DENİZ YAĞ KİRLİLİĞİNİN TESPİTİ İÇİN YAPAY ZEKA OPTİMİZASYON YÖNTEMLERİNİN GENELLEŞTİRİLMİŞ LİNEER MODEL SINIFLANDIRMASINDA KULLANIMI

Coşkun Özkan[1], *Filiz Sunar*[2]

[1]*Erciyes Uni., Engineering Faculty, Geodesy and Photogrammetry Engineering Dept., 38039 Kayseri, Turkey,* cozkan@erciyes.edu.tr
[2]Istanbul Technical Uni., Civil Engineering Faculty, Remote Sensing Division, 34469 Maslak Istanbul, Turkey, *fsunar@ins.itu.edu.tr*

ÖZET

Yağ kirliliği deniz doğal yaşamı için önemli biyolojik ve ekeonomik etkileri olan bir afettir. Son yıllarda en zararlı karasal kirlenme yaklaşık 110000 varil civarında Doğu Akdeniz'de Lübnan kıyılarında gerçekleşmiştir. Yeterli temizleme olanağı olmadığı için denize karışan yağ tabakası kıyıdan 100 mil açığa taşınmış ve Suriye kıyılarında tehdit etmiştir. Rüzgâr ve akıntı koşullarına göre dökülen yağ tabakası Türkiye, Kıbrıs ve Yunanistan gibi komşu ülkeler içinde tehdit olmuştur.

Yağ kirlilik analizi için kirliliğin konum ve geometrisi (kapladığı alan) gibi bazı özelliklerinin tanımlanması gereklidir. Bu amaçla, uydu bazlı yağ kirliliği izlene sistemleri erken uyarı ve olası kirleticileri tespit etmek için etkin bir şekilde kullanılmaktadır. Günümüzde, yapay açıklıklı RADAR (SAR) sistemleri bütün hava koşullarında ve gece-gündüz çalışabilmelerinden dolayı yağ kirlilik tespitinde optik sistemlere tercih edilmekte ve yeterli doğruluklarla kullanılabilmektedir.

Bu çalışmada yağ kirlilik analizi için, yağ boşalmasının olduğu zaman diliminde İTÜ-UHUZAM (Uydu Haberleşmesi ve Uzaktan Algılama Merkezi) tarafından elde edilen Lübnan kıyılarına ait RADARSAT-1 uydu görüntüleri kullanılmıştır. Uzaysal filtreleme ve gri değer birlikte oluşma matrisine dayalı olarak doku bilgilerinin çıkarılması gibi bazı görüntü zenginleştirme ve transformasyon teknikleri kullanıldıktan sonra, yağ kirlilik alanlarını tespiti için kontrollü sınıflandırma yöntemleri kullanılmıştır. Yapay Sinir Ağları Çok Katmanlı Perseptron (YSA ÇKP) ve Maksimum Olabilirlik (MO) yöntemlerine ek olarak Genelleştirilmiş Lineer Model (GLM) yaklaşımı sınıflandırma için kullanılmıştır. Bu modele ait parametrelerin hesaplanmasında kullanılan klasik İteratif Ağırlıklı En Küçük Kareler (İAEKK) yöntemi Genetik Arama (GA) ve Diferansiyel Gelişim (DG) algoritmaları gibi yapay zeka optimizasyon yöntemleriyle karşılaştırılmıştır.

Anahtar Sözcükler: Deniz Yağ Kirliliği, Radarsat-1, Genelleştirilmiş Lineer Model, Genetik Arama, Evrimsel Gelişim Arama.

ABSTRACT

THE USAGE OF ARTIFICIAL INTELLIGENCE OPTIMIZATION ALGORITMS IN GENERALIZED LINEAR MODEL CLASSIFICATION FOR OIL SPILL DETECTION

Oil spill discharges have serious biological and economic impacts upon the marine environment. One of the most hazardous land-based threats with an estimation of 110,000 barrels of oil discharges was occurred in the Lebanon coast of the eastern Mediterranean Sea recently. Because of not enough cleaning activities, the oil pollution has spread 100 miles along the coast and effected also to Syria's shoreline. Depending on the wind and current condition, the spilled oil could also be a big threat to other neighborhood countries such as Turkey, Greece, and Cyprus.

It is necessary to identify some features such as the type, areal extent, position, (nearest ship position if any), the possibility percentage for the oil spill analysis. For this purpose, satellite-based oil pollution monitoring systems are being used to take precautions and even to determine the possible polluter. Today, Synthetic Aperture Radar (SAR) satellites are often preferred to optical sensors due to the all-weather and all-day capabilities and being used to detect the oil spills discharged into the sea with sufficient accuracies.

In this study, Radarsat-1 images covering Lebanon coasts acquired by ITU-CSCRS (Istanbul Technical University – Center of Satellite Communication and Remote Sensing) during the event were employed for oil spill analysis. After some required image enhancement and transformation techniques such as spatial filtering and extraction of textural features based on gray level co-occurrence matrix (GLCM), the oil spill areas were determined by supervised classification using Generalized Linear Model (GLM). Genetic Algorithm (GA) and Diferential Evolution (DG) algortihms were used to optimize the parameters of the GLM.

KEYWORDS: Oil pollution, Radarsat-1, Generalized linear model, Genetic Search, Differential Evolution

GİRİŞ

Denizcilik taşımacılığındaki artış ve gelişmeler deniz doğası için yağ kirliliğinin sosyal ve ekonomik açılardan önemli bir faktör olmasına neden olmuştur. Yıllık denizlere dökülen yağ miktarının 4.5 milyon ton olduğu tahmin edilmektedir (Bava *et al*. 2002). Denizlerdeki illegal yağ deşarjları özellikle tanker ve kargo gemilerinin balast tanklarından ve/veya depo yıkama artıklarından dolayı oluşmaktadır (Maar *et.al.* 2003; Harahsheh *et al.* 2004). Uluslararası deniz ticaretinin %30'u Akdeniz ve yakın denizlerde yapılmaktadır. Dünya petrol transferinin %28'i Akdeniz'den geçerken, toplam transferin yarısı büyük bir risk ve tehlike oluşturmaktadır. Bilinçli veya bilinçsiz kazaların bir sonucu olarak Akdeniz'i çevreleyen 60 petrol rafinerisinden her yıl yaklaşık 20000 ton petrol sızıntısı oluşmaktadır (Günel 2004).

Buna bağlı olarak deniz ekosistemi için büyük bir tehdit oluşturan yağ kirliliğinin izlenmesi ve tespit edilmesi gittikçe artan bir öneme sahiptir. Günümüzde, uzaktan algılama teknolojisi yıllardır bu amaçla kullanılmaktadır. SAR uyduları gece-gündüz ve her türlü meteorolojik koşullarda algılama yapabilme özelliklerinden dolayı yağ kirlilik analizleri için optik algılama sistemlerine tercih edilmektedirler. (Solberg *et al.* 2007). SAR verisi kullanılarak yapılan yağ kirlilik analizleri genel olarak segmentasyon, özellik çıkartımı ve sınıflandırma aşamalarından oluşur (Solberg *et al.* 2007; Brekke & Solberg 2007). Yağla kirlenmiş alanlardan geri saçılan enerji miktarı yağ tabakasının deniz yüzeyindeki kılcal dalgaları baskıladığı için oldukça az gerçekleşir. Fakat bu geri saçılan enerji miktarındaki azalma başka doğal etkilerden de oluşmakta ve bu bölgeler yağ kirliliğin olduğu alanlarla birlikte koyu görünmektedir (Solberg *et al.* 2007). Böylece, yağ kirlilik analizlerinde yağ veya yağ benzer alanlar olma olasılıkları yüksek olan koyu alanlar görüntülerden segmente edilir. Daha sonra bu bölgelerdeki orijinal yansıtım değerleri kullanılarak şekil, kontrast ve doku karakteristiklerine dayalı özellikler çıkartılır. Sınıflandırma aşamasında çıkartılan özellik bilgileri kullanılarak sınıflandırma işlemiyle görüntüdeki koyu bölgelerden yağ ve yağa benzer alanlar ikili sistemle tanımlanır. Sınıflandırma aşamasında istatistiksel, nöral, bulanık, kural tabanlı, destekleme algoritmaları gibi değişik yöntemler kullanılmıştır (Fiscella *et al.* 2000; Frate *et al.* 2000; Solberg *et al.* 1999; Keramitsoglou *et al.* 2006; Ramalho & Medeiros 2006; Ozkan & Sunar 2007). Farklı bir yaklaşım olarak GLM, çıkartılan özellik bilgileriyle yağ ve yağ benzer sınıflar arasında ilişki kurmak için kullanılabilir. GLM hem sürekli hemde ayrık verinin analizi için genel bir istatistiksel çerçeve oluşturur (Khuri *et al.* 2006). GLM'nin bilinmeyen parametreleri konvansiyonel olarak İAEKK yöntemiyle belirlenir (Lindsay 1997; Dobson 2002). GLM'nin parametre tahmini için İAEKK yöntemine ek olarak GA ve DG algoritmaları da aynı etkinlikte kullanılabilir. GA ve DG oldukça etkili stokastik global optimizasyon yöntemleridir. Bu algoritmalar doğal evrim işlemini taklit eder ve verilen probleme uygun amaç fonksiyonunu en küçükleyecek popülasyon tabanlı bir arama işlemi gerçekleştirirler. Bu popülasyon göreceli olarak en iyi uygunluk değerlerine göre seçilir ve belirli genetik operatörlerle geliştirilir (Pham & Karaboga 2000).

Bu çalışmada, son yıllardaki yağ bazlı en büyük deniz kirliliği olan Lübnan kıyılarındaki yağ kirliliği, bu kirlenmeyi içeren İTÜ UHUZAM (Uydu Haberleşmesi ve Uzaktan Algılama Merkezi) tarafından algılanmış RADARSAT-1 görüntüleri aracılığıyla incelenmiştir. Suriye kıyılarını da içeren 100 millik bir kıyı alanı etkilenmiştir. Bu kirlilik rüzgâr ve akıntı koşullarına göre Türkiye, Yunanistan ve Kıbrıs içinde büyük bir tehdit olmuştur. GLM'nin etkinliği bu bölgedeki yağ kirlilik alanları kullanılarak test edilmiştir. Çalışma yöntemi, görüntü filtreleme, karanlık bölgelerin segmentasyonu, özellik çıkartımı, GLM modelinin kurulması, GLM için parametre tahmini ve performans analizinden oluşmaktadır. Ayrıca, GLM'nin İAEKK, GA ve DE algoritmalarıyla optimize edilen sınıflandırıcıları MO, YSA ÇKP sınıflandırma yöntemleriyle karşılaştırılmıştır.

ÇALIŞMA ALANI VE VERİ

Doğu Akdeniz'de Suriye ve İsrail'in komşusu olan Lübnan 255 km'lik bir sahile sahiptir (Şekil 1). En son yağ kirliliği Jieh'daki rafinerinin bombalanmasından dolayı oluşmuş ve bütün Lübnan sahil şeridinin 1/3'ü etkilenmiştir. Hava koşullarına bağlı olarak, bu kirlilik komşu ülkeler Türkiye, Suriye ve İsrail içinde tehlike oluşturmuştur. Özellikle Lübnan'dan 162 km uzaklıkta ve yaklaşık 330 km sahile sahip Kuzey Kıbrıs için daha ciddi bir tehlike oluşmuştur (Sunar *et al.* 2007; Ozkan & Sunar 2007).

Şekil 1: Map and satellite image of the study area.

Bu çalışmada kullanılan 5 adet RADARSAT-1 görüntülerine ait özellikler Tablo 1'de verilmiştir.

Uydu	Alım Tarihi	Demet Genişliği	Çözünürlük (m)	Bant	Dalgaboyu (cm)	Polarizasyon	Tarama Genişliği (km^2)
RADARSAT-1	2006-07-21	Fine	8	C	5.3	HH	50x50
	2006-08-09	Standard	25				75x75
	2006-08-17	Wide	30				150x150
	2006-08-23	Standard	25				75x75
	2006-10-01	Fine	8				50x50

Tablo 1: Radar görüntü karakteristikleri.

ÇALIŞMA YÖNTEMİ

Deniz yüzeyindeki yağ sızıntıları SAR görüntülerinde kılcal dalgaların bu yağ tabakası tarafından baskılanmasından dolayı kolayca tespit edilebilir. Genel olarak 3 farklı yağ tespit yöntemi vardır: i) Elle belirleme, ii) Yarı-otomatik belirleme, iii) Otomatik belirleme. Bu çalışmada, yarı-otomatik bir yöntem seçilmiş ve bu amaçla YSA ÇKP, MO ve GLM yöntemleri test edilmiştir.

Yapay Sinir Ağları (YSA)

Yapay sinir ağları biyolojik nöronların çalışma prensibini taklit eden işlemsel sistemlerdir. Birçok paralel çalışan yapay nöron içermektedir. Verideki ilişkileri öğrenip genelleyebilen bu yapılar, dağılımlardan bağımsız yani parametrik olmama, rastlantısal karar sınırlarını belirleyebilme, farklı tipteki verilere uyum sağlayabilme ve birlikte kullanılabilme gibi birçok avantajlara sahiptirler. Yapay sinir ağlarının sınıflandırma amaçlı tasarımı oldukça zor olmasına rağmen özellikle yağ tespiti için son yıllarda çok katmanlı perseptron ağ yapısına dayalı değişik bilimsel çalışmalar yapılmıştır (Frate *et al.* 2000; Topouzelis *et al.* 2005).

Genelleştirilmiş Lineer Model (GLM)

Bağımlı çıkış ve bağımsız giriş (tahmin edici) değişkenler arasındaki lineer ilişkiyi modelleyen lineer modeller aşağıdaki eşitlikteki gibi yazılabilirler (Eşitlik 1):

$$E(Y_i) = \mu_i = x_i^T \beta \quad ; \quad Y_i \sim N(\mu_i, \sigma^2) \tag{1}$$

Bu yaklaşımda çıkış değişkenlerinin birbirinden bağımsız ve $x_i^T \beta$ ortalama ve σ^2 varyansla normal dağıldıkları kabul edilir. Fakat genel olarak bağımlı ve bağımsız değişkenler arasındaki ilişki lineer değildir. Lineer olmayan modellerin özel bir hali olarak GLM'ler lineer yaklaşımları kullanırlar (Matlab, 2008). GLM'ler genel olarak üç kısımdan oluşurlar: (i) Çıkış değişkeninin (Y_i) dağılımı fonksiyonu, (ii) lineer tahmin edici ($x_i^T \beta$) ve (iii) bağlantı fonksiyonu.

Bazı matematiksel gerekliliklerden dolayı, bağımlı değişkenin dağılım fonksiyonu üstel dağılım ailesinden herhangi bir fonksiyonu takip eder. Bu fonksiyonlar, Normal, Binomial, Poisson, Multinomial, Gamma, Negatif

Binomial gibi mutlaka μ ortalama parametresine sahip fonksiyonlardır. Bu durumda, bağımlı çıkış değişkeninin umulan değeri lineer tahmin edici kısma monoton ve diferansiyellenebilir bir bağlantı fonksiyonu kullanılarak bağlantılanır (Eşitlik 2).

$$g(\mu_i) = x_i^T \beta \tag{2}$$

Bağlantı fonksiyonu, bağımlı çıkış değişkeninin olasılık dağılımını modelin lineer tahmin edici kısmıyla ilişkilendirir. Konvansiyonel bağlantı fonksiyonları, özdeş, log, logit, ters, probit, loglog gibi fonksiyonlardan herhangi biri olabilir (Tablo 2). Böylece, GLM, normal dağılan bir çıkış değişkeni ve özdeş bağlantı fonksiyonu ile genelleştirilmiş lineer modellerin özel bir halidir.

Lineer tahmin edici terimin (β) parametreleri genel olarak İAEKK yöntemiyle maksimum olabilirlik parametre kestirim yöntemine uygun olarak belirlenir (Hardin & Hilbe 2007).

Özdeş	μ=xβ
Log	log(μ)=xβ
Logit	log(μ/(1−μ))=xβ
Probit	norminv(μ)=xβ
Loglog	log(-log(μ))=xβ
Ters	1/μ=xβ

Tablo 2: Bazı bağlantı fonksiyonları.

Genetik Arama (GA) ve Diferansiyel Gelişim (DG)

GA algoritmasının temel fikri 1975 yılında Holland tarafından yönlü rastlantısal arama tekniği olarak ortaya konmuştur. GA oldukça etkili bir stokastik global optimizasyon algoritmasıdır ve global uygun çözümü karmaşık çok boyutlu arama uzaylarında bulabilir. Lokal bir minimuma takılıp kalmaması ve paralel çalışabilme yeteneği GA'ların en önemli avantajlarındandır. GA'lar bilgisayarlı görme, tıbbi görüntü kaydı, görüntü segmentasyonu, model tabanlı çakıştırma, kamera kalibrasyonu ve patern tanıma gibi birçok alanda etkili bir şekilde kullanılmaktadır (Bhanu *et al.* 1991; Grefenstette & Fitzpatrick 1985; Hill & Taylor 1992; Tsang 1997; Ji & Zhang 2001). Amaç fonksiyonunun optimize edecek şekilde genel olarak kullanılan Genetik Arama operatörleri seçim, çaprazlama ve mutasyon işlemleridir (Pham & Karaboga 2000).

DG, Price ve Storn tarafından 1995 yılında geliştirilmiş, popülasyon temelli sezgisel optimizasyon tekniğidir (Price & Storn 1995). Genetik Algoritma gibi evrimsel algoritmalardandır. Genetik algoritmadaki çaprazlama, mutasyon ve seçim operatörleri diferansiyel gelişim algoritmasında da kullanılmaktadır fakat her bir operatör GA'da olduğu gibi tüm popülâsyona sırayla uygulanmamaktadır (Bendeş 2008).

4. UYGULAMA VE SONUÇLAR

SAR görüntü verisi kohorent görüntüleme teknolojisinden dolayı benek gürültüsü içerir. Bu gürültünün uzaklaştırılması için öncelikle görüntüler sırasıyla 3x3 medyan ve 5x5 alçak geçişli uzaysal filtrelerle filtrelendiler. Filtreleme işleminden sonra gri seviyesi birlikte oluşum matrisine dayalı olarak değişik doku özellikleri çıkartıldı. Piksel yoğunluk değerlerinin tersine doku özellik bilgileri komşu pikseller arasındaki uzaysal korelasyonla ilgili bilgiler sağlarlar. Birçok doku özelliği arasından homojenite, açısal ikinci moment (Assilzadeh & Mansor 2001), varyans ve ortalama ölçütlerinin yağ kirlilik analizi için etkin oldukları görüldü (Ozkan & Sunar 2007).

Kontrollü Sınıflandırma işlemi için gerekli olan eğitim alanları hem meteorolojik koşullar (rüzgar, hava durumu) hem de görsel analizlerle belirlendi. Yağ ve yağ benzer sınıfları için kullanılan özellik paternleri bütün RADARSAT-1 görüntüleri üzerinden toplanan patern kümesinden rastlantısal seçildi. Performans analizi için gerekli olan test paternleri de aynı şekilde seçildi. Her bir sınıf için 5000 eğitim ve 5000 test paterni olmak üzere toplam 10000 özellik paterni seçildi (Ozkan & Sunar 2007).

YSA sınıflandırıcısı olarak ÇKP ağ modeli kullanıldı. Sinaptik ağırlıkları ve bias değerlerini optimize etmek için Esnek Geri Yayılma öğrenme kuralı kullanıldı (Reidmiller & Braun 1993). Bu algoritmanın, eşlenik gradyen,

momentumlu geri yayılma algoritmaları gibi diğer birçok öğrenme kuralından daha iyi sonuçlar verdiği görülmüştür. Ağ topolojisi tek ara katman ve bu katmanda 50 yapay nöron olacak şekilde oluşturuldu (Ozkan & Sunar 2007).

GLM uygulamasında, yağ kirliliği belirlenmesi iki sınıflı bir problem olduğu için model çıkış değişkeni için binomial dağılım seçildi. Lineer tahmin ediciyle çıkış değişkeni arasındaki dönüşümü sağlayan bağlantı fonksiyonu olarak daha iyi performans değerleri veren loglog foksiyonu seçildi. Buna göre GLM şu şekilde oluşmuştur (Eşitlik 3):

$$\log(-\log(\mu_i)) = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \beta_3 x_{i3} + \beta_4 x_{i4} \qquad (3)$$

Modeldeki bilinmeyen parametreler hem İAEKK hem de GA ve DG yöntemleriyle belirlenmiştir. Bütün algoritmalar Matlab ortamında çalışılmıştır. GA ve DG uygulamalarında seçim operatörü üniform stokastik, çaprazlama operatörü saçılan ve mutasyon operatörü de Gaussian seçilmiştir.

Test verisi sınıflandırma sonuçları Tablo 3, 4, 5, 6 ve 7'de verilmiştir. Genel doğruluk ölçütüne ek olarak Kappa ve Z istatistiklerine göre de istatistiksel hipotez testleri yapılmıştır (Congalton & Green 1999). Testler için anlamlılık seviyesi 0.05 seçilmiştir. Birinci grup testte, Kappa istatistiği her bir sınıflandırmanın tamamen rastlantısal bir sınıflandırmadan farklı olup olmadığı şeklinde test edilmiştir. İkinci tip testte, sınıflandırma yöntemlerinin elde ettikleri sonuçların birbirlerinden istatistiksel anlamda farklı olup olmadıkları test edilmiştir. Bu testlerde kullanılan Kappa ve Z istatistikleri Tablo 8 ve 9'da veriliştir.

Test 1:
H_0:$Kappa_1$=0 , H_1:$Kappa_1 \neq 0$ ve ret bölgesi R: $|Z| \geq z_{\alpha/2}$
α=0.05 için R: $Z \geq 1.96$ veya $Z \leq -1.96$
Test istatistiği, $Z = Kappa_1 / \sqrt{Var(Kappa_1)}$

Test 2:
H_0:($Kappa_1$-$Kappa_2$)=0 ve H_1:($Kappa_1$-$Kappa_2$)$\neq$0 ve ret bölgesi R: $|Z| \geq z_{\alpha/2}$
α=0.05, R: $Z \geq 1.96$ veya $Z \leq -1.96$
Test istatistiği, $Z = (|Kappa_1 - Kappa_2|) / \sqrt{Var(Kappa_1) + Var(Kappa_2)}$

	Yağ	Benzer	KD
Yağ	2714	733	78.7
Benzer	2286	4267	65.1
ÜD	54.3	85.3	**GD=69.8**

Table 3. MO sınıflandırması.

	Yağ	Benzer	KD
Yağ	3311	521	86.4
Benzer	1689	4479	72.6
ÜD	66.2	89.6	**GD=77.9**

Table 4. YSA ÇKP sınıflandırması.

	Yağ	Benzer	KD
Yağ	2918	1085	72.9
Benzer	2082	3915	62.3
ÜD	58.4	78.3	**GD=68.3**

Table 5. GLM sınıflandırması (İAEKK ile).

	Yağ	Benzer	KD
Yağ	2535	587	81.2
Benzer	2465	4413	64.2
ÜD	50.7	88.3	**GD=69.5**

Table 6. GLM sınıflandırması (GA ile).

	Yağ	Benzer	KD
Yağ	2425	514	82.5
Benzer	2575	4486	63.5
ÜD	48.5	89.7	**GD=69.1**

Table 7. GLM sınıflandırması (DG ile).

	Kappa(%)	Z-statistic
MO	39.62	45.40
YSA ÇKP	55.80	69.16
GLM (İAEKK)	36.70	40.21
GLM (GA)	38.96	45.64
GLM (DG)	38.22	45.40

Table 8. Kappa and Z istatistikleri.

	MO	YSA ÇKP	GLM (İAEKK)	GLM (GA)	GLM (DG)
MO	-	13.61	2.35	0.54	1.15
YSA ÇKP	13.61	-	15.72	14.34	15.08
GLM (İAEKK)	2.35	15.72	-	1.84	1.26
GLM (GA)	0.54	14.34	1.84	-	0.62
GLM (DG)	1.15	15.08	1.26	0.62	-

Table 9. Karşılıklı Z istatistikleri.

5. SONUÇLAR

Uzaktan algılama yağ kirliliği gibi insan kaynaklı felaketler için yersel ölçmelerin yapılamadığı ve acil müdahalelerin gerektiği acil durumlarda kullanılabilecek etkili tek yöntemdir. Bunun nedeni uzaktan algılamanın nerdeyse eş zamanlı ve sinoptik görüntü verisi üretimi ve bu sayede otoritelerin hızlı ve etkili müdahalelerine imkân vermesidir. Yağ kirliliği için uzaktan algılamanın sağladığı en kritik veri olası yağ kirlilik konumu, kirlilik derecesi ve bunun olasılığıdır. Bu bilgiye dayalı olarak müdahale ekipleri yönlendirileceğinden bu analizlerin doğruluğu son derece önemlidir.

Bu çalışmada, GLM sınıflandırma yaklaşımı YSA ÇKP ve MO sınıflandırma yöntemleriyle karşılaştırılmışlardır. Yapılan birinci hipotez testine göre, bütün sınıflandırma yöntemleri rastlantısal bir sınıflandırma yaklaşımından farklıdır ve daha iyidir. Yani sıfır hipotezi %5 anlamlılık seviyesine göre reddedilmiştir. Bu testte MLP ÇKP diğerlerinden daha kuvvetli bir istatistiksel kanıta dayanmaktadır.

İkinci tip istatistiksel hipotez testine göre, GA ve DG yöntemleriyle optimize edilen GLM ile MO yöntemleri istatistiksel anlamda eşittir. İAEKK yönteminde ise sıfır hipotezi verilen anlamlılık seviyesi için reddedilmiştir. Fakat GA ve DG optimizasyon yöntemleri İAEKK yönteminden daha yüksek genel doğruluk vermesine rağmen bu hipotez testine göre alternatif hipotezin kabul edilmesi için yeterli kanıtı sağlanamamıştır. Yani GLM sınıflandırması için kullanılan bütün parametre tahmin yöntemleri istatistiksel olarak birbirinden farksızdır.

Bu çalışmada elde edilen sonuçlara göre, GLM yöntemi yağ kirlilik analizi için cesaretlendirici sonuçlar vermiştir. GA ve DG yöntemleri için seçim, çaprazlama ve mutasyon operatörlerinin farklı kombinasyonlarının araştırılması gerekmektedir.

KAYNAKLAR

ASSILZADEH, H.; MANSOR, S.B. (2001), Early warning system for oil spill using SAR images. Proceedins of ACRS 2001—22nd Asian Conference on Remote Sensing, Singapore, November 5–9: 460–465.

BAVA J.; TRISTAN, O.; YASNIKOUSKI J. (2002), Earth observation applications through systems and instruments of high performance computer. ASI/CONEA Training Course, September-December, Matera, Italy.

BENDEŞ, E. (2008), Kamera kalibrasyonunda yapay zeka yöntemlerinin kullanımı. Yüksek Lisans Tezi, Erciyes Üniversitesi Fen Bilimleri Enstitüsü.

BHANU, B.; LEE, S.; MING, J.C. (1991), Self-optimizing image segmentation system using a Genetic Algorithm. International Conference on Genetic Algorithms, San Diego, CA, USA: 362-369.

CONGALTON, R.G.; GREEN, K. (1999), Assessing the accuracy of remotely sensed data: Principles and practices. Lewis Publishers.

DOBSON, A. J. (2002), An introduction to generalized linear models. Chapman & Hall.

FISCELLA, B.; GIANCASPRO, A.; NIRCHIO, F.; PAVESE, P.; TRIVERO, P. (2000), Oil spill detection using marine SAR images, International Journal of Remote Sensing 21(18) 3561–3566.

FRATE, F.D.; PETROCCHI, A.; LICHTENEGGER, J.; CALABRESI, G. (2000), Neural networks for oil spill detection using ERS-SAR data, IEEE Transactions on Geoscience and Remote Sensing 38(5) 2282–2287.

GÜNEL, İ. (2004), Mediterranean Sea will die. Radikal newspaper, http://www.radikal.com.tr/haber.php?haberno=111649 (in Turkish, last accessed: 30.10.2006).

GREFENSTETTE, J.J.; FITZPATRICK, J.M. (1985), Genetic search with approximate function evaluation. In Proceedings of International Conference on Genetic Algorithms and their Applications: 112–120.

HARAHSHEH, H.; ESSA, S.; SHIOBARAC, M.; NISHIDAID, T.; ONUMAD, T. (2004), Operational satellite monitoring and detection for oil spill in offshore of United Arab Emirates, http://www.isprs.org/istanbul2004/comm7/papers/130.pdf (last accessed: 30.10.2006).

HARDIN, J.W.; HILBE, J.M. (2007), Generalized linear models and extensions. Stata Press.

HILL, A.; TAYLOR, C.J. (1992), Model-based image interpretation using genetic algorithm, Image Vision Comput. 10 295–300.

HOLLAND, J.H. (1975), Adaptation in natural and artificial systems. MIT Press, Cambridge, MA.

JI, Q.; ZHANG, Y. (2001), Camera calibration with genetic algorithms, IEEE Transactions on Systems, Man and Cybernetics 31(2) 120-130.

KERAMITSOGLOU, I.; CARTALIS, C.; KIRANOUDIS, C. (2006), Automatic identification of oil spills on satellite images, Environ. Model. Softw. 21(5) 640–652.

KHURI, A.I.; MUKHERJEE, B.; SINHA, B.K.; GHOSH, M. (2006), Design issues for generalized linear models: A review, Statistical Science 21(3) 376–399.

LINDSAY, J.K. (1997), Applying generalized linear models. Springer.

MAAR M.; BURCHARD H.; BOLDİNG, K. (2003), Simulating the fate of illegal oil discharges in the marine envronment– Oceanides deliverable report #7, http://pta.jrc.cec.eu.int/show.gx?Object.object_id=SEC-----0000000000025AD9 , Bolding & Burchard Hydrodynamics (last accessed: 30.10.2006).

MATLAB (2008), Statistics toolbox user guide. The Mathworks Inc.

OZKAN, C.; SUNAR, F. (2007), Comparisons of different semi-automated techniques for oil-spill detection: A case study in Lebanon. 27th EARSeL Symposium, Italy.

PHAM, D.T.; KARABOGA, D. (2000), Intelligent optimization techniques. Springer.

RAMALHO, G.L.B.; MEDEIROS, F.N.S. (2006), Using boosting to improve oil spill detection in SAR images. The 18th International Conference on Pattern Recognition (ICPR'06).

REIDMILLER, M.; BRAUN, H. (1993), A direct adaptive method for faster backpropogation learning: The rprop algorithm. Proceedings of the IEEE Int. Conf. On Neural Networks, San Francisco, CA: 586–591.

SOLBERG, A.H.S.; STORVIK, G.; SOLBERG, R.; VOLDEN, E. (1999), Automatic detection of oil spills in ERS SAR images, IEEE Transactions on Geoscience and Remote Sensing 37(4) 1916–1924.

SOLBERG, A.H.S.; BREKKE, C.; HUSØY, P.O. (2007), Oil spill detection in radarsat and envisat sar images, IEEE Transactions on Geoscience and Remote Sensing 45(3) 746-755.

STORN, R.; PRICE, K. (1995), Differential Evolution: A Simple and Efficient Adaptive Scheme for Global Optimization over Continuous Spaces. International Computer Science Institute, Berkeley.

SUNAR, F.; AKKARTAL, A.; GÖRAL, B.; UÇA AVCI, Z.D. (2007), The Threat of the oil pollution incident occurred in Lebanon to the Northern Cyprus Coasts and the importance of operational satellite monitoring system. Int. Conference on Environment: Survival and Sustainability, 19-24 Feb. Nicosia, Northern, Cyprus.

TOPOUZELIS, K.; KARATHANASSI, V.; PAVLAKIS, P.; ROKOS, D. (2005), Oil spill detection using rbf neural networks and sar data. Proceedings on ISPRS, July: 724–729.

TSANG, P.W.M. (1997), A genetic algorithm for affine invariant recognition of object shapes from broken boundaries, Pattern Recognition Letters 18 631-639.