



Orijinal Araştırma / Original Research

İSTATİSTİKSEL ÖĞRENME TEORİSİ İLE METAL İÇERİĞİNİN ÇOKLU SINIR DEĞERLERİNDE SINIFLANDIRMA PERFORMANSININ İNCELENMESİ

INVESTIGATION OF STATISTICAL LEARNING THEORY PERFORMANCE ON CLASSIFICATION OF MULTIPLE THRESHOLD VALUES OF METAL CONTENT

Güneş Ertunç^{a,*}

^a Hacettepe Üniversitesi, Maden Mühendisliği Bölümü, Beytepe, Ankara, Türkiye

Geliş Tarihi / Received : 17 Mayıs / May 2017

Kabul Tarihi / Accepted : 02 Ağustos / August 2017

ÖZ

Anahtar Sözcükler:

Sınıflandırma,
Makine öğrenme,
Destek vektör makineleri,
Kadmium

Verilerin kategorik değişkenliğe göre sınıflandırılması gerekliliği madencilikte oldukça sık rastlanan durumdur. Bu çalışma kapsamında ele alınan metal içeriğine göre sınıflandırma veya jeolojik zonların maden kaynak kestirimi için sınıflandırılması, madencilik üretim aşamasında blokların sınıflandırılması örnek olarak sayılabilir. Krigleme gibi jeostatistiksel kestirim yöntemleri, sınıflandırma için çözüm üreten bir araç değildir ve çalışmada karşılaştırmalı olarak neden kullanılmaması gerektiği açıkça ortaya konmuştur. Çalışmada, ikili sınıftan fazla, çoklu sınıfların etkin bir şekilde sınıflandırmaya yarayan, istatistiksel öğrenme teorisine dayalı, verilerin konumuna bağlı olarak sınıflandırma yapan ve parametre seçimi otomatik halde algoritmaya entegre edilen bir destek vektör makinesi programı kodlanmıştır. Bu program sayesinde bağımsız değişkenlere bağlı kategorik değişkenler problemin tanımına göre sınıflandırılabilmektedir. Algoritma girdisi olarak sahada toplanan verilerin devamlı bağımsız değişkenlerine göre var olan kategorik değişkenlerin, sahada bilinmeyen lokasyonlardaki kategorileri, sadece uzaklığa bağlı konumları kullanılarak ortaya konabilmektedir.

ABSTRACT

Keywords:

Classification,
Machine learning,
Support vector machines,
Cadmium

The necessity of classifying the data according to the categorical variable is quite common in earth sciences. Especially in mining, classification regarding to the metal content, which is covered in the study, classification of geological zones for mineral resource estimation or classification of blocks in the mining production phase can be given as an example of classification problems. Geostatistical estimations methods such as kriging cannot be regarded as solution for classification, and in this study it is clearly shown by comparative case study example. In the study, support vector machines algorithm is coded that classifies depending upon position of the data, based on the statistical learning theory, which can classify multiple and binary classes. The parameter selection is automatically integrated into the algorithm. By using the categorical variables depending on the continuous independent variables from collected data, algorithm reveals the categories in the unknown locations by using only the distance based information. Through introduced algorithm in the study, categorical variables related to independent variables can be classified with respected to the definition of the problem.

* Sorumlu yazar: gertunc@hacettepe.edu.tr • orcid.org/0000-0003-0914-2745

GİRİŞ

Madencilik faaliyetleri, potansiyel maden varlığının ortaya konmasından sonra sahada yapılan sondaj ve sahadan toplanan çeşitli veriler ile başlayan bir süreçtir. Verilerin analizleri ve yorumlanmasıyla devam eden süreçte en önemli aşama bu verilerin elde edilmesi ve doğru yorumlanmasıdır. Özellikle ormanlık alanlar veya topoğrafyanın elvermediği koşullarda örnek toplanmasının zaman alıcı olması veya zor olması durumu söz konusudur. Dolayısıyla kısıtlı veri ile özniteliğin geniş alanlardaki dağılımının ortaya konması gerekir. Sahadan elde edilen verilerin yorumlanması, konuma bağlı değişkenliğin ortaya konması ve lokasyonların kestirimi tamamen veri girdisine bağlıdır. Gerçek değere yakın sonuçların elde edilebilmesi, sürdürülebilir yönetim ve mühendislik fizibilitesi anlamına geldiğinden, sonuçların doğruluğu önemli bir konudur. Örnek konum seçimi, yerel doğruluğun artırılmasında önemli bir rol oynamaktadır. Ayrıca, yer bilimlerinde bağımsız sürekli değişkenlere bağlı olan kategorik değişkenlerin dağılımının ortaya konması daha iyi bir planlanma yapılmasına olanak sağlayacaktır.

Literatürde uzaklığa bağlı değişkenliğin ortaya konmasında krigleme, yapay sinir ağları, zaman serileri analizi, istatistiksel öğrenme teorisi gibi yaklaşımlar önerilmiştir (Tercan vd, 2013; Atalay ve Tercan, 2017).

Kriging, variogram analizi ve uzaklığa bağlı korelasyon yapılarının modellenmesine dayanan en popüler ve gelişmiş yaklaşım olarak kabul edilebilir (Cressie, 1991; Deutsch, 1998; Goovaerts, 1997). Kriging durağanlık varsayımı altında mümkün olan en iyi gerçeğe yakın sonuçlar üretmektedir. Gösterge krigleme, önceden tanımlanmış eşik değerlerin aşılma ihtimalinin bulunmasında ve kümülatif dağılım fonksiyonunun (cdf) yaklaşık olarak bulunmasında kullanılan parametrik olmayan jeostatistiksel iç kestirim yöntemidir. Bu yöntem ile olasılık dağılımına göre saha genelinde belirlenen eşik değer için en büyük belirsizlik bölgeleri ortaya konmaktadır. Bu belirsiz bölgelerden toplanacak veriler ile belirsizlik seviyesi düşürülmelidir.

Bu çalışmada, öğrenme teorisi (veya makine öğrenmesi) ile bilinmeyen lokasyonlardaki özniteliklerin dağılımını tahmin etmek için verilere dayalı bir makine öğrenme sınıflandırmasının kullanılabilirliği araştırılmıştır. Çalışmanın amacı, Destek Vektör Makineleri ile tahmini yapılmış bilinmeyen lokasyonların ortalamasız krigleme (OK, ordinary kriging) sonuçlarıyla karşılaştırmaktır.

Vapnik-Chervonenkis teorisi (VC teorisi) ya da öğrenme teorisi, öğrenme sürecini istatistiksel bir bakış açısıyla, yani verilere dayalı bir tahmin fonksiyonu bulmayı amaçlamaktadır. Öğrenme algoritmaları, kalıp tanıma, el yazısı ve ses tanıma sistemleri, teşhis, robotik, optimizasyon, finansal tahmin, kredi uygunluk uygulamaları gibi pek çok alanda kullanılmaktadır (Kecman, 2001). İstatistiksel öğrenmenin temel görevleri sınıflandırma, regresyon ve olasılık yoğunluk modeli olarak listelenebilir. Destek Vektör Makineleri öğrenme yöntemlerinden biridir ve kategorik veriler kullanılarak bilinmeyen lokasyonlardaki sınıfları tahmin etmeyi sağlar. Bu yöntemlere göre verilerin uzaydaki konumuna bağlı olarak veri yapısında gizli bir örüntü bulunduğunu varsayılmaktadır. Jeostatistiksel yöntemler uzaklığa bağlı değişkenliği variogram fonksiyonu ile ortaya koyarken destek vektör makineleri yönteminde bu ilişki çok katmanlı algılayıcılar ile ortaya konur. Çok katmanlı algılayıcılar, girdiler ve bu girdilere göre üretilen çıktılarının üretildiği bir ağ yapısıdır. Adından da anlaşılacağı gibi birçok katmandan oluşan algılayıcılarda ara katmanlar yer alır ve girdi verilerinden gelen bilgilerin işlendiği kısım olarak tanımlanabilir. Destek vektör makineleri ile ilgili çok kapsamlı ve tanımlayıcı açıklamalar Vapnik, 1995; Burges, 1998 ve Vapnik, 1998'te yer almaktadır. Yer bilimlerinde de uzaklığa bağlı dağılımın ortaya konduğu, gözeneklilik tahmini, atık konsantrasyon tahmini haritalama, uzaktan algılama gibi birçok çalışma yapılmıştır (Kanevski vd, 2002; Kanevski, 1999; Kanevski, 2000a; Kanevski, 2000b; Tartakovsky ve Wohlberg, 2004; Pozdnoukhov ve Kanevski, 2006; Bahria vd., 2011).

Çalışmanın birinci bölümünde ortalamasız krigleme ile destek vektör makinesi yöntemini, ikinci bölümde durum çalışması ve üçüncü bölümde sonuçlar yer almaktadır.

1. YÖNTEM

Kriging, çevreleyen veri noktalarının z değerlerine karşı regresyona dayalı ve konumsal verilere göre ağırlıklandırıldığı bir iç kestirim yöntemidir (Krige, 1951; Matheron, 1967; Isaaks ve Srivastava, 1989;). Uzaklığa bağlı değişkenliği karakterize etmek için bir variogram fonksiyonu tanımlanmıştır. Bu fonksiyonun hesaplanması deneysel variograma, $\gamma(h)$, bağlıdır. Birbirlerinden h uzaklığındaki örnek çiftleri dikkate alınarak hesaplanan variogram Eşitlik 1.1'de formüle edilmiştir.

$$\gamma(h) = \frac{1}{2N(h)} \left(\sum_{i=1}^{N(h)} [z(u_i + h) - z(u_i)]^2 \right) \quad (1.1)$$

Burada,

$N(h)$ Örnek çifti sayısını, $z(u_i)$ i noktasındaki rastlantı değişkenini ve h örnek çiftleri arasındaki uzaklığı ifade etmektedir.

Deneysel variogram hesaplandıktan sonra, model variogram uyarlanarak kestirim matrisi oluşturulur (Chilès ve Delfiner, 1999). Ortalamasız krigleme, rastlantı değişkenlerinin uzaklığa bağlı değişkenliğini ortaya koyan en yaygın kullanılan jeostatistiksel kestirim yöntemidir. Yöntem, örnek lokasyonlarındaki değerlere göre doğrusal ağırlıklandırmayı temel alır ve kestirici λ_i aşağıdaki şekilde tanımlanmıştır.

$$Z^*(u_0) = \sum_{i=1}^n \lambda_i(u_i) Z(u_i) \quad (1.2)$$

Burada,

$Z^*(u_0)$ bilinmeyen u_0 noktasında kestirim değerini, $\lambda_i(u_i)$, $Z(u_i)$ örnek değerinde atanmış krigleme ağırlığını ifade etmektedir.

Her kestirim yönteminde olduğu gibi, amaç kestirim işleminde hatayı en küçüklemektir. Krigleme yönteminde λ_i ağırlıkları, $Z^*(u_0)$ krigleme hata varyansının küçüklenmesi yapılırken türemiştir. Varyans değerinin $\sigma_E^2(u) = \text{Var}\{Z^*(u_0) - Z(u_0)\}$ küçüklenmesi yansızlık kısıtını gerektirir. Bu yansızlık kısıtı $E = \{Z^*(u_0) - Z(u_0)\} = 0$ olarak ifade edilmektedir. Bu yansızlık kısıtı bir optimizasyon problemidir ve optimum durum dolayısıyla krigleme yöntemi en iyi doğrusal yansız kestirici olarak tanımlanır. Optimizasyon probleminin çözümü matris formunda şu şekilde ifade edilir (Armstrong, 1998):

$$\begin{bmatrix} \lambda \\ \mu \end{bmatrix} = \begin{bmatrix} \gamma(u_1, u_1) & \dots & \gamma(u_1, u_n) & 1 \\ \vdots & \ddots & \vdots & \vdots \\ \gamma(u_n, u_1) & \dots & \gamma(u_n, u_n) & 1 \\ 1 & \dots & 1 & 0 \end{bmatrix}^{-1} \begin{bmatrix} \gamma(u_1, u^*) \\ \vdots \\ \gamma(u_n, u^*) \\ 1 \end{bmatrix} \quad (1.3)$$

Burada,

λ krigleme ağırlıklarını, μ Langrange çarpanı, $\gamma(u_i, u_j)$ u_i, u_j verileri arasındaki variogram fonksiyonunu, $\gamma(u_1, u^*)$ veri ve kestirimi yapılacak lokasyon arasındaki variogram fonksiyonunun ifade etmektedir.

Makine öğrenimi (ML) yöntemlerinden destek vektör makineleri, genelleştirilmiş doğrusal sınıflandırıcı temelinde çalıştıkları için uzaklığa bağlı tahminler yaparak jeostatistiksel yöntemler için

bir alternatif olarak değerlendirilebilir. Bu yöntemde kategorik ve bağımsız değişkenlerin kestirim hassasiyetini ayarlamak adına öğrenme makinasının parametrelerinin dikkatle seçilmesi gerekmektedir. Destek vektör makineleri kuadratik optimizasyon problemine dayanır ve verinin dağılım fonksiyonuna ihtiyaç duymaz. İkili sınıflandırma yapan destek vektör makinelerinde hedef veriyi iki kategoriye ayıran sınırı belirlemektir. Doğrusal ve doğrusal olmayan ayırım durumları, isimlendirmeden de anlaşılacağı gibi ayırım çizgisinin doğrusal olup olmaması ile özetlenebilir. İki fazla kategorik değişkenin ayırımında destek vektör makineleri bire-karşı-hepsi (Rifkin ve Klautau, 2004) ve bire-karşı-bir yöntemleri ile çözüm üretmektedir (Bishop, 2006).

Doğrusal destek vektör makineleri çözümü Eşitlik 1.4'te formüleleştirilmiştir.

$$f(x) = w^T x + b \quad (1.4)$$

Burada,

w ayırım doğrusuna normal, x veri noktası ve b sınır öteleme değerini ifade etmektedir.

Ayırım çizgisini tanımlayan sınır, objektif fonksiyonunun Lagrange çarpanlarına α_i dayalı kuadratik program ile belirlenmektedir. En küçükleme eşitliği $\alpha_i \geq 0, \forall i$ ve $\sum_{i=1}^N y_i \alpha_i = 0$ kısıtları altında aşağıdaki şekilde ifade edilir.

$$\min_{w,b} m = \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N y_i y_j (x_i \cdot x_j) \alpha_i \alpha_j - \sum_{i=1}^N \alpha_i \quad (1.5)$$

Kuadratik forma göre, doğrusal olmayan durumlar için Eşitlik 1.6 kullanılmaktadır.

$$\min_{\alpha} m = \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N y_i y_j K(x_j, x_i) \alpha_i \alpha_j - \sum_{i=1}^N \alpha_i \quad (1.6)$$


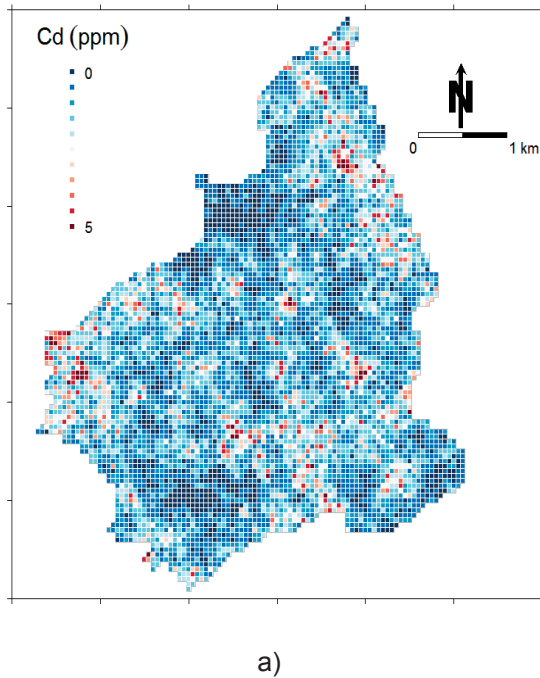
Burada $K(x_j, x)$ çekirdek girdi vektörü x ile öğrenme vektörü x_j arasındaki çekirdek fonksiyonu ifade etmektedir.

Destek vektör makineleri çözümlerinde birçok çekirdek fonksiyonu kullanmak mümkündür. Bu çekirdek fonksiyonlarına Gauss, polinom, ve sinir ağları örnek gösterilebilir. Çalışmada seçilen çekirdek fonksiyonu radyal temelli Gauss'tur ve $K(x_i, x_j) \equiv e^{-\gamma \|x_i - x_j\|^2}$ ile ifade edilir.

Kuadratik problem çözümü, $\alpha_i = 0, 0 \leq \alpha_i \leq C$, ve $\alpha_i = C$ kısıtları sağlandığında çözümlenmektedir. Büyük ölçekli kuadratik program çözümleri için ardışık en küçükleme optimizasyon methodu kullanılmaktadır (Platt, 1999).

2. DURUM ÇALIŞMASI

Durum çalışmasında, yerbilimleri çalışmalarında sıklıkla kullanılan İsviçre'deki Jura veri seti (Goovaerts vd., 1997; Atteia vd., 1994; Webster vd., 1994) kullanılmıştır. Jura veri seti R yazılımının 'gstat' paketi ile erişime açıktır (Pebesma, 2004). İki boyutlu veri seti paketinde 7 ağır metal içeriği içeren lokasyonlar ve ızgara yapısında kestirimi yapılacak lokasyonlar yer almaktadır. Çalışmada sadece Kadmiyum, Cd (ppm) dikkate alınmıştır. Çevresel etkileri, belirli sınır değerini üzerine çıktığı durumlarda son derece kanserojen olarak değerlendirilen Cd içeriği için kritik sınır değeri 0,8 ppm olarak belirlenmiştir (FOEFL (Swiss Federal Office of Environment, 1987). Kadmiyum seviyeleri, "güvenli", "potansiyel olarak tehlikeli" ve "tehlikeli" bölgeler olarak Cd (ppm) $\leq 0,65$, $0,65 < \text{Cd (ppm)} \leq 0,8$ ve $\text{Cd (ppm)} > 0,8$ olarak belirlenmiştir. Kestirim yapılacak lokasyonlarda ortalamasız krigleme ve destek vektör makineleri çözümlerinden önce ardışık Gauss benzetimi yöntemi ile gerçekleştirilmiştir. Bu benzetimlerden rastgele seçilen bir gerçekleştirme, sahanın bilinen değerleri olarak kabul edilmiştir. Kestirim ve makine öğrenme yöntemlerinde kullanılacak girdi verileri bilinen değerler arasından rastgele seçilmiştir. Sahadaki gerçek değerler olarak kabul edilen lokasyonlar ve bu lokasyonlardan rastgele seçilen girdi verileri Şekil 1'de verilmektedir.




Şekil 1. a) Sahadaki Cd dağılımı ve b) Rastgele seçilmiş Cd örnek lokasyonları

2.1. Ortalamasız Krigleme

Kestirim işleminden önce, verilerin deneysel variogramı hesaplanmıştır. Yönlere göre değişkenlik göstermeyen deneysel variogramlara, yuvalı yapıda küresel model variogram uyarlanmıştır (Şekil 2). Yuvalı yapıdaki küresel variogram parametreleri Çizelge 1'de verilmiştir.


Çizelge 1. Cd (ppm) model variogram parametreleri

Külçe etkisi,	Yapısal uzaklık (km)	
	C_1	C_2
C_0	a_1	a_2
0,3	0,29	0,12
	0,22	1,1



Şekil 2. Cd (ppm) özneliğinin deneysel ve model variogramı

Ortalamasız krigleme ile kestirimi yapılan toplam 5700 noktada Cd (ppm) dağılımı Şekil 3'te verilmiştir.



Şekil 3. Cd (ppm) özniteliğinin ortalamasız krigleme kestirim sonuçları

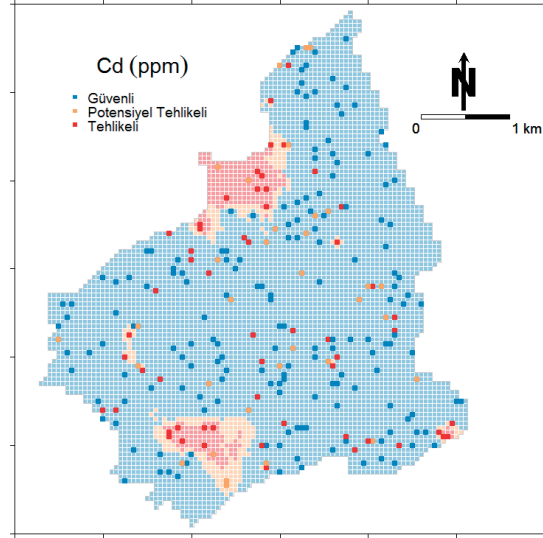
Sonuçlara ilişkin tanımlayıcı istatistiksel bilgiler, girdi veriler ile karşılaştırılmalı biçimde Çizelge 2'de sunulmuştur. Kestirimde kullanılan veri ile karşılaştırıldığında, kestirim sonuçlarının varyansının daha düşük olduğu görülmektedir. Bunun sebebi, krigleme yönteminde yüksek değerlerin düşük; düşük değerlerin de yüksek olarak kestirilmesi. Dolayısıyla, ortalamasız krigleme kestirimlerinde, verilerin en küçük değerinden daha büyük en düşük değer; en büyük değerinden de daha düşük en yüksek değer edilmiştir.

Çizelge 2. Girdi verileri ile ortalamasız krigleme kestirim istatistikleri

Cd (ppm)	Girdi verileri	Ortalamasız krigleme sonuçları
Veri Sayısı	257	5700
En düşük değer	0,14	0,39
En yüksek değer	4,46	3,03
Ortalama	1,34	1,35
Varyans	0,8	0,19

Bir sonraki aşamada, krigleme sonuçları Cd (ppm) sınır değerlerine göre gösterge değişkenlerine dönüştürülmüştür. Sonuçların Cd < 0,65 ppm, 0,65 ppm < Cd ≤ 0,8 ppm ve Cd > 0,8 ppm

olduğu durumlar sırasıyla “güvenli”, “potansiyel tehlikeli” ve “tehlikeli” bölgeler olarak etiketlenerek tematik hale getirilmiştir. Bu harita Şekil 4'te verilmiştir.



Şekil 4. Cd (ppm) özniteliğinin ortalamasız krigleme kestirim sonuçlarının kategorik dönüşümleri

2.2. Destek Vektör Makineleri

Destek vektör makineleri çözümlerinde, radyal temelli Gauss çekirdek fonksiyonu $K(x_i, x_j) \equiv e^{-\gamma \|x_i - x_j\|^2}$ kullanılmıştır. Veri seti öğrenme ve deneme alt gruplarına ayrılarak 10-katı çapraz doğrulama ile çözüm gerçekleştirilmiştir. Çekirdek fonksiyonu içinde, doğru ayırım hassasiyetinin belirlenmesinde kullanılan (C, γ) parametrelerinin seçiminde aşağıda listelenen kümeler kullanılmıştır.


$$C = \{2^{-12}, 2^{-11.75}, 2^{-11.5}, 2^{-11.25}, 2^{-11}, 2^{-10.75}, 2^{-10.50}, 2^{-10.25}, 2^{-10}, 2^{-9.75}, 2^{-9.5}, 2^{-9.25}, 2^{-9}, 2^{-8.75}, 2^{-8.5}, 2^{-8.25}, 2^{-8}\}$$

$$\gamma = \{2^{-3}, 2^{-2}, 2^{-1}, 2^0, 2^1, 2^2, 2^3, 2^4, 2^5\}$$

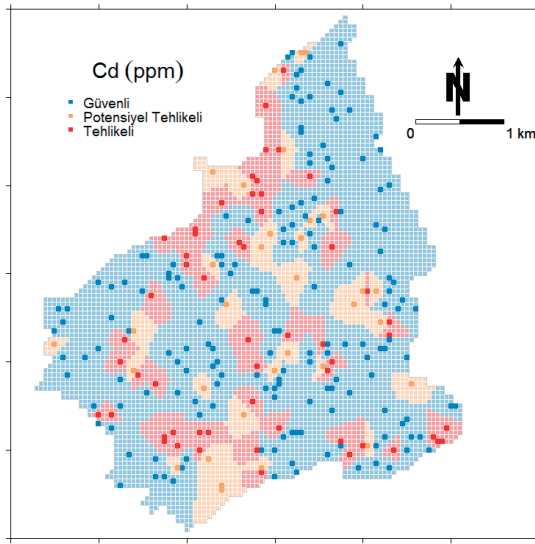
Olası her parametre çifti için yapılan çözümlerde (Bu durum çalışması için $17 \times 9 = 153$) elde edilen en yüksek hassasiyet yüzdesi 75.41% olarak $[C, \gamma] = [2^{-10.50}, 2^4]$ parametre çiftinde elde edilmiştir. Şekil 5'te her parametre çifti için yapılmış çözümlerden elde edilen hassasiyet yüzdeleri görselleştirilmiştir.

Destek vektör makineleri, bilinmeyen lokasyonlara doğrudan kategorik değişken atadığı için çö-

züm sonunda herhangi bir çözüm sonrası işleme gerek yoktur. Şekil 6'da destek vektör makinelerinin ürettiği sonuç verilmektedir. Sonuçların girdi parametrelerinin kategorik değişkenleri ile tutarlı sonuçlar ürettiği görülmektedir.



Şekil 5. Destek vektör makineleri parametreleri ve hassasiyet yüzdeleri.



Şekil 6. Destek vektör makineleri sınıflandırma sonuçları

SONUÇLAR VE TARTIŞMA

Çalışmada, destek vektör makineleri (DVM) kullanılarak bir sahada Kadmiyum (Cd) özniteliğinin önceden belirlenmiş sınır değerlerine göre sınıflandırılması yapılmıştır. Sınıflandırma sonuçlarının bölgesel olarak gerçek değere yakınlığı bakımından performansı, ortalamasız krigleme yöntemi ile karşılaştırılmıştır. Çoklu sınıflandırma yöntemi olarak kodlanan Gauss radyal temelli DVM'de fonksiyon parametre seçimi algoritmada

otomatik olarak yapılmıştır ve kuadratik programlama problemi "ardışık en küçükleme en iyileme" ile çözümü önerilmiştir. DVM, çoklu sınır değerlere göre dağılım söz konusu olduğunda, ortalamasız kriglemenin aksine, tek çözüm aşamasında sonuç üretmektedir.

Ortalamasız krigleme kestirim değerleri, önceden tanımlı sınır değerler süzgeçlerine göre kategorik değişkenlere dönüştürüldüğünde oldukça yumuşatılmış değerler söz konusu olduğu için gerçek değere yakınlık bakımından, beklendiği gibi, iyi performans göstermemiştir (Şekil 4). Destek vektör makineleri ile kestirimlerden çıkarılan sonuçlar (Şekil 6), sahada bilinen değerlerin kategorileri ile karşılaştırılmıştır. Doğru sınıflandırılan lokasyon sayısına göre oluşturulan karşılaştırma tablosu Çizelge 3'te sunulmuştur.

Ardışık Gauss benzetim yöntemi ile gerçekleştirilen ve bilinen lokasyonlar değerlendiren sahada Cd (ppm) içeriklerine göre 3838 nokta "güvenli", 1319 nokta "potansiyel olarak tehlikeli" ve 543 lokasyon ise "tehlikeli" olarak sınıflandırılmıştır.

Çizelge 3. Bilinen lokasyonlar ile sonuçların karşılaştırılması

	Ortalamasız krigleme	Destek vektör makineleri (%)
Güvenli	96,74	75,09
Potansiyel tehlikeli	6,63	17,86
Tehlike	16,14	38,29

Çizelge 3 incelendiğinde, krigleme yöntemi bilinen lokasyonlardaki kategorik değişkenleri daha iyi tahmin etmiş gibi görünmektedir. Ancak, görsel incelendiğinde bunun nedeni sahanın büyük bölümünün "güvenli" olarak nitelendirilmesidir. Özellikle "potansiyel olarak tehlikeli" kategorisinde destek vektör makinelerinin çok daha iyi sınıflandırma yapabildiği açıkça görülmektedir ve bu durum tematik haritada da gözlemlenmiştir.

Çalışmanın ileriki aşamalarında, yönlere bağlı değişkenliğin (anisotropi) Destek Vektör Makineleri ile araştırılması ve bu değişkenliğin ortaya konabilmesi için farklı çekirdek fonksiyonlarının denenmesi önerilmektedir. Böylece, farklı çekirdek fonksiyonların sınıflandırma hassasiyeti üzerindeki etkisinin de ortaya konması mümkün olacaktır.

KAYNAKLAR

Armstrong, M., 1998. *Basic Linear Geostatistics* (Springer Berlin Heidelberg).

Atalay F., Tercan A.E., 2017. Coal resource estimation using Gaussian copula. *International Journal of Coal Geology*, 175, 1-9.

Atteia, O., Dubois J. P., Webster R., 1994. Geostatistical Analysis of Soil Contamination in the Swiss Jura. *Environmental Pollution*, 86: 315-27.

Bahria, S., Essoussi N., Limam M., 2011. Hyperspectral data classification using geostatistics and support vector machines. *Remote Sensing Letters*, 2: 99-106.

Bishop, C.M., 2006. *Pattern Recognition and Machine Learning (Information Science and Statistics)* (Springer-Verlag New York, Inc.).

Burges, C.J.C., 1998. A Tutorial on Support Vector Machines for Pattern Recognition. *Data Mining and Knowledge Discovery*, 2: 121-67.

Chilès, J.P., Delfiner P., 1999. *Geostatistics: modeling spatial uncertainty* (Wiley).

Cressie, N.A.C., 1991. *Statistics for Spatial Data* (J. Wiley).

Deutsch, C.V., Journel A.G., 1998. *GSLIB - Geostatistical Software Library and User's Guide* (Oxford University Press).

FOEFL (Swiss Federal Office of Environment, Forest and Landscape) 1987. *Commentary on the Ordinance Relating to Pollutants in Soil (VSBo; of June 9, 1986)* (FOEFL).

Goovaerts, P., Webster R., Dubois J.P., 1997. Assessing the risk of soil contamination in the Swiss Jura using indicator geostatistics. *Environmental and Ecological Statistics*, 4: 49-64.

Goovaerts, P., 1997. *Geostatistics for natural resources evaluation* (Oxford University Press: New York).

Isaaks, E. H., Srivastava R.M., 1989. *Applied Geostatistics* (Oxford University Press).

Kanevski, M., 1999. Spatial Predictions of Soil Contamination Using General Regression Neural Networks. *Int. Journal of Systems Research and Information Systems*, 8: 15.

Kanevski, M., Canu, S., 2000b. Spatial Data Mapping with Support Vector Regression and Geostatistics. In: *IDIAP Research Report*.

Kanevski, M., Pozdnukhov A., Canu S., Maignan M., Wong P. M., Shibli S. A. R., 2002. Support Vector Machines for Classification and Mapping of Reservoir

Data. in Patrick Wong, Fred Aminzadeh and Masoud Nikravesh (eds.), *Soft Computing for Reservoir Characterization and Modeling* (Physica-Verlag HD: Heidelberg).

Kanevski, M., Pozdnukhov, A., Canu, S., Maignan, M., 2000a. *Advanced Spatial Data Analysis and Modelling with Support Vector Machines*. In: *IDIAP Research Report*.

Kecman, V., 2001. *Learning and Soft Computing: Support Vector Machines, Neural Networks. and Fuzzy Logic Models* (MIT Press).

Krige, D. G., 1951. A statistical approach to some basic mine valuation problems on the Witwatersrand: *J. Chem. Metal. Min. Soc. South Africa*, v. 52, p. 119–139.

Matheron, G., 1967. Kriging or polynomial interpolation procedures: *Trans. Canad. Inst. Min. Metal.*, v. 70, p. 240–244.

Pebesma, E. J., 2004. Multivariable geostatistics in S: the gstat package. *Computers & Geosciences*, 30: 683-91.

Platt, J.C., 1999. Fast training of support vector machines using sequential minimal optimization. in Sch Bernhard, Ikopf, J. C. Burges Christopher and J. Smola Alexander (eds.), *Advances in kernel methods* (MIT Press).

Pozdnoukhov, A., Kanevski, K., 2006. Monitoring network optimisation for spatial data classification using support vector machines. *International Journal of Environment and Pollution*, 28: 465-84.

Rifkin, R., Klautau A., 2004. In Defense of One-Vs-All Classification. *J. Mach. Learn. Res.*, 5: 101-41.

Tercan, A.E., Ünver B., Hindistan M.A., Ertunç G., Atalay F., Ünal S., Killoğlu Y., 2013. Seam modeling and resource estimation in the coalfields of western Anatolia. *International Journal of Coal Geology*, 112, 1, 94–106

Vapnik, V., 1998. *Statistical learning theory* (Wiley).

Vapnik, Vladimir N., 1995. *The nature of statistical learning theory* (Springer-Verlag New York, Inc.).

Webster, R., Atteia O., Dubois, J. P., 1994. Coregionalization of Trace-Metals in the Soil in the Swiss Jura. *European Journal of Soil Science*, 45: 205-18.