir dikkörtgenin yerleştirildikten sonra oluşturduğu alanın dok aday bölgesi olabilmesi için bir testten geçmesi gerekmektedir (2).

Dikkörtgenler kümesi  $P = \{p_i\}_{i=1}^K$  olmak üzere,

$$\forall p_i \text{ için } \begin{cases} p_i \in A, Y_{p_i} > t_y \text{ ve } S_{p_i} < t_s \\ p_i \notin A, \text{ diğ er durumlarda} \end{cases} \quad (2)$$

$P$  kümesi, dok olmaya aday dikkörtgensel alanlar kümesi olmak üzere, (2)'de  $Y_{p_i}$ ,  $p_i$ 'nin içindeki yeşil alanların  $p_i$ 'nin toplam alanına,  $S_{p_i}$  ise  $p_i$ 'nin içindeki su bölgelerinin alanlarının  $p_i$ 'nin toplam alanına oranını göstermektedir. İzin verilen en yüksek yeşil alan oranı eşik değeri  $t_y$  0.25, su oranı eşik değeri  $t_s$  ise 0.75 olarak belirlenmiştir.

Son olarak, çıkartılan aday dikkörtgenler, her yönde kısa kenarları uzunluğunda genişletilerek daha büyük hale getirilir ve hepsi aynı yöne gelecek şekilde döndürülüp kaydedilir. İki

dok tipi için de oturtulan dikkörtgenlerin oluşturduğu alan, bu aşamada aynı boya gelecek şekilde yeniden boyutlandırılır. Böylece her bir örnek, 3 bantlı (RGB) görüntü olarak özniteliklerin çıkartılması için hazırlanmış olur.

#### IV. ÖZİNİTELİKLERİN ÇIKARTILMASI

Uzaktan algılama görüntüleri kullanılarak nesne tanıma ve sınıflandırmak maksadıyla geliştirilen geleneksel makina öğrenme algoritmalarının başarımı büyük ölçüde veri betimlemenin (özniteliklerin) nasıl ve ne olarak seçildiğine bağlı kalmaktadır. Öznitelik mühendisliği [1] olarak da adlandırılan bu süreçler insan yaratıcılığını ve önsel bilgiyi, geliştirilen algoritmaya aktarmak maksadıyla oldukça önemli olmakla beraber, bunların genelleştirilmesi oldukça zor ve masraflıdır. Günümüz hesaplama gücündeki gelişmeler göz önüne alındığında, büyük miktardaki etiketsiz veri kullanarak, veri setini en verimli betimleyecek olan özniteliklerin bir makina öğrenme algoritması tarafından öğrenilmesi uygulanabilirlik açısından elverişlidir. Bu çalışmada da kullanılan öğreticisiz öznitelik öğrenme temelde, sınıflandırıcı tasarlarken verisetinden faydalı bilgiyi çıkartmak maksadıyla veri dönüşümlerini ve gözlemlenen girdiden sonsal olasılığı en iyi yakalayacak olan etmenlerin etiketsiz verisetinden öğrenilmesidir [2]. Öğreticisiz olan bu yöntemler esasen, girdilerini yeniden inşa etmeye çalışan modeller olup, ceza fonksiyonlarına eklenen seyreklik bileşenleri ve/veya girdi-geçiş-çıkı eleman sayısını eniyileme ile özdeşlik fonksiyonundan uzaklaşırlar. Sonuçta, özlü ve yüksek-seviyeli öznitelik betimlemelerinin etiketsiz veriden öğrenilmesi ile, sınıflamanın daha kolay ve etkin yapılmasını sağlamayı amaçlarlar [3].

##### A. Öznitelik Öğrenme ve Seyrek Oto-kodlayıcılar

Öğreticisiz öznitelik öğrenme, etiketsiz verisetindeki görüntülerden rastgele aynı boyutta alt-parçalar toplamaya başlanmaktadır. Ardından toplanan  $m$  adet alt-parça öznitelik öğrenme algoritması için  $X = \{x^{(1)}, \dots, x^{(m)}\}$  olan bir verisetinde toplanırsa, burada  $x^{(i)} \in \mathbb{R}^N$  olacaktır. Oluşturulan veriseti  $X$  öznitelik öğrenme algoritmasına girdi olarak verilecektir. Literatürde öğreticisiz öznitelik öğrenme maksatlı seyrek-kodlama, RBM'ler, seyrek-RBM'ler ve hatta k-ortalama yöntemini sıklıkla kullanılmaktadır [14]. Bu çalışmada yapay-sinir ağları ve seyrek kodlama ile olan benzerlikleri nedeniyle seyrek oto-kodlayıcılar tercih edilmiştir. Oto-kodlayıcılar temelde, öğreticisiz geri-yayılım (backpropagation) uygulayan yapay-sinir ağları olup [15] çıktı nöronları (düğüm) olarak girdi nöronlarını kestirmeye çalışırlar. Gizli nöronların seyreklikleri (sıfıra yakın aktivasyon) ayarlanarak, girdisini en kompakt şekilde ifade etmek üzere en iyileştirilirler. Bu maksatla, bir önceki adımda oluşturulan veriseti  $X$  girdi olarak alıp, çıktı olarak da  $f: \mathbb{R}^N \rightarrow \mathbb{R}^K$  olan bir eşleme-fonksiyonu veren seyrek oto-kodlayıcı eğitilmiştir. Burada  $f$  bir eşleme fonksiyonu olup  $N$  boyutlu bir girdi vektörünü  $x^{(i)}$ ,  $K$  boyutlu yeni bir öznitelik uzayına eşlemektedir.  $K$  kullanıcı tarafından belirlenen bir parametre olup oto-kodlayıcının gizli katmanındaki nöron sayısını belirlemektedir.  $K$  adet gizli düğümü olan bir oto-kodlayıcı, yeniden inşa etme hatasının karesini minimize etmek üzere geri-yayılım algoritması ile eğitilmektedir. Eğitim için ceza

fonksiyonuna, gizli düğümlerde düşük ortalama aktivasyonu (seyreklik) sağlamak maksadıyla ek bir ceza bileşeni koyulmuştur.

$$J_{seyrek}(W, b) = J(W, b) + \beta \sum_{j=1}^K \text{KL}(\rho || \hat{\rho}_j) \quad (3)$$

Optimizasyon için kullanılan ceza fonksiyonu (3) ilk terim olarak tek-seviyeli standart yapay-sinir ağı ceza terimini  $J(W, b)$ , ikinci terim olarak da seyreklik ceza terimini içermektedir. Algoritma parametresi olan  $\beta$ , seyreklik ceza teriminin ağırlığını belirlemekte olup;  $\text{KL}(\rho || \hat{\rho}_j)$  ortalaması  $\rho$  olan bir Bernoulli rastgele değişken ile ortalaması  $\hat{\rho}_j$  olan bir Bernoulli rastgele değişken arasındaki Kullback-Leibler uyumsuzluğudur. Algoritma seyreklik parametresi olan  $\rho$  genellikle sıfıra yakın bir değer olarak seçilmektedir. Seyrek oto-kodlayıcının  $i$ 'inci girdisi  $x^{(i)}$  kullanılan  $j$ 'inci gizli düğüm olmak üzere,  $\hat{\rho}_j$  bu düğüme ait (tüm veri-seti üzerinden) ortalama aktivasyonu ifade etmektedir.

Sonuçta seyrek oto-kodlayıcı algoritması çıktı olarak, geçiş ağırlıkları  $W \in \mathbb{R}^{K \times N}$  ile yanlılık ağırlıkları  $b \in \mathbb{R}^K$  vermekte ve  $f$  öznitelik eşleme fonksiyonu olan  $f(x) = \sigma(Wx + b)$  şeklinde tanımlanmaktadır. Burada  $\sigma(z) = 1/(1 + \exp(-z))$  sigmoid fonksiyonudur. Öğrenilen öznitelik çıkarma fonksiyonunu  $f: \mathbb{R}^N \rightarrow \mathbb{R}^K$  etiketli veri setinde tespit edilecek nesne için öznitelik çıkarmak için kullanılmaktadır.

Öznitelik öğrenme safhası 4 metre çözünürlüğe sahip 20 adet GeoEye görüntüsünde, yakın kızılötesi bandı atılarak 3 bant üzerinden yapılmıştır. Betimleme sayısı (oto-kodlayıcı gizli düğüm) 400 olarak sabitlenmiştir. Alış alanı olarak da adlandırılan betimleme boyutu 8x8 piksel olarak seçilmiş ve seyrek oto-kodlayıcı verisetinden bu boyutta rastgele seçilen 100.000 alt-parça ile eğitilerek parametreleri öğrenilmiştir. Ceza fonksiyonunun optimizasyonu için L-BFGS metodu kullanılmış olup [16], geçiş ağırlıkları  $W$ 'lar L2 düzenleştirmeye tabi tutulmuştur.

#### V. DENEYLER

##### A. Karşılaştırılan Yöntemler

Önerilen yöntem, alan uzmanının önerisiyle belirli doku yöntemleriyle karşılaştırılmıştır. Dokların belirleyici özelliği olan dokusal örgüler, beş farklı öznitelikle öğrenilmiştir.

Tüm deneylerde, görüntü eşit büyüklükte 25 pencereye bölünmüş (5x5) ve dokusal öznitelikler bu parçalardan ayrı ayrı çıkarılarak uç uca eklenmiştir. Sınıflandırma, Destek Vektör Makinesi(SVM) kullanılarak yapılmış, parametreler ise eğitim setinden çapraz doğrulama yöntemiyle öğrenilmiştir. Tüm yöntemler, elde edilen veri setinin tümünde test edilmiştir.

- 1) *Gabor Süzgeci*[4]: Görüntü, 2 farklı yönde Gabor Süzgeci'nden geçirilir (5x5x2).
- 2) *Renk*: Görüntü, tüm bantlara eşit ağırlık verilerek gri banda dönüştürülür (5x5x2).
- 3) *Düzensizlik Süzgeci*: Görüntü, düzensizlik süzgecinden geçirilir (5x5x2).

4) GLBRM, Gri Seviye Birlikte Rastlanma Matrisi[12]: GLBRM hesaplanıp, matrizen karşıtlık, ilinti, enerji ve türdeşlik öznelikleri çıkarılır (5x5x4).

5) YİD, Yerel İkili Desen[13]: Bölünmemiş görüntünün 16 basamaklı YİD Histogramı çıkarılır (16).


1, 2 ve 3'te ortalama değer ve standart sapma öznelikleri olarak kullanılır.

## KAYNAKÇA

Performans Tablosu	Metrikler		
	Kesinlik	Geri Getirme	F-Skor
Önerilen	<b>41.5</b>	<b>65.6</b>	<b>50.8</b>
Gabor	39.26	60.0	47.5
Renk	26.6	34.1	29.9
Düzensizlik	32.3	64.0	42.9
GLBRM	23.5	43.2	30.4
YİD	21.4	18.0	19.6

Tablo 1: Performans Değerleri

Önerilen görüntüden çıkartılan aday dikdörtgenler, ve doku analizi sonucu elde edilen çıktılar Şekil 3'te verilmektedir.



Şekil 3. Örnek görüntüye ait aday dok bölgeleri ve sınıflandırma sonucu (yeşil: gerçek pozitif, kırmızı: yanlış pozitif, mavi: yanlış negatif)

## VI. SONUÇLAR

Tablo 1'de verilen performans değerlerine bakılınca, önerilen yöntemin elle çıkartılan ve probleme uygunluğu bilinen özneliklerden daha iyi sonuç verdiği görülmektedir. Bu da yöntemin hiç alan bilgisine ihtiyaç duymadan veriyi betimleyecek öznelikleri öğrenebildiğini göstermektedir. Önerilen yöntemin performansının, her daim o problemde iyi çalıştığı bilinen özneliklerden iyi olması beklenmemelidir. Aksine, performansın düşük olması beklenebilir bir durumdur. Burada dikkat edilmesi gereken nokta, uzmanlık gerektirmeyen ve otomatik öğrenilen özneliklerle, zorlu bir problemde başarılı bir sonuç elde edilmiş olmasıdır.

İleriki çalışmalarda, otomatik öğrenme algoritması daha da geliştirilerek, iki seviyeli bir derin öğrenme algoritmasına dönüştürülecektir. Veri setindeki örneklerin sayısının artırılarak, pozitif örneklerin ve negatif örneklerin kendi içerisinde gruplanması, dolayısıyla çok sınıflı bir sınıflandırma yapılması hedeflenmektedir. Bu sayede, verinin daha tutarlı hale gelmesi sağlanarak algoritmanın performansının artırılabilceği düşünülmektedir.

- [1] Y. Bengio, A. C. Courville, and P. Vincent, "Unsupervised Feature Learning and Deep Learning: A Review and New Perspectives," *CoRR*, vol. abs/1206.5, 2012.
- [2] I. Arel, D. C. Rose, and T. P. Karnowski, "Deep Machine Learning - A New Frontier in Artificial Intelligence Research," *IEEE Computational Intelligence Magazine*, vol. 5, Nov. 2010.
- [3] Q. V. Le et al., "Building high-level features using large scale unsupervised learning," in *ICML*, 2012.
- [4] Thomas Strohmer Hans G. Feichtinger, "Gabor Analysis and Algorithms", Birkhäuser, 1998.
- [5] Nobuyuki Otsu, "A threshold selection method from gray-level histograms," in *IEEE Trans. Sys., Man., Cyber*.9(1):62-66,1979.
- [6] Jérémie Jakubowicz, Jean-Michel Morel, Gregory Randall Rafael Grompone von Gioi, "LSD: A Fast Line Segment Detector with a False Detection Control", *Pattern Analysis and Machine Intelligence*, IEEE Transactions on , 2010.
- [7] Yan Li and Jiaxiong Peng, "Feature extraction and recognition of harbor contour," in *Proc. SPIE 4550*, 2001, p. 234.
- [8] Bhagavathy, S.; Newsam, S.; Manjunath, B.S.; , "Modeling object classes in aerial images using texture motifs," *Pattern Recognition*, 2002. Proceedings. 16th International Conference on , vol.2, no., pp. 981- 984 vol.2, 2002.
- [9] Qi Chen; Na Wang; Lingjun Zhao; Jun Lu; Canbin Hu; Yongmei Jiang; Gangyao Kuang; , "Harbor detection of remote sensing images based on model," *Future Computer and Communication (ICFCC)*, 2010 2nd International Conference on , vol.1, no., pp.V1-322-V1-325, 21-24 May 2010.
- [10] Jiang, L.B., Z. Wang and W.D. Hu, 2007. An AIAC based inshore ship target detection approach. *Remote Sensing Technol. Appl.*, 22(1): 88-94.
- [11] Xu H.; "Modification of normalised difference water index (NDWI) to enhance open water features in remotely sensed imagery," *International Journal of Remote Sensing*, 27(14):3025-3033, 2006.
- [12] Haralick, R.M., K. Shanmugan, and I. Dinstein, "Textural Features for Image Classification", *IEEE Transactions on Systems, Man, and Cybernetics*, Vol. SMC-3, 1973, pp.610-621.
- [13] T. Ojala, M. Pietikäinen, and D. Harwood (1994), "Performance evaluation of texture measures with classification based on Kullback discrimination of distributions", *Proceedings of the 12th IAPR International Conference on Pattern Recognition (ICPR 1994)*, vol. 1, pp. 582 - 585.
- [14] A. Coates, H. Lee, and A. ~Y. Ng, "An analysis of single-layer networks in unsupervised feature learning," in *AISTATS*, 2011.
- [15] Y. Bengio, Y. LeCun, "Scaling learning algorithms towards AI," *Large-Scale Kernel Machines*, 2007.
- [16] R. H. Byrd, J. Nocedal, and R. B. Schnabel, "Representations of quasi-Newton matrices and their use in limited memory methods," *Mathematical Programming*, vol. 63, no. 1-3, pp. 129-156, Jan. 1994.
- [17] Changren Zhu; Hui Zhou; Runsheng Wang; Jun Guo; , "A Novel Hierarchical Method of Ship Detection from Spaceborne Optical Image Based on Shape and Texture Features," *Geoscience and Remote Sensing*, IEEE Transactions on , vol.48, no.9, pp.3446-3456, Sept. 2010.
- [18] Wang Luo, Weixing Wang, Fangnian Lang and Guan Gui, 2012. Ship Detection of Remote Sensing Image on FRHT and Multi-Points Curvature Based Polygon Approximation. *Research Journal of Applied Sciences, Engineering and Technology*, 4(15): 2590-259